



Universidad de San Carlos de Guatemala
Facultad de Ingeniería
Escuela de Estudios de Postgrado
Maestría en Estadística Aplicada

**PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN
CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA**

Lic. Diego Ignacio Sánchez del Cid
Asesorado por la Mtra. Mariela Lizeth Benavides Lázaro

Guatemala, mayo de 2023

UNIVERSIDAD DE SAN CARLOS DE GUATEMALA



FACULTAD DE INGENIERÍA

**PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN
CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA**

TRABAJO DE GRADUACIÓN

PRESENTADO A LA JUNTA DIRECTIVA DE LA
FACULTAD DE INGENIERÍA

POR

LIC. DIEGO IGNACIO SÁNCHEZ DEL CID

ASESORADO POR LA MTRA. MARIELA LIZETH BENAVIDES LÁZARO

AL CONFERIRSE EL TÍTULO DE

MAESTRO EN ARTES EN ESTADÍSTICA APLICADA

GUATEMALA, MAYO DE 2023

UNIVERSIDAD DE SAN CARLOS DE GUATEMALA
FACULTAD DE INGENIERÍA



NÓMINA DE JUNTA DIRECTIVA

DECANA	Inga. Aurelia Anabela Cordova Estrada
VOCAL I	Ing. José Francisco Gómez Rivera
VOCAL II	Ing. Mario Renato Escobedo Martínez
VOCAL III	Ing. José Milton de León Bran
VOCAL IV	Br. Kevin Vladimir Cruz Lorente
VOCAL V	Br. Fernando José Paz González
SECRETARIO	Ing. Hugo Humberto Rivera Pérez

TRIBUNAL QUE PRACTICÓ EL EXAMEN GENERAL PRIVADO

DECANA	Inga. Aurelia Anabela Cordova Estrada
DIRECTOR	Mtro. Ing. Edgar Darío Álvarez Cotí
EXAMINADOR	Mtro. Ing. Edwin Adalberto Bracamonte Orozco
EXAMINADOR	Mtro. Ing. William Eduardo Fagiani Cruz
SECRETARIO	Ing. Hugo Humberto Rivera Pérez

HONORABLE TRIBUNAL EXAMINADOR

En cumplimiento con los preceptos que establece la ley de la Universidad de San Carlos de Guatemala, presento a su consideración mi trabajo de graduación titulado:

PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA

Tema que me fuera asignado por la Dirección de la Escuela de Estudios de Postgrado, con fecha 31 de enero 2022.

Lic. Diego Ignacio Sánchez del Cid

LNG.DECANATO.OI.494.2023

La Decana de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala, luego de conocer la aprobación por parte del Director de la Escuela de Estudios de Posgrado, al Trabajo de Graduación titulado: **PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA**, presentado por: **Lic. Diego Ignacio Sánchez del Cid**, que pertenece al programa de Maestría en artes en Estadística aplicada después de haber culminado las revisiones previas bajo la responsabilidad de las instancias correspondientes, autoriza la impresión del mismo.

IMPRÍMASE:


Inga. Aurelia Anabela Cordova Estrada
Decana



Guatemala, mayo de 2023

AACE/gaac



Guatemala, mayo de 2023

LNG.EEP.OI.494.2023

En mi calidad de Director de la Escuela de Estudios de Postgrado de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala, luego de conocer el dictamen del asesor, verificar la aprobación del Coordinador de Maestría y la aprobación del Área de Lingüística al trabajo de graduación titulado:

“PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA”

presentado por **Lic. Diego Ignacio Sánchez del Cid** correspondiente al programa de **Maestría en artes en Estadística aplicada**; apruebo y autorizo el mismo.

Atentamente,

“Id y Enseñad a Todos”

Mtro. Ing. Edgar Darío Álvarez Cotí
Director

**Escuela de Estudios de Postgrado
Facultad de Ingeniería**





Guatemala, 29 de septiembre de 2022

M.A. Ing. Edgar Dario Alvarez Coti
Director
Escuela de Estudios de Postgrado
Presente

Estimado M.A. Ing. Alvarez Coti

Por este medio informo a usted, que he revisado y aprobado el **INFORME FINAL y ARTÍCULO CIENTÍFICO** titulado: **PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA** del estudiante **Diego Ignacio Sánchez Del Cid** quien se identifica con número de carné **202191234** del programa de Maestría En Estadística Aplicada.

Con base en la evaluación realizada hago constar que he evaluado la calidad, validez, pertinencia y coherencia de los resultados obtenidos en el trabajo presentado y según lo establecido en el **Normativo de Tesis y Trabajos de Graduación aprobado por Junta Directiva de la Facultad de Ingeniería Punto Sexto inciso 6.10 del Acta 04-2014 de sesión celebrada el 04 de febrero de 2014**. Por lo cual el trabajo evaluado cuenta con mi aprobación.

Agradeciendo su atención y deseándole éxitos en sus actividades profesionales me suscribo.



Mtro. Ing. Edwin Adalberto Bracamonte Orozco
Coordinador
Maestría En Estadística Aplicada
Escuela de Estudios de Postgrado

Guatemala, 29 de septiembre de 2022

M.A. Ing. Edgar Dario Alvarez Coti
Director
Escuela de Estudios de Postgrados
Presente

Estimado M.A. Ing. Alvarez Coti

Por este medio informo a usted, que he revisado y aprobado el Trabajo de Graduación y el Artículo Científico: **"PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA"** del estudiante **Diego Ignacio Sánchez Del Cid** del programa de **Maestría En Estadística Aplicada** identificado(a) con número de carné 202191234.

Agradeciendo su atención y deseándole éxitos en sus actividades profesionales me suscribo.

Mariela Lizeth Benavides Lázaro
Licenciada en Matemática Aplicada
Colegiado No. 13863



Mtra. Inga. Mariela Lizeth Benavides Lázaro

Colegiado No. 13863

Asesora de Tesis

ACTO QUE DEDICO A:

Dios

Por sus bendiciones.

Mis padres

José David Sánchez Hicks y Zaida Julieta del Cid
García, por todo el amor, paciencia y esfuerzo
durante todos estos años

Mi novia

Por su apoyo incondicional, enseñanzas y ser
mi fuente de inspiración para mi superación
académica.

AGRADECIMIENTOS A:

**Universidad de San
Carlos de Guatemala**

Por ser una institución que me ha permitido continuar con mi educación en un momento de incertidumbre

**Facultad
de Ingeniería**

Por el aporte técnico a mi formación profesional.

Mi asesora

Mariela Lizeth Benavides Lázaro, por impulsarme a seguir estudiando.

ÍNDICE GENERAL

ÍNDICE DE ILUSTRACIONES.....	V
LISTA DE SÍMBOLOS.....	IX
GLOSARIO.....	XI
RESUMEN.....	XV
PLANTEAMIENTO DEL PROBLEMA.....	XVII
OBJETIVOS	XXVII
RESUMEN DEL MARCO METODOLÓGICO	XXIX
INTRODUCCIÓN.....	XXXVII
1. MARCO REFERENCIAL.....	1
2. MARCO TEÓRICO.....	11
2.1. Series de tiempo.....	11
2.1.1. Procesos estocásticos	12
2.1.2. Estacionariedad de un P.E.....	13
2.1.3. Autocorrelación de una S.T.....	14
2.1.4. Modelos lineales	15
2.1.4.1. El proceso de ruido blanco.....	15
2.1.4.2. Modelos A.R.s.....	15
2.1.4.3. Modelos de medias móviles	16
2.1.4.4. Invertibilidad.....	17
2.1.4.5. Modelos ARMA	17
2.1.5. Modelos no estacionarios	18
2.1.5.1. No estacionariedad en varianza	19

	2.1.5.2.	No estacionariedad en la media.....	20
2.2.		Epidemias	22
	2.2.1.	Epidemiología.....	22
	2.2.2.	Tipos de transmisión de una enfermedad.....	24
		2.2.2.1. Transmisión directa	26
		2.2.2.2. Transmisión indirecta.....	26
2.3.		Ecuaciones diferenciales.....	27
	2.3.1.	Ecuaciones diferenciales de primer orden	28
		2.3.1.1. Ecuaciones homogéneas.....	28
		2.3.1.2. Ecuaciones no homogéneas.....	29
	2.3.2.	Sistemas de ecuaciones diferenciales simultáneas	30
2.4.		Modelos epidemiológicos	32
	2.4.1.	Modelo SI	33
	2.4.2.	Modelo SIS.....	34
	2.4.3.	Modelo SIR.....	36
	2.4.4.	Modelo SEIR	37
2.5.		Aspectos importantes de estadística paramétrica	38
	2.5.1.	Variables aleatorias discretas y sus distribuciones	38
		2.5.1.1. Distribución de Poisson	40
	2.5.2.	Distribuciones de probabilidad discreta	41
		2.5.2.1. D.P. Gamma.....	42
	2.5.3.	Coeficiente de correlación	44
3.		PRESENTACIÓN DE RESULTADOS.....	45
	3.1.	Estimación de los parámetros de transmisión, recuperación e incubación con series de tiempo y estadística paramétrica en dos escenarios de confinamiento	45

3.1.1.	Primer escenario de confinamiento	45
3.1.2.	Segundo escenario de confinamiento	64
3.1.2.1.	Análisis paramétrico del segundo escenario de confinamiento.....	65
3.2.	Pronostico casos confirmados, recuperados y fallecidos en confinamiento laxo con el modelo SEIR.....	85
3.2.1.	Comparación de las predicciones del modelo con lo observado	95
3.3.	Correlación existente entre el número de casos positivos y la actividad económica en los dos escenarios de confinamiento	98
3.3.1.	Análisis de correlación en confinamiento estricto	99
3.3.2.	Análisis de correlación en confinamiento laxo	101
3.4.	Estimar los parámetros que gobiernan el proceso epidémico de COVID-19 en Guatemala y pronosticar contagios y su repercusión en la actividad económica, para proponer medidas de confinamiento que no entren en conflicto con las metas de crecimiento económicas nacionales	104
4.	DISCUSIÓN DE RESULTADOS	109
4.1.	Análisis interno	109
4.1.1.	Parámetros de transmisión, recuperación y fallecimientos	109
4.1.2.	Confinamiento estricto	109
4.1.3.	Confinamiento laxo	113
4.1.4.	Pronósticos de los casos confirmados, recuperados y fallecidos para el confinamiento laxo.	121
4.1.4.1.	Pronósticos del modelo	121

4.1.4.2.	Contraste de los pronósticos.....	125
4.1.5.	Análisis de correlación entre la actividad económica y la cantidad de casos positivos	128
4.1.5.1.	Correlación entre la actividad económica y casos positivos en confinamiento estricto	128
4.1.5.2.	Correlación entre la actividad económica y casos positivos en confinamiento laxo	129
4.2.	Análisis externo.....	131
CONCLUSIONES		133
RECOMENDACIONES		135
REFERENCIAS.....		137
APENDICES		141

ÍNDICE DE ILUSTRACIONES

FIGURAS

1.	Índice mensual de actividad económica	XVIII
2.	Cantidad de contagios de COVID-19 en Guatemala.....	XIX
3.	Proceso de transición del modelo SI	33
4.	Transición modelada en el modelo SIS	35
5.	Transición en el modelo SIR.....	36
6.	Transición en el modelo SEIR	37
7.	Función de acumulación de una D.P. continua.....	42
8.	D.G. Gamma	44
9.	Distribución casos confirmados en confinamiento estricto	46
10.	Distribución casos recuperados en confinamiento estricto.....	47
11.	Distribución casos de fallecidos confinamiento estricto	47
12.	Correlación temporal de los rezagos de casos confirmados con los casos recuperados	48
13.	Significancia de la correlación temporal entre recuperados y confirmados.....	49
14.	Correlación temporal de los rezagos de casos confirmados con los casos fallecidos	50
15.	Significancia de la correlación temporal entre recuperados y fallecidos	50
16.	Series de tiempo de casos confirmados y recuperados	52
17.	S.T. de los casos fallecidos	52
18.	S.T. transformadas de casos confirmados y recuperados	53

19.	S.T. transformada de casos fallecidos	54
20.	Distribución de los residuos del modelo 1	57
21.	Dispersión del residuo del modelo 1	58
22.	Función de auto correlación del término de residuo para el modelo 1	59
23.	Distribución del residuo del modelo 2.....	61
24.	Dispersión del residuo del modelo 2	62
25.	Función de autocorrelación del término de residuo para el modelo 2	63
26.	Distribución de casos nuevos en confinamiento laxo	65
27.	Distribución de casos recuperados en confinamiento laxo	66
28.	Distribución de casos fallecidos en confinamiento laxo	66
29.	Distribución transformada casos nuevos confinamiento laxo	67
30.	Distribución transformada de casos recuperados confinamiento laxo	68
31.	Distribución transformada de casos fallecidos confinamiento laxo	68
32.	Correlación temporal de los rezagos de casos confirmados con los casos fallecidos	69
33.	Significancia de la correlación temporal entre recuperados y confirmados	70
34.	Correlación temporal de los rezagos de casos confirmados con los casos fallecidos	70
35.	Significancia de la correlación temporal entre fallecidos y confirmados	71
36.	S.T. de casos confirmados y recuperados	72
37.	S.T. de casos fallecidos	73
38.	S.T. transformadas casos confirmados, recuperados y fallecidos	74
39.	Distribución de los residuos del modelo 3	77
40.	Dispersión del residuo del modelo 3	77

41.	Función de auto correlación del término de residuo para el modelo 3	79
42.	Distribución del residuo del modelo 4	81
43.	Dispersión del residuo del modelo 4	82
44.	Función de autocorrelación del término de residuo para el modelo 4	83
45.	Resultado completo modelo SEIR	86
46.	Comportamiento del R0 en el tiempo con la función sigmoïdal	89
47.	Función de acumulación casos susceptibles modelo SEIR	90
48.	Distribución casos infectados modelo SEIR.....	91
49.	Distribución de casos expuestos	92
50.	Distribución acumulada de casos recuperados.....	93
51.	Distribución acumulada de casos fallecidos.....	94
52.	Predicciones modelo respecto a casos confirmados	95
53.	Predicciones del modelo respecto a casos recuperados	96
54.	Predicciones del modelo respecto a casos fallecidos	97
55.	Diagrama de dispersión variación IMAE como función a la variación de casos positivos confinamiento estricto.....	100
56.	Diagrama de dispersión variación IMAE como función a la variación de casos positivos confinamiento laxo.....	102
57.	Distribución de casos confirmados en Guatemala	104
58.	Distribución de casos recuperados en Guatemala.....	105
59.	Distribución de fallecimientos en Guatemala	106

TABLAS

I.	Acciones del estado como medidas para la reducción de casos	XX
II.	Operativización de variables	XXX

III.	Resumen análisis paramétrico para el confinamiento estricto.....	51
IV.	Resultados prueba Dickey Fuller S.T. en confinamiento estricto	55
V.	S.T. confirmados sobre recuperados en confinamiento estricto.....	56
VI.	Resultados de las pruebas estadística del residuo del modelo 1	58
VII.	S.T. confirmados sobre fallecidos en confinamiento estricto.....	60
VIII.	Resultados de las pruebas estadísticas del residuo del modelo 2	62
IX.	Resumen de parámetros que guiaron el proceso epidémico en confinamiento estricto.....	64
X.	Resumen análisis paramétrico para el confinamiento laxo	71
XI.	Resultados prueba Dickey Fuller S.T. en confinamiento estricto	75
XII.	S.T. de confirmados sobre recuperados en confinamiento laxo.....	76
XIII.	Resultados de las pruebas estadística del residuo del modelo 3	78
XIV.	S.T. casos confirmados sobre fallecidos en confinamiento laxo.....	80
XV.	Resultados de las pruebas estadísticas del residuo del modelo 4	82
XVI.	Resumen de parámetros del proceso epidémico en confinamiento estricto y laxo.....	84
XVII.	Parámetros que guiaron el proceso epidémico en Guatemala en confinamiento laxo.....	85
XVIII.	Series IMAE-casos positivos confinamiento estricto	99
XIX.	Series brutas y transformadas IMAE casos positivos confinamiento laxo.....	101
XX.	Correlación casos positivos e IMAE ambos confinamientos.....	103
XXI.	Posibles razones de la sobrestimación por parte del modelo SEIR .	126

LISTA DE SÍMBOLOS

Símbolo	Significado
ρ	Correlación
γ	Covarianza
σ	Desviación Estándar
ε	Error
λ	Exponente de la transformación Box-Cox
∞	Infinito
x_t	Observación en tiempo t
Σ	Operación de suma
Phi	Parámetros del modelo AR
Theta	Parámetros modelo MA
Mu	Promedio

GLOSARIO

Autocorrelación	Característica que consiste en que, elementos cercanos en el espacio o en el tiempo, se parecen más entre sí que con respecto a elementos más lejanos, solamente por el hecho de estar cerca.
A.R.	Autorregresivo
BANGUAT	Banco de Guatemala
Correlación	Medida estadística que expresa hasta qué punto dos variables están relacionadas linealmente (esto es, cambian conjuntamente a una tasa constante). Es una herramienta común para describir relaciones simples sin hacer afirmaciones sobre causa y efecto.
Distribución normal	La <i>distribución normal</i> es un modelo teórico capaz de aproximar satisfactoriamente el valor de una variable aleatoria a una situación ideal.
D.P.	Distribución de probabilidad
E.D.	Ecuación diferencial

Estocástico	Concepto matemático que sirve para usar magnitudes aleatorias que varían con el tiempo o para caracterizar una sucesión de variables aleatorias que evolucionan en función de otra variable, generalmente el tiempo.
Epidemia	Enfermedad que ataca a un gran número de personas o de animales en un mismo lugar y durante un mismo período de tiempo.
Estacionariedad	Una serie es estacionaria cuando es estable a lo largo del tiempo, es decir, cuando la media, varianza y covarianza son constantes en el tiempo.
Función A.C.	La función de autocorrelación resulta de gran utilidad para encontrar patrones repetitivos dentro de una señal, como la periodicidad de una señal enmascarada bajo el ruido o para identificar la frecuencia fundamental de una señal que no contiene dicha componente, pero aparecen numerosas frecuencias armónicas de esta.
Función A.C.P	Medida de la correlación entre observaciones de una serie de tiempo que se encuentran separadas por k unidades de tiempo (y_t y y_{t-k}), después de ajustarse para la presencia de los demás términos de desfase más corto.
Heterocedasticidad	En los modelos de regresión lineales se dice que hay heterocedasticidad cuando la varianza de los

residuos no es igual en todas las observaciones realizadas.

Homocedasticidad Existe *homocedasticidad* cuando la *varianza* de los residuos estocásticos de la regresión es la misma para cada observación.

IMAE Índice sintético cuyo fin es proporcionar una medida de la evolución de la actividad real de la economía en el corto plazo, el cual se ajusta a la metodología utilizada en las cuentas nacionales trimestrales y está compuesto por un conjunto heterogéneo de indicadores mensuales.

Incubación Tiempo que se necesita para que se desarrolle una infección después de que una persona se ve expuesta a una enfermedad

M.A. Media móvil

Muestra Parte o cantidad pequeña de una cosa que se considera representativa del total y que se toma o se separa de ella con ciertos métodos para someterla a estudio, análisis o experimentación.

MSPAS Ministerio de Salud Pública y Asistencia Social

Pandemia	Enfermedad epidémica que se extiende a muchos países o que ataca a casi todos los individuos de una localidad o región.
Población	Conjunto de objetos que representa la totalidad de un grupo.
Ruido Blanco	Señal aleatorio que se caracteriza por el hecho de que sus valores de señal en dos tiempos diferentes no guardan correlación estadística.
SEIR	Susceptibles, expuestos, infectados, removido.
Serie de tiempo	Secuencia de datos u observaciones, medidos en determinados momentos y ordenados cronológicamente.
Simulación	Imitación de un proceso de la vida real en condiciones que tienen supuestos dados por un investigador.
Variable aleatoria	Función que asigna un valor, usualmente numérico, al resultado de un experimento aleatorio.
Varianza	Medida de dispersión que se utiliza para representar la variabilidad de un conjunto de datos respecto de la media aritmética de estos.

RESUMEN

El propósito del presente trabajo fue proponer una herramienta para la toma de decisiones de las autoridades sanitarias y económicas, para crear medidas de confinamiento dinámicas que respondan para reducir la presión sobre el sistema de salud sin poner en riesgo las medidas de crecimiento económicas.

El objetivo general de la investigación es estimar los parámetros que gobiernan el proceso epidémico de COVID-19 en Guatemala y pronosticar contagios y su repercusión en la actividad económica, a través de análisis de S.T., estadística paramétrica y un modelo SEIR.

El principal problema es que parece que las medidas de confinamiento laxas implican un mejor desempeño de la actividad económica, sin embargo, también exacerban la cantidad de contagios a nivel nacional.

El principal resultado es que el modelo estimado es capaz de predecir con precisión el momento en el que se dará el pico de contagios, muertes y recuperaciones, siendo una herramienta útil para la propuesta de escenarios de confinamiento dinámicos.

Se recomienda utilizar al modelo SEIR y sus pronósticos, como una herramienta que permita predecir en qué punto del tiempo se podrían presentar los picos de casos positivos, y fallecidos de COVID-19 en Guatemala, y de esta manera generar medidas de confinamiento dinámicas que liberen la presión sobre el sistema de salud público.

PLANTEAMIENTO DEL PROBLEMA

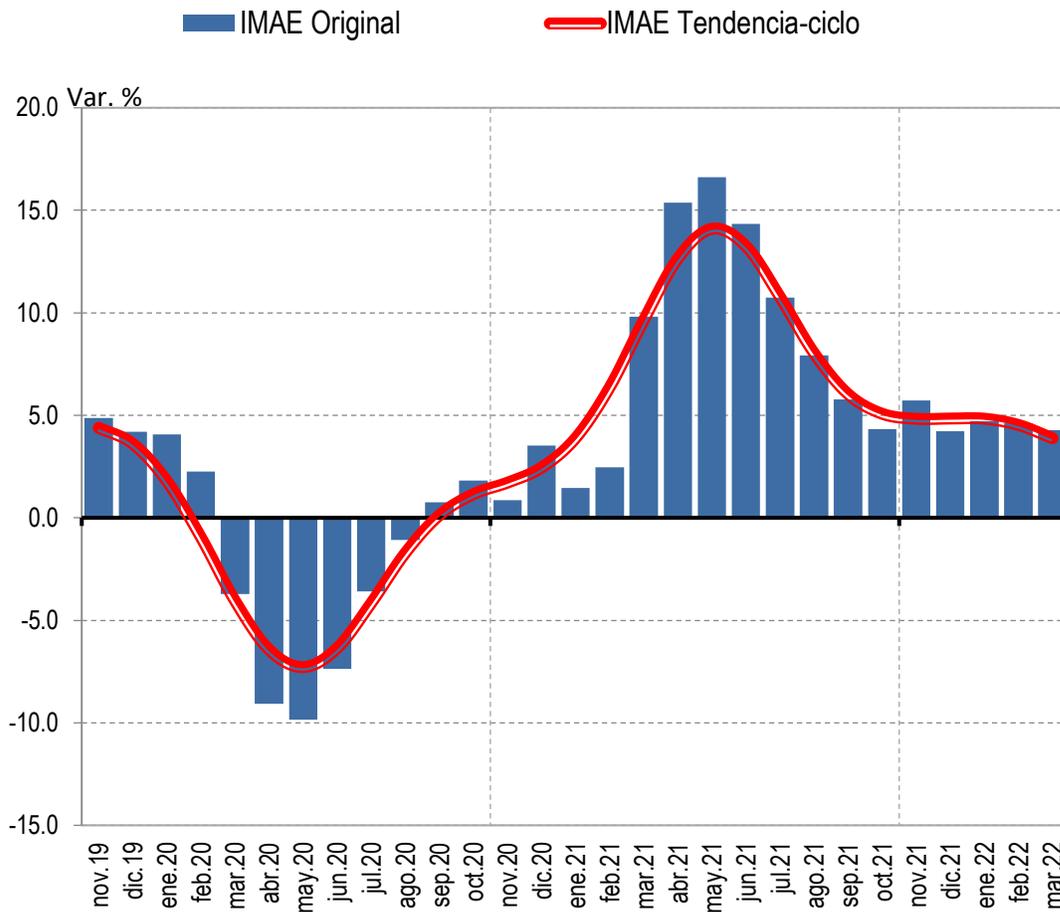
En marzo de 2020 se detectó el primer caso positivo de COVID-19 en Guatemala, desde ese momento hasta mayo de 2022 se han detectado más de 860,000 casos en territorio nacional y se han registrado 18,131 fallecidos, dando como resultado una tasa de letalidad de 2.11 %. En el mundo, para mayo de 2022 los casos ascienden a más de 529 millones y se ha tomado la vida de más de 6.3 millones de personas.

Derivado del primer caso de COVID-19 en Guatemala se aplicaron medidas de confinamiento a nivel nacional. Estas medidas golpearon de forma directa la interacción social como se conocía hasta ese momento, dado que la actividad económica se fundamenta en la confianza de los agentes económicos y la interacción entre estos, las medidas que se interpusieron tuvieron como resultado también un descenso en la actividad.

Este descenso en la actividad económica tuvo una respuesta por parte del BANGUAT, que como principal medida recortó la tasa de interés líder, para estimular a la actividad económica y buscar reducir el impacto de las medidas de confinamiento. Vale la pena destacar que este fuerte descenso de la actividad económica impactó principalmente sobre la población de escasos recursos a nivel nacional, población que tiende a ser lastimosamente mayoritaria en el país.

A continuación, se muestra el índice mensual de actividad económica que inicia en noviembre 2019 a marzo 2022, mostrando el descenso en la actividad económica que se describió anteriormente.

Figura 1. Índice mensual de actividad económica



Fuente: BANGUAT. (2022). *Índice Mensual de Actividad Económica*. Consultado el 12 de junio de 2022.

Recuperado de: <https://www.banguat.gob.gt/es/page/indice-mensual-de-la-actividad-economica-ima-e-ano-de-referencia-2013>

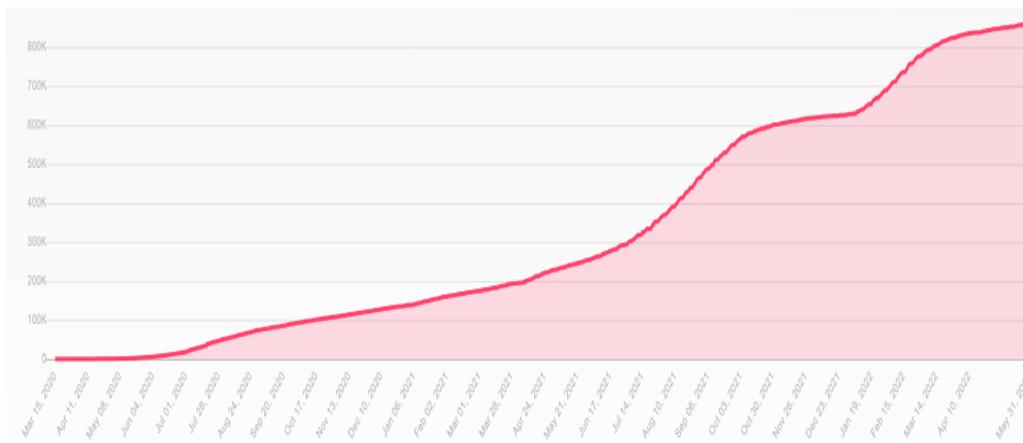
Para finales de marzo de 2021, en el contexto de la semana santa, con el fin de estimular la actividad económica las restricciones impuestas por el gobierno fueron relajadas, dando como principal resultado que para finales de abril de 2021 se declarara alerta roja institucional por el aumento de casos de COVID-19 en los hospitales nacionales y temporales. Desde finales de abril de

2021 a junio 2021 no se ha aplicado ninguna medida de confinamiento, sin embargo, no se observa tampoco ningún descenso en la cantidad de personas contagiadas por el COVID-19.

Para el período de diciembre de 2021 se observa una estabilización en el IMAE, y también una estabilización en la cantidad de contagios a nivel diario, esto puede ser por el efecto de los programas de vacunación a nivel nacional.

A continuación, se muestra la S.T. de casos confirmados de COVID-19 en Guatemala desde marzo de 2020 a finales de mayo de 2022.

Figura 2. **Cantidad de contagios de COVID-19 en Guatemala**



Fuente: Coronavirus (2022) *Casos confirmados*.

Tabla I. **Acciones del estado de Guatemala como medidas para la reducción de casos**

Acción	Fecha	Instancia Responsable
Cierre de fronteras con el Salvador	16/03/2020	Presidencia de Guatemala
Suspensión de Clases	16/03/2020	Presidencia de Guatemala.
Suspensión de actividades laborales para el sector público y privado.	17/03/2020	Presidencia de Guatemala.
Suspensión de transporte público urbano y extraurbano.	17/03/2020	Presidencia de Guatemala
Prohibición de actividades religiosas, deportivas, culturales y sociales.	17/03/2020	Presidencia de Guatemala.
Cierre de consultas externas a hospitales para dedicarse a emergencias	17/03/2020	MSPAS

Continuación de la tabla I.

Acción	Fecha	Instancia Responsable
Prohibición de reuniones	17/03/2020	Presidencia de Guatemala.
Cierre de centros comerciales	17/03/2020	Presidencia de Guatemala.
Cordón sanitario por caso comunitario de Covid-19	18/04/2020	Presidencia de Guatemala.
Instauración de toques de queda de 6P.M. a 4A.M.	04/05/2020	Presidencia de Guatemala.
Restricción de locomoción entre departamentos	04/05/2020	Presidencia de Guatemala.
Cierre total del país por tres días.	14/05/2020 Al 17/05/2020	Presidencia de Guatemala.
Instauración de toques de queda de 5P.M. a 5A.M.	14/05/2020	Presidencia de Guatemala.
Restricción de operación de mercados cantonales en horario de 6 a 1	14/05/2020	Presidencia de Guatemala.

Continuación de la tabla I.

Acción	Fecha	Instancia Responsable
Cierre total del país 29/05 y 01/06	25/05/2020	Presidencia de Guatemala
Restricción a la movilidad vehicular en función del último dígito de la placa	15/06/2020	Presidencia de Guatemala.
Instauración de toques de queda entre semana 18 PM a 5 AM y fines de semana 2PM a 5AM. Y eliminación de restricción interdepartamental	13/07/2020	Presidencia de Guatemala.
Eliminación de restricción de movilización por placa y reducción del tiempo del toque de queda	26/07/2020	Presidencia de Guatemala.
Zoo la Aurora abre sus puertas	26/08/2020	Presidencia de Guatemala.
Reapertura del aeropuerto la aurora	18/092020	Presidencia de Guatemala.

Continuación tabla I.

Acción	Fecha	Instancia Responsable
Apertura al sector hotelero y turístico	07/10/2020	Presidencia de Guatemala.
Llegada de las primeras 5,000 dosis de vacunas a Guatemala	25/02/2021	Gobierno de Guatemala.

Fuente: SICA (2022). *Coronavirus observatorio medidas*. Consultado el 12 junio de 2022

Recuperado de: <https://www.sica.int/coronavirus/observatorioSICACOVID19/medidas/guatemala>

Descripción del problema

Parece que las medidas de confinamiento laxas implican un mejor desempeño de la actividad económica, sin embargo, también exacerban la cantidad de contagios a nivel nacional. Por otro lado, medidas de confinamiento más estrictas reducen la cantidad de personas contagiadas, con el costo de reducir también la actividad económica, de forma intuitiva se entiende que antes del programa de vacunación existía una relación positiva entre la cantidad de contagios y la actividad económica nacional.

Basado en esta relación, a priori, directa que hubo previo al programa de vacunación entre cantidad de contagios y actividad económica se hace necesario estimar por medio de estadística paramétrica y análisis de S.T. los parámetros de contagio recuperación y letalidad que guiaron el proceso epidemiológico de COVID-19 en Guatemala.

Con los parámetros estimados anteriormente aproximar la dinámica de contagios bajo distintos escenarios de confinamiento y con estos hacer pronósticos del comportamiento de los contagios de COVID-19 en Guatemala para el segundo semestre del año 2022 y estimar como impactan estos en el índice mensual de actividad económica del BANGUAT. Con el fin de entender el costo de oportunidad que existe entre mantener un sistema de salud con una carga que pueda soportar y mantener un nivel de actividad económica que permita llegar a las metas de crecimiento nacional.

Formulación del problema

Pregunta central

¿Cómo los pronósticos de contagio de COVID-19 en Guatemala derivado de las distintas medidas de confinamiento impuestas por el gobierno y la tasa de vacunación, impactan en el índice de actividad económica de Guatemala?

Preguntas auxiliares

- ¿Cuáles son los parámetros de contagio, recuperación y letalidad de COVID-19 en Guatemala bajo dos distintos escenarios de confinamiento?
- ¿Cuáles son los pronósticos de contagio, recuperación y muertes de COVID-19 basado en medidas de confinamiento estrictas y totalmente laxas?
- ¿Cómo sería el índice mensual de actividad económica bajo medidas de confinamiento estrictas y totalmente laxas?

Delimitación del problema

El problema se abordó para Guatemala, se realizó una predicción de la cantidad de contagios de COVID-19 para el segundo semestre del 2022 utilizando los parámetros de los dos escenarios de confinamiento, que se obtuvieron a través de la estimación de dos modelos de series temporales que capturan información del proceso epidémico subyacente del COVID-19, estos parámetros luego alimentaron al modelo SEIR.

OBJETIVOS

General

Estimar los parámetros que gobiernan el proceso epidémico de COVID-19 en Guatemala y pronosticar contagios y su repercusión en la actividad económica, a través de análisis de S.T., estadística paramétrica y un modelo SEIR para proponer medidas de confinamiento que no entren en conflicto con las metas de crecimiento económicas nacionales.

Específicos

1. Estimar los parámetros de recuperación y fallecimiento de COVID-19 en Guatemala a través de análisis de S.T. y estadística paramétrica para entender y poder predecir cuál será la dinámica de contagios de COVID-19 en Guatemala, bajo dos escenarios de confinamiento distintos.
2. Pronosticar contagios de COVID-19 en Guatemala a través de un modelo SEIR para obtener la cantidad de casos positivos, recuperados e índice de mortalidad bajo el escenario de confinamiento laxo.
3. Estimar la correlación existente entre el número de casos positivos en Guatemala y la actividad económica basado los dos escenarios de confinamiento propuestos.

RESUMEN DEL MARCO METODOLÓGICO

Características del estudio

Enfoque

El estudio realizado tiene un enfoque cuantitativo, pues se buscaba estimar los parámetros de contagio, recuperación y letalidad de COVID-19 en Guatemala a través de análisis de S.T. y con estos parámetros estimados, fue utilizado un modelo SEIR, para hacer pronósticos en una ventana temporal de un año de contagios, recuperación y muertes derivadas de la infección causada por el SARS-Cov-2. Con estos pronósticos fueron establecidos dos tipos de escenarios; uno totalmente laxo y uno totalmente estricto ante los contagios de COVID-19 en Guatemala y se realizó un análisis de correlación con el Índice Mensual de Actividad Económica (IMAE).

Diseño

El diseño de la investigación es observacional, pues no se realizó ninguna manipulación de las variables, así mismo, fue de corte transversal, debido a que se tomaron los datos en un momento del tiempo, y se estimó la relación y dinámica de las variables ya mencionadas anteriormente para los datos obtenidos entre 2020, 2021 y 2022.

Alance

El tipo de estudio es descriptivo y de corte transversal, pues se buscó entender el fenómeno de la relación entre la cantidad de casos positivos de COVID-19 en Guatemala con el IMAE, vale la pena destacar que esta relación es correlacional y no causal, así mismo, esta relación es válida en el contexto de la pandemia.

Unidad de análisis

El objeto de estudio es la dinámica de contagios de COVID-19 y su repercusión en el índice mensual de actividad económica nacional para una ventana temporal comprendida entre marzo 2020 y abril 2022; los datos se analizaron en frecuencia diaria para la región geográfica de Guatemala, y tomando en cuenta a toda la población guatemalteca de acuerdo con la información suministrada por el MSPAS

Tabla II. **Operativización de variables**

Variable	Definición conceptual	Definición operativa	Escala
Tasa de contagios	Tasa a la que los individuos susceptibles pasan a ser individuos expuestos por unidad de tiempo.	Parámetro estimado beta obtenido del análisis de S.T. de los contagios a nivel diario.	De razón

Continuación de la tabla II.

Variable	Definición conceptual	Definición operativa	Escala
Alfa	Tasa a la que los individuos expuestos pasan a ser individuos que pueden contagiar a los individuos susceptibles	Valor esperado del tiempo de incubación del SARS-Cov-2 en los individuos expuestos, para el estudio será 7 días	De razón
Tasa de recuperación	Tasa a la que los individuos contagiados pasan a ser individuos recuperados por unidad de tiempo.	Parámetro estimado gamma uno obtenido del análisis de series de tiempo de los niveles de recuperación diario.	De razón.

Continuación de la tabla II.

Variable	Definición conceptual	Definición operativa	Escala
Tasa de letalidad	Tasa a la que los individuos contagiados pasan a ser individuos eliminados del sistema por unidad de tiempo	Parámetro estimado γ dos obtenido del análisis de series de tiempo de los niveles de muertes diario.	De Razón
Niveles de Contagio	Solución de las ecuaciones diferenciales dS/dt y dE/dt , dI/dt del modelo SEIR	Cantidad de contagios diaria pronosticada por el modelo SEIR	De razón
Niveles de recuperación	Solución de la ecuación diferencial dR/dt del modelo SEIR	Cantidad de casos recuperados pronosticados por el modelo SEIR	De razón
Niveles de mortalidad	Solución de la ecuación diferencial dR_2/dt del modelo SEIR	Cantidad de casos mortales pronosticados por el modelo SEIR	De razón

Continuación de la tabla II.

Variable	Definición conceptual	Definición operativa	Escala
IMAE	índice sintético cuyo fin es proporcionar una medida de la evolución de la actividad real de la economía en el corto plazo, el cual se ajusta a la metodología utilizada en las cuentas nacionales trimestrales y está compuesto por un conjunto heterogéneo de indicadores mensuales relacionados con la producción	Indicador proporcionado por el BANGUAT con 45 días de rezago respecto al mes que se evalúa.	De Razón

Fuente: elaboración propia.

Las fases que se tuvieron que realizar para hacer posible el cumplimiento de objetivos de este estudio se enumeran y describen a continuación:

- Fase 1. Revisión bibliográfica: se realizó una revisión de artículos académicos y libros cuya especialización es ecuaciones diferenciales,

análisis de S.T., modelos epidemiológicos y análisis económico del impacto de la pandemia en la sociedad. Estos artículos, dada la reciente coyuntura tienen entre 2 y 3 años de antigüedad, exceptuando los artículos que hablan de análisis de S.T. y ecuaciones diferenciales.

- Fase 2. Gestión y recolección de información: se recolectó la información de los casos positivos, casos recuperados y letales de COVID-19 en frecuencia diaria, publicado por el MSPAS. La información del Índice Mensual de Actividad Económica (IMAE), fue obtenida del sitio oficial del BANGUAT, vale la pena destacar que toda esta información es de carácter público y por tanto no se hizo necesario la generación de algún trámite más allá de la consulta web de la información. A las series de tiempo crudas obtenidas del MSPAS se les hizo primeramente una transformación Box-Cox, que buscaba corregir problemas de la distribución de los casos, pero también puede corregir problemas de heterocedasticidad derivado del cambio de escala. A las series transformadas, se les aplicó una segunda transformación, que es una primera diferenciación, esto para volver a estas series estacionarias en sentido débil, y con estas series poder realizar análisis de S.T. que permitan hacer inferencia acerca de la influencia de los casos positivos sobre los casos fallecidos y recuperados en la etapa de confinamiento estricto en el país.
- Fase 3. Análisis univariado y multivariado: se analizó y transformó la S.T. de casos positivos, recuperados y letales de COVID-19 en Guatemala para hacerla estacionaria en sentido débil, lo anterior se realizó tomando como puntos de referencia dos escenarios, el primero que se da con fuertes restricciones a la movilidad y la interacción social y el segundo, en el punto en el que la economía se abre en casi su totalidad. Así mismo, se

estimó también la correlación de los casos positivos de COVID-19 con el IMAE en estos dos escenarios, esto de forma preliminar, para tener una aproximación del comportamiento de la correlación.

- Fase 4. Modelación: se estimaron los parámetros de contagio, recuperación y letalidad con las series de tiempo transformadas en los dos escenarios ya mencionados, en función de criterios como la autocorrelación de cada una de las series de tiempo. Así mismo, se estimaron modelos de series de tiempo, para entender el peso de los rezagos sobre las observaciones actuales.
- Fase 5. Simulación y correlación: con los parámetros anteriormente estimados se utilizó un modelo SEIR para realizar la simulación de la dinámica de contagios, recuperados y muertes de COVID-19 en Guatemala, bajo escenarios los dos escenarios encierro y casi apertura total, para luego correlacionarlos con los niveles del índice mensual de actividad económica.
- Fase 6. Interpretación de información: con la información obtenida de las fases anteriores, se procedió al análisis de esta, que permitiera obtener conclusiones objetivas y una serie de recomendaciones para las autoridades interesadas.

El desarrollo de esta investigación se apoyó de distintas herramientas estadísticas y matemáticas, estas son:

- Análisis de S.T.: se utilizó el análisis de S.T., para entender ciclos, tendencias, estacionalidad y autocorrelación de la cantidad de contagios, muertes y recuperación de COVID-19 en Guatemala, el análisis de S.T.

estuvo fundamentado en la metodología propuesta por Box-Jenkins (1976), para asegurar que la estimación de los parámetros fue la mejor estimación linealmente insesgada de varianza mínima.

La metodología Box-Jenkins se fundamenta en hacer a la S.T. estacionaria en sentido débil, y luego observar las funciones de autocorrelación y autocorrelación parcial para determinar el orden de los coeficientes A.R.s y de M.A.s.

- Análisis y selección de modelos: la selección de modelos se hizo en función de criterios de información, bondad de ajuste, error cuadrático medio, error absoluto medio, y la prueba de Ljung-box esto para elegir los estimadores de los parámetros que dan el mejor ajuste a las series de tiempo, así como para entender cuál es el efecto de las observaciones rezagadas sobre las observaciones actuales.
- Análisis de modelos matemáticos para epidemiología: se utilizó un modelo SEIR. Con el modelo se realizaron los pronósticos de los contagios de COVID-19 en Guatemala y se obtuvo el entendimiento de la dinámica de la epidemia bajos los dos contextos de encierro y casi apertura total.
- Análisis de correlación: el análisis de correlación se realizó a través del índice de correlación de Pearson, que sirve para medir la fuerza y dirección lineal entre dos V.A., para este caso, la cantidad de contagios de COVID-19 y el índice mensual de actividad económica.

INTRODUCCIÓN

El presente trabajo fue una sistematización de la medición de casos positivos de COVID-19, para generar medidas de confinamiento dinámicas que superen el conflicto que implica el aumento de casos positivos de COVID-19 y el aumento de la actividad económica.

Para finales del primer trimestre del año 2020 en Guatemala se recibió la noticia del primer caso positivo de COVID-19 en el país, derivado de eso, el estado en su función de velar por la preservación de la vida tomó la decisión de cerrar el país. De esta manera la cantidad de contagios en el segundo y tercer trimestre del 2020 se mantuvieron muy bajos. El principal costo de la decisión anterior fue un descenso abrupto del índice mensual de la actividad económica, esto contraviene otra función del estado, el de velar por el desarrollo. Para finales de 2020, las medidas de distanciamiento social se relajaron, provocando un aumento en la actividad económica nacional, con el costo de un aumento de los casos positivos.

La falta de interacciones sociales reduce la cantidad de contagios y de casos letales de COVID-19, sin embargo, esto implica una reducción en la actividad económica que está en parte fundamentada por las interacciones sociales de los agentes.

Este trabajo de investigación es una propuesta para la generación de medidas de confinamiento dinámicas respondan a alivianar la presión sobre el sistema de salud sin que se pongan en riesgo las metas de crecimiento económico nacionales.

En esta investigación se delimitó el análisis a dos ventanas temporales que se definieron como confinamiento estricto y laxo caracterizadas por las acciones de medidas de distanciamiento social dadas por el estado. La información se obtuvo del MSPAS y del BANGUAT.

Con la información obtenida, se realizó una agregación a nivel nacional indexada en el tiempo y se tomaron dos aproximaciones para la estimación de los parámetros que gobernaron al proceso epidémico en el confinamiento laxo y estricto. Una aproximación fue por medio de estadística paramétrica y la otra fue por medio de análisis de S.T.

Ambos análisis convergieron a parámetros similares, que se exponen en la sección de resultados. Los parámetros utilizados sirvieron para alimentar al modelo SEIR, que pronosticó la dinámica de contagios, recuperaciones y muertes en el país para las ventanas temporales elegidas.

Adicional al análisis anterior, se realizó un análisis de la correlación entre los casos reportados de COVID-19 en Guatemala para las ventanas temporales que abarcaban a los confinamientos laxo y estricto, dando un entendimiento del costo existente entre la presión sobre el sistema de salud y el cumplimiento de las metas de crecimiento económico nacional.

Este informe está estructurado en cuatro capítulos, el primero es el marco referencial, que muestra estudios previos realizados en otros países sobre el tema a tratar, el segundo capítulo muestra el marco teórico, que es el fundamento técnico sobre el cual descansa la propuesta de solución que se plantea en la investigación. El tercer capítulo se describen los resultados obtenidos que responden a los objetivos planteados. El cuarto capítulo corresponde a la discusión de resultados.

1. MARCO REFERENCIAL

De acuerdo con la RAE (2022), epidemia se refiere a: “Enfermedad que se propaga durante algún tiempo por un país, acometiendo, simultáneamente a gran número de personas” (párr. 1). Si se extiende el concepto a pandemia, la RAE lo define como: “Enfermedad epidémica que se extiende a muchos países o que ataca a casi todos los individuos de una localidad o región” (RAE, 2022, párr. 2). Bajo el marco conceptual anterior, una epidemia es un proceso de transmisión de una enfermedad en menor escala que una pandemia.

La humanidad a lo largo de la historia ha sufrido de distintas epidemias y pandemias, y con el pasar de los años y el desarrollo de nuevas tecnologías se ha logrado diseñar herramientas que permiten generar una aproximación en el entendimiento de cómo es gobernado desde el punto de vista matemático y estadístico un proceso epidémico.

Zhou, Dong, Ma, Wu y Qiu (2021), argumentan que:

La propagación de una enfermedad infecciosa puede ser impredecible; afortunadamente, técnicas de modelación pueden compensar la recolección de información imperfecta de grandes poblaciones (...) La aproximación de la dinámica de indisposiciones infecciosas es una técnica matemática que se ha desarrollado en un rico campo interdisciplinario. (p. 12)

Adicional a la aproximación anterior, es posible modelar los procesos epidémicos a través de modelos estadísticos tradicionales, que, según estos

autores pueden describir el proceso de las muertes, transmisión y predecir el estado de las futuras muertes. Sin embargo, la aproximación de la dinámica de indisposiciones infecciosas permite también evaluar los efectos de estados de control y prevención y proveer de un soporte para la toma de decisiones apropiadas de las distintas autoridades interesadas en el tema.

Un ejemplo de la aproximación de la dinámica de indisposiciones infecciosas viene dado por He, Dushoff, Day, y Ma (2013), quienes muchos años antes de la pandemia ocasionada por el SARS-CoV-2, infirieron las causas de las tres olas de la influenza de 1918 en Inglaterra y Gales. Para lo anterior incluyeron 3 factores que contribuyeron a la generación de las olas, estos fueron: apertura y clausura de escuelas, cambios en el clima, cambios en la conducta humana en respuesta a las infecciones de las personas a su alrededor. Dentro del artículo se menciona que la tasa de mortalidad en los ambientes urbanos fue entre 30 %-40 % mayor que en los ambientes rurales.

En el contexto académico anterior es que se inicia a desarrollar la pandemia causada por el SARS-CoV-2. En febrero 2020 Lin, *et al.*, (2020), toman como referencia la investigación de He, Dushoff, Day, y Ma realizada en el 2013, para proponer un modelo conceptual del comportamiento de COVID-19, para ello estudian la influencia de factores como: el año nuevo chino que coincide con el inicio de la transmisión, la restricción de viajes, hospitalizaciones y la cuarentena.

El modelo adoptado por Lin, es un modelo de susceptibles-expuestos-infecciosos-recuperados, tomando en cuenta un factor de percepción de riesgo social, que es una dependencia del número de casos severos y muertes. La principal conclusión de la investigación se centra en que el modelo utilizado para simular la dinámica de contagios de COVID-19 se apega a los contagios de la enfermedad que había en ese momento. Sin embargo, se hace mención que no

es clara la contribución de los asintomáticos a la dinámica de contagios, pues estos, pueden generar casos sintomáticos, pero el impacto de ellos en ese momento ameritaba una mayor profundización.

El trabajo anterior, permite comprender que para poder modelar la dinámica de contagio de COVID-19 en Guatemala, es necesario no solo un modelo estadístico, sino también un modelo matemático, en el caso anterior un modelo SEIR permitió a los autores pronosticar como sería la dinámica de contagios en China.

En mayo 2020 Tian, Liu, Li, Wu y Ai (2020) investigan las fuentes de transmisión y medidas de control durante los primeros 50 días de la epidemia de COVID-19 en China. En el artículo se menciona como el gobierno chino en un intento por frenar la propagación del virus cierra todos los transportes el 23/01/2020, así como pone en alerta máxima a todo el sistema sanitario. Los autores estiman un modelo para entender cuál fue el efecto de las medidas impuestas por el gobierno chino. El modelo estimado sugiere que, sin la restricción de viajar, para el día 50 de la epidemia hubiese habido 744,000 casos de covid-19 en China en lugar de los 76,000 que se registraron para el día 50.

Una de las conclusiones de la investigación anteriormente mencionada es que una de las medidas más exitosas del gobierno chino para contener la propagación de SARS-CoV-2 fue la restricción de viajar, así como el aislamiento de aquellos casos positivos. Es decir, todo aquello que implica una interacción social promueve la propagación del virus.

Bajo la premisa de que las interacciones sociales son la mayor causa de la propagación de COVID-19 es que se ha modelado el comportamiento de la propagación del SARS-CoV-2. Zhou, *et al.*, (2021) por ejemplo, utilizan un modelo

SEIR para simular la propagación de una enfermedad en una estación de tren urbana. Para este objetivo consideran el tráfico de personas en la estación de Tiany, ubicada en el distrito de Huishan, China.

Los autores modelan el comportamiento de 4 tipos de personas que interactúan dentro de la estación: susceptibles, expuestos, infectados y recuperados, asumen que la enfermedad tiene un período de incubación de 14 días. El principal resultado encontrado fue que la tasa de contacto, infectividad y el promedio de duración de la enfermedad estaban correlacionadas de forma positiva con el número de infecciones. Por otro lado, el promedio de incubación de la enfermedad estaba negativamente correlacionado con el número de personas infecciosas.

Las investigaciones anteriores, muestran que, si la propagación del virus está directamente relacionada con las interacciones sociales, entonces, las medidas de distanciamiento social impuestas por los gobiernos son una solución para mantener estable al sistema de salud pública, y contener al virus, y por tanto, son una referencia para el presente trabajo, pues hace notar que es importante modelar el comportamiento del gobierno.

La misma línea de pensamiento siguen Angulo, *et al.*, (2021) quienes utilizan un modelo SEIR modificado que adicional a la percepción de riesgo propuesta por Lin, agregan también a la serie de ecuaciones del modelo SEIR el comportamiento del gobierno dentro de la sociedad.

Los autores destacan que el modelo teórico reproduce el comportamiento de los datos que arroja la pandemia, y, por tanto, se puede hablar con certeza de la importancia de las acciones del gobierno dentro de la sociedad para la contención de la propagación de los agentes patógenos.

El rol del gobierno en la sociedad toma más importancia en el momento en el que la tasa de mortalidad del virus es mayor al 4 %. Vale la pena añadir que, el modelo propuesto puede ayudar a predecir comportamientos futuros de procesos epidémicos derivados de virus con la misma estructura biológica y molécula que el SARS-CoV-2.

Cabe destacar que la data utilizada en todos los trabajos mencionados hasta el momento corresponde a los primeros meses de propagación de COVID-19 en China para las 33 provincias.

A pesar de que las medidas de distanciamiento social son efectivas para contener, estas no son sostenibles en el largo plazo, principalmente porque parte del bienestar humano está fundamentado en la actividad económica, que requiere de interacciones sociales.

El comportamiento social humano, es uno de los componentes principales para explicar cómo se propaga o disipa un agente patógeno. En el contexto de la pandemia de COVID-19, los gobiernos alrededor del mundo enfrentan grandes retos para poder cubrir las necesidades de salud pública y crecimiento económico que generen bienestar social.

A priori, se percibe que los conceptos salud pública y crecimiento económico chocan en el mundo que ha dejado la pandemia, pues el crecimiento económico implica consumo e inversión y parte de los componentes principales de estas dos variables es la interacción y cercanía de los agentes económicos, estas interacciones exacerban la cantidad de contagios y gente expuesta al virus, que reduce la capacidad de atención del sistema de salud público.

El argumento expresado en el párrafo anterior es justamente el marco que engloba la investigación realizada por Kolumbu y Nisan (2021), en el que plantean un costo de oportunidad entre la cantidad de pérdidas humanas derivadas de COVID-19 y los costos económicos que implican los cierres de los países para contener la propagación de la enfermedad.

Entre los principales resultados de Kolumbu Y Nisan (2021) destaca que:

El hacer pruebas sobre la población y encuarentenar a aquellos casos positivos reducen tanto los costos económicos como la mortalidad, esto requiere mucha infraestructura y bastante flexibilidad por parte del estado para adaptarse rápidamente. Otro resultado es que el poder hacer un seguimiento a los contactos de los individuos que dieron positivo, mezclado con pruebas puede lograr muy buenos resultados para evitar los cierres totales de las economías. El último resultado es que en presencia de nuevas variantes de una enfermedad los cierres dinámicos son más eficientes que los cierres estáticos. (p.38)

Para llegar a los resultados anteriores los autores se valieron de un modelo SEIR, en el que dan distintos parámetros de comportamiento social, mortalidad e incubación a los agentes sintomáticos y asintomáticos. Dado que el enfoque principal de la investigación estaba centrado en los costos de oportunidad de las pérdidas económicas respecto derivado de los cierres de un país para proteger la vida, las variables de estudio fueron las vidas perdidas y los días de trabajo perdidos.

La simulación del trabajo se enfocó en dar distintos niveles de cierre de un país, para determinar cómo sería la dinámica de contagios y mortalidad para luego compararla con las pérdidas económicas.

Es posible notar que la investigación de Kolumbu y Nisan, (2021), dan un nuevo enfoque al análisis de la dinámica de contagios, agregando no solo variables económicas, sino también, distintos parámetros de comportamiento de los individuos en una sociedad. Este mismo enfoque es el que fue utilizado por Grimm, Mengel y Schmidt en el 2021, en el cual proponen una extensión del modelo SEIR, en donde introducen distintos grupos al modelo que son mutuamente excluyentes, por tanto, los parámetros de comportamiento social, respuesta a las intervenciones públicas, tasas de letalidad y síntomas de la enfermedad son diferentes.

Con el relajamiento del supuesto de que todos los agentes del modelo son iguales logran demostrar que las combinaciones de medidas de distanciamiento social a la medida de los diferentes grupos pueden ser efectivas para la reducción de la mortalidad, sin entrar en conflicto con las metas de crecimiento económico. Sin embargo, existe un supuesto que se debe de tomar en cuenta, este es el alto cumplimiento de las reglas de distanciamiento social que se impongan.

El poder imponer medidas de distanciamiento social acordes con los distintos tipos de poblaciones en la vida real, puede llegar a ser difícil, principalmente por que no existe un criterio para poder generar conglomerados o estratos basados en condiciones de percepción de riesgo del virus, o vulnerabilidad de la infección causada. Por tanto, una buena forma de solventar lo anterior, es rastrear a los casos positivos, aislarlos, determinar en qué grupo de vulnerabilidad y percepción de riesgo se encuentran y en función de estas características imponer medidas de cumplimiento.

Los trabajos de los autores mencionados anteriormente sirven de base para la presente investigación, pues hacen notar no solo los efectos económicos de los cierres para evitar las interacciones sociales, también, relajan el supuesto

de que todas las personas en una sociedad son homogéneas y, por tanto, se buscará utilizar la misma metodología de modelación de una sociedad con parámetros heterogéneos en la presente investigación.

Hasta el momento se ha ido mencionando la interacción social como un factor que genera la propagación de un agente patógeno, sin embargo, vale la pena mencionar que existen distintos tipos de interacciones sociales, la interacción de los agentes con otros agentes está en función del entorno que los engloba, por ejemplo, la investigación de Zhou, *et al.*, (2021) propone que la interacción social de los agentes modelados es convivir en una estación de metro con alta densidad poblacional.

Chung y Chew (2021) relajan el supuesto de que la interacción social es homogénea en todo el tiempo, para esto toman patrones de interacciones entre los agentes y diferencian la interacción de los agentes en su casa de la interacción de los agentes en el trabajo y la interacción de grandes reuniones sociales, así como el contacto con extranjeros.

Para poder modelar las interacciones anteriores lo que utilizan es un modelo SEIR que toma en cuenta una red de interacciones sociales múltiples. Entre los principales resultados de la investigación se destaca que los residentes de áreas con alta densidad poblacional pueden ser infectados fácilmente, a pesar de que estos constituyan una pequeña fracción de la población. Así mismo, una vez las infecciones inician en lugares altamente densos, no es posible controlar la propagación de la enfermedad si no se implementan los controles necesarios.

La representación de una red de interacciones sociales múltiples a través de un modelo SEIR, hace más flexible la modelación de las distintas interacciones que pueden tener los agentes en un modelo, para la simulación y evaluación de

exclusión social de algunos agentes durante algún tiempo para tener un control epidémico.

El trabajo mencionado anteriormente servirá en la presente investigación para poder tomar en cuenta dentro del modelo, que las interacciones sociales de las personas varían en función del contexto que las engloba, en este caso, el contexto será el período en el que se hará la simulación.

Las investigaciones descritas con anterioridad se han enfocado en modelar la dinámica de contagios, muertes, recuperaciones para distintas sociedades, así como los distintos impactos económicos que los cierres para evitar la propagación de un virus implican. El trabajo de investigación se centra en Guatemala y, por tanto, vale la pena mencionar cuál fue la reacción del BANGUAT en el contexto de la pandemia.

Como primer punto, se debe mencionar que el primer caso positivo de COVID-19 en Guatemala se dio el 13/03/2020. Para el 25/03/2020 el BANGUAT había bajado ya 75 puntos básicos la tasa de interés líder de política monetaria con el fin de moderar la desaceleración de la actividad económica y aminorar el costo de crédito. Adicional, abrió ventanillas de liquidez temporal para los bancos del sistema financiero.

En cuanto al tipo de cambio refiere, salió a atender la demanda de dólares para mantener un tipo de cambio de referencia estable, para junio de 2020 había vendido ya US\$ 421.7 millones, esto es casi el doble de lo que vendió en todo 2019.

Todos los trabajos de investigación anterior, así como la respuesta del BANGUAT, son el marco de referencia y el contexto en el que el presente trabajo

de investigación se desenvuelve, esto, porque en el presente trabajo de investigación se utilizará un modelo SEIR, para tener una aproximación al entendimiento de la dinámica de contagios de COVID-19 en Guatemala, adicional, la idea de cómo existen distintos agentes dentro de una sociedad que pueden tener parámetros heterogéneos de contagio, letalidad, incubación y percepción del riesgo.

De forma paralela, la reacción del BANGUAT a la coyuntura derivada de los contagios del SARS-CoV-2, sirvió para entender, como la dinámica de contagios puede cambiar el comportamiento del banco central, así mismo, el índice mensual de actividad económica (IMAE) dado por el BANGUAT, sirvió para poder simular como distintas medidas de restricción impuestas por el gobierno, afectan a la actividad económica.

2. MARCO TEÓRICO

La presente sección tiene por objetivo exponer e interpretar la teoría estadística y epidemiológica que fundamenta a las técnicas utilizadas en la investigación para el cumplimiento de los objetivos planteados.

El desarrollo de esta sección inicia con la teoría de S.T., que es fundamental para el entendimiento de la evolución del COVID-19 en Guatemala. La segunda parte aborda el tema de epidemiología y ecuaciones diferenciales que sirven de base para la modelación epidemiológica. El tercer punto aborda el tema de modelos epidemiológicos, que son alimentados por los parámetros obtenidos del análisis de S.T. y estadística paramétrica y sirven para entender la dinámica de la pandemia dentro del territorio nacional, así como para generar los pronósticos de casos positivos que fueron correlacionados con el índice de la actividad económica estimado por el BANGUAT. El último punto de esta sección aborda temas muy puntuales de estadística paramétrica.

2.1. Series de tiempo

Enders (2015) Comenta que el análisis de series de tiempo implica desarrollar de forma razonable modelos simples capaces de pronosticar, interpretar y probar hipótesis concernientes a variables que evolucionan en el tiempo.

2.1.1. Procesos estocásticos

“Cuando se analiza una S.T., es de gran utilidad considerar las series observadas (x_1, x_2, \dots, x_T) como una realización particular de un P.E.” (Monsalve y Harmath, 2015. p.42).

Rincón (2011) expresa que:

Un P.E. es una colección de V.A. $\{X_t: t \in T\}$ parametrizada por un conjunto T , llamado espacio parametral, y con valores en un conjunto S llamado espacio de estados. El espacio parametral se define como: $T = \{0,1,2 \dots\}$ o el conjunto continuo $T = [0, \infty)$, y estos números se interpretan como tiempos. El primer caso es un proceso discreto y el segundo caso es un proceso continuo. El espacio de estados es el conjunto de los números reales, que nos dice el valor que toma la v.a. en un tiempo definido en el espacio parametral. (p. 62)

Por analogía se puede decir que una S.T. es a un P.E., como una muestra es a una población. Se dice por tanto que una S.T. hereda todas las características de un P.E.

Para trabajar con series de tiempo, se dice que el P.E. del cual heredó su comportamiento es ergódico, es decir que el P.E. da en promedio el mismo resultado cuando se repite una cantidad de veces indefinida.

Para simplificar lo que implica que un P.E. sea ergódico, Box y Jenkins (1976) establecen que: “La estacionariedad del P.E., esta condición es un equilibrio estadístico y la base del análisis de series de tiempo es la estacionariedad” (p. 82).

2.1.2. Estacionariedad de un P.E.

“Se dice que un P.E. es estacionario en sentido estricto si no existe varianza en la distribución de las V.A. que están igualmente separados en el tiempo” (Monsalve y Harmath 2015, p. 31). La condición anteriormente mencionada es bastante fuerte y difícil de verificar de forma empírica, por lo que con frecuencia se utiliza una condición de estacionariedad en sentido débil.

Un P.E. es estacionario en sentido débil si cumple con las siguientes condiciones:

Condición de estacionariedad en media

$$E(x_t) = \mu \quad \forall t \quad (\text{Ec. 1})$$

Condición de Estacionariedad en covarianza

$$\text{cov}(x_t, x_{t+k}) = \gamma_k \quad \forall k \quad (\text{Ec. 2})$$

Las dos ecuaciones anteriores implican que un P.E. es estacionario en sentido débil si el V.E. de la v.a. es constante a lo largo del tiempo y, además, la covarianza de la v.a. con el k-ésimo rezago es una dependencia de cuan alejadas están en el tiempo las variables y es la misma para todas las variables que están alejadas k momentos en el tiempo.

La idea anterior, implica homocedasticidad de la S.T., pues:

Homocedasticidad de una S.T. estacionaria en sentido débil.

$$\text{cov}(x_t, x_t) = \text{var}(x_t) = \gamma_0 \quad \forall t \quad (\text{Ec. 3})$$

Es decir, la varianza de la v.a. a lo largo del tiempo es constante a lo largo de toda la realización.

Las V.A. en las series de tiempo se caracterizan por tener autocorrelación con sus rezagos, de esto deriva la función de autocorrelación de una S.T.

2.1.3. Autocorrelación de una S.T.

En cuanto a la correlación entre x_t, x_{t-k} , es conocido como con el nombre de autocorrelación del retardo k de x_t y se denota por ρ_k . Asumiendo que la S.T. es estacionaria en sentido débil, entonces la covarianza, solo depende del rezago k, así la autocorrelación ρ_k , se puede denotar por.

Autocorrelación del rezago k en un P.E. estacionario en sentido débil.

$$\rho_k = \frac{cov(x_t, x_{t+k})}{(var(x_t) * var(x_{t-k}))^{0.5}} = \frac{\gamma_k}{\gamma_0} \quad (\text{Ec. 4})$$

Cuando las autocorrelaciones ρ_k son consideradas como una dependencia del retardo k entonces se definen como función de autocorrelación (ACF). La ACF juega un papel muy importante en la caracterización de la dependencia entre las observaciones. En otras palabras, la ACF, permite determinar qué tan influyentes son las observaciones del pasado en las observaciones del futuro. (Monsalve y Harmath, 2015, p. 28)

2.1.4. Modelos lineales

Los modelos lineales intentan capturar la relación lineal entre el valor que puede tomar una v.a. en un momento t , y la información disponible en t . La correlación juega un papel importante para la estimación de modelos lineales.

Los modelos lineales, engloban modelos econométricos que a continuación se describen.

2.1.4.1. El proceso de ruido blanco

Se denomina R.B. de media 0 y varianza σ_2 si se satisface que:

$$E(\varepsilon_t) = 0 \quad \forall t, \quad var(\varepsilon_t) < \infty, \quad covar(\varepsilon_t, \varepsilon_{t-k}) = 0 \quad \forall k \neq 0 \quad (\text{Ec. 5})$$

Un P.E. es R.B. si el V.E. de la v.a. es 0 todo el tiempo, es de varianza finita y todas las observaciones son independientes entre sí, es decir, que el R.B., es básicamente un P.E. totalmente aleatorio. Si, además, las variables se distribuyen de forma normal, se dice que se tiene un R.B. gaussiano.

El R.B., es el componente aleatorio que caracteriza a una S.T.

2.1.4.2. Modelos A.R.s

Un modelo A.R. es un proceso cuyos valores del pasado son estadísticamente significativos en la predicción de la v.a. en el momento t .

De forma general, un modelo A.R. de orden p (AR(p)), es un modelo en el que p rezagos de la v.a. que son estadísticamente significativas, para explicar la varianza de la v.a. en el momento t.

Matemáticamente, un modelo A.R. de orden p, se puede expresar como:

$$x_t = \phi_0 + \sum_{i=1}^p \phi_i x_{t-i} + \varepsilon_t \quad (\text{Ec. 6})$$

Se asume que ε_t es un proceso de R.B., por tanto, poniéndolo en términos del V.E. y la varianza de la v.a., se llega a:

$$E(x_t | x_{t-1}, \dots, x_{t-p}) = \phi_0 + \sum_{i=1}^p \phi_i x_{t-i},$$

$$\text{Var}(x_t | x_{t-1}, \dots, x_{t-p}) = \sigma_\varepsilon^2 \quad (\text{Ec. 7})$$

Para que un modelo regresivo AR(p), sea estacionario en sentido débil, se tiene que cumplir que: La suma de los parámetros que ponderan el peso de los rezagos sobre el V.E. de la v.a. en t, sean menores a 1.

Adicional a los modelos A.R.s, también es necesario considerar a los modelos de M.A.s.

2.1.4.3. Modelos de medias móviles

Un modelo de M.A.s, denotado como MA(q), se puede escribir como:

$$x_t = \mu_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad (\text{Ec. 8})$$

Los modelos MA, son débilmente estacionarios, esto porque, porque son una combinación lineal de una sucesión que es R.B., es decir que los primeros dos momentos del proceso son invariantes en el tiempo.

$$E(x_t) = \mu_t, Var((x_t)) = (1 + \theta_1^2 + \dots + \theta_q^2)\sigma_\varepsilon^2 \quad (\text{Ec. 9})$$

Dado que un proceso de M.A.s está gobernado por un proceso de R.B., la correlación de la v.a. con un rezago $k > q$ es 0.

Una vez un modelo AR(p) sea estacionario, este se puede convertir en un modelo de M.A.s, y los modelos de M.A.s pueden ser convertidos a su vez en un modelo A.R., el siguiente tema hablará brevemente acerca de la propiedad de Invertibilidad de una S.T.

2.1.4.4. Invertibilidad

Una propiedad deseada en las series de tiempo es la Invertibilidad. Se dice que un P.E. es invertible, si es posible reconstruir el valor del *shock* estocástico ε_t en un proceso que depende únicamente de las observaciones pasadas. Siempre y cuando los factores θ_i sean menores que 1, el proceso de M.A.s se puede convertir en un proceso A.R. de orden infinito. La demostración del enunciado anterior, esta fuera del alcance del tema que se trata en el presente trabajo de investigación, sin embargo, se puede acudir a Monsalve y Harmath para revisarla.

2.1.4.5. Modelos ARMA

En la práctica puede ser necesario considerar procesos que son una combinación de modelos A.R.s y modelos de M.A.s. Lo anterior puede ser

derivado de que un modelo A.R. puro podría tender a tener parámetros infinitos, además un modelo de M.A.s puro implicaría que la v.a. se explica como una combinación lineal de un proceso de R.B.

Para solventar los posibles inconvenientes mencionados anteriormente, muchas veces se recurre a procesos A.R.s de M.A.s, que se denota como ARMA (p,q).

$$x_t = \phi_0 + \sum_{i=1}^p \phi_i x_{t-i} + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (\text{Ec. 10})$$

La condición necesaria y suficiente para que el proceso ARMA(p,q) sea estacionario en sentido débil es que, la suma de los parámetros phi y theta sean menores a 1. Que implicaría que el polinomio característico del modelo ARMA (p,q) tiene raíces unitarias fuera del círculo unitario.

En lo que a series de tiempo concierne, el último tema a tocar es el de modelos no estacionarios, es decir, cuando las series de tiempo incumplen con los supuestos de homocedasticidad, covarianza como función de que tan rezagadas están las variables y V.E. constante a lo largo del tiempo.

2.1.5. Modelos no estacionarios

Una S.T. no es estacionaria, cuando la varianza, auto covarianza y/o el V.E. de la v.a. no son constantes a lo largo del tiempo. Se discuten brevemente estos temas a continuación.

2.1.5.1. No estacionariedad en varianza

La modelación de series de tiempo que no son estacionarias en la varianza viene acompañada de dos supuestos. El primer supuesto: “Una S.T. se puede descomponer en dos términos, un primer término no estocástico, su media y un segundo término, un residuo aleatorio” (Monsalve y Harmath, 2015, p.94).

El segundo supuesto, es que, la varianza de los residuos, ε_t , se mapea como una dependencia de la media μ_t y de otra forma funcional que ya es conocida. Lo que se busca es encontrar una forma funcional que se encargue de hacer constante la varianza en el tiempo.

Las siguientes ecuaciones, muestran lo que se describió anteriormente.

$$x_t = \mu_t + \varepsilon_t, \text{Var}(x_t) = \text{Var}(\varepsilon_t) = \mu_t f(x_t) \sigma^2 \quad (\text{Ec. 11})$$

Bajo los supuestos anteriores, (que no son muy difíciles de cumplir en las series de tiempo), Cox & Box (1964), propusieron de forma general, la función que estabiliza la varianza. Monsalve y Harmath, la cual ilustran en su libro, y a continuación, se muestra aquí.

$$g(x_t) = \begin{cases} \frac{x_t^\lambda - 1}{\lambda}; & \lambda \neq 0 \\ \ln(x_t) & \end{cases} \quad (\text{Ec. 12})$$

La serie de transformaciones propuestas por estos autores es una aproximación para estabilizar la varianza, sin embargo, existen métodos más robustos (modelos de la familia ARCH y GARCH), que permiten estabilizar la varianza de las series de tiempo y problemas de colas pesadas de una distribución, si ese fuese el caso.

Adicional a lo anterior, cabe resaltar que la transformación propuesta por Box y Cox en (1964), no solo es una función estabilizadora de la varianza, adicional, sirve para corregir problemas de distribución de la v.a.

2.1.5.2. No estacionariedad en la media

Para los casos en donde no existe estacionariedad en la media, Enders (2015) en su libro, dedica un capítulo completo a la modelación de series de tiempo que no son estacionarias en la media, que se pueden particularizar como series de tiempo con tendencia.

La primera aproximación para modelar una S.T. con tendencia, de acuerdo con Enders (2015), la primera aproximación es descomponer las series de tiempo en tres partes distintas: tendencia, componente estacionario y ruido.

En la sección anterior del marco teórico se discutió y citó como distintos autores recomiendan la modelación de series de tiempo estacionarias, en el caso particular de series de tiempo con tendencia de acuerdo con este autor, los métodos más usuales para eliminar la tendencia son la diferenciación y el “*detrending*”.

La diferenciación de una S.T. para hacerla estacionaria está basada en el supuesto de que la media es un término de tendencia, y es una dependencia de un polinomio con d raíces, adicional, el *shock* estocástico tiene autocorrelación.

La expresión matemática que representa el párrafo anterior se presenta a continuación:

$$x_t = \mu_t + \varepsilon_t = \sum_{j=0}^d \beta_j t^j + \Psi(L)\varepsilon_t \quad (\text{Ec. 13})$$

Dado que los términos β_j permanecen constantes en el tiempo, se dice que la tendencia es un proceso determinista, y por tanto esta se puede eliminar con una diferenciación.

Para lo anterior considérese $d=1$, es decir se tiene un proceso lineal, y que el shock estocástico es R.B., se procederá a realizar la diferenciación para mostrar cómo se elimina la tendencia.

$$\begin{aligned}x_t &= \beta_0 + \beta_1 t + \varepsilon_t \\x_{t-1} &= \beta_0 + \beta_1 t - \beta_1 + \varepsilon_{t-1} \\y_t = x_t - x_{t-1} &= \beta_1 + \varepsilon_t - \varepsilon_{t-1}\end{aligned}\tag{Ec. 14}$$

La ecuación anterior, muestra como un proceso con una tendencia lineal, al ser diferenciado pasa a ser un proceso de M.A.s, este proceso MA(q) de ser invertible, se puede caracterizar como un proceso ARMA (p,q).

Para el caso del “*detrending*”, se utiliza cuando no es posible caracterizar la diferenciación de la S.T. con tendencia como un proceso ARMA (p,q). De tal manera que la forma apropiada de transformar a la S.T. es estimar una regresión de la v.a. en función de un polinomio del tiempo determinístico.

Para poder determinar cuál es el mejor polinomio del tiempo se utilizan criterios de información o el estadístico F de Fischer en su defecto.

La siguiente ecuación muestra, la regresión que se utiliza en el *detrending* para eliminar la tendencia de una S.T.

$$y_t = \sum_{j=0}^d a_j t^j + e_t \tag{Ec. 15}$$

El análisis de S.T. es mucho más amplio de lo que se narra en el presente marco teórico, sin embargo, las herramientas descritas, son las que en la actualidad son las más utilizadas.

2.2. Epidemias

Una epidemia corresponde al crecimiento de una enfermedad endémica, o a la aparición de un gran número de pacientes donde la enfermedad estaba ausente.

2.2.1. Epidemiología

De acuerdo con Beaglehole, Bonita y Kjellström (2023) “hasta el siglo XIX no empezó a ser relativamente frecuente que se midiera la distribución de una indisposición en grupos determinados de la población” (p.7). Una de las investigaciones insignias de esa época, fue, por ejemplo, el hallazgo de John Snow, que relacionó la incidencia de cólera con el consumo de agua suministrada por una empresa determinada en Londres.

Con el inicio del siglo XX, la utilización del enfoque epidemiológico de comparar tasas de indisposición en subgrupos de poblaciones se empezó a utilizar más. Beaglehole, *et al.*, (2003), al respecto comentan que se demostró que este método es una herramienta poderosa para revelar asociaciones entre circunstancias o agentes ambientales e indisposiciones específicas.

En el contexto de la estadística, el enfoque epidemiológico de comparar tasas de indisposición en subgrupos de población no es más que el enfoque de tablas de contingencia de estadística no paramétrica, que facilita la realización de pruebas de homogeneidad o independencia de grupos que se desean comparar. Estas pruebas están fundamentadas en la distribución chi cuadrada.

Last (citado en Alarcón, 2009) plantea que epidemiología es el estudio de la distribución y los determinantes del estado de salud-enfermedad o eventos en poblaciones específicas y su aplicación al control de problemas de salud.

Alarcón (2009), comenta que la definición dada por el autor arriba mencionado es insuficiente, dado que una ciencia debe de tener definido lo que estudia y como lo estudia. Como complemento de la definición ya dada, se agrega que la epidemiología estudia las causas por la que las indisposiciones se difunden en poblaciones.

Siguiendo la línea de pensamiento anterior, se dice que: “Epidemiología es la ciencia de las leyes objetivas que subyacen en la originación, propagación y reducción de indisposiciones infecciosas en grupos de humanos y en la erradicación de las indisposiciones” (Elkin, 1961, p. 52).

La epidemiología busca, por tanto, el tiempo, lugar, persona y causalidad, es decir, busca las ventanas temporales en las que se está dando la transmisión de indisposiciones, los espacios físicos, en los cuales se está transmitiendo las indisposiciones, el tipo de personas que se están contagiando, y busca también explicar las explicaciones del por qué suceden estos eventos.

La epidemiología, ve a la transmisión de una indisposición con un enfoque dinámico, y por tanto la propagación de las indisposiciones es una dependencia de los contactos sociales y la susceptibilidad de los agentes involucrados.

Habiendo aclarado el concepto de epidemiología, se hablará acerca de los distintas formas y canales por las que se puede transmitir una indisposición entre seres humanos y que puede derivar en procesos epidémicos.

2.2.2. Tipos de transmisión de una enfermedad

Esta sección inicia definiendo el término enfermedad transmisible como: “Cualquier indisposición causada por un agente infeccioso específico o sus productos tóxicos, que se manifiesta por la transmisión de este agente o sus productos, de un reservorio a un huésped susceptible” (Castillo, *et al.*, 2011 p.42).

Adicional a esta definición, los autores citados anteriormente mencionan que tipos de mecanismos de transmisión se pueden utilizar. Estos son: persona a persona, animal a persona, huésped intermediario, vector del medio ambiente inanimado.

Lederberg (citado en Castillo 2011) señala que existen distintos factores que pueden hacer que una indisposición transmisible que estaba controlada pueda emerger nuevamente.

- Factores sociales: entre estos se encuentran el crecimiento de la población, deterioro urbano, conflictos civiles y armados.
- Atención de salud: el uso masivo de antibióticos por ejemplo podría ser una causa.
- Producción de alimentos: cambios en la cadena de suministro.
- Conducta humana: migraciones, comportamiento sexual, drogas.
- Cambios ambientales: cambios en el ecosistema del agua.
- Infraestructura de la salud pública: reducción de programas preventivos o inadecuada gestión en la vigilancia de indisposiciones transmisibles.
- Adaptación y cambio microbiano: mutaciones, microbios como cofactores de indisposiciones crónicas.

Cabe resaltar, que una indisposición emergente, de acuerdo con Castillo, *et al.*, (2011), es una enfermedad transmisible cuya incidencia en humanos se ha incrementado en los últimos 25 años o que amenaza con incrementarse en un futuro cercano.

Antes de pasar de forma directa a los mecanismos de transmisión que tiene una indisposición transmisible, vale la pena profundizar en conceptos que se mencionan en la definición de enfermedad transmisible.

Iniciando con “Reservorio”, en el marco contextual de indisposiciones transmisibles, este se define como el hábitat en el que crece un agente infeccioso, un reservorio, puede ser humano cuando el mecanismo de transmisión se da de persona a persona. Se dice que un reservorio es extrahumano, cuando la transmisión viene de otras fuentes que no son la interacción social por sí misma.

Vale la pena destacar, que una vez se identifica el reservorio de un agente infeccioso, es posible determinar qué tipo de medidas, son las necesarias para fomentar la disipación de un agente infeccioso sobre las distintas redes de interacción social de los seres humanos.

La OPS, en su módulo de principios de epidemiología para el control de enfermedades mencionan qué:

Otra dimensión importante por evaluar de las características de las indisposiciones transmisibles es: los períodos de incubación, latencia y transmisibilidad. Se define al período de incubación, como el tiempo que transcurre entre la exposición a un agente infeccioso y la aparición del primer síntoma. El período de latencia por su parte es el tiempo que pasa desde el inicio de la infección hasta que una persona se vuelve infecciosa,

el período de transmisibilidad es el intervalo de tiempo en el que el agente infeccioso puede transmitirse de forma indirecta o directa otras personas. (OPS, 2011, p. 21)

Estadísticamente, las variables mencionadas anteriormente, pueden modelarse con una distribución exponencial o una distribución geométrica, que es la distribución de una va. continua para modelar tiempos de espera.

Tomando en cuenta, que es una enfermedad transmisible, sus características, los factores que pueden hacer que una enfermedad transmisible pueda emerger en un grupo de personas, se procede a detallar cuales son los mecanismos de transmisión que puede tener un agente.

Para Castillo, *et al.*, (2011) el modo de transmisión es “la forma en que el agente infeccioso se transmite del reservorio al huésped” (p.21).

2.2.2.1. Transmisión directa

De forma intuitiva, se denomina transmisión de persona a persona, esta se puede dar por los distintos tipos de interacciones sociales que se pueden dar entre las personas. El rociado de gotillas derivado de estornudos, hablar, escupir, cantar, entre otros. es lo que puede derivar en este tipo de transmisión.

2.2.2.2. Transmisión indirecta

- Vehículos de transmisión: objetos o materiales contaminados
- Vectores de transmisión: insectos o portadores vivos que transportan al agente infeccioso.
- A través del aire

Los mecanismos de transmisión de los agentes infecciosos pueden darse por distintas puertas de eliminación o salida del agente, las que más destacan Castillo, *et al.*, (2011) son: “Respiratorias, genitourinarias, digestivas, piel, placentarias” (p. 22).

La siguiente sección del marco teórico, describirá temas puntuales de ecuaciones diferenciales, que son la herramienta para describir de forma determinista la dinámica de variables, estas son base en los modelos epidemiológicos.

2.3. Ecuaciones diferenciales

Una ecuación diferencial ordinaria es una ecuación funcional que toma en cuenta una o más derivadas y', y'', y''' , entre otros. de una dependencia desconocida del tiempo $f(t)$, que es obviamente diferenciable.

El orden de una E.D. se puede determinar por el número de diferenciaciones que tiene la variable que se está analizando, así una E.D., cuya ecuación funcional tenga solamente la primera derivada será una E.D. de orden 1.

Un teorema importante en las ecuaciones diferenciales es que: “La solución general de una E.D. de orden n es una dependencia del tiempo que envuelve exactamente n constantes arbitrarias. (Gandolfo, 2009, p.52)

En el marco teórico que se desenvuelve la presente investigación, se requiere el entendimiento de ecuaciones diferenciales de primer orden y sistemas de ecuaciones diferenciales simultaneas.

2.3.1. Ecuaciones diferenciales de primer orden

Una E.D. de primer orden se caracteriza de la siguiente forma:

$$a_0 y' + a_1 y = g(t) \quad (\text{Ec. 16})$$

Donde $g(t)$, a_0 y a_1 son conocidas. En el caso en el que el componente de y sea 0, entonces se tiene que:

$$y' = \frac{g(t)}{a_0} \quad y(t) = \frac{1}{a_0} \int g(t) dt + C \quad (\text{Ec. 17})$$

En el caso anterior, la solución se puede encontrar con las reglas de integración tradicionales.

2.3.1.1. Ecuaciones homogéneas

En el caso en el que el componente de y sea diferente de 0, se puede iniciar el análisis de ecuaciones diferenciales asumiendo que $g(t)=0$.

Solución de una E.D. homogénea.

$$a_0 y' + a_1 y = 0 \quad (\text{Ec. 18})$$

$$y' + by = 0, \text{ donde } b = \frac{a_1}{a_0}$$

$$y' = -by$$

$$-b = \frac{y'}{y} = \frac{dy}{dt}$$

$$-b \int dt = \int \frac{dy}{y}$$

$$-bt + d = \ln(y) + c$$

$$-bt + k = \ln(y), \text{ donde } k \text{ es } c + d$$

$$y = e^{-bt} * e^k = Ae^{-bt} \text{ donde } e^k \text{ es } A$$

$$y(t) = Ae^{-bt}$$

Para encontrar A y b, es necesario tener condiciones adicionales, lo que es posible ver en la resolución de la E.D. anterior, es la solución de una E.D. es una familia de funciones, que se pueden hacer particulares, con condiciones iniciales.

En el caso en el que $g(t)$ no sea 0, se está ante el caso es una E.D. no homogénea, la resolución de ecuaciones diferenciales de primer orden no homogéneas implica la resolución de ecuaciones diferenciales en dos etapas, la primera es la resolución de la parte homogénea y luego de la parte no homogénea.

2.3.1.2. Ecuaciones no homogéneas

E.D. no homogénea $g(t)$

$$y(t) = Ae^{-bt}$$

De tal forma que la resolución de la parte no homogénea viene dada por:

$$y(t) = e^{-\int p(t)dt} \int e^{-\int p(t)dt} * g(t)dt$$

$$y(t) = Ae^{-bt} \int Ae^{-bt} * g(t)dt$$

Asumiendo que $g(t)$ es una constante:

$$y(t) = Ae^{-bt} \int Ae^{-bt} * C dt = A^2 C \int e^{-bt} dt$$

Siguiendo la ecuación anterior, se da que la solución de una E.D. no homogénea viene dada por:

$$y(t) = Ae^{-bt} + A^2 C \int e^{-bt} dt$$

Habiendo descrito de forma general la resolución de ecuaciones diferenciales de primer orden homogéneas y no homogéneas, se procede a describir los sistemas simultáneos de ecuaciones diferenciales, que son las herramientas en las que están fundamentados los modelos epidemiológicos actuales.

2.3.2. Sistemas de ecuaciones diferenciales simultáneas

Un sistema de ecuaciones diferenciales simultáneas está hecho de dos o más ecuaciones diferenciales en donde dos o más funciones desconocidas están envueltas, para que el sistema pueda ser resuelto, debe tener tantas ecuaciones como funciones desconocidas. (Gandolfo, 2009)

La forma más simple de un sistema de ecuaciones diferenciales de primer orden se muestra a continuación.

$$\begin{aligned} y'(t) &= a_{11}y(t) + a_{12}z(t) + g_1(t) & (\text{Ec. 19}) \\ z'(t) &= a_{21}y(t) + a_{22}z(t) + g_2(t) \end{aligned}$$

Nótese, que como todo sistema de ecuaciones este puede ser caracterizado como matrices, las funciones $g(t)$ y los parámetros a , son también constantes conocidas.

Los sistemas de ecuaciones diferenciales buscan caracterizar la dinámica de dos variables que coexisten e interactúan en un mismo espacio, para este caso, se analiza como varían las funciones en el tiempo.

La resolución de sistemas de ecuaciones implica en la reducción del sistema en una sola E.D. en la cual solo una dependencia desconocida aparece, esta reducción es solamente posible mediante transformaciones apropiadas.

Para el caso más simple, la familia de funciones que describe la dinámica entre $y(t)$ y $z(t)$, viene dado por:

$$y(t) = (A_1 + A_2 t)e^{\lambda t} \tag{Ec. 20}$$

$$z(t) = e^{\lambda t} \left[\frac{a_{11}(A_1 + \theta A_2)}{a_{12}} \cos \theta t + \frac{a_{11}(A_2 - \theta A_1)}{a_{12}} \sin \theta t \right]$$

Existe más de una metodología para la resolución de sistemas de ecuaciones diferenciales, en esta sección lo que se busca es dar una breve introducción que permita entender cuál es la aplicación y como es el aporte de estos en los modelos epidemiológicos, que son el enfoque central de este trabajo de investigación.

Adicional al esquema de solución anterior, existen otras metodologías para la resolución de sistemas de ecuaciones diferenciales, entre ellos se pueden utilizar raíces reales desiguales, raíces reales iguales, raíces complejas. Estos esquemas de solución se basan en la obtención de valores λ ; en donde

el determinante de la matriz que define el sistema de ecuaciones diferenciales es igual a cero en donde $\lambda = \lambda_1$ y $\lambda = \lambda_2$.

La solución anterior da lugar a dos soluciones, α_1 y α_2 que se pueden caracterizar con las siguientes ecuaciones.

$$0 = (a_{11} - \lambda)\alpha_1 + a_{12}\alpha_2 \quad (\text{Ec. 21})$$

2.4. Modelos epidemiológicos

Los modelos epidemiológicos son utilizados para entender la dinámica de indisposiciones infecciosas, las ecuaciones diferenciales son la herramienta matemática que sirve para describir la dinámica de variables.

“El desarrollo de modelos se enfocan básicamente en dos puntos, como una herramienta predictiva o como una manera o como una manera de describir y ayudar a entender el proceso epidemiológico fundamental” (Ramos, Ramalho, 2019, p.27).

De acuerdo con estos autores, los modelos epidemiológicos pueden ser clasificados de múltiples maneras, entre estos se destacan lineales, no lineales, dinámicos, estáticos, determinísticos. Adicionalmente, existen distintas formas de modelar, entre ellos se pueden destacar los modelos compartimientos, simulación basada en agentes, modelos de redes y modelos estáticos.

En el presente trabajo de investigación se estarán utilizando modelos de compartimientos, que se fundamentan en sistemas de ecuaciones diferenciales para describir la dinámica de cada uno de los compartimientos. Se profundizará en los modelos de compartimientos que han sido mayormente

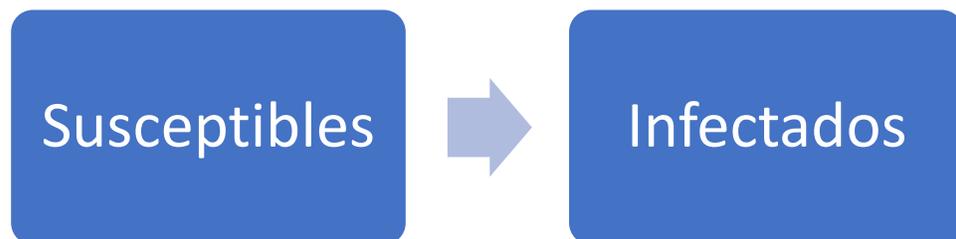
usados, la descripción irá desde el modelo más simple hasta el modelo más complejo.

2.4.1. Modelo SI

Este modelo se divide en dos compartimentos, susceptibles (S) e infectados (I), el modelo se fundamenta en el supuesto que todos los individuos son susceptibles y que una vez existe una transición al estado infectado, los individuos permanecen en este estado durante el resto del tiempo.

El siguiente gráfico muestra el proceso epidemiológico que se muestra en el modelo.

Figura 3. Proceso de transición del modelo SI



Fuente: Ramos, (2019). *Mathematical Models in Epidemiology: Simulating Chagas Disease Transmission and Evaluating the Control Measure*.

El modelo está matemáticamente descrito por el siguiente sistema de ecuaciones diferenciales ordinarias:

$$\frac{dS}{dt} = -\beta SI, \quad \frac{dI}{dt} = \beta SI \quad (\text{Ec. 22})$$

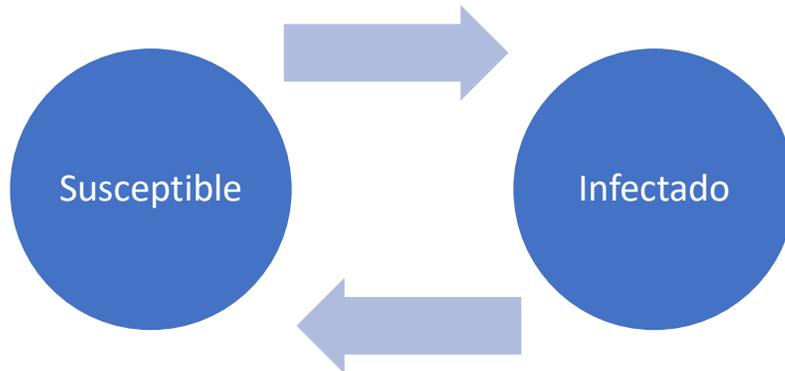
Se puede observar que lo que pierde el bloque de los susceptibles, lo gana el bloque de los infectados, el factor βI es conocido también como la fuerza de la infección, que es la tasa a la que los susceptibles se vuelven infectados por unidad de tiempo.

En un modelo SI, la dinámica es que la cantidad de susceptibles se reduce con el tiempo y llega a ser 0, mientras la cantidad de infectados aumenta con el tiempo, y el bloque de los infectados llega a abarcar toda la población.

2.4.2. Modelo SIS

Este modelo relaja el supuesto de que las personas susceptibles una vez infectadas, se quedan infectadas por el resto del tiempo, este supuesto relajado, implica que las personas que están infectadas pueden pasar de nuevo a ser susceptibles y luego podrían pasar nuevamente al estado de infectado.

Figura 4. Transición modelada en el modelo SIS



Fuente: Ramos, (2019) *Mathematical Models in Epidemiology: Simulating Chagas Disease Transmission and Evaluating the Control Measure*.

La principal implicación de haber relajado el supuesto ya mencionado es que ya no solo se tiene un factor βI que gobierna como los susceptibles pasan a infectados, también se tiene un factor αI que indica la dinámica en la que los infectados se vuelven nuevamente individuos susceptibles.

El sistema de ecuaciones diferenciales que modela este proceso epidemiológico es:

$$\frac{dS}{dt} = -\beta SI + \alpha I, \quad \frac{dI}{dt} = \beta SI - \alpha I \quad (\text{Ec. 23})$$

De forma intuitiva se entiende que la magnitud de los factores alfa y beta son las que indican que grupo será el que tiene más individuos en la dinámica que se modela.

2.4.3. Modelo SIR

Este modelo agrega una extensión más, se dice que aquellas personas que fueron infectadas luego adquieren inmunidad, esta inmunidad es para el resto del tiempo, la R tiene dos significados: “*Recovered*” o “*Removed*”, la primera implica que las personas en efecto adquirieron una inmunidad y por tanto no pueden ser susceptibles, mientras la segunda significa que fueron removidos, es decir, son individuos que no pueden pasar nuevamente al estado de susceptibles porque murieron durante el proceso epidemiológico.

A continuación, se muestra el diagrama de transición del proceso epidemiológico.

Figura 5. Transición en el modelo SIR



Fuente: Ramos, (2019). *Mathematical Models in Epidemiology: Simulating Chagas Disease Transmission and Evaluating the Control Measure.*

En este modelo, los individuos infectados tienen una probabilidad dada de morir o de ganar inmunidad que es homogénea, para toda la población, es decir, que no existe diferencias entre la población que hacen que unos tengan mayor o menor propensión a morir dado un contagio.

$$\frac{dS}{dt} = -\beta SI \quad \frac{dI}{dt} = \beta SI - \alpha I, \quad \frac{dR}{dt} = \alpha I \quad (\text{Ec. 24})$$

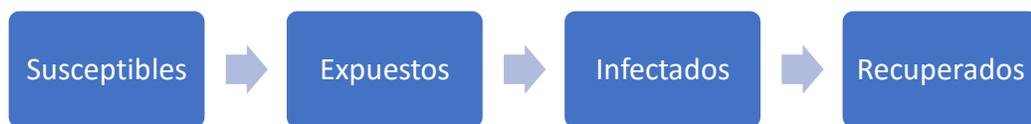
El sistema de ecuaciones muestra como los susceptibles pasan a una tasa beta al conglomerado de los infectados, y como los infectados pasan a una tasa alfa al conglomerado de los recuperados o removidos del sistema. Se puede observar nuevamente que, en función de la magnitud de beta y alfa, es que será la cantidad de infectados y de recuperados que habrá en el sistema.

2.4.4. Modelo SEIR

Este modelo es una extensión del modelo SIR, en donde ahora se toma en cuenta otro conglomerado de individuos, el de los expuestos, que son individuos que están infectados, pero que todavía no pueden infectar a los demás.

A continuación, se muestra el diagrama de transición del proceso epidemiológico.

Figura 6. Transición en el modelo SEIR



Fuente: Ramos, (2019). *Mathematical Models in Epidemiology: Simulating Chagas Disease Transmission and Evaluating the Control Measure*.

$$\frac{dS}{dt} = -\beta SI, \quad \frac{dE}{dt} = \beta SI - \alpha E, \quad \frac{dI}{dt} = \alpha E - \gamma I, \quad \frac{dR}{dt} = \gamma I \quad (\text{Ec. 25})$$

El nuevo parámetro introducido en este sistema de ecuaciones diferenciales es el parámetro gamma. Este parámetro indica la tasa a la cual los individuos infectados pasan al estado de recuperado o removido del sistema.

Por su parte el parámetro alfa, ahora toma en cuenta como los individuos susceptibles pasan al conglomerado de individuos expuestos.

2.5. Aspectos importantes de estadística paramétrica

Para Geisser y Wesley (2006) la estadística paramétrica es una rama de la estadística que parte del supuesto, que las muestras de datos que se toma (asumiendo que es representativa de la población) proviene de una población que tiene un conjunto de parámetros fijos.

En el presente estudio la estadística paramétrica no solo sirve como fundamento de la distribución del residuo de las series de tiempo estimadas, también sirve, para entender los parámetros de contagio, recuperación y fallecimiento que guiaron a la dinámica de la pandemia ocasionada por el COVID-19.

A continuación, se exponen las distribuciones abordadas para la estimación de los parámetros ya mencionados anteriormente.

2.5.1. Variables aleatorias discretas y sus distribuciones

Se inicia la exposición de este tema abordando la definición de una v.a., Wackerly, *et al.*, (2010). Definen a una v.a. como una dependencia de valor real

cuyo dominio se encuentra sobre un espacio muestral. Dada la definición anterior, una v.a. se puede utilizar para identificar eventos de interés que sean numéricos sobre un experimento. Un evento de interés simple se podría ser la cantidad de veces que se obtiene cara en el lanzamiento de una moneda después de n lanzamientos.

“Se dice que una v.a. es discreta, si puede tomar sólo un número finito o contablemente infinito de valores distintos” (Wackerly, Mendenhall y Scheaffer 2010, p.125).

Para ilustrar el concepto de v.a. discreta, se partirá de un ejemplo muy simple, el del lanzamiento de un dado. Se dice que la v.a. discreta puede ser cualquiera de los 6 valores que puede tener un dado, para denotar a cualquiera de esos 6 valores se define a Y como variable. Una vez se sabe cuál es el valor que se obtuvo del lanzamiento del dado se dice que la v.a. Y , toma el valor de y .

Siguiendo la notación que se presentó anteriormente, se puede decir que la expresión $(Y=y)$ se puede leer como el conjunto de datos en los que la v.a. Y , asigna el valor y . Dada la notación, se puede introducir entonces al conjunto de probabilidad, y es que, derivado de que existe un espacio muestra y en algunos puntos la v.a. toma el valor y , se puede decir que con cierta probabilidad la v.a. Y , toma el valor de y .

“La probabilidad de que, Y tome el valor y , $P(Y=y)$, se define como la suma de las probabilidades de todos los puntos muestrales en S a los que se les asigna el valor y ” (Wackerly, *et al.*, 2010, p.173).

Existen puntos muestrales que serán más frecuentes que otros, de manera intuitiva, se entiende que estos puntos muestrales, son más probables que otros y es aquí, en donde entra el concepto de D.P.

Una D.P. es una función que se define sobre el espacio muestral s y asigna una probabilidad de acuerdo con el valor que pueda tomar un punto sobre el espacio muestral S .

Una v.a. discreta se puede distribuir de distintas formas, esto es de acuerdo con la naturaleza del evento que se quiere estudiar. En la presente investigación, el principal enfoque es entender que los casos de COVID-19 es un conteo que se da en el tiempo. Una implicación de esto es que la D.P. de Poisson es una buena aproximación para entender a los parámetros que guían la dinámica de contagios, recuperación y muertes del COVID-19 en Guatemala.

2.5.1.1. Distribución de Poisson

Este tipo de distribución, como fue ya mencionado anteriormente es utilizado para entender la cantidad de eventos que se da en un intervalo de tiempo específico. Esta distribución es una consecuencia del análisis en el límite de la distribución binomial, haciendo que λ se igual a np como se muestra a continuación.

$$\begin{aligned} \lim_{n \rightarrow \infty} \binom{n}{y} p^y (1-p)^{n-y} &= \lim_{n \rightarrow \infty} \frac{n(n-1)\dots(n-y+1)}{y!} \left(\frac{\lambda}{n}\right)^y \left(1 - \frac{\lambda}{n}\right)^{n-y} \\ &= \lim_{n \rightarrow \infty} \frac{\lambda^y}{y!} \left(1 - \frac{\lambda}{n}\right)^n \frac{n(n-1)\dots(n-y+1)}{n^y} \left(1 - \frac{\lambda}{n}\right)^{-y} \\ &= \frac{\lambda^y}{y!} \lim_{n \rightarrow \infty} \left(1 - \frac{\lambda}{n}\right)^n \left(1 - \frac{\lambda}{n}\right)^{-y} \left(1 - \frac{1}{n}\right) \left(1 - \frac{2}{n}\right) \dots \left(1 - \frac{y-1}{n}\right) \\ &\qquad \lim_{n \rightarrow \infty} \left(1 - \frac{\lambda}{n}\right)^n = e^{-\lambda} \end{aligned}$$

Dado que los otros límites son 1, se tiene por tanto que la probabilidad de una v.a. y que se distribuye de forma Poisson es.

$$p(y) = \frac{\lambda^y}{y!} e^{-\lambda} \text{ Ec. (26)}$$

La D.P. es frecuente para modelar el conteo de eventos en un espacio temporal. Wackerly *et al.*, (2010) comenta que una forma común de encontrar una v.a. que se distribuye de forma Poisson por medio de un proceso Poisson. Un proceso Poisson es tal que lambda (λ) es el número medio de sucesos por unidad, en este caso es unidad de tiempo.

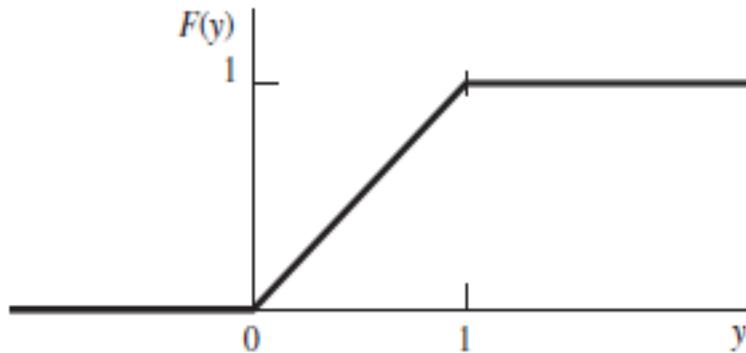
2.5.2. Distribuciones de probabilidad discreta

La presente subsección es una continuación del tema de V.A. discretas y sus distribuciones de probabilidad, resulta que no todo en el mundo se puede medir como un número discreto. También existen eventos que requieren la utilización de números reales y no enteros.

El tipo de distribuciones que se realiza con números reales se apoya de las V.A. continuas, para iniciar con este tema, es necesario exponer a la función de distribución acumulativa asociada a una v.a..

La función de distribución acumulativa se define sobre el espacio muestral, y mapea la proporción de casos que se observan conforme aumenta el valor de la variable sobre el espacio muestral. La siguiente figura ilustra mejor, lo que se acaba de decir.

Figura 7. **Función de acumulación de una D.P. continua**



Fuente: Wackerly, Mendenhall y Scheaffer (2010). *Estadística Matemática con Aplicaciones*.

Lo que se observa en la anterior figura, es un intervalo entre 0 y 1, en el dominio o espacio muestral, y en el rango, se obtiene la probabilidad acumulada. Se tiene por ejemplo que el 100 % de los datos está por debajo del valor de 1, mientras el 0 % de los datos está por debajo del valor de 0.

La derivada de una dependencia de acumulación da lugar a la función de densidad, que es la función que en el dominio mapea al espacio muestral de forma ordenada y en el rango mapea la probabilidad de ocurrencia del evento. Vale la pena destacar que en una dependencia de densidad cuya v.a. es continua, la probabilidad de ocurrencia de un evento puntual es 0. Esto es porque el dominio de la función se encuentra en todo el intervalo de los reales.

2.5.2.1. D.P. Gamma

Otro tema importante para el presente estudio es la D.P. Gamma, Wackerly, *et al.*, (2010) inicia la discusión de esta distribución comentando que

existen V.A. que son siempre positivas y que tienden a tener un sesgo a la derecha, es decir que casi toda el área bajo la curva de la función de densidad tiende a acumularse cerca del origen. Lo anterior implica que la función de acumulación de este tipo de distribuciones tiende a crecer muy rápidamente al inicio, pero se estabiliza también así conforme se avanza en el dominio de la función.

La discusión anterior se genera, porque el tiempo que se da entre casos de COVID-19 tiende a ser una distribución Gamma, si se es menos riguroso, se puede modelar como una función exponencial, que no es más que un caso particular de este tipo de funciones.

Se dice que una v.a. se distribuye de forma gamma si y solo si la función de densidad de Y es:

$$\begin{cases} \frac{y^{\alpha-1}e^{-y/\beta}}{\beta^\alpha\Gamma(\alpha)}, & 0 \leq y < \infty \\ 0, & \text{en cualquier otro punto} \end{cases}$$

donde

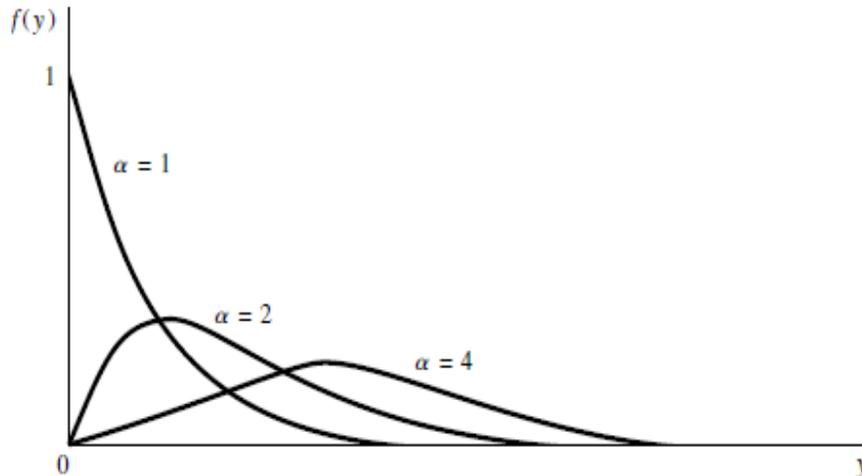
Ec. (27)

$$\Gamma(\alpha) = \int_0^\infty y^{\alpha-1}e^{-y}dy$$

$\Gamma(\alpha)$ es conocido como la función gamma, el parámetro α se conoce como parámetro de forma. El parámetro β es conocido como parámetro de escala, esto porque multiplicar una v.a. por una constante, produce una v.a. que se distribuye de la misma forma, es decir con el mismo valor de α , pero con distinto valor de β .

La siguiente figura ilustra la distribución que se acaba de describir, con distintos parámetros de alfa.

Figura 8. D.G. Gamma



Fuente: Wackerly, Mendenhall y Scheaffer (2010). *Estadística Matemática con Aplicaciones*.

2.5.3. Coeficiente de correlación

En esta investigación, se trabaja con V.A. continuas, por tanto, para la correlación se utilizará el C.C. de Pearson. Lo que se busca es entender el nivel de asociación lineal que existe entre la variable de casos positivos de COVID-19 y el índice de actividad económica (IMAE).

La siguiente ecuación muestra cómo se mide la correlación entre dos V.A.

$$\rho = \frac{Cov_{Casos-IMAE}}{\sigma_{Casos}\sigma_{IMAE}} \quad \text{Ec. (28)}$$

3. PRESENTACIÓN DE RESULTADOS

A continuación, se exponen los resultados de la investigación.

3.1. Estimación de los parámetros de transmisión, recuperación e incubación con series de tiempo y estadística paramétrica en dos escenarios de confinamiento

La siguiente sección muestra los resultados del análisis de series temporales y estadística paramétrica para los dos escenarios de confinamiento propuestos en la investigación.

3.1.1. Primer escenario de confinamiento

El primer escenario de confinamiento a mostrar es el estricto, este para Guatemala abarcó el período de marzo 2020 a finales de julio 2020. Este período se caracteriza por el cese de actividades laborales y académicas, prohibición de reuniones, estrictos toques de queda, restricciones a la movilización interdepartamental y movilización en vehículo en función del último dígito de la placa.

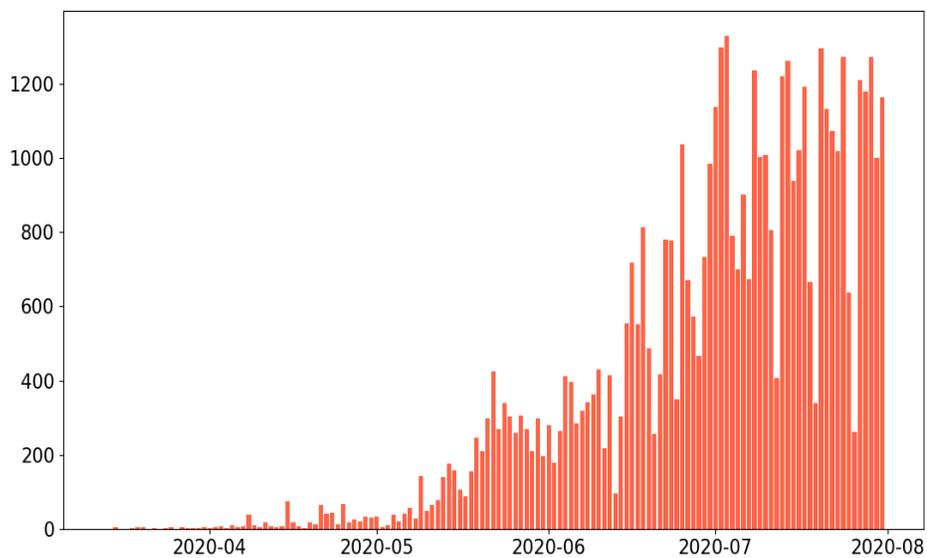
En esta investigación, el final de este período se da el 26 de julio de 2020, momento en el que se elimina la restricción de movilización vehicular en función de la placa y se reduce el horario del toque de queda.

La siguiente subsección pretende ilustrar el análisis paramétrico del primer escenario de confinamiento de la presente investigación.

Análisis paramétrico confinamiento estricto.

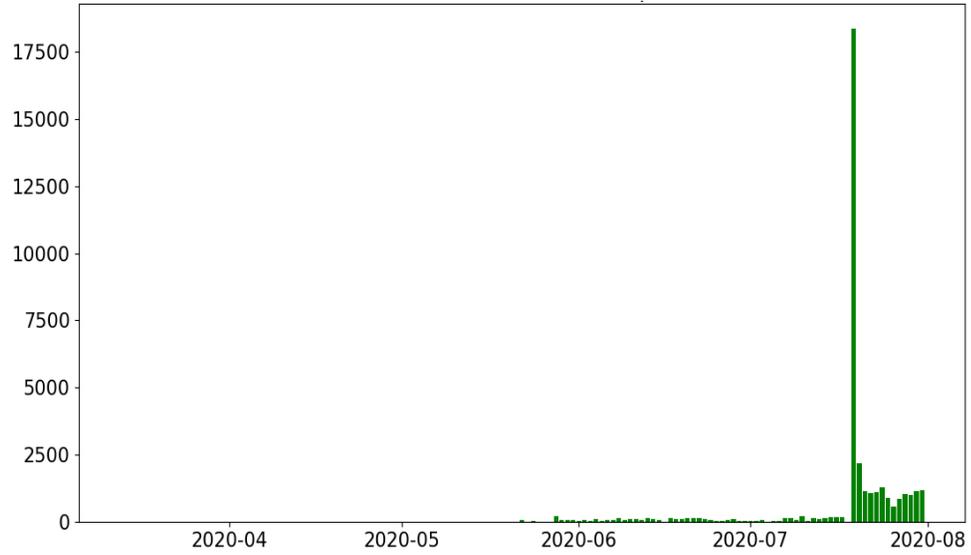
A continuación, se muestran los resultados de los casos confirmados, recuperados y fallecidos para este período.

Figura 9. **Distribución casos confirmados en confinamiento estricto**



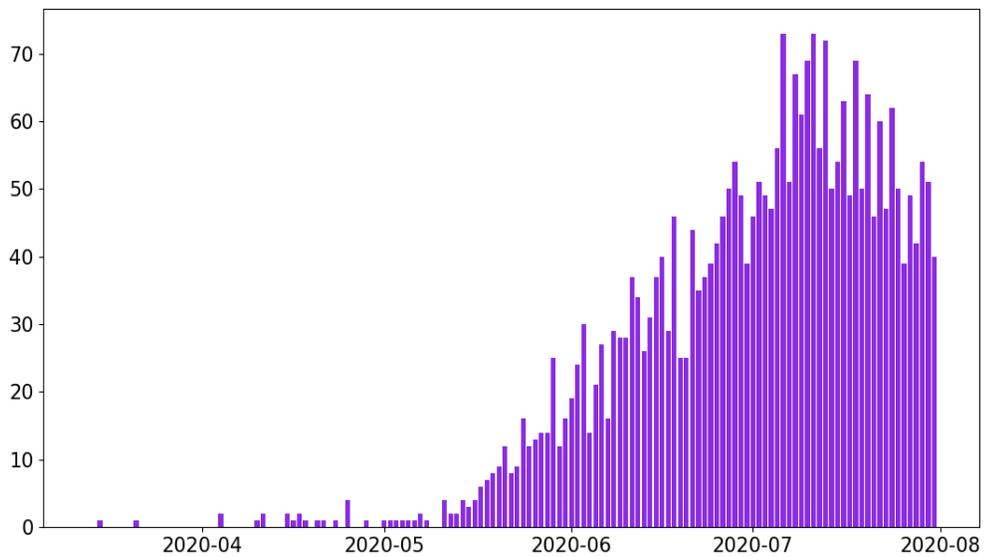
Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

Figura 10. **Distribución casos recuperados en confinamiento estricto**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

Figura 11. **Distribución casos de fallecidos confinamiento estricto**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

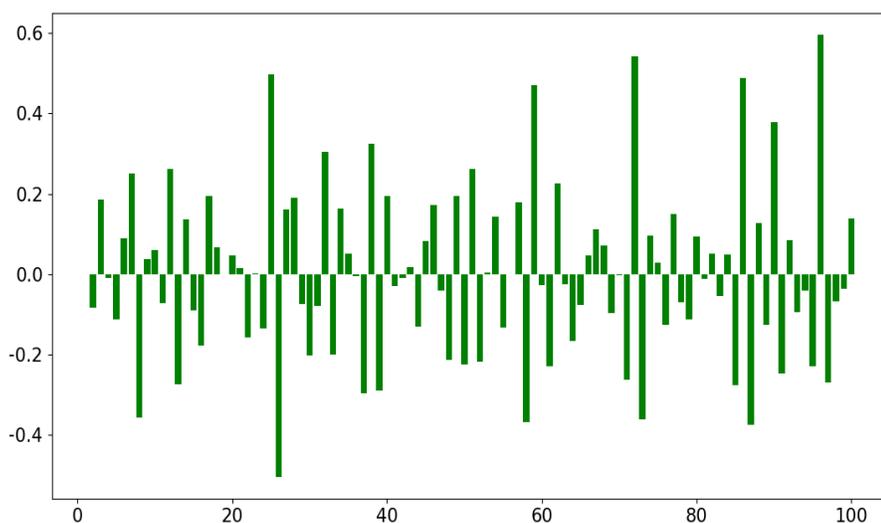
Correlación temporal con casos confirmados.

Parte del análisis paramétrico de esta fase de la pandemia incluye, entender cuál fue la incidencia en el tiempo de los casos confirmados sobre los casos recuperados y fallecidos. Lo que se muestra a continuación es una dependencia de correlación en el tiempo entre la variable de casos confirmados y casos recuperados. Así como la correlación temporal de los casos confirmados con los fallecidos.

Para poder generar esta gráfica se hizo necesario rezagar las observaciones de los casos confirmados y luego obtener la correlación de los rezagos de estos casos confirmados con los casos recuperados.

De la misma forma, se realizó el análisis para entender la correlación temporal entre los casos confirmados y los casos fallecidos.

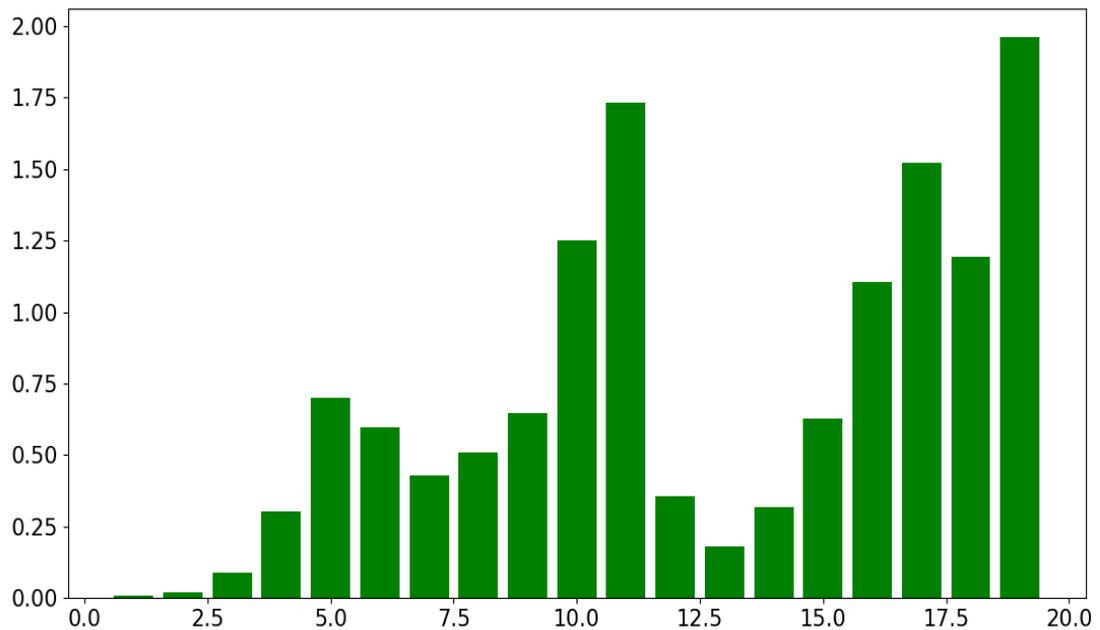
Figura 12. **Correlación temporal de los rezagos de casos confirmados con los casos recuperados**



Fuente: elaboración propia, usando Python.

Se observa que la recuperación de un caso confirmado tomaba en torno a 25 días luego de su confirmación. La prueba de Ljung-Box, fue utilizada para confirmar la significancia de esta correlación.

Figura 13. **Significancia de la correlación temporal entre recuperados y confirmados**

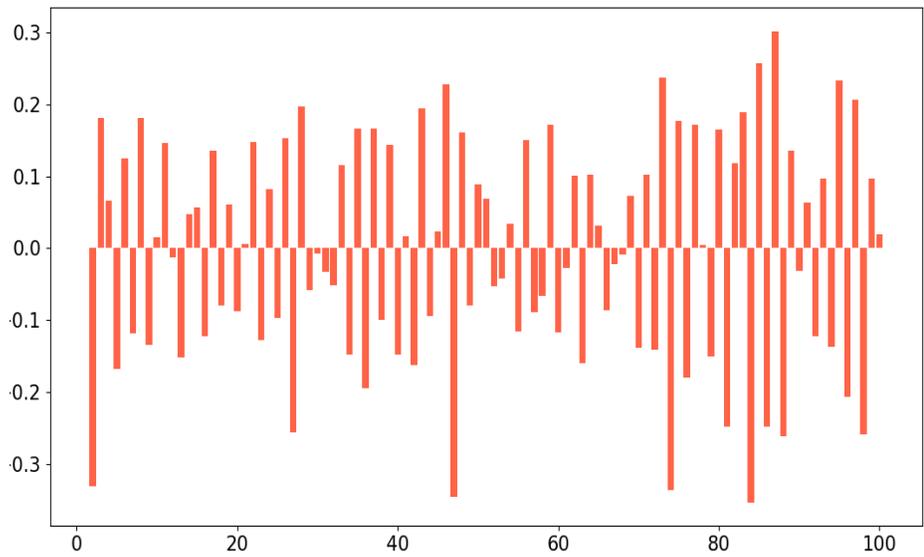


Fuente: elaboración propia, usando Python.

Los valores de probabilidad, en contraste con la significancia están en un orden de 10^{-5} , lo que implica que la correlación es estadísticamente significativa en el tiempo.

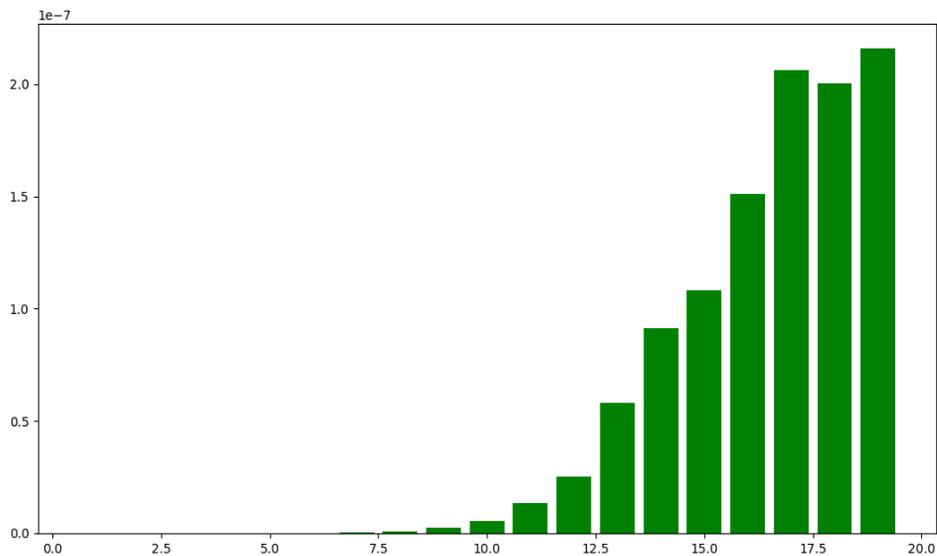
A continuación, se muestra la correlación temporal de casos fallecidos y confirmados para la primera etapa de la pandemia en Guatemala.

Figura 14. **Correlación temporal de los rezagos de casos confirmados con los casos fallecidos**



Fuente: elaboración propia, usando Python.

Figura 15. **Significancia de la correlación temporal entre recuperados y fallecidos**



Fuente: elaboración propia, usando Python.

Los valores de probabilidad, en contraste con la significancia están en un orden de 10^{-7} , lo que implica que la correlación es estadísticamente significativa en el tiempo.

A continuación, se muestra una tabla que resume las principales conclusiones acerca del análisis paramétrico de los casos confirmados, recuperados y fallecidos.

Tabla III. **Resumen análisis paramétrico para el confinamiento estricto**

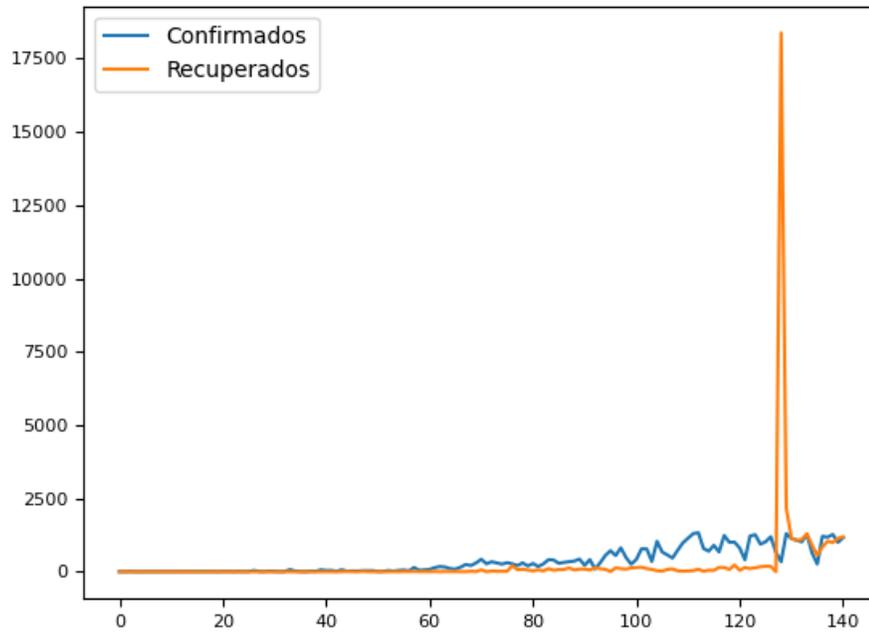
Días de rezago de Confirmados	Grupo de análisis	Correlación	Significativo
25 días	Recuperados	>0.5	Sí
9-18	Fallecidos	>0.15	Sí

Fuente: elaboración propia.

El análisis de S.T., como ya se abordó con anterioridad, está fundamentado principalmente en la ergodicidad del P.E., para poder generar un modelo estadísticamente correcto del fenómeno que se está analizando, es necesario antes realizar transformaciones sobre los datos, estas transformaciones se describirán a lo largo de esta sección.

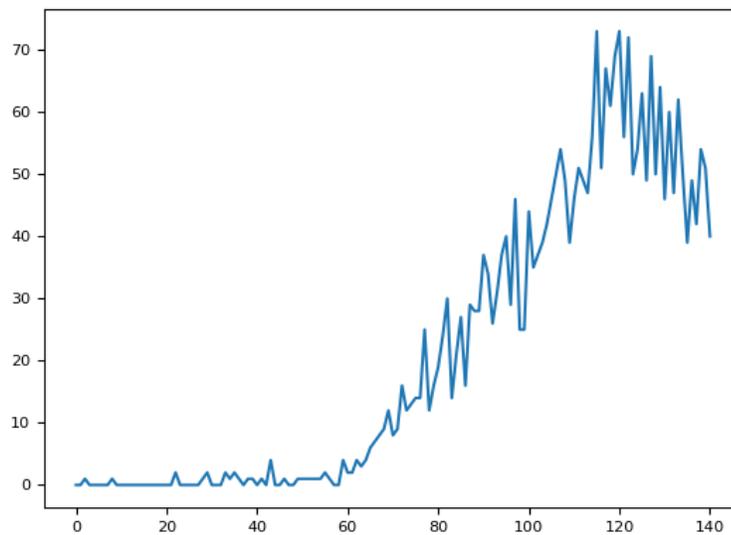
A continuación, se muestra la S.T. de los casos confirmados, recuperados y fallecidos, durante el inicio de la pandemia.

Figura 16. **Serie de tiempo de casos confirmados y recuperados**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

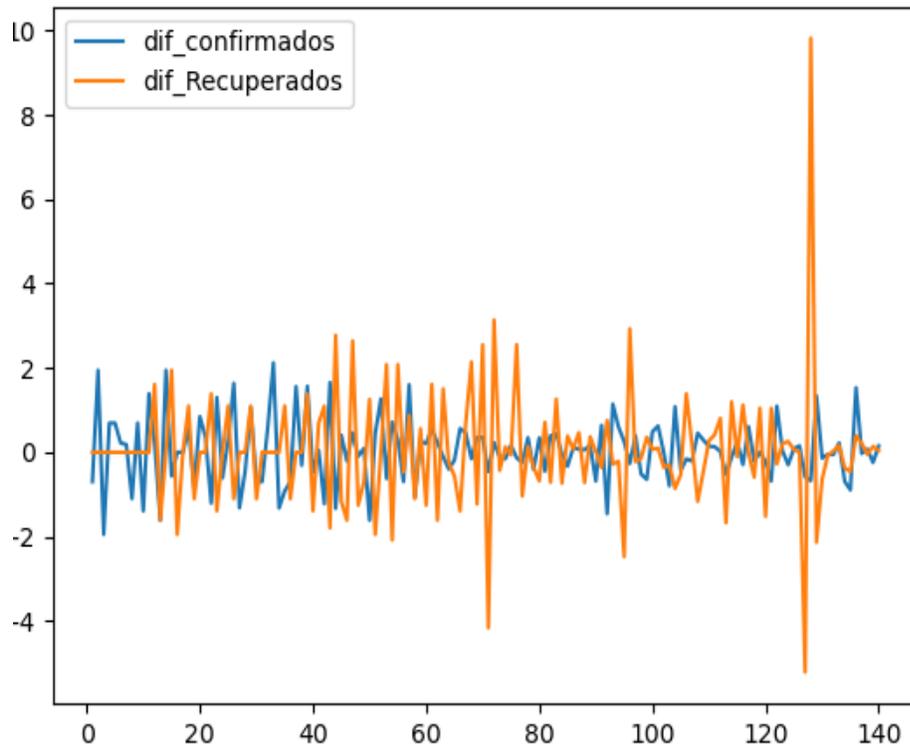
Figura 17. **S.T. de los casos fallecidos**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

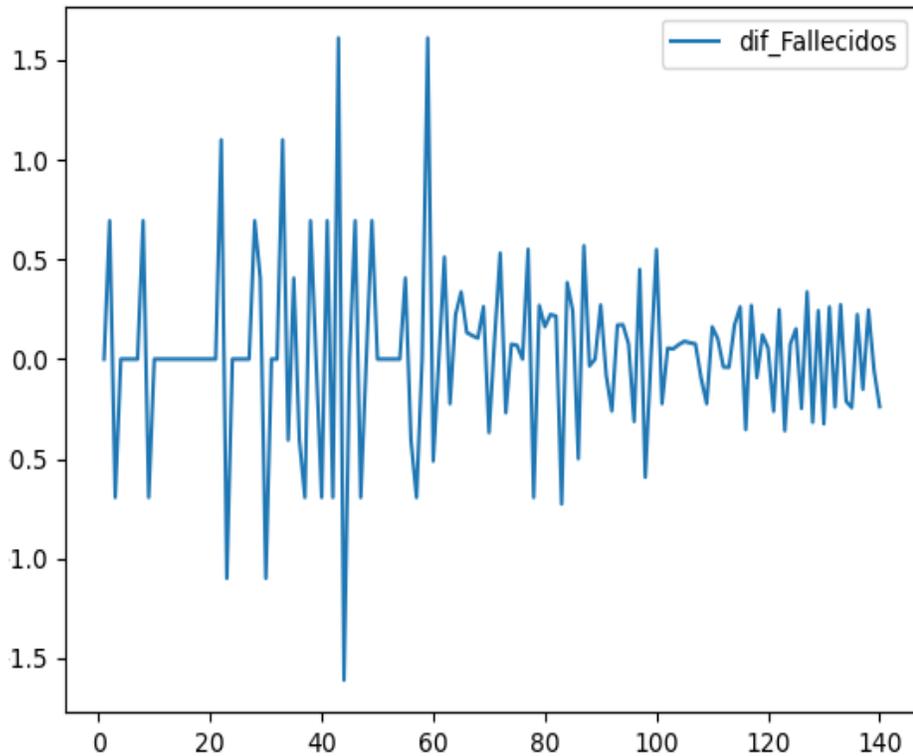
Las siguientes imágenes muestran las S.T. con las transformaciones antes mencionadas. Se puede observar estacionariedad en sentido débil de estas series, es decir que la media y la varianza son estadísticos que no presentan variación respecto del tiempo.

Figura 18. **S.T. transformadas de casos confirmados y recuperados**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

Figura 19. **S.T. transformada de casos fallecidos**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

Las S.T. anteriores antes de ser modeladas pasaron por la prueba de Dickey-Fuller aumentada, para rechazar que los procesos estocásticos tuvieran una raíz unitaria y, por tanto, estos no fueran estacionarios en sentido débil.

La siguiente tabla muestra los resultados de la prueba realizada a cada una de las S.T. ilustradas previamente.

Tabla IV. **Resultados prueba Dickey Fuller S.T. en confinamiento estricto**

S.T.	p-valor	Conclusión
confirmados	1.12×10^{-15}	Serie estacionaria en sentido débil
recuperados	5.27×10^{-16}	Serie estacionaria en sentido débil
fallecidos	2.20×10^{-16}	Serie estacionaria en sentido débil

Fuente: elaboración propia, usando Python.

La prueba anterior, permite por tanto pasar a la modelación de las S.T., lo que se describirá a continuación son los resultados de la modelación de la influencia de la transformación de los casos confirmados de COVID-19 en Guatemala sobre la transformación de los casos recuperados y fallecidos.

Tabla V. **S.T. de los casos confirmados sobre los casos recuperados en confinamiento estricto**

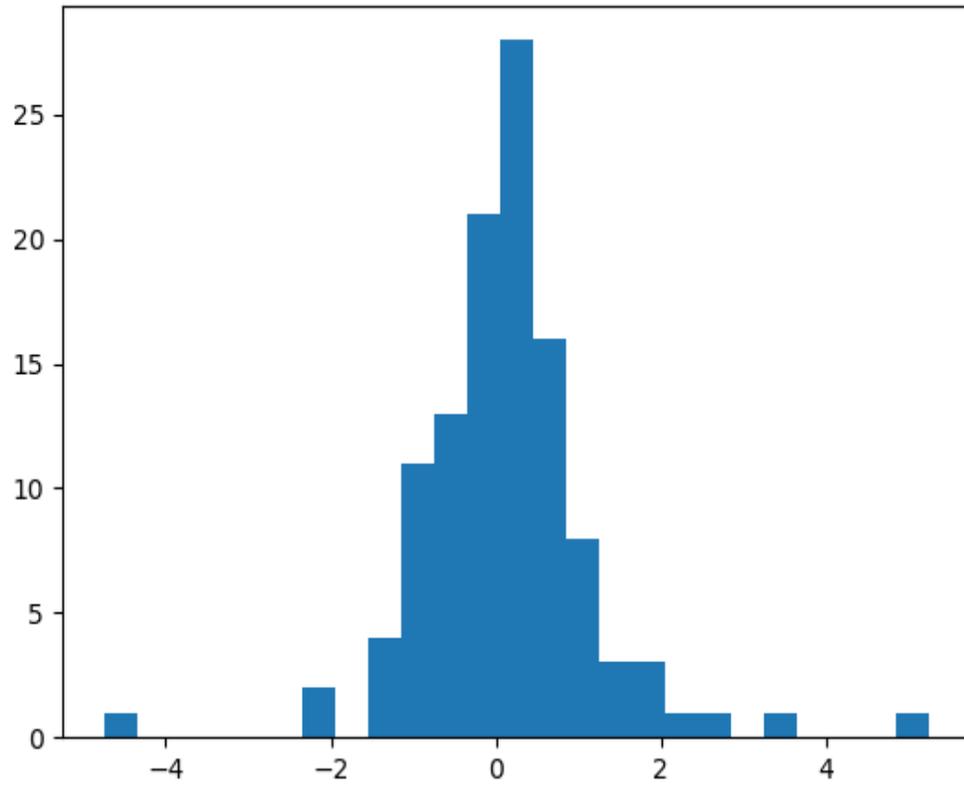
OLS Regression Results						
=====						
Dep. Variable:	dif_Recuperados	R-squared (uncentered):	0.515			
Model:	OLS	Adj. R-squared (uncentered):	0.488			
Method:	Least Squares	F-statistic:	19.14			
Date:	Fri, 10 Jun 2022	Prob (F-statistic):	4.38e-15			
Time:	20:02:48	Log-Likelihood:	-171.71			
No. Observations:	114	AIC:	355.4			
Df Residuals:	108	BIC:	371.8			
Df Model:	6					
Covariance Type:	nonrobust					
=====						
	coef	std err	t	P> t	[0.025	0.975]

Rezago Confirmados 16	0.2327	0.141	1.651	0.102	-0.047	0.512
Rezago Confirmados 21	0.2555	0.141	1.812	0.073	-0.024	0.535
Rezago Confirmados 24	0.4505	0.137	3.280	0.001	0.178	0.723
Rezago Recuperados 1	-0.7949	0.090	-8.875	0.000	-0.972	-0.617
Rezago Recuperados 2	-0.4631	0.108	-4.281	0.000	-0.678	-0.249
Rezago Recuperados 3	-0.2473	0.088	-2.804	0.006	-0.422	-0.072
=====						
Omnibus:	28.609	Durbin-Watson:	2.161			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	226.530			
Skew:	0.388	Prob(JB):	6.45e-50			
Kurtosis:	9.862	Cond. No.	3.09			
=====						

Fuente: elaboración propia, usando Python.

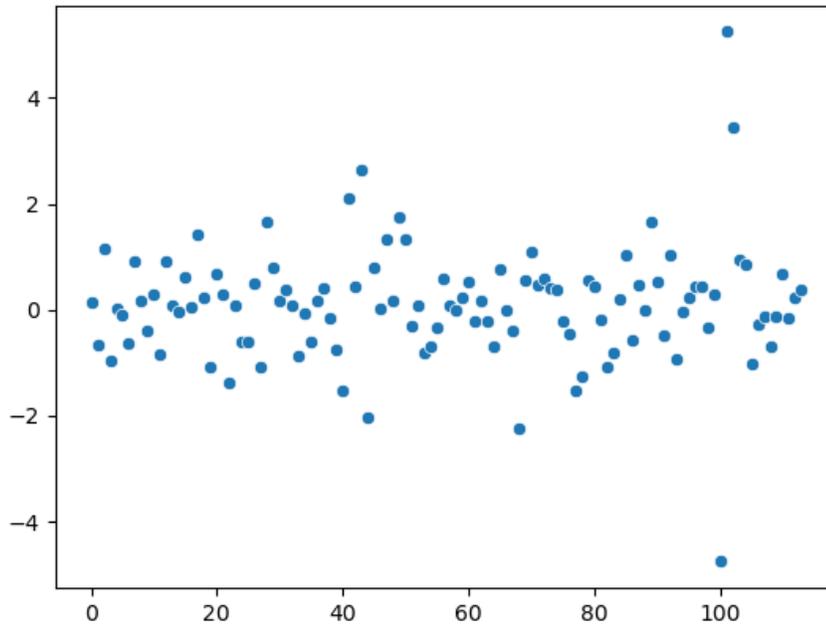
Las siguientes figuras, muestran tanto la distribución del residuo, así como la dispersión de este.

Figura 20. **Distribución de los residuos del modelo 1**



Fuente: elaboración propia, usando Python.

Figura 21. **Dispersión del residuo del modelo 1**



Fuente: elaboración propia, usando Python.

La siguiente tabla expone los resultados de las pruebas realizadas sobre el residuo.

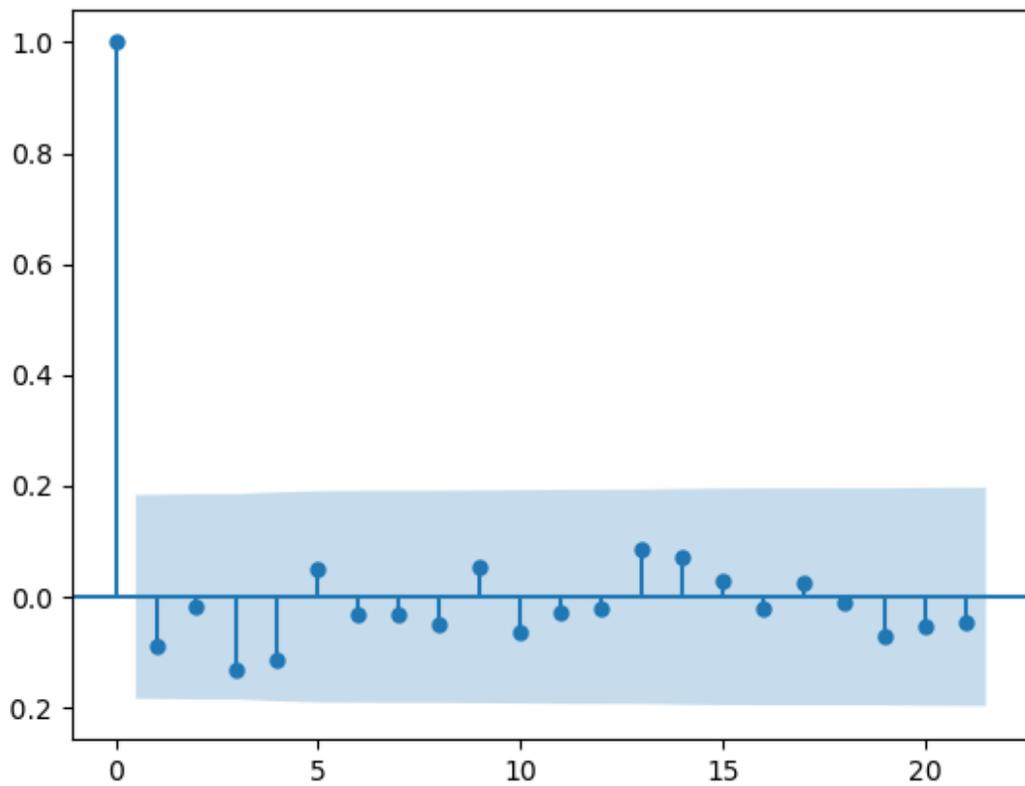
Tabla VI. **Resultados de las pruebas estadística del residuo del modelo 1**

Prueba	P-valor.	Conclusión
Shapiro	0.73	Distribución normal del residuo
Ljung-Box	>0.54 para los primeros 20 rezagos	No autocorrelación del residuo.

Fuente: elaboración propia.

Adicional a la prueba de Ljung-Box se muestra la función de correlación del residuo, para entender que tan bajos son los valores de correlación temporal del término del residuo del modelo.

Figura 22. **Función de auto correlación del término de residuo para el modelo 1**



Fuente: elaboración propia, usando Python.

El siguiente apartado expone los resultados del modelo de S.T. utilizado para analizar la influencia de la transformación de casos confirmados sobre la transformación de los casos fallecidos.

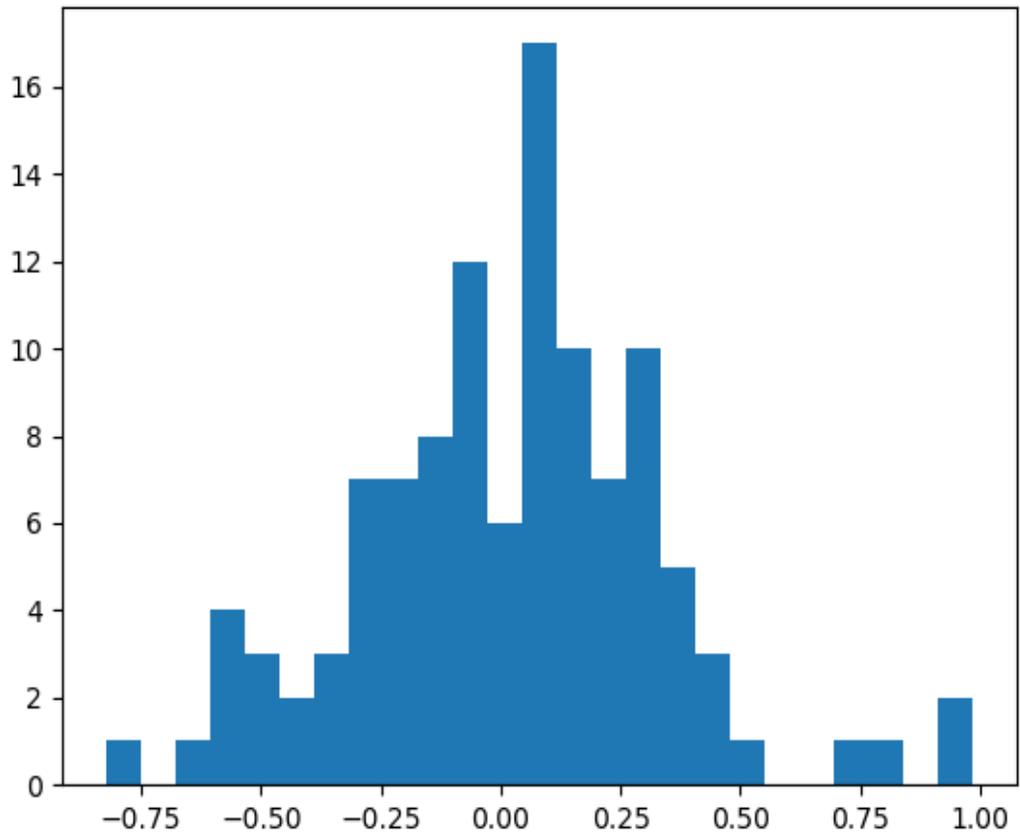
Tabla VII. **S.T. confirmados sobre fallecidos en confinamiento estricto**

OLS Regression Results						
Dep. Variable:	dif_Fallecidos	R-squared (uncentered):	0.499			
Model:	OLS	Adj. R-squared (uncentered):	0.460			
Method:	Least Squares	F-statistic:	12.84			
Date:	Sat, 11 Jun 2022	Prob (F-statistic):	1.13e-12			
Time:	07:40:50	Log-Likelihood:	-28.906			
No. Observations:	111	AIC:	73.81			
Df Residuals:	103	BIC:	95.49			
Df Model:	8					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
Rezago Confirmados 2	0.1703	0.050	3.405	0.001	0.071	0.269
Rezago Confirmados 7	0.1024	0.047	2.191	0.031	0.010	0.195
Rezago Confirmados 10	0.0770	0.044	1.740	0.085	-0.011	0.165
Rezago Confirmados 22	0.0865	0.042	2.058	0.042	0.003	0.170
Rezago Confirmados 29	0.1158	0.040	2.896	0.005	0.036	0.195
Rezago Fallecidos 1	-0.5135	0.082	-6.250	0.000	-0.677	-0.351
Rezago Fallecidos 2	-0.4163	0.081	-5.134	0.000	-0.577	-0.255
Rezago Fallecidos 10	0.2154	0.072	2.980	0.004	0.072	0.359
Omnibus:	3.709	Durbin-Watson:	1.989			
Prob(Omnibus):	0.157	Jarque-Bera (JB):	3.699			
Skew:	0.193	Prob(JB):	0.157			
Kurtosis:	3.807	Cond. No.	2.67			

Fuente: elaboración propia, usando Python.

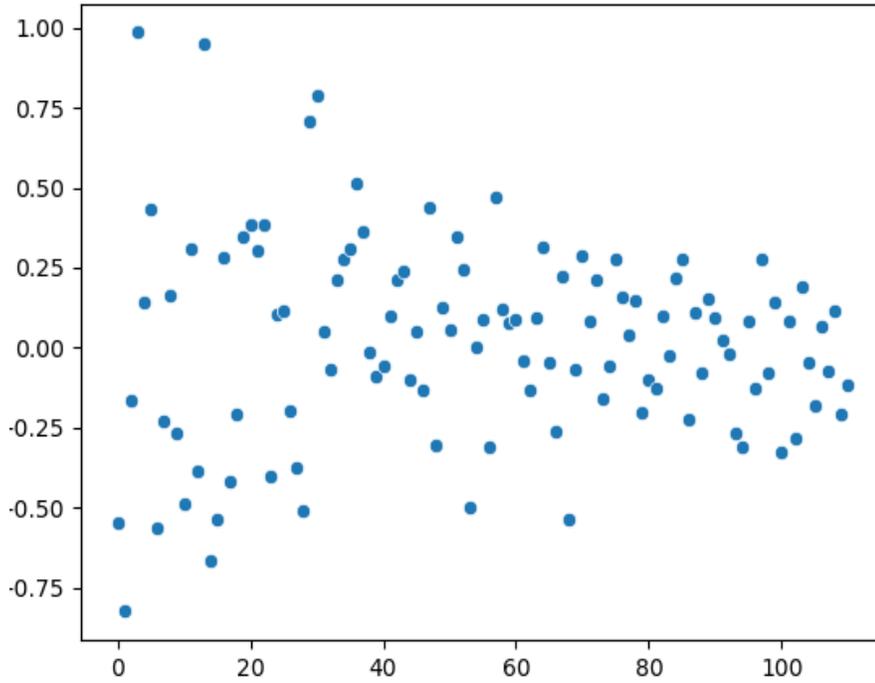
Las siguientes figuras muestran la distribución del término del residuo y su dispersión a lo largo del tiempo.

Figura 23. **Distribución del residuo del modelo 2**



Fuente: elaboración propia, usando Python.

Figura 24. **Dispersión del residuo del modelo 2**



Fuente: elaboración propia, usando Python.

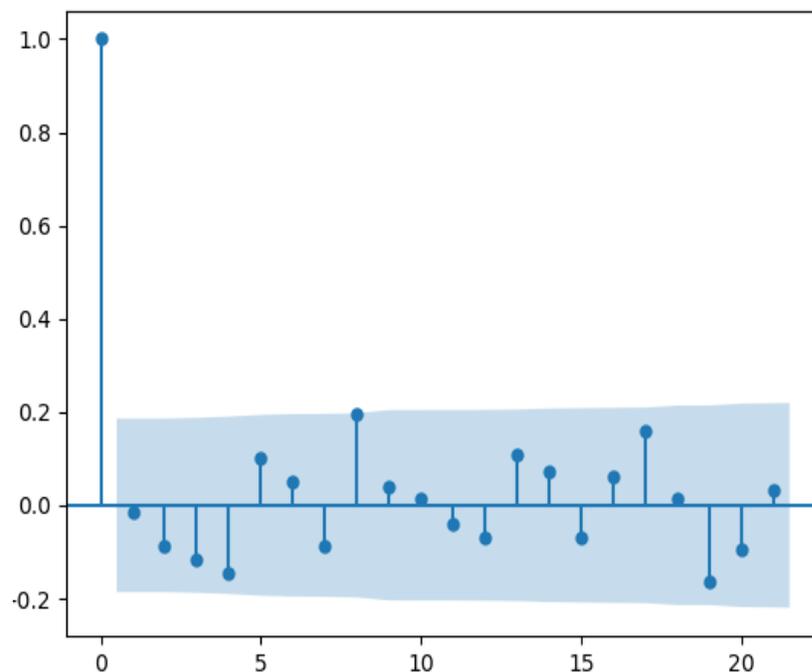
Tabla VIII. **Resultados de las pruebas estadísticas del residuo del modelo 2**

Prueba	P-valor.	Conclusión
Shapiro	0.13	Distribución normal del residuo
Ljung-Box	>0.35 para los primeros 20 rezagos	No autocorrelación del residuo.

Fuente: elaboración propia.

También se muestra la función de autocorrelación del residuo del modelo 2, que visualmente da otra perspectiva acerca de la no autocorrelación del término del residuo.

Figura 25. **Función de autocorrelación del término de residuo para el modelo 2**



Fuente: elaboración propia, usando Python.

La siguiente tabla expone un resumen de todos los parámetros encontrados en esta sección que correspondió al análisis de la dinámica de la pandemia en Guatemala mientras hubo confinamiento estricto.

Tabla IX. **Resumen de parámetros que guiaron el proceso epidémico en confinamiento estricto**

Análisis	Parámetro	Tiempo de influencia
Paramétrico	Recuperación	25 días después de confirmado el caso.
Paramétrico	Defunción	9 – 18 días después de confirmado el caso.
Series de tiempo	Recuperación	16 – 24 días después de confirmado el caso.
Series de tiempo	Defunción	2 – 29 días después de confirmado el caso.

Fuente: elaboración propia.

3.1.2. Segundo escenario de confinamiento

El segundo escenario de confinamiento se da de principios de junio de 2021 a finales de diciembre de 2021, este período se caracteriza por que inicia la masificación de la vacunación en Guatemala, ya no existe ninguna restricción a la locomoción, en términos generales la sociedad tiene una menor percepción del riesgo que implicaba el virus y la actividad económica regresa a niveles anteriores a los de la pandemia.

Adicional a lo anterior, también se destaca que existía una mayor organización por parte del estado para el reporte de casos confirmados, fallecidos y recuperados, esto derivado a que la metodología de medir casos recuperados había sido ya cambiada, y evidentemente existía ya una mayor experiencia de todo el sistema de salud tanto público como privado para reportar la cantidad de casos.

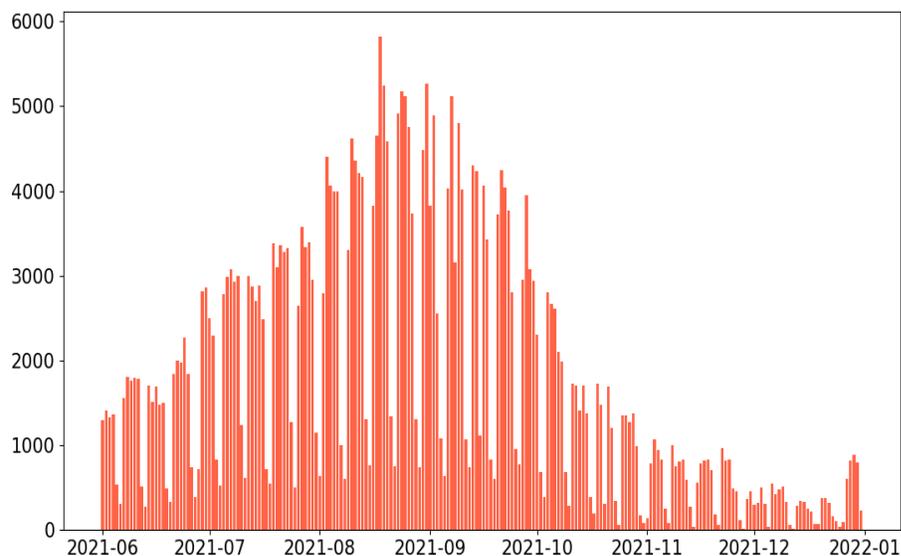
Derivado de la presión constante que para este momento ya tenía el sistema de salud, así como la experiencia ya mencionada anteriormente la forma en que se reportaban los casos tenía de forma sistemática datos ausentes en unos días que implicaba que los días subsiguientes tuviesen más casos reportados.

Para superar este problema de reporte de casos sistemático, se requirió utilizar una simple transformación sobre los datos.

3.1.2.1. Análisis paramétrico del segundo escenario de confinamiento

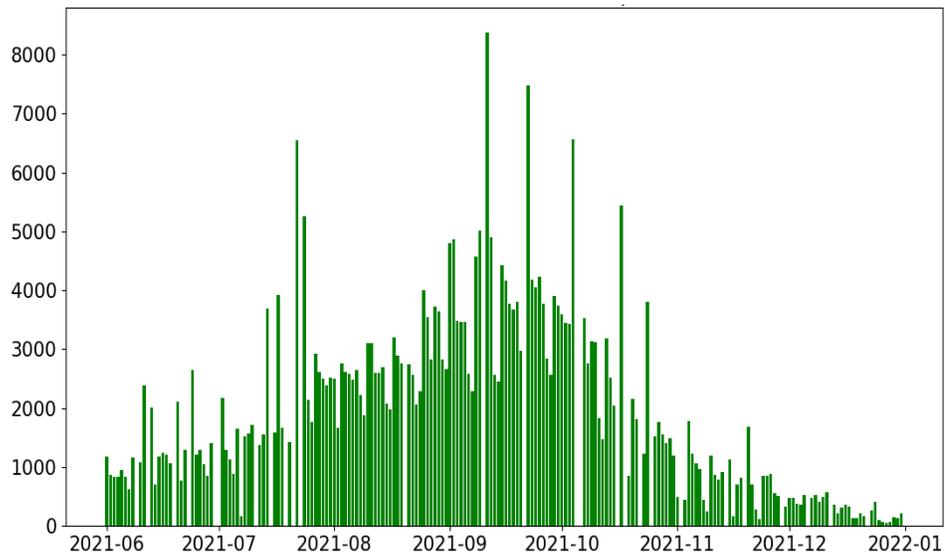
A continuación, se presenta el análisis paramétrico del segundo escenario de confinamiento.

Figura 26. Distribución de casos nuevos en confinamiento laxo



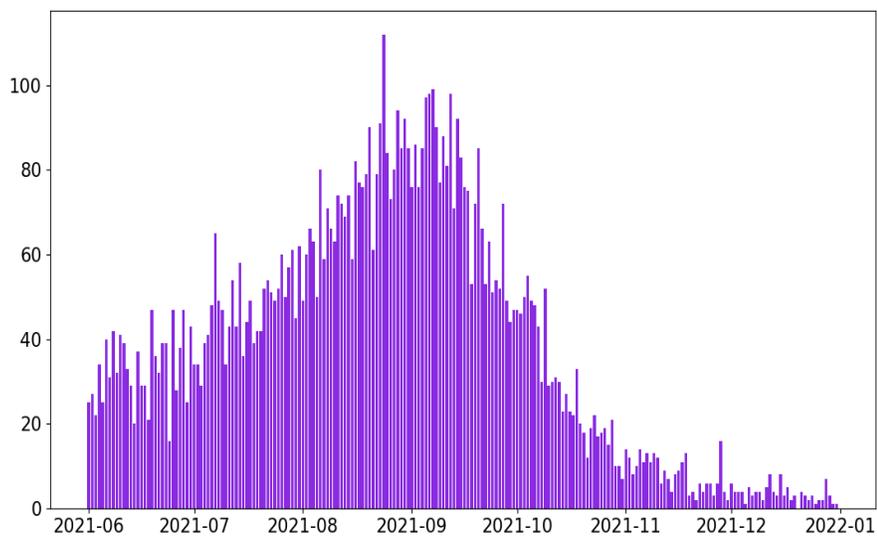
Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

Figura 27. **Distribución de casos recuperados en confinamiento laxo**



Fuente: elaboración propia, usando Python.

Figura 28. **Distribución de casos fallecidos en confinamiento laxo**



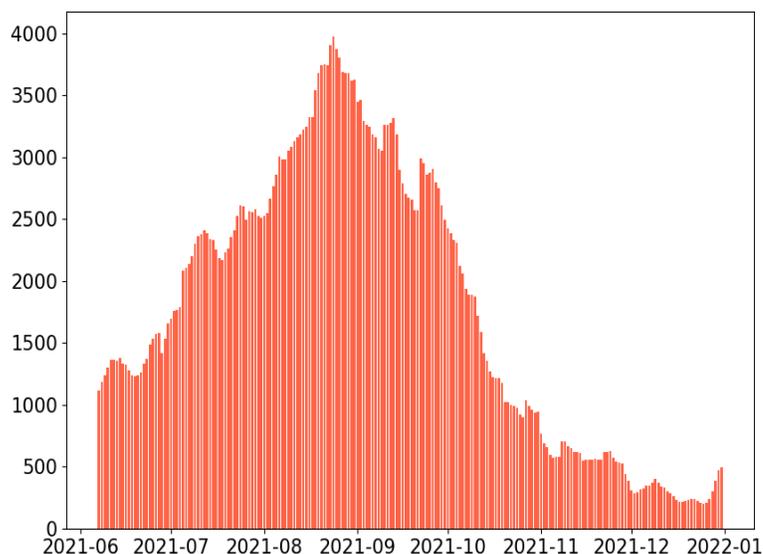
Fuente: elaboración propia, usando Python.

Al inicio de esta sección se mencionó que iba a ser necesario hacer una transformación de los datos debido a que sistemáticamente se dejaron de reportar casos, la transformación utilizada fue una M.A. de 7 días para tomar en cuenta el comportamiento medio semanal de la dinámica de la pandemia en Guatemala, esto se realizó con el fin de no tomar en cuenta sesgos por esta falta de reportes sistemática.

Luego de esta transformación, se hace notar que se tiene una distribución suavizada que reduce el ruido que esta falta de reportería sistemática indujo en las distribuciones crudas.

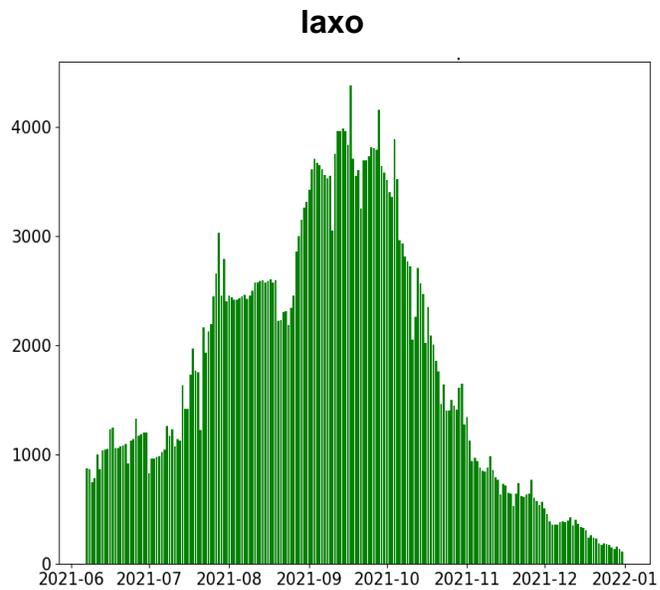
El principal beneficio de generar una M.A. semanal para las distribuciones de casos es que se eliminar el sesgo subyacente de la falta de reportes sistemático, uno de los costos, es la pérdida de información, sin embargo, este costo es asumible, pues el número de datos con los que se cuenta permite generar esta transformación.

Figura 29. **Distribución transformada casos nuevos confinamiento laxo**



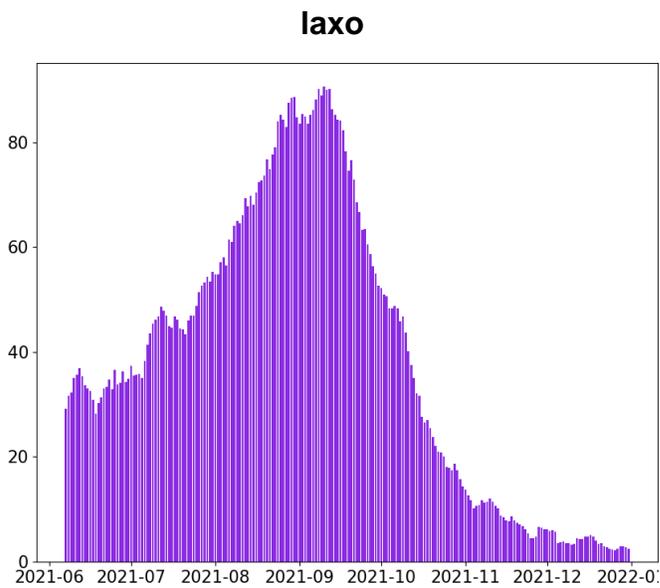
Fuente: elaboración propia, usando Python.

Figura 30. **Distribución transformada de casos recuperados confinamiento**



Fuente: elaboración propia, usando Python.

Figura 31. **Distribución transformada de casos fallecidos confinamiento**

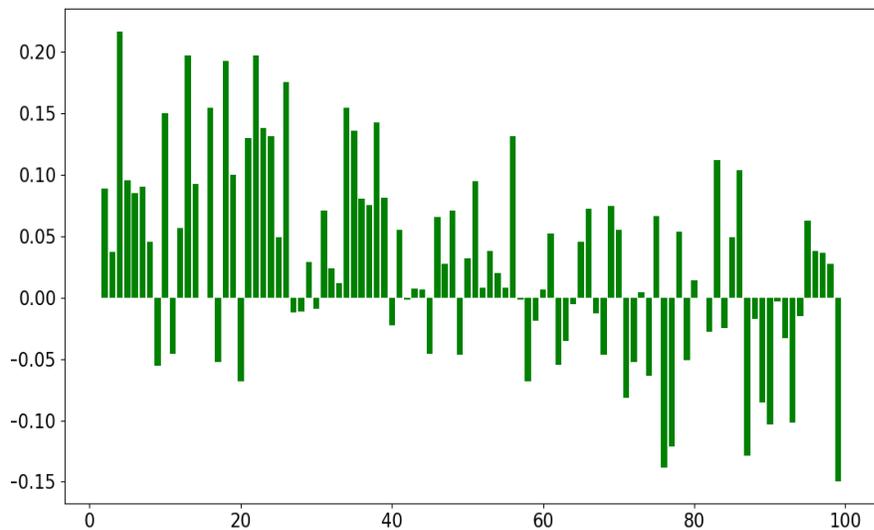


Fuente: elaboración propia, usando Python.

- Análisis de correlación temporal entre los casos fallecidos y recuperados con los confirmados.

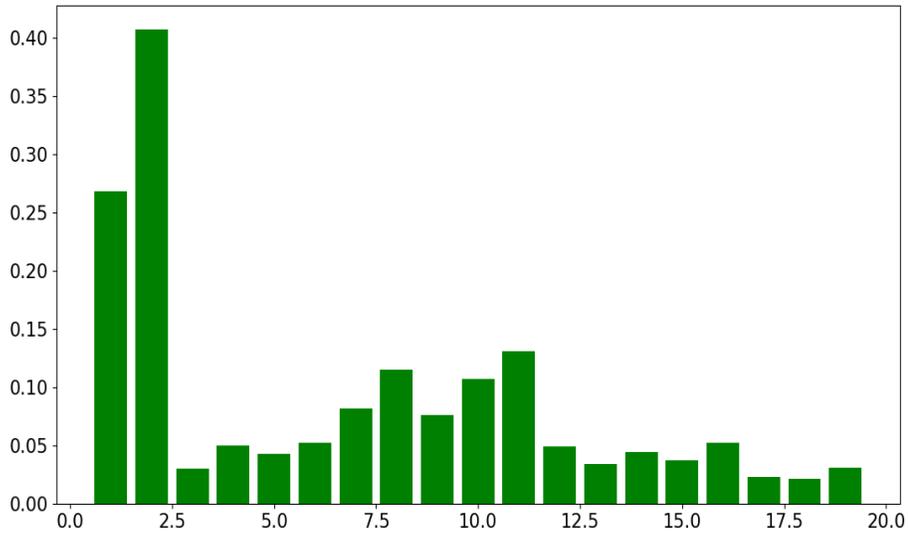
El objetivo de este análisis fue entender cuál era la incidencia en el tiempo de los casos confirmados, sobre los casos recuperados y fallecidos, esto para ganar intuición de cómo puede ser el comportamiento en los modelos de S.T. y también para contrastar los resultados y entender si existe consistencia de estos desde las dos perspectivas que se propusieron en el primer objetivo.

Figura 32. **Correlación temporal de los rezagos de casos confirmados con los casos fallecidos**



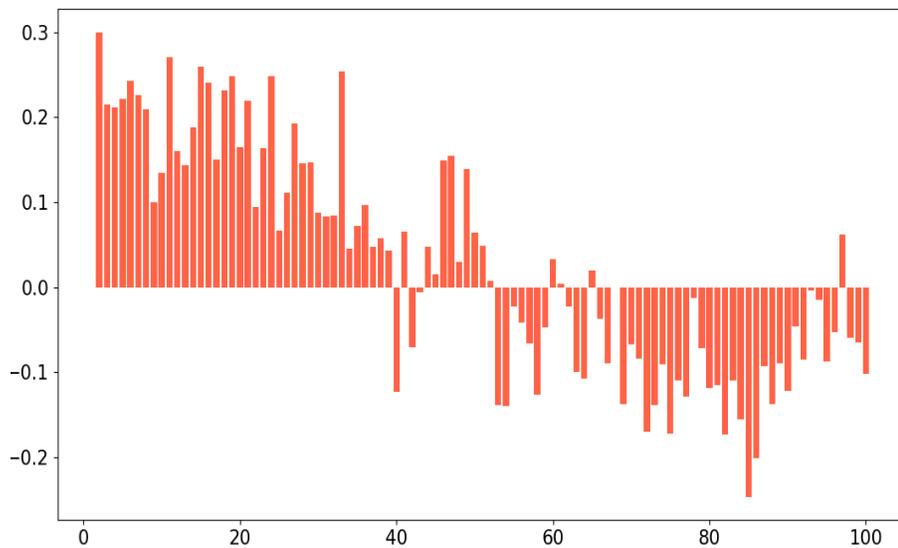
Fuente: elaboración propia, usando Python.

Figura 33. Significancia de la correlación temporal entre recuperados y confirmados



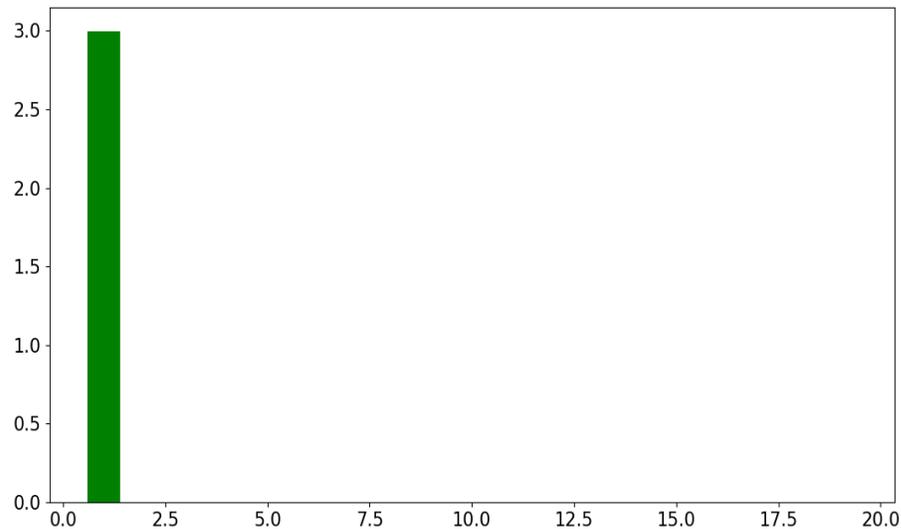
Fuente: elaboración propia, usando Python.

Figura 34. Correlación temporal de los rezagos de casos confirmados con los casos fallecidos



Fuente: elaboración propia, usando Python.

Figura 35. **Significancia de la correlación temporal entre fallecidos y confirmados**



Fuente: elaboración propia, usando Python.

Evidentemente el análisis paramétrico y de correlación en el confinamiento laxo, no es suficiente para generarse una idea de la dinámica de la pandemia, y por tanto se hace necesario el análisis de S.T.

La siguiente tabla muestra un resumen de los resultados obtenidos, para el análisis paramétrico y de correlación del confinamiento laxo.

Tabla X. **Resumen análisis paramétrico para el confinamiento laxo**

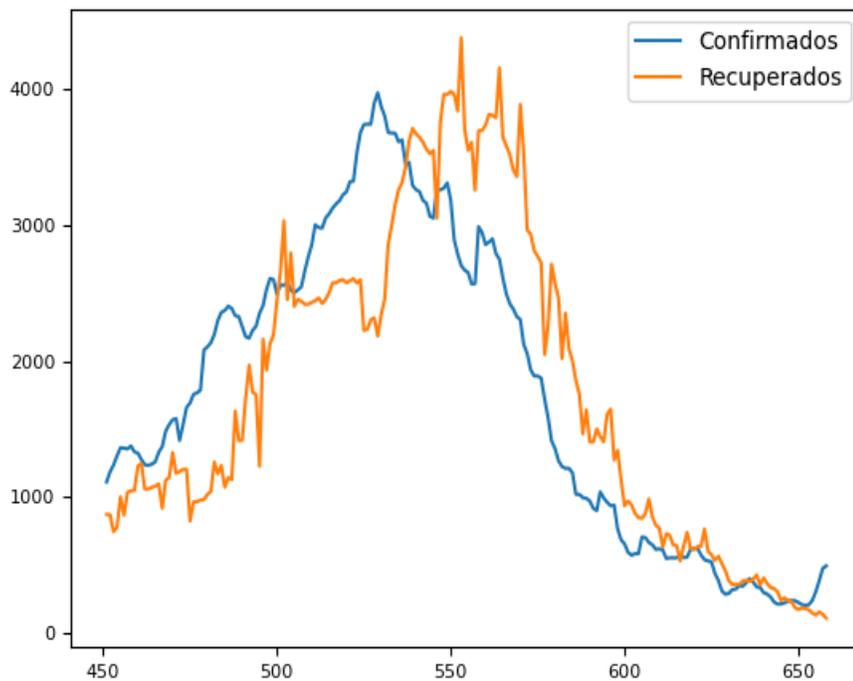
Días de rezago de Confirmados	Grupo de análisis	Correlación	Significativo
10 - 25	Recuperados	>0.15	Sí
9 – 35	Fallecidos	>0.25	Sí

Fuente: elaboración propia.

- Análisis por medio de S.T.

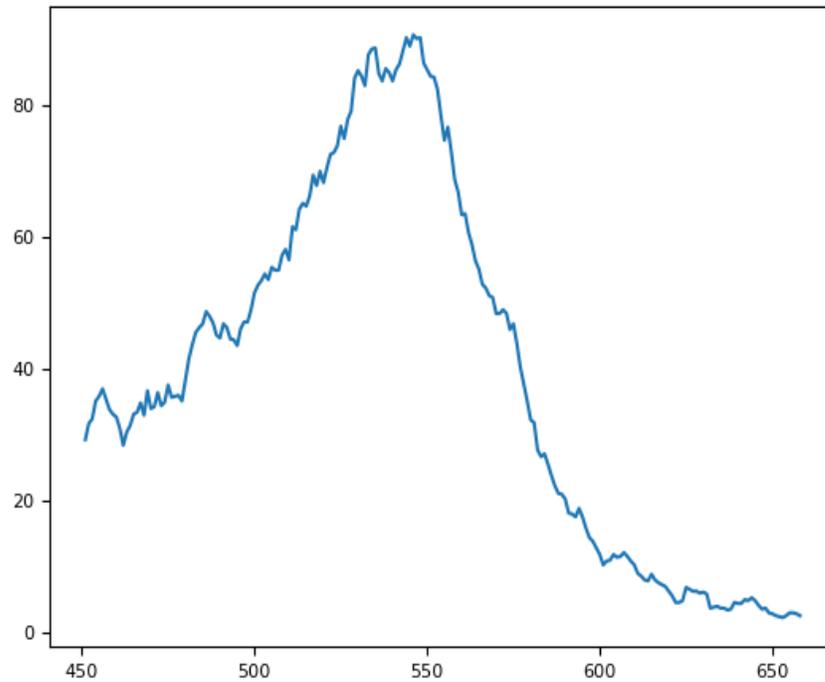
Las siguientes figuras muestran, las S.T. de los casos confirmados, recuperados y fallecidos de Covid-19 en Guatemala en el contexto de confinamiento laxo.

Figura 36. **S.T. de casos confirmados y recuperados**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

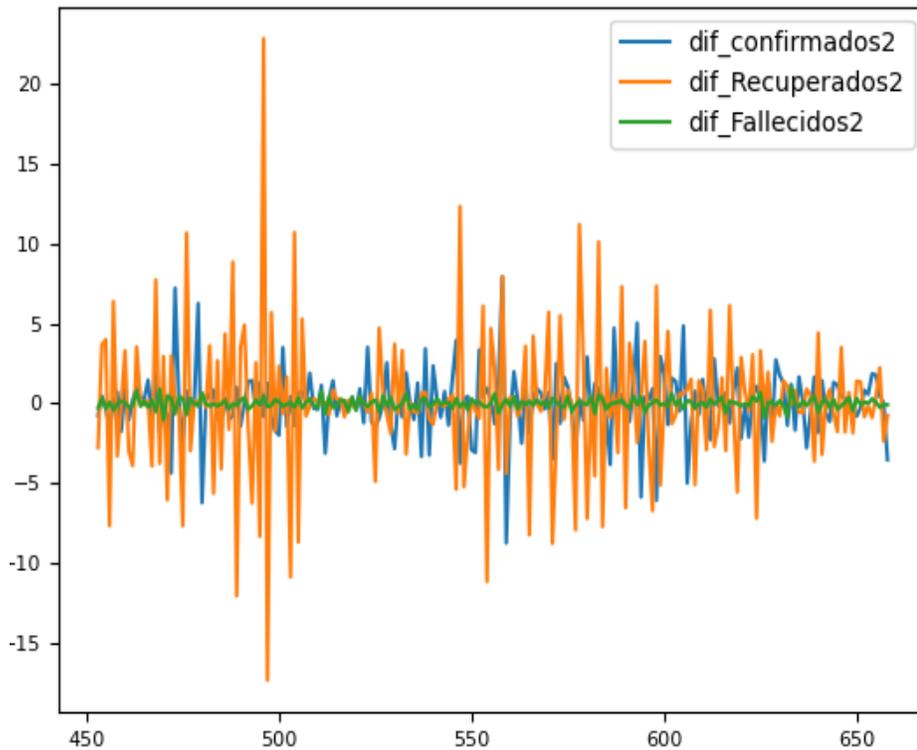
Figura 37. **S.T. de casos fallecidos**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

La figura que a continuación se muestra, ilustra a las S.T. transformadas y diferenciadas dos veces.

Figura 38. **S.T. transformadas casos confirmados, recuperados y fallecidos**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

Previo a pasar al análisis de S.T., se presentan los resultados de la prueba de Dickey-Fuller aumentada, que aseguran la carencia de raíz unitaria en los procesos estocásticos, que implican estacionariedad en sentido débil.

Tabla XI. **Resultados prueba Dickey Fuller S.T. en confinamiento estricto**

S.T.	p-valor	Conclusión
Casos confirmados	9.52×10^{-14}	Serie estacionaria en sentido débil
Casos recuperados	3.22×10^{-8}	Serie estacionaria en sentido débil
Casos fallecidos	5.91×10^{-10}	Serie estacionaria en sentido débil

Fuente: elaboración propia.

La tabla anterior, muestra que todas las S.T. transformadas son estacionarias en sentido débil y por tanto, es posible pasar a la modelación a través de S.T.

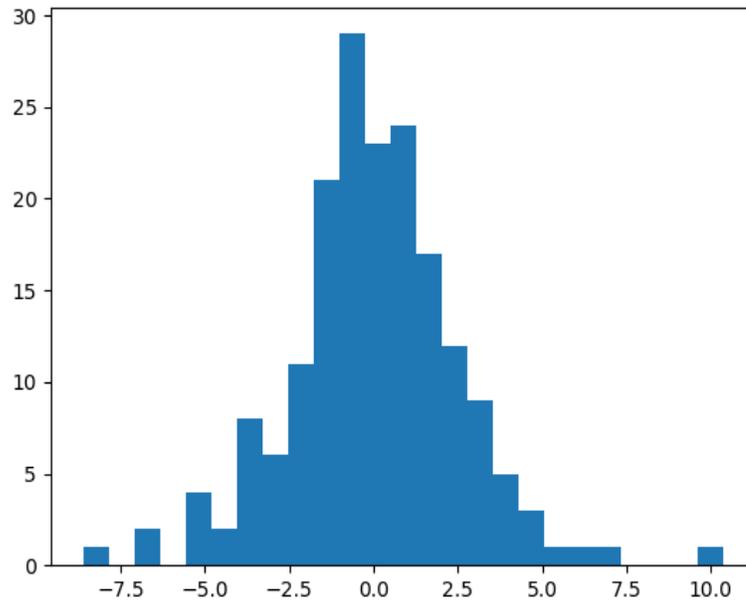
Tabla XII. **S.T. de confirmados sobre recuperados en confinamiento laxo**

OLS Regression Results						
=====						
Dep. Variable:	dif_Recuperados2	R-squared (uncentered):	0.675			
Model:	OLS	Adj. R-squared (uncentered):	0.660			
Method:	Least Squares	F-statistic:	44.98			
Date:	Sat, 11 Jun 2022	Prob (F-statistic):	1.99e-38			
Time:	11:39:31	Log-Likelihood:	-425.11			
No. Observations:	181	AIC:	866.2			
Df Residuals:	173	BIC:	891.8			
Df Model:	8					
Covariance Type:	nonrobust					
=====						
		coef	std err	t	P> t	[0.025 0.975]

Rezago Confirmados 8		-0.1969	0.090	-2.190	0.030	-0.374 -0.019
Rezago Confirmados 19		-0.2750	0.095	-2.890	0.004	-0.463 -0.087
Rezago Confirmados 25		0.2584	0.093	2.788	0.006	0.075 0.441
Rezago Recuperados 1		-1.1572	0.069	-16.686	0.000	-1.294 -1.020
Rezago Recuperados 2		-1.0742	0.100	-10.717	0.000	-1.272 -0.876
Rezago Recuperados 3		-0.9674	0.108	-8.951	0.000	-1.181 -0.754
Rezago Recuperados 4		-0.7098	0.099	-7.151	0.000	-0.906 -0.514
Rezago Recuperados 5		-0.3801	0.068	-5.612	0.000	-0.514 -0.246
=====						
Omnibus:	10.703	Durbin-Watson:	1.820			
Prob(Omnibus):	0.005	Jarque-Bera (JB):	24.435			
Skew:	0.079	Prob(JB):	4.94e-06			
Kurtosis:	4.793	Cond. No.	6.35			
=====						

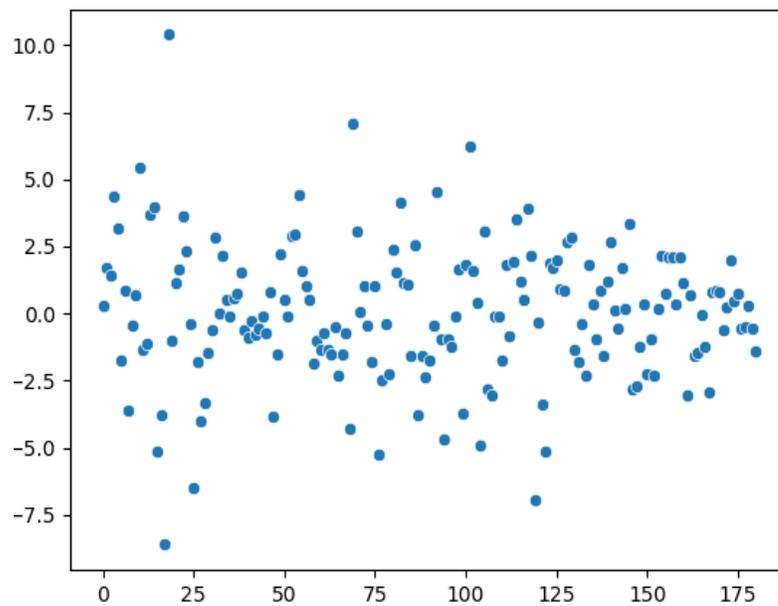
Fuente: elaboración propia, usando Python.

Figura 39. **Distribución de los residuos del modelo 3**



Fuente: elaboración propia, usando Python.

Figura 40. **Dispersión del residuo del modelo 3**



Fuente: elaboración propia, usando Python.

Tabla XIII. **Resultados de las pruebas estadística del residuo del modelo**

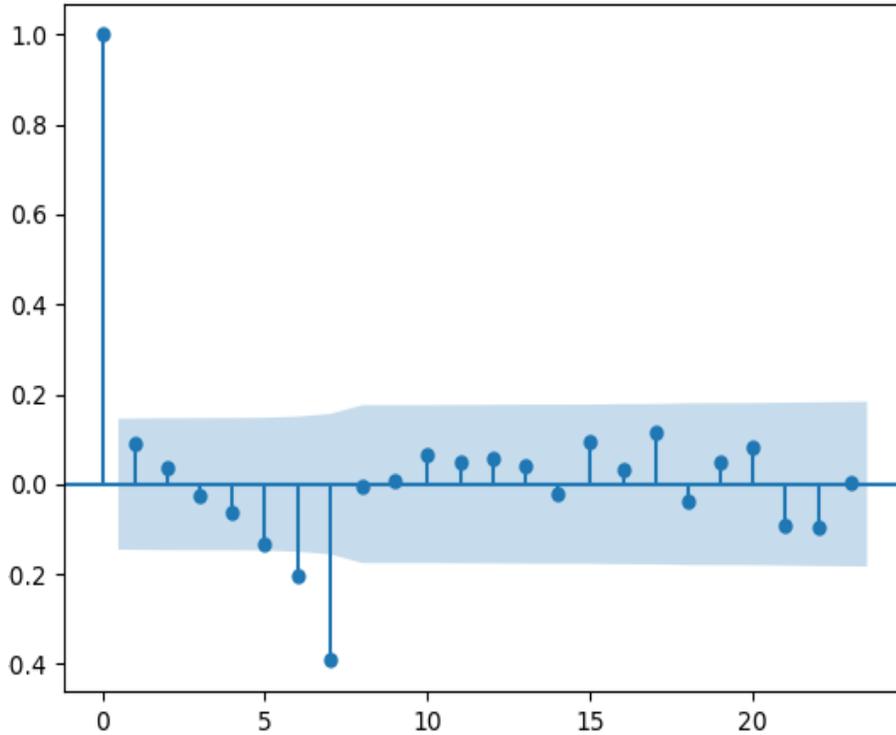
3

Prueba	P-valor.	Conclusión
Shapiro	0.17	Distribución normal del residuo
Ljung-Box	>0.26 para los primeros 20 rezagos	No autocorrelación del residuo.

Fuente: elaboración propia, usando Python.

Adicional a la prueba de Ljung-Box se muestra la función de correlación del residuo, para entender que tan bajos son los valores de correlación temporal del término del residuo del modelo.

Figura 41. **Función de auto correlación del término de residuo para el modelo 3**



Fuente: elaboración propia, usando Python.

Casi todos los valores están por debajo de 0.2 y están dentro del intervalo de confianza de 95 %, que implica ausencia de auto correlación en el residuo.

El siguiente apartado expone los resultados del modelo de S.T. utilizado para analizar la influencia de la transformación de casos confirmados sobre la transformación de los casos fallecidos.

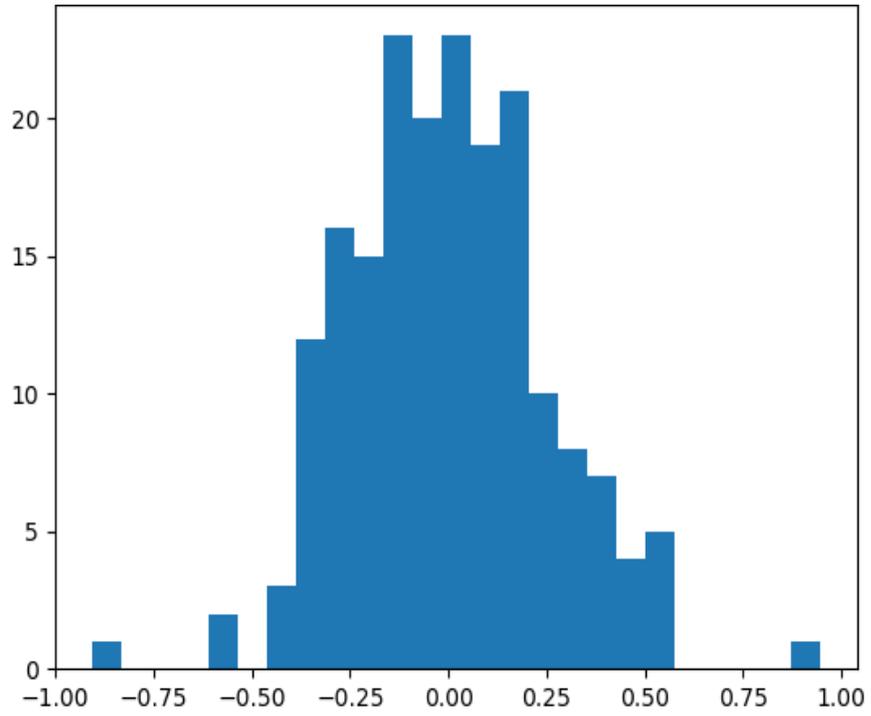
Tabla XIV. **S.T. casos confirmados sobre fallecidos en confinamiento laxo**

OLS Regression Results						
Dep. Variable:	dif_Fallecidos2	R-squared (uncentered):	0.408			
Model:	OLS	Adj. R-squared (uncentered):	0.396			
Method:	Least Squares	F-statistic:	32.09			
Date:	Sat, 11 Jun 2022	Prob (F-statistic):	2.48e-20			
Time:	12:05:23	Log-Likelihood:	-8.4851			
No. Observations:	190	AIC:	24.97			
Df Residuals:	186	BIC:	37.96			
Df Model:	4					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
Rezago Confirmados 15	0.0173	0.009	2.005	0.046	0.000	0.034
Rezago Fallecidos 1	-0.7860	0.071	-11.127	0.000	-0.925	-0.647
Rezago Fallecidos 2	-0.5000	0.083	-6.022	0.000	-0.664	-0.336
Rezago Fallecidos 3	-0.1943	0.071	-2.746	0.007	-0.334	-0.055
Omnibus:	5.442	Durbin-Watson:	2.007			
Prob(Omnibus):	0.066	Jarque-Bera (JB):	6.276			
Skew:	0.218	Prob(JB):	0.0434			
Kurtosis:	3.776	Cond. No.	12.7			

Fuente: elaboración propia, usando Python.

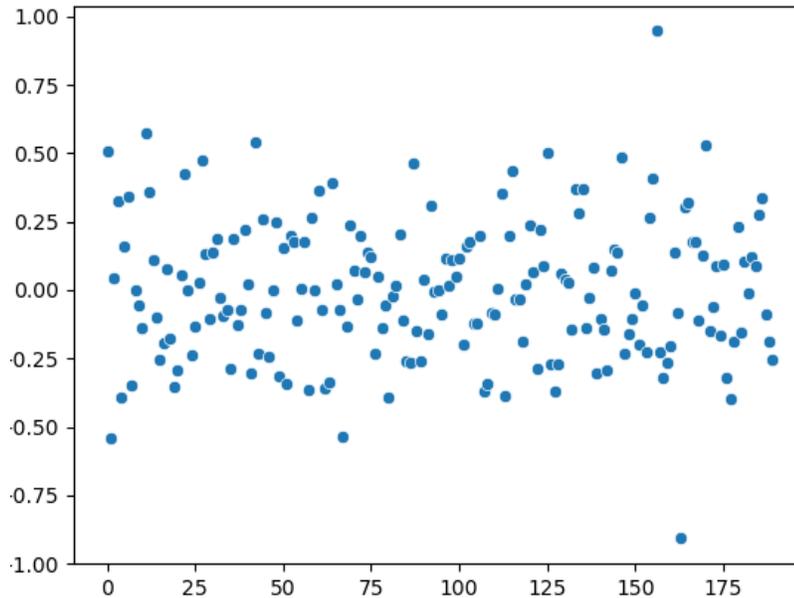
Las siguientes figuras muestran la distribución del término del residuo y su dispersión a lo largo del tiempo.

Figura 42. **Distribución del residuo del modelo 4**



Fuente: elaboración propia, usando Python.

Figura 43. **Dispersión del residuo del modelo 4**



Fuente: elaboración propia, usando Python.

Aunque de forma visual se puede apreciar una tendencia a la normalidad de la distribución del término de residuo, no autocorrelación y homocedasticidad, la siguiente tabla confirma estadísticamente las aseveraciones anteriores.

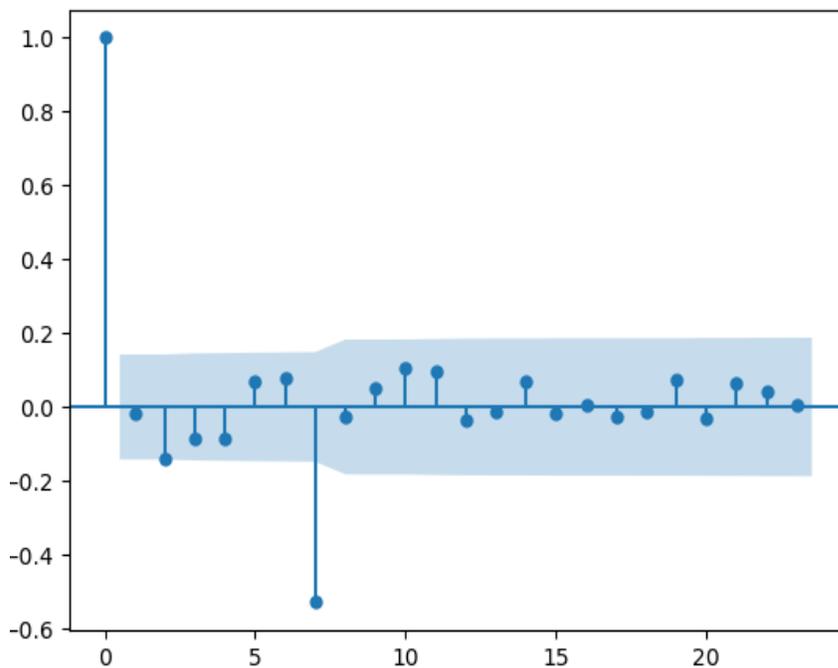
Tabla XV. **Resultados de las pruebas estadísticas del residuo del modelo 4**

Prueba	P-valor.	Conclusión
Shapiro	0.07	Distribución normal del residuo
Ljung-Box	>0.15 para los primeros 7 rezagos	No autocorrelación del residuo.

Fuente: elaboración propia.

También se muestra la función de autocorrelación del residuo del modelo 4, que visualmente da otra perspectiva acerca de la no autocorrelación del término del residuo.

Figura 44. **Función de autocorrelación del término de residuo para el modelo 4**



Fuente: elaboración propia, usando Python.

La siguiente tabla expone un resumen de todos los parámetros encontrados en esta sección que correspondió al análisis de la dinámica de la pandemia en Guatemala para ambos confinamientos.

Tabla XVI. **Resumen de parámetros del proceso epidémico en confinamiento estricto y laxo**

Análisis	Parámetro	Tiempo de influencia	Confinamiento
Paramétrico	Recuperación	25 días después de confirmado el caso.	Estricto
Paramétrico	Defunción	9 – 18 días después de confirmado el caso.	Estricto
S.T.	Recuperación	16 – 24 días después de confirmado el caso.	Estricto
S.T.	Defunción	2 – 29 días después de confirmado el caso.	Estricto
Paramétrico	Recuperación	10 – 25 días después de confirmado el caso	Laxo
Paramétrico	Defunción	9 – 35 días después de confirmado el caso.	Laxo
S.T.	Recuperación	8 – 25 días después de confirmado el caso.	Laxo
S.T.	Defunción	15 días después de confirmado el caso.	Laxo

Fuente: elaboración propia.

3.2. Pronostico casos confirmados, recuperados y fallecidos en confinamiento laxo con el modelo SEIR

La siguiente tabla muestra los parámetros que se utilizaron dentro del modelo SEIR que dieron lugar a los resultados que se expondrán más adelante.

Tabla XVII. **Parámetros que guiaron el proceso epidémico en Guatemala en confinamiento laxo**

Parámetro	Valor
Población Susceptible	9,450,000 personas
Duración de infección	19 días
γ	0.05 contagiados/día individuo infeccioso
Período de incubación	7 días
δ	0.14 días ⁻¹
Tasa de mortalidad	2%
Tiempo de infección hasta la muerte	15 días
R_0 inicial	4
R_0 final	3.5

Fuente: elaboración propia.

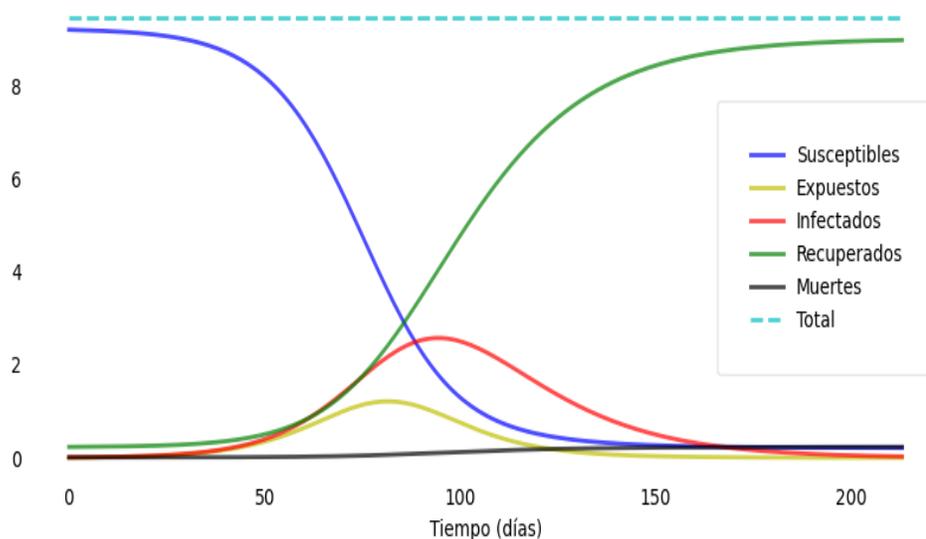
Los datos anteriores muestran los parámetros obtenidos del análisis de S.T. de la primera sección de este capítulo.

De acuerdo con datos del censo del 2018 en Guatemala, hay casi 15 millones de personas. Derivado de que casi 30 % de la población es menor a 19 años, se asume que es población que tiene una menor exposición al virus por la

razón de que los contactos sociales son menores. Del mismo modo, se excluyó a la población mayor a 70 años, que representa el 7 % de la población.

Las imágenes que se muestran a continuación son el resultado, del modelo SEIR alimentado por los parámetros obtenidos a través del análisis de S.T. de la primera sección del presente capítulo.

Figura 45. **Resultado completo modelo SEIR**



Fuente: elaboración propia, usando Python.

La figura 45 muestra la dinámica de casos susceptibles, expuestos, infectados, recuperados y fallecidos por COVID-19 en Guatemala para la ventana temporal de principios de junio de 2021 a finales de diciembre del mismo año, esta ventana temporal son 214 días. Se puede observar cómo los casos susceptibles descienden en el tiempo, esto es a causa, de que el modelo asume que ningún agente dentro de la sociedad está exento de ser expuesto al virus.

En lo que a los casos expuestos respecta, se puede observar que la curva está levemente desfasada que la curva de infectados, esto es porque, un caso expuesto da lugar a uno infeccioso. Se puede apreciar que la cantidad de casos fallecidos predichos para la ventana temporal del modelo, no se pueden observar bien en esta gráfica, la principal razón de esto es que la cantidad de casos fallecidos predichos es mucho menor que los casos predichos para los otros grupos.

Los casos recuperados tienen un comportamiento creciente, esto es porque es una dependencia de distribución acumulada, se puede notar que existe un espacio entre el total de la población y el total de casos recuperados (línea verde y punteada celeste). El espacio que se menciona es otra forma de ver el total de gente fallecida al final de la ventana temporal elegida para realizar el análisis.

Las ecuaciones diferenciales que guían al proceso descrito por la figura 45, se muestran a continuación.

Ec. (29)

$$\begin{aligned}\frac{dS}{dt} &= -\beta(t) S(t) \frac{I(t)}{N} \\ \frac{dE}{dt} &= \beta(t) S(t) \frac{I(t)}{N} - E(t) \delta \\ \frac{dI}{dt} &= E(t)\delta - I(t)\gamma(1 - \alpha) - I(t)\alpha\rho \\ \frac{dR}{dt} &= I(t)\gamma(1 - \alpha) \\ \frac{dD}{dt} &= I(t)\alpha\rho\end{aligned}$$

Se puede observar que el parámetro beta, en la modelación es una función del tiempo, esto se introdujo para relajar el supuesto que beta es constante. La función del tiempo propuesta para beta fue:

Ec. (30)

$$\beta(t) = 0.05\left(\frac{R0_{inicial} - R0_{final}}{1 + e^{-k(-t+x0)}} + R0_{final}\right)$$

Las condiciones de R0 inicial y R0 final, se dieron de tal forma, que se redujera el error entre el modelo SEIR propuesto y los datos del proceso epidémico observado, los parámetros k y x0 sirven para dar forma a la función sigmoïdal de caída de R0 en el tiempo.

Los valores que minimizan el error entre el modelo SEIR y el proceso epidémico observado son:

$$R0_{inicial} = 4$$

$$R0_{final} = 3.5$$

$$k = 0.08$$

$$x0 = 170$$

Por su parte las condiciones iniciales, para la solución del sistema de ecuaciones diferenciales, se muestran a continuación:

$$N = 17 \text{ millones}$$

$$S0 = 9.4 \text{ millones}$$

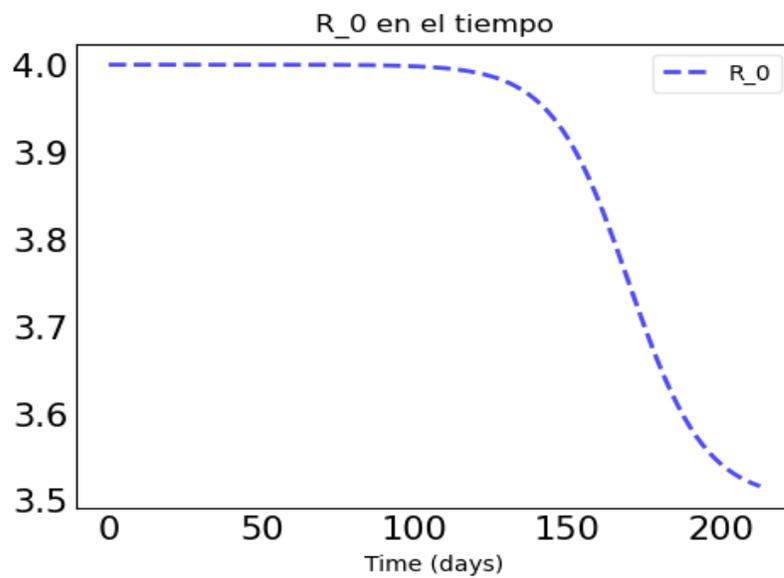
$$E0 = 1406$$

$$I0 = 12519$$

$$D0 = 9116$$

Los parámetros de recuperación, mortalidad y transmisión están resumidos en la tabla XII.

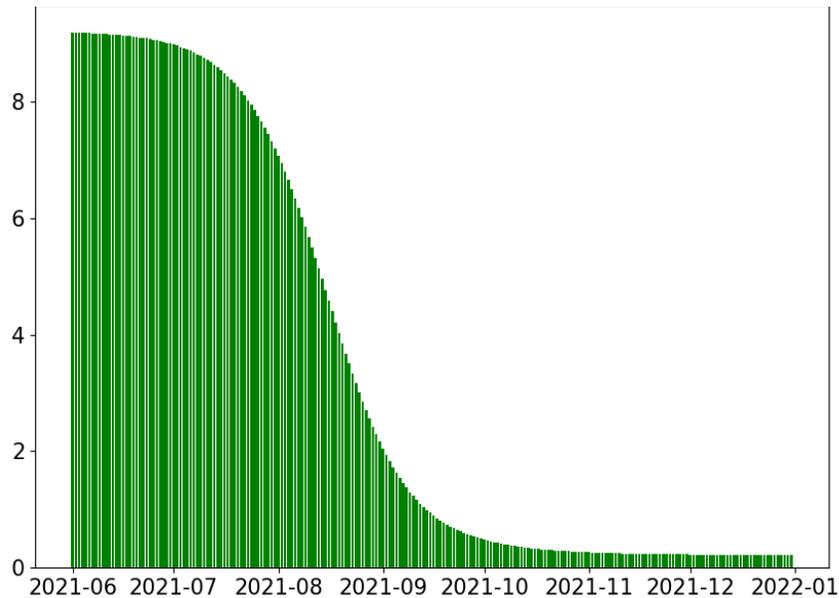
Figura 46. **Comportamiento del R0 en el tiempo con la función sigmoideal**



Fuente: elaboración propia, usando Python.

La imagen anterior captura el comportamiento del parámetro R_0 (la cantidad de personas que una persona infectada puede contagiar) a lo largo de la ventana temporal elegida para el análisis. Aunque este resultado no es un producto que esté respaldado estadísticamente, es presentado aquí porque modelar esta parte se hace necesario, debido a la introducción de la vacunación en el país.

Figura 47. **Función de acumulación casos susceptibles modelo SEIR**

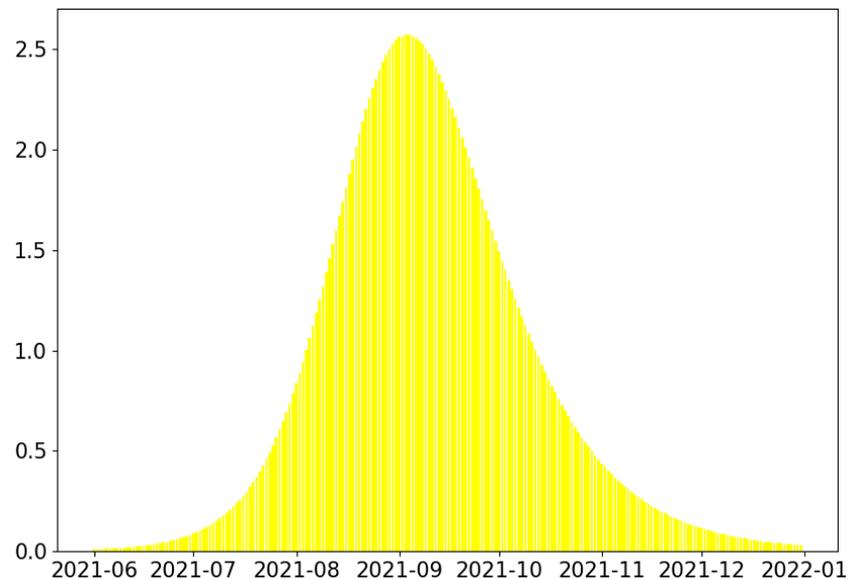


Fuente: elaboración propia, usando Python.

El resultado presentado en la figura 45, ilustra el comportamiento descendiente del grupo de susceptibles en Guatemala para la ventana temporal del período laxo. Se puede ver como al inicio, se tienen los 10 millones de habitantes que en el supuesto de esta investigación se tomaron en cuenta como susceptibles.

El comportamiento de la curva es exponencial como es de esperarse, esto porque al principio de la ventana temporal derivado que hay relativamente menos casos, estos pueden propagar en menor medida al virus, pero conforme avanza el tiempo, también la propagación del virus se hace más sencilla a través de la sociedad. Esto es hasta llegar a un punto en el que ya quedan muy pocos casos susceptibles y se vuelve a tener el mismo comportamiento al inicio.

Figura 48. **Distribución casos infectados modelo SEIR**

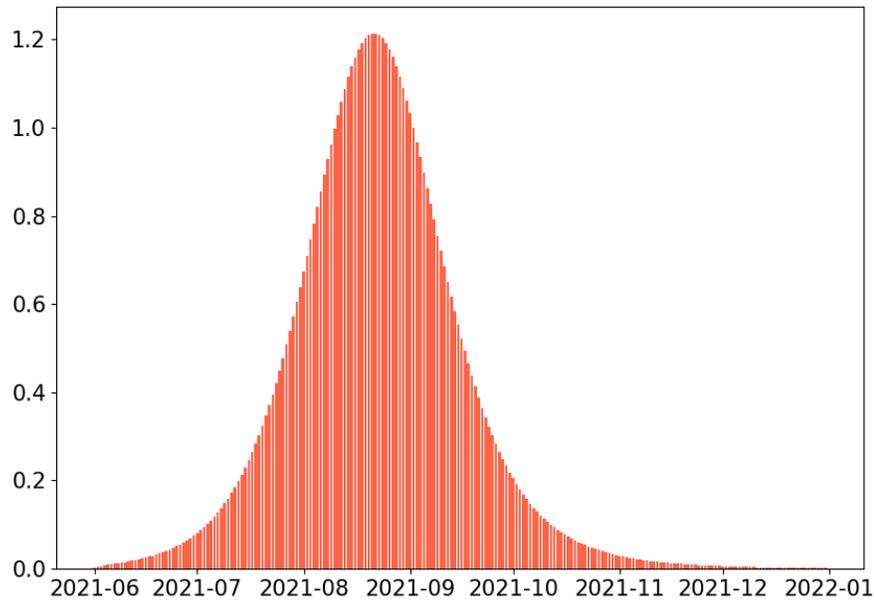


Fuente: elaboración propia, usando Python.

Bajo los supuestos que toma el modelo y con los parámetros obtenidos en el análisis de S.T., se puede observar que el máximo de contagios en la ventana temporal elegida fue de casi 2.5 millones de agentes en un solo día.

Se puede observar que para el día 100 aproximadamente se alcanza el máximo de contagios en un solo día, esto corresponde a la mitad de septiembre de 2021. Posteriormente se contrastarán los datos observados, con los datos que arrojó el modelo, para entender no solo la magnitud de contagios que se predijo, sino también, los tiempos en los que este lo predijo.

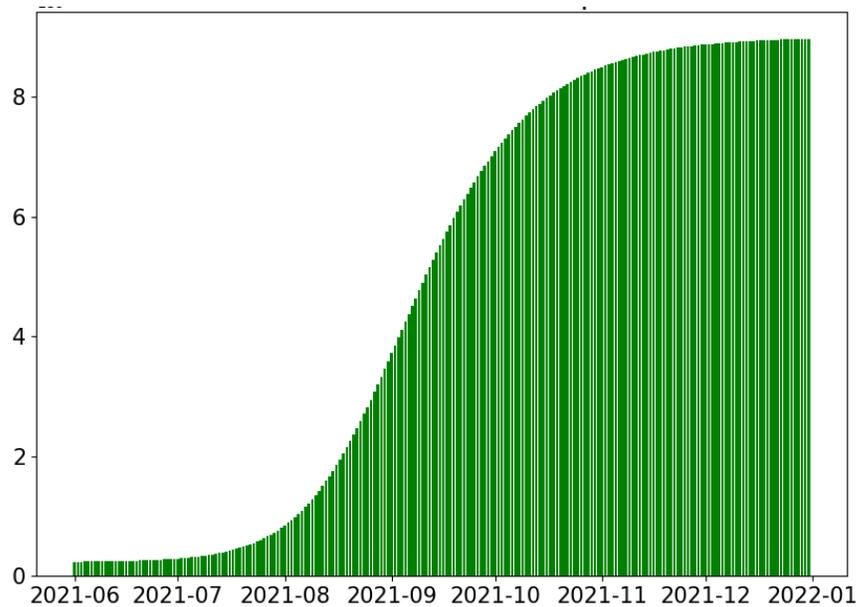
Figura 49. **Distribución de casos expuestos**



Fuente: elaboración propia, usando Python.

La distribución de casos expuestos al virus muestra que, para el máximo, se tendrían alrededor de 1.2 millones de casos, y esto sucedería en torno al día 75, lo que implicaría que esto probablemente pasaría para mediados, de agosto de 2021. Se entiende que la distribución de casos expuestos esté desfasada de la distribución de casos infectados en el tiempo, esto porque los casos expuestos son un causal de los casos infectados. Esta distribución tiene menos casos que los infectados, por el coeficiente R_0 que se planteó en las condiciones iniciales.

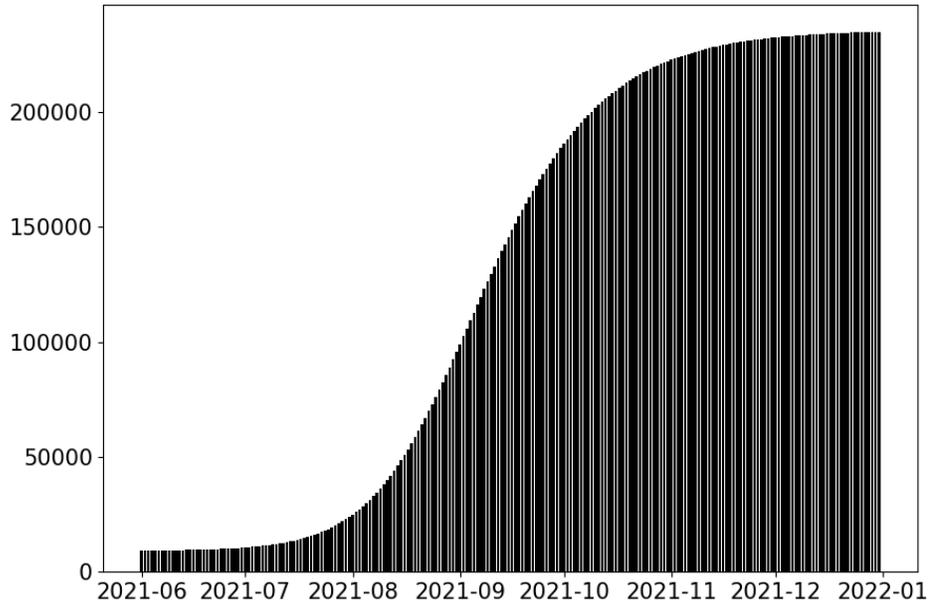
Figura 50. **Distribución acumulada de casos recuperados**



Fuente: elaboración propia, usando Python.

Más adelante, se contrastará esta función diferenciada, con los casos observados que se recuperaron. Esto para poder entender en que punto del tiempo se da el máximo y cuál es el máximo de casos recuperados en un día de acuerdo con el modelo, pues con la información que se tiene, se puede observar que el total de casos recuperados para el final de análisis de la ventana temporal se tiene en torno a 8 millones de casos.

Figura 51. **Distribución acumulada de casos fallecidos**



Fuente: elaboración propia, usando Python.

La figura 51 indica que, para el fin de la ventana temporal de análisis, se tendrían alrededor de 250 mil casos fallecidos. Los modelos SEIR, nuevamente se resalta que los casos fallecidos son causa de los casos infectados y por tanto existe un desfase en el tiempo.

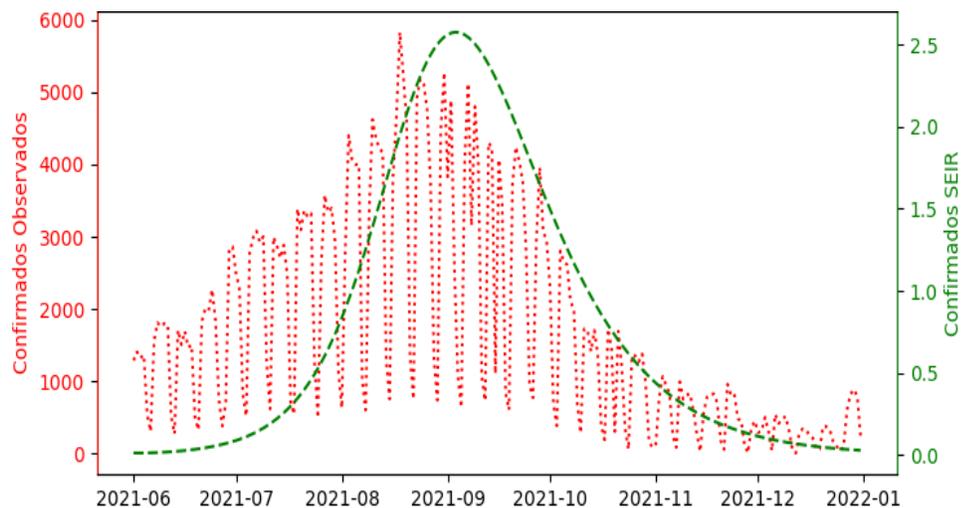
La distribución de acumulación será diferenciada, para poder hacerla comparable con la curva de casos fallecidos de la ventana temporal del confinamiento laxo, esto para entender los tiempos en los que el modelo pronostica el pico de casos y la cantidad.

3.2.1. Comparación de las predicciones del modelo con lo observado

Hasta el momento, se han mostrado los resultados dados por el modelo SEIR, alimentado por los parámetros obtenidos del análisis de S.T. de la primera sección de este capítulo. Lo que se presenta a continuación, es un contraste de los pronósticos con lo observado.

La sección de discusión de resultados profundizará en los detalles, el objetivo de esta sección es únicamente exponer los resultados obtenidos.

Figura 52. **Predicciones modelo respecto a casos confirmados**



Fuente: elaboración propia, usando Python.

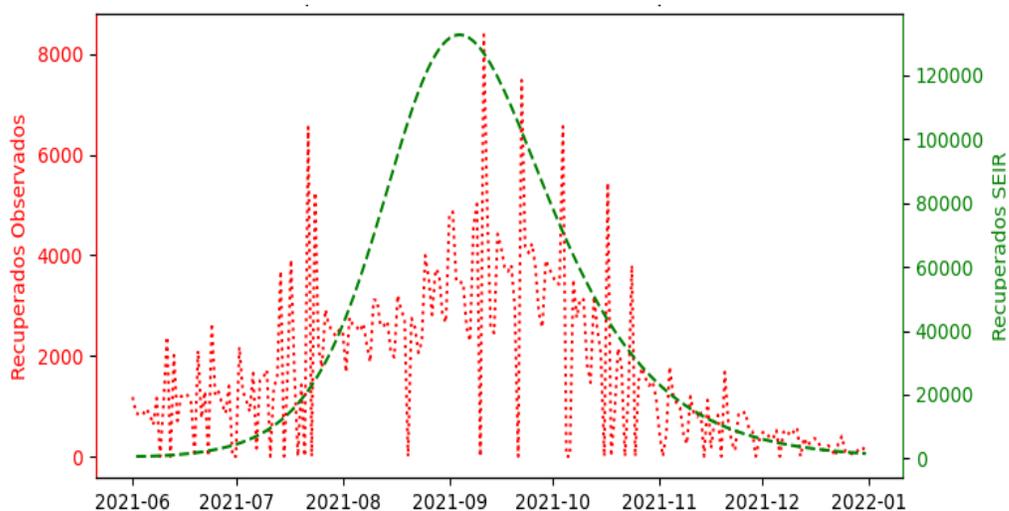
La figura 52 contrasta los casos confirmados que se observaron en la S.T., cuyo eje es el izquierdo y es la gráfica que presenta mayor ruido, mientras lo pronosticado por el modelo, es la curva más suave cuyo eje está del lado derecho.

El primer punto por observar es que temporalmente los máximos de las distribuciones se ubican temporalmente en lugares muy similares en septiembre 2021, sin embargo, la cantidad de casos que el predice es alrededor de 400 veces mayor de lo que realmente se observó.

La sección de discusión de resultados profundizará en este tema. Lo que se puede comentar en esta sección, es que evidentemente existe una sobrestimación por parte del modelo, pero, también es cierto que existió asimetría de información a la hora de reportar los casos, por tanto, lo que el gobierno reportó es más bien una subestimación de la cantidad de casos confirmados, esto es una posibilidad.

La siguiente figura contrasta la cantidad de casos recuperados predichos por el modelo, con los observados, para la ventana temporal de confinamiento laxo.

Figura 53. **Predicciones del modelo respecto a casos recuperados**



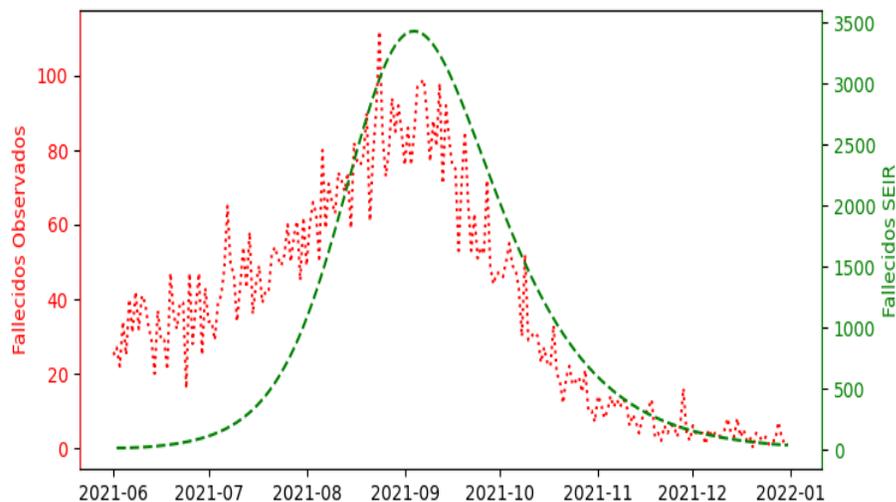
Fuente: elaboración propia, usando Python.

Los casos observados se capturan en la curva que presenta mayor ruido y cuyo eje muestra las cantidades en el lado izquierdo, lo predicho por el modelo es la curva más suave, cuyo eje está del lado derecho. Para este rubro, la cantidad de casos predichos por el modelo son casi 120 mil en un solo día, mientras lo que se observó realmente fueron 8 mil casos. En este caso, el modelo sobrestimó en casi 15 veces la cantidad de casos recuperados.

En cuanto a la temporalidad que se muestra el máximo de casos recuperados nuevamente existe una coincidencia entre lo que el modelo predijo y lo que se observó, dándose un máximo en el mes de septiembre de 2021. Puntualmente este máximo se encuentra en el inicio.

Es importante mencionar que nuevamente, para este rubro, lo que se presentan son subestimaciones en el lado de los casos reportados y una sobrestimación para el modelo, los datos reales, tienen que estar en un punto entre estas dos distribuciones.

Figura 54. **Predicciones del modelo respecto a casos fallecidos**



Fuente: elaboración propia, usando Python.

Los casos observados se capturan en la curva que presenta mayor ruido y cuyo eje muestra las cantidades en el lado izquierdo, lo predicho por el modelo es la curva más suave, cuyo eje está del lado derecho. Para este rubro, la cantidad de casos predichos por el modelo son más de 3 mil en un solo día, mientras lo que se observó realmente fueron 100 casos. En este caso, el modelo sobrestimó en casi 35 veces la cantidad de casos fallecidos.

En cuanto al tiempo en el que se predijeron el máximo de casos fallecidos con los observados, se puede apreciar que coincide nuevamente, incluso luego de ese máximo, la forma del decaimiento de los casos fallecidos predichos se apega muy bien a los casos observados.

La naturaleza del reporte de fallecimientos por COVID-19, está sujeto a que el sistema de salud haya identificado bien a los casos y los haya reportado, así mismo, siempre existe la posibilidad de casos que hayan fallecido por el virus, que no fueron reportados, porque no fueron atendidos por el sistema. Dado lo anterior se tiene la posibilidad de una subestimación en el reporte y una sobrestimación en el modelo.

3.3. Correlación existente entre el número de casos positivos y la actividad económica en los dos escenarios de confinamiento

Para poder entender la correlación entre casos positivos de COVID-19 en Guatemala y el índice mensual de la actividad económica, fue necesario transformar las series, la primera transformación realizada, fue la de aplicar logaritmo natural a la cantidad de casos positivos. La razón de esta transformación es para reducir la varianza. La segunda transformación sobre la serie de casos positivos fue la de la variación intermensual de casos. Esta transformación con el fin de entender el comportamiento creciente o decreciente en el tiempo.

La transformación realizada sobre el IMAE únicamente constó en aplicar la variación intermensual del índice con el fin de entender el comportamiento creciente o decreciente de este.

3.3.1. Análisis de correlación en confinamiento estricto

El primer escenario de confinamiento, para esta investigación, corresponde al período que abarca desde marzo 2020 hasta finales de julio 2020.

Tabla XVIII. **Series IMAE-casos positivos confinamiento estricto**

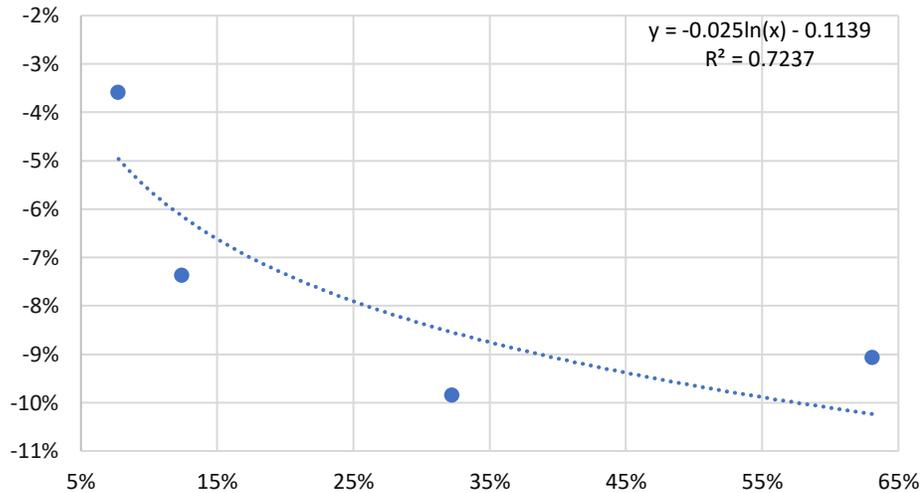
Mes	Casos	Ln(Casos)	Variación	IMAE	Variación
mar-20	52	3.95		121.36	-4 %
abr-20	629	6.44	63 %	112.71	-9 %
may-20	5025	8.52	32 %	111.48	-10 %
jun-20	14476	9.58	12 %	111.56	-7 %
jul-20	30443	10.30	8 %	118.50	-4 %
ago-20	24208	10.09	-2 %	120.60	-1 %

Fuente: elaboración propia, usando datos del MSPAS y BANGUAT.

Se puede observar que para el escenario de confinamiento estricto para este análisis se tiene hasta el mes de agosto de 2020. La razón de esto es porque el análisis de la variación intermensual implica la pérdida de un dato, dada la cantidad de meses que se tiene para el análisis, se incluye a agosto, para compensar esta pérdida de información.

El siguiente gráfico ilustra la relación que existió en la ventana temporal en el confinamiento estricto.

Figura 55. **Diagrama de dispersión variación IMAE como función a la variación de casos positivos confinamiento estricto**



Fuente: elaboración propia.

Lo principal a resaltar del gráfico anterior, es la relación negativa que existe entre la variación de casos positivos de COVID-19 y la variación del IMAE. Esto implica que a mayor sea el crecimiento de casos positivos, más caerá el IMAE.

El resultado anterior se discutirá en la siguiente sección. Sin embargo, parece ser que esta relación se captura por la misma forma en la que se dio el confinamiento laxo, en el que, si hubo casos positivos, pero la actividad económica cayó.

Otro resultado a destacar aquí es que la línea de tendencia se captura parece no ser lineal, sino, logarítmica. Este resultado, puede influenciar sobre la verdadera correlación, ya que una correlación captura el nivel de asociación lineal y para este caso, se puede entender que una mejor tendencia es logarítmica.

3.3.2. Análisis de correlación en confinamiento laxo

El segundo escenario de confinamiento por su parte abarca la ventana temporal comprendida desde junio de 2021 hasta finales de diciembre de ese mismo año.

A continuación, se muestra la serie del IMAE y casos positivos tanto brutas como transformadas para el análisis.

Tabla XIX. **Series brutas y transformadas IMAE-casos positivos confinamiento laxo**

Mes	Casos	Ln(Casos)	Variación	IMAE	Variación
jun-21	41854	10.64	4 %	127.54	14 %
jul-21	73185	11.20	5 %	131.22	11 %
ago-21	105922	11.57	3 %	130.14	8 %
sep-21	87707	11.38	-2 %	128.76	6 %
oct-21	38399	10.55	-7 %	130.63	4 %
nov-21	16779	9.72	-8 %	135.34	6 %
dic-21	10153	9.22	-5 %	140.75	4 %

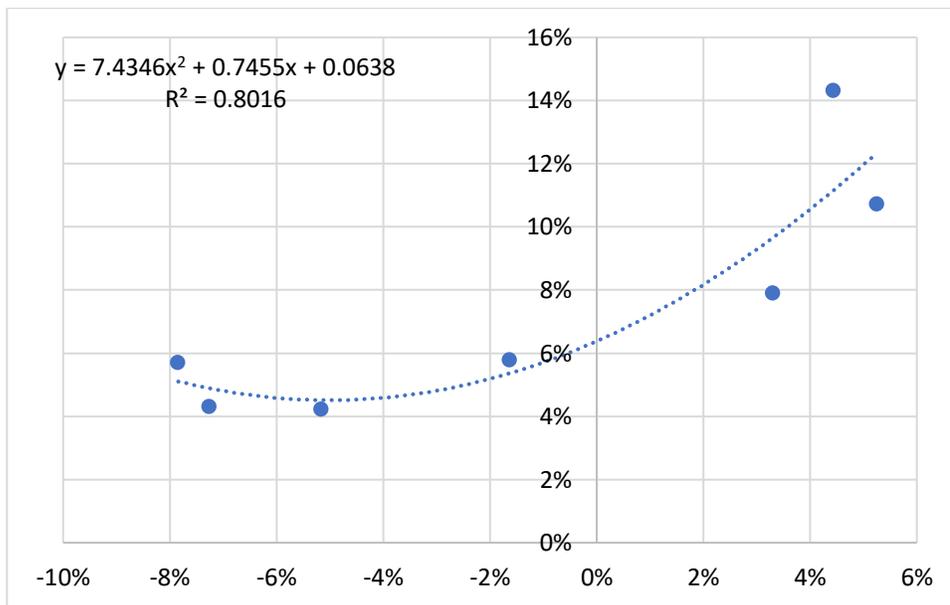
Fuente: elaboración propia, usando datos del MSPAS y BANGUAT.

Para esta ventana temporal lo principal a destacar es que las variaciones en la cantidad de casos confirmados de COVID-19 en Guatemala son mucho más estables que para el inicio de la pandemia.

La serie del IMAE por su lado presenta variaciones positivas, esto porque para este momento ya no existían restricciones a la movilidad e interacciones sociales, permitiendo que la actividad económica naturalmente retomará la tendencia prepandemia.

El siguiente gráfico muestra la dispersión de casos positivos y el IMAE en el confinamiento laxo.

Figura 56. **Diagrama de dispersión variación IMAE como función a la variación de casos positivos confinamiento laxo**



Fuente: elaboración propia.

En la ventana temporal que contiene al confinamiento laxo, se puede observar una relación positiva entre las variaciones de casos confirmados de COVID-19 en Guatemala y las variaciones del índice mensual de la actividad económica.

El resultado anterior parece un poco más intuitivo, pues se entendería que un mayor crecimiento de casos de COVID-19 en el país implicaría también un mayor crecimiento de la actividad económica, esto porque la actividad económica de forma inherente tiene a la interacción social.

El último resultado a exponer de la figura 59 es la línea de tendencia que mejor captura a la relación de variaciones entre casos positivos y variaciones del IMAE. Para este caso, se tiene una tendencia cuadrática.

A continuación, se muestra la tabla con las correlaciones capturadas para las variaciones del IMAE y de los casos positivos de COVID-19 en Guatemala.

Tabla XX. **Correlación casos positivos e IMAE ambos confinamientos**

Escenario	Correlación
Confinamiento Estricto	-0.79
Confinamiento Laxo	0.84

Fuente: elaboración propia, usando datos del MSPAS y BANGUAT.

Los resultados anteriores, muestran que para el confinamiento estricto se tiene una correlación negativa y para el confinamiento laxo se tenía una correlación positiva. Este resultado implica un cambio estructural, que naturalmente se dio por el mismo confinamiento.

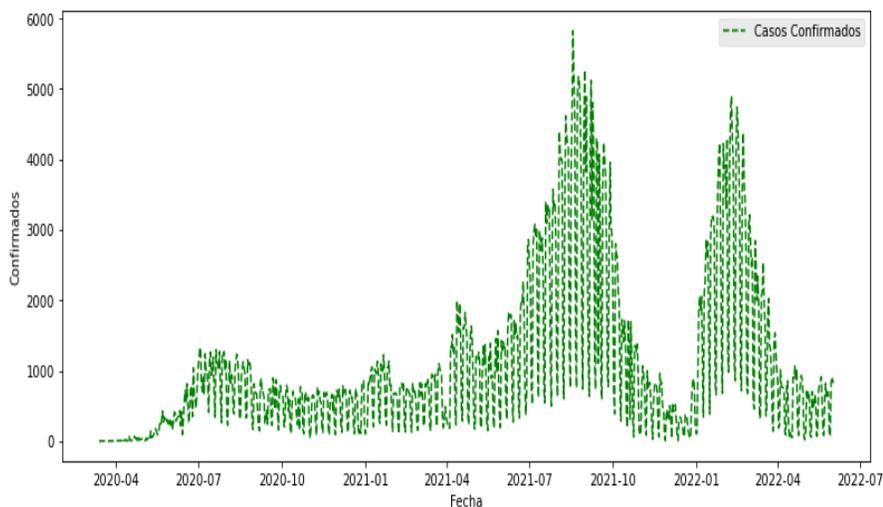
Se debe de tomar en cuenta que las correlaciones mostradas aquí, miden un nivel de asociación lineal, pero los resultados indican también que las asociaciones son mejor explicadas con relaciones no lineales.

3.4. Estimar los parámetros que gobiernan el proceso epidémico de COVID-19 en Guatemala y pronosticar contagios y su repercusión en la actividad económica, para proponer medidas de confinamiento que no entren en conflicto con las metas de crecimiento económicas nacionales

A lo largo de este capítulo se han mostrado los resultados de cada uno de los objetivos planteados en la presente investigación. En esta sección se muestra como cada uno de los resultados sirvió para la obtención del objetivo general.

Se inicia mostrando la cantidad de casos confirmados, recuperados y fallecidos del COVID-19 en Guatemala, para el período del 13/03/2020 al 02/06/2022, así como una muy breve cronología de las acciones del estado que se consideran más importante dentro del contexto de la pandemia en el país.

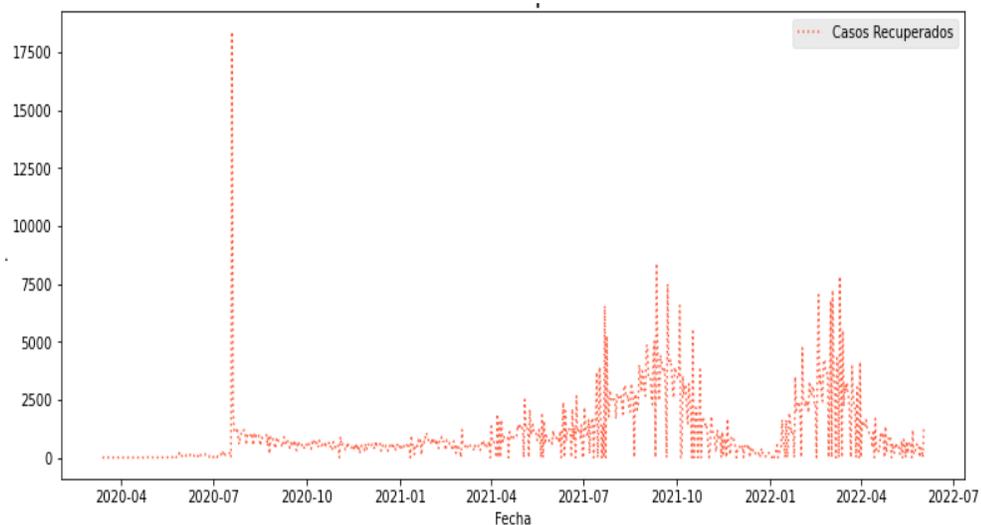
Figura 57. **Distribución de casos confirmados en Guatemala**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

Se puede observar de forma muy general 4 “picos” de casos confirmados de COVID-19 en Guatemala, distribuidos en distintos momentos del tiempo, el primero ubicado en julio 2020 que responde a la apertura gradual del país luego de las fuertes medidas de confinamiento. El segundo ubicado temporalmente en abril de 2021, que pareciera ser más bien un cambio estructural, y coincide con la semana santa de ese año. El tercero se ubica 4 meses después, en agosto de 2021 que coincide con un momento en el que la sociedad y economía estaban más abiertas, así como con la llegada de la variante “Delta” al país. El último pico, se observa en febrero de 2022 y podría estar guiado por la variante “Ómicron” que es más contagiosa.

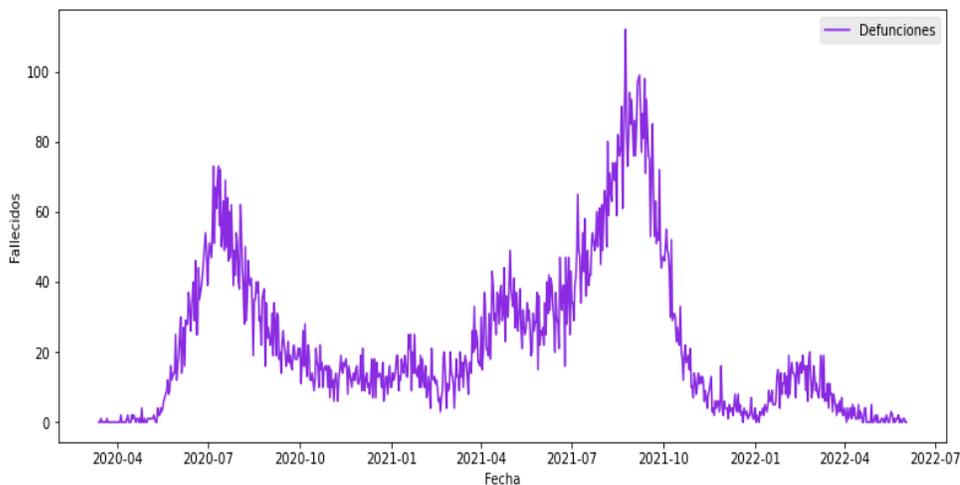
Figura 58. **Distribución de casos recuperados en Guatemala**



Fuente: elaboración propia, usando Python, utilizando datos del Ministerio de Salud Pública y Asistencia Social (MSPAS).

Vale la pena destacar el salto importante que se dio de los casos recuperados en julio 2020, este salto responde al cambio de metodología en la estimación de casos recuperados que hubo en ese momento. Es importante resaltar que los casos recuperados son una estimación por parte del MSPAS.

Figura 59. **Distribución de fallecimientos en Guatemala**



Fuente: elaboración propia, usando Python, utilizando datos del MSPAS.

De la imagen anterior, se destaca, el fuerte descenso de la cantidad de casos fallecidos en Guatemala, esto a pesar de que los casos confirmados se hayan mantenido similares en el pico de agosto 2021 y febrero 2022.

Una respuesta a este evidente descenso en la tasa de mortalidad del virus es el inicio del proceso de vacunación en Guatemala, que inició a ser masivo alrededor de agosto 2021.

Lo anterior da un panorama muy general del proceso epidémico vivido en Guatemala, desde el momento del primer caso de COVID-19 en marzo de 2020

hasta principios de junio de 2022. La tabla I: *Acciones del Estado de Guatemala como medidas en pro de la reducción de casos de COVID-19* utilizada en el planteamiento del problema, muestra como algunas acciones del gobierno en efecto redujeron la cantidad de casos positivos, mostrando la consistencia entre lo que se ilustró en las 3 figuras anteriores y las acciones del Estado.

4. DISCUSIÓN DE RESULTADOS

4.1. Análisis interno

A continuación, se desarrollan los resultados obtenidos en el capítulo anterior, con un enfoque interno de la investigación.

4.1.1. Parámetros de transmisión, recuperación y fallecimiento

La naturaleza de la investigación llevó a que se analizaran dos escenarios de confinamiento, el primer punto a discutirse será el confinamiento estricto.

4.1.2. Confinamiento estricto

En esta investigación se ha mencionado que el confinamiento estricto se definió para la ventana temporal que abarca desde el momento que surgió el primer paciente en Guatemala hasta finales de julio de 2020.

Las razones de haber escogido esta ventana temporal es que en este momento se cuentan con condiciones homogéneas en cuanto al confinamiento, restricción de movimientos, reuniones de cualquier índole, incluso el aeropuerto internacional estuvo cerrado.

La figura 9 que se ilustra en la sección de resultados muestra que este período de confinamiento estricto se puede subdividir en 3 subetapas, en el período inicial que dura hasta principios de mayo de 2020, este es el que tuvo el período más estricto de confinamiento, y de hecho derivado de esto se puede observar la cantidad reducida de casos.

El segundo período se puede observar que inicia a principios de mayo y finaliza a mediados de junio del mismo año. Este período inicia con la reducción de restricciones en las ciudades, pero un aumento de restricciones de movilización interdepartamentales.

El último período inicia a mediados de junio y finaliza a finales de julio, se puede observar un comportamiento al alza de los casos derivado de una menor restricción a la movilización, actividad económica e interacción social.

Se puede observar que, durante esta etapa inicial de la pandemia en Guatemala, los casos positivos no superaron los 1,400 casos en un día.

La figura 10, que muestra la cantidad de casos recuperados por su parte cambia mucho respecto de los casos confirmados, se puede observar 17,000 casos recuperados en un solo día. La principal razón de esto se deriva de que los casos confirmados son una estimación, y la metodología de la estimación cambió en este período inicial de la pandemia en Guatemala.

La figura 11, muestra la distribución de casos fallecidos. Para este período tiene una forma más semejante a la de una campana. Vale la pena destacar que para el estado fue más fácil durante este período rastrear a los casos fallecidos, que, los casos confirmados y recuperados, principalmente por los casos asintomáticos y los casos que no se reportaron.

Durante este período no se pasó de los 100 casos fallecidos a nivel diario, en esta fase inicial de la pandemia, aún no existía ninguna vacuna en el mundo.

Para el análisis de la incidencia de los casos confirmados sobre los casos recuperados, se tienen las figuras 12 y 13. La figura 12 muestra que, a los 25 días de haber sido confirmado, la mayoría de las personas se recuperaba.

Se entiende que existe una relación causal de los casos confirmados sobre los casos recuperados, se tiene que hacer ver que los casos confirmados son vienen del reporte que día a día era realizado por el MSPAS en función de las pruebas de COVID-19 positivas.

La figura 13 por su parte, muestra que, a lo largo del tiempo, la correlación siempre fue significativa.

Las figuras 14 y 15 muestran la incidencia de los casos recuperados sobre los casos fallecidos. Se puede observar, que naturalmente, la incidencia de los casos confirmados, sobre los casos fallecidos, es más rápida que sobre los casos recuperados. Es decir, que los casos fallecidos, tienden a ser más rápidos que los casos confirmados. Las correlaciones más fuertes se encuentran entre 0.15 y 0.2, entre los días 10 y 20 después de confirmados.

Las figuras 16 y 17 que se muestran en la sección de resultados, ilustran la cantidad de casos confirmados, recuperados y fallecidos para el escenario en el que se tuvo un confinamiento estricto, esta es otra perspectiva que las figuras 9-11 de esta misma sección ya ilustraron anteriormente. El propósito de exponerlas es mostrar los resultados consistentes desde ambas perspectivas.

El análisis de S.T. descansa sobre los supuestos de la estacionariedad al menos en sentido débil de los procesos estocásticos, por esta razón es que se debió de realizar una primera diferenciación a las S.T. mostradas en las figuras 16 y 17 que dieron lugar a las figuras 18 y 19. Las pruebas de Dickey Fuller,

mostradas en la tabla III, demuestran el rechazo de la hipótesis nula de una raíz unitaria.

El modelo 1, es el resultado de la serie de transformaciones que se realizaron sobre las S.T. Sobre el modelo 1 se puede destacar que, por la serie de transformaciones hechas, la interpretación de los parámetros y su influencia sobre la variable dependientes es compleja.

El principal detalle por mencionar es que el modelo, proporciona evidencia estadística (con un 90 % de nivel de confianza), que, en los primeros momentos de la pandemia en Guatemala, un caso confirmado de COVID-19 se resolvía entre 16 y 24 días.

Dado que el coeficiente más significativo es el de los rezagos de los casos confirmados 24 días antes de los casos recuperados, se podría inferir, que la mayoría de los casos confirmados, pasaban a ser casos recuperados en este lapso.

Se destaca que la tabla V sustenta que el modelo cumple con los supuestos, derivado de la distribución del residuo y su homocedasticidad en el tiempo. En cuanto a la correlación Todos los valores están por debajo de 0.2 y están dentro del intervalo de confianza de 95 %, que implica ausencia de auto correlación en el término del residuo, apreciándose en la imagen 22.

El análisis de estadística paramétrica mostró que la recuperación tomaba en torno a los 25 días. Esto demuestra la consistencia de ambos análisis.

El siguiente modelo por discutir es el de la incidencia de casos confirmados, sobre los casos fallecidos.

El modelo 2 muestra que para los casos fallecidos de COVID-19 en Guatemala para el primer escenario de confinamiento, los casos confirmados tenían una influencia que iba desde los 2 días de haber sido confirmados, hasta los 29 días.

El resultado anterior, muestra la variabilidad de la incidencia de los casos positivos, sobre los fallecimientos, esto pudo haber sido por factores que van desde el rezago de la información publicada, hasta que los individuos son heterogéneos y por tanto la resistencia hacia el virus varía de individuo a individuo.

Las figuras 23 a la 25 proporcionan evidencia de forma visual de la tendencia a la normalidad del término de residuo, no autocorrelación y homocedasticidad, la tabla VI, demuestra estadísticamente estos supuestos y aseguran que se está ante un modelo estadístico confiable.

Esta subsección de la discusión se finaliza mencionando los resultados resumidos en la tabla VII, en donde se puede apreciar, aunque no una convergencia a valores iguales, la similitud de los resultados, mostrando consistencia y por tanto dando a entender que la perspectiva de S.T. o la de análisis paramétrico son viables para poder abarcar al problema que en esta investigación se abordó.

4.1.3. Confinamiento laxo

El confinamiento laxo para esta investigación abarcó el período de julio de 2021 a finales de ese mismo año. La razón de haber seleccionado esta ventana temporal es por el hecho de que, para este punto del tiempo, las restricciones a

la movilidad, reuniones y eventos sociales eran mínimas, así como que esta ventana del tiempo coincide con el inicio de la vacunación.

El inicio de la vacunación en el país tuvo una incidencia en las tasas de mortalidad, esto está respaldado en los resultados, así mismo, la percepción de riesgo del virus cambió, dando lugar a que los parámetros que gobernaron el proceso epidémico también hayan cambiado.

La figura 26 de la sección de resultados ilustra el comportamiento de los casos confirmados durante el confinamiento laxo.

Se puede observar que, existieron momentos que sistemáticamente no se reportaron casos, esta ausencia de reporte de casos probablemente no implica ausencia de casos confirmados, esto se ve reflejado en como sistemáticamente los días subsiguientes a los días con ausencia de reportes crece el número de casos reportados.

Otra característica que reportar es que la distribución de casos para el confinamiento laxo, derivado de que es ya 1 año 3 meses después del primer caso, parece tener una mejor forma de campana que la distribución de casos durante el confinamiento estricto.

Vale la pena notar, que, en este período, el máximo de casos llegó casi a los 6,000 reportes en un solo día, alrededor de 4 veces lo que se llegó a reportar en el máximo del primer escenario de análisis en esta investigación.

La figura 27 muestra la distribución de casos recuperados en el confinamiento laxo. Si se compara esta distribución, con la del confinamiento

estricto, se puede observar, que, para este caso específico, ya existía un consenso respecto de cómo estimar este tipo de casos.

Esta distribución, por su naturaleza presentó un desfase en tiempo respecto de la distribución de confirmados, pues un caso confirmado, tiene una relación causal sobre los casos recuperados.

Al igual que la distribución pasada, aunque con mucha menor medida, se puede observar que existen días con ausencia de casos recuperados, en los cuales, los días subsiguientes se reportó sistemáticamente una mayor cantidad. La mayor cantidad de casos reportados para este período ascendió a los 8,000 casos recuperados.

La aseveración anterior implica que, durante el máximo, se recuperó más gente de lo que se enfermó, y naturalmente esto generó un descenso marcado en la curva de casos positivos en el último trimestre del año 2021.

La figura 28 muestra la distribución de casos fallecidos para el confinamiento laxo. Esta distribución, pareciera no diferir mucho de la distribución de muertes en el confinamiento estricto, más allá de que la campana en confinamiento estricto parece que tiene una tendencia al descenso al final, mientras que, en el confinamiento laxo, si se puede ver la forma en que descendió.

Otro efecto importante por hacer notar es que la cantidad de muertes tampoco difiere mucho entre el confinamiento laxo y el estricto, esto a pesar de que los casos confirmados para el confinamiento laxo hayan alrededor de 4 veces mayores que para el confinamiento estricto. Indudablemente, existe un efecto de la vacunación en la población para las muertes.

Se puede observar que esta distribución también tiene de forma sistemática momentos que no se presentan casos. Vale la pena destacar, que evidentemente no existió un cambio de metodología en el conteo de las muertes del escenario estricto al laxo, esto podría ser por que la naturaleza del evento permite hacer más fácil el seguimiento de parte del estado.

Las figuras 29 a la 31, ilustran las distribuciones que son producto de la transformación del suavizamiento mediante una media móvil de una semana. Estas transformaciones reducen los sesgos que pudieron haber sido inducidos por la forma en que sistemáticamente se dejaron de reportar casos en algunos días específicos de la pandemia durante el confinamiento laxo.

Luego de generadas las transformaciones, se hace necesario entender la incidencia de los casos confirmados sobre los casos recuperados y fallecidos. Por esta razón se realizó el análisis de correlación en el tiempo.

Las figuras 32 y 33 muestran que, para el caso del confinamiento laxo, la correlación de los rezagos de los casos confirmados con los casos recuperados es 25 días. No existe un día tan marcado como en el confinamiento estricto.

A pesar de que la correlación temporal no tiene tan claro un punto específico de la incidencia temporal de los casos confirmados sobre los recuperados, la prueba de Ljung-Box, hace saber que a partir del décimo primer rezago se inicia a tener significancia estadística.

Las figuras 34 y 35, muestran la incidencia de los casos confirmados sobre los fallecidos. Comparado con el confinamiento estricto, la correlación temporal de los casos positivos con los casos confirmados es mucho más estable, de

manera intuitiva, se entiende que la correlación es positiva y fuerte hasta aproximadamente el rezago 35.

El enunciado anterior implica que los casos que fallecieron por Covid-19 en el contexto del confinamiento laxo, pudieron darse en los primeros 35 días luego de haber sido confirmados. Esta ventana temporal tan amplia, obliga a que sea necesaria puntualizar sobre el día más probable de muerte, a través de análisis de S.T.

Otro punto por destacar es que la correlación temporal, indicaría que un buen modelo de S.T. para entender la incidencia incluiría términos de media móvil, para esta investigación no se utilizó términos de medias móviles, la razón, es que estos términos son una dependencia del residuo, y la interpretación del residuo se volvería más compleja y está fuera del alcance de los objetivos, una investigación posterior, podría incluir estos términos.

La tabla VIII muestra los resultados del análisis paramétrico, se entiende que para esta ventana temporal los rangos de influencia de los casos confirmados sobre los casos recuperados y fallecidos son mucho más amplios y, por tanto, se hace necesario el análisis de S.T.

Las figuras 36 y 37 son la representación de las S.T. de los casos confirmados, recuperados y fallecidos, esta es otra forma de representar las figuras 29-31. Desde esta perspectiva, se hace más fácil observar, el desfase que tiene la distribución o S.T. de los casos recuperados respecto de los casos confirmados, esto es por la causalidad de los confirmados hacia los recuperados.

Las S.T. de las figuras 35 y 37 requirieron de transformaciones. El inconveniente de las transformaciones es que hacen más difícil la interpretación

de los parámetros, sin embargo, más que interpretar parámetros, lo que se busca en esta investigación es entender la incidencia de los casos confirmados sobre los fallecidos y recuperados para poder alimentar con los parámetros de estos análisis al modelo SEIR.

La figura 38, ilustra el resultado de las transformaciones realizadas sobre las S.T., para poder estimar modelos que fueran estadísticamente confiables. Más que el análisis de la incidencia de los parámetros sobre la variable dependiente, lo que se busca entender es la incidencia de casos confirmados sobre casos recuperados y fallecidos.

Los resultados que se muestran en la tabla IX, confirman que en efecto se cuentan con S.T. estacionarias en sentido débil que permiten generar modelos que están estadísticamente bien fundamentados.

El primer modelo por analizar es el de la incidencia de los casos confirmados, sobre los casos recuperados. El modelo 3, proporciona evidencia estadística (con un 99 % de nivel de confianza), que, en los primeros momentos de la pandemia en Guatemala, un caso confirmado de COVID-19 se resolvía entre 8 y 25 días.

Dado que el coeficiente más significativo es el de los rezagos de los casos confirmados 25 días antes de los casos recuperados, se podría inferir, que la mayoría de los casos confirmados, pasaban a ser casos recuperados en este lapso.

Nuevamente se destaca la inclusión de rezagos de los casos confirmados, para de obtener una especificación correcta del modelo que elimine la autocorrelación de los residuos.

El análisis de estadística paramétrica mostró que la recuperación tomaba entre 10 y 25 días. Mostrando consistencia entre ambas perspectivas.

Las figuras 39-41 proporcionan visualmente una evidencia el residuo se distribuye de forma normal, es no auto correlacionado y homoscedástico la tabla X, muestra la evidencia estadística de lo que se expuso visualmente.

El último modelo que se discutirá es el de la incidencia de los casos confirmados, sobre los fallecidos, este modelo muestra que para los casos fallecidos de COVID-19 en Guatemala para el confinamiento laxo, los casos fallecidos, tomaban 15 días desde el momento de ser un caso confirmado hasta ser un caso fallecido.

Las figuras 42 a la 44, brindan pruebas visuales de la tendencia a la distribución normal, no autocorrelación y homocedasticidad del término del residuo del modelo 4 que buscaba comprender la incidencia de los casos confirmados sobre los casos fallecidos en el confinamiento laxo. La tabla XII, respalda la evidencia visual, con los resultados de las pruebas estadísticas que confirman lo que aquí se discute.

Vale la pena destacar en la autocorrelación que a pesar de que, en torno al séptimo rezago del residuo, exista un pico, que implique que existe autocorrelación en ese punto, los otros “lags” están dentro del área que envuelve a la significancia, por tanto, se afirma que los residuos no están autocorrelacionados al menos en los primeros 7 rezagos.

El último resultado a discutir acerca de los parámetros de transmisión, recuperación y fallecimiento es la comparación que se da en la tabla XII, que resume los hallazgos de las aproximaciones desde el punto paramétrico y de S.T.

Para el confinamiento estricto, en el caso puntual del parámetro de recuperación, se observa la consistencia de los resultados, pues del lado paramétrico se obtiene el tiempo aproximado de recuperación de 25 días, mientras en las S.T., se tiene un lapso entre 16 y 24 días. Este parámetro puede ser el más engañoso, principalmente, porque la cantidad de casos recuperados era una estimación del MSPAS.

Para el parámetro de la defunción en el confinamiento estricto se tiene un desvío entre lo estimado con estadística paramétrica y el modelo de S.T. Una pone un máximo de 18 días (aproximación paramétrica) mientras lo estimado por modelos de S.T. dice que son 29 días.

No obstante, la observación anterior, se puede rescatar que el punto medio de ambas aproximaciones converge a valores similares, para el análisis paramétrico se tiene una ventana temporal entre 9 y 18 días, dando un punto medio de 14 días. Por su parte el análisis de S.T. propone un intervalo temporal mucho más amplio, que se ubica entre 2 y 29 días, el punto medio de esta ventana temporal también se ubica en 14 días.

Con el resultado anterior, se puede llegar a concluir que, en promedio, los casos de fallecimientos en el confinamiento estricto tomaban alrededor de 14 días para llegar a definirse.

En el confinamiento laxo, para la recuperación, desde las dos perspectivas se tienen resultados similares con el límite superior de días, situándose en 25 para ambas aproximaciones, de igual forma en el límite inferior es muy parecido, dando como respuesta 10 días para la perspectiva paramétrica y 8 para la de S.T.

Nuevamente la defunción parece divergir en el análisis de ambos escenarios, y es que para el análisis con modelos de S.T. se obtuvo una estimación exacta de 15 días, por otro lado, el análisis paramétrico arroja evidencia estadística que sugiere que los casos de defunción en la ventana temporal del confinamiento laxo se resolvían entre 9 y 35 días.

No es posible observar una distribución de los tiempos en los que en efecto se dio una muerte, pero es posible estimar, es que el punto medio de la resolución de muertes desde la aproximación paramétrica era de 22 días, es decir, 7 días más de lo que el modelo de S.T. sugiere.

La posible razón de esta divergencia se podría explicar porque la realización del modelo de S.T. se fundamentó en las transformaciones que hacían al modelo estadísticamente confiable, pero estas transformaciones pudieron haber tenido una incidencia en la interacción de las variables en este modelo.

4.1.4. Pronósticos de los casos confirmados, recuperados y fallecidos para el confinamiento laxo

La presente sección discute todas las implicaciones del análisis en el confinamiento laxo.

4.1.4.1. Pronósticos del modelo

Derivado que el modelo SEIR fue utilizado para pronosticar el período de confinamiento laxo, y este período incluye el período de vacunación en Guatemala, es necesario incluir al parámetro R_0 (que es uno de los parámetros que guía el proceso epidémico) es cambiante en el tiempo.

La manera de poder hacer a este parámetro cambiante en el tiempo es con la inclusión de una función sigmoïdal, mostrado en la ecuación 31 de la sección de resultados.

La ecuación 31, es la responsable de describir el movimiento en el tiempo de la figura 46, que parte de un R_0 inicial de 4 y llega a un R_0 final de 3.5, estos resultados son un parámetro que no tienen una evidencia estadística, sino son el resultado de un proceso de optimización y por tanto es susceptible a una mejora en futuras investigaciones.

El comportamiento cambiante de R_0 en el tiempo es uno de los responsables de la dinámica de la pandemia para la ventana temporal que engloba al confinamiento laxo de esta investigación.

La figura 45, describe el comportamiento de los casos susceptibles, expuestos, infectados, recuperados y fallecidos, no solo el parámetro R_0 modelado de forma determinista en esta investigación es el encargado de la forma de las funciones, también lo son los parámetros estimados con el análisis de S.T.

En la sección anterior de la sección de resultados se discutía que existía una leve discordancia entre los parámetros obtenidos por medio del análisis de S.T. y aquellos que el análisis paramétrico arroja, al menos para los casos fallecidos. La razón de haber utilizado al análisis de S.T. es que, este parámetro es puntual, es decir no tiene un intervalo de días.

La figura 47 de la sección de resultados, ilustra el comportamiento de los casos susceptibles en Guatemala, como se mencionó brevemente en la descripción de la figura, se observa un comportamiento de caída exponencial.

Este comportamiento de caída exponencial se hace cierto solo bajo el supuesto de que aquellas personas que fueron contagiadas no pueden volver a contagiar nuevamente, este supuesto puede ser un motivo a fortalecer en investigaciones futuras, pues se sabe que, aunque existe un período de inmunidad post COVID, es posible volver a contagiarse. Por tanto, la gráfica anterior, puede tener un comportamiento oscilante en el tiempo y no monótonamente decreciente como se planteó aquí.

El modelo SEIR, planteado en esta investigación no toma en cuenta que los individuos susceptibles pueden retornar a este estado en el tiempo, sin embargo, en términos generales, la forma de la curva es semejando a lo que se planteó aquí.

Las figuras 48 y 49, ilustran lo que el modelo SEIR predijo con las condiciones dadas de los casos infectados y expuestos correspondientemente. La cantidad de casos expuestos se refiere a aquellos individuos que ya fueron contagiados, pero que aún no cuentan con síntomas ni pueden contagiar a otros, los casos infectados por su parte son los casos que presentan síntomas y pueden esparcir el virus por la sociedad a través de sus interacciones sociales.

La variable de casos expuestos es un causal de la cantidad de casos infectados, el modelo, no puede tomar en cuenta a los casos que son asintomático y nunca pasan del estado expuesto al infectado. Una de las razones por la cual los casos expuestos son menores que los casos infectados, en este caso es por el parámetro de recuperación, y el parámetro de incubación, pues toma mucho más tiempo recuperarse que enfermarse.

El párrafo anterior, implica que los individuos estén más tiempo en el estado infectado, que, en el estado expuesto, promoviendo que no solo exista un

desfase, sino que el volumen de casos infectados sea mayor que los casos expuestos.

A pesar de que más adelante, se hará un contraste de lo que pronosticó el modelo SEIR con lo que se reportó, puede hacerse desde ya una corta mención de que se destaca la alta cantidad de casos infectados que se pronostican en el pico (casi 2.5 millones de personas), mientras lo que se observó fueron realmente solo 6,000 casos.

Una de las razones, puede ser la asimetría de información que existe entre todos los agentes sociales, llevando a tener una subestimación de los casos confirmados, otra razón, puede ser el supuesto del R_0 que se tomó para el modelo, así como su evolución en el tiempo, además de las interacciones sociales que se dieron realmente.

Las figuras 50 y 51 muestran la función de acumulación de casos recuperados y fallecidos.

Contrariamente a la función acumulada de casos susceptibles, los casos recuperados tienen una tendencia al alza, esto porque en el modelo se asume que ningún caso recuperado pasa a ser susceptible. Realmente esto no es así, y por tanto la función de acumulación no debería de tener un comportamiento monótonamente creciente. Si no, más bien, debería de tener fluctuaciones en función del tiempo, una futura investigación podría cambiar el parámetro que se tiene de la función de casos recuperados y hacerla oscilante.

Otra observación importante del resultado que ilustra la figura 50, es que los casos recuperados, son causados por los casos infectados, porque no puede existir un caso que haya sido recuperado, sino estuvo infectado antes. Dada esta

naturaleza de causalidad, se entiende que existe un desfase temporal de esta función de acumulación con respecto de los casos infectados.

Los casos fallecidos en la figura 51 se muestran como una dependencia de acumulación que ilustra el desarrollo en el tiempo, se destaca la alta cantidad de casos fallecidos pronosticados, esto es producto de la posible sobrestimación que se hace en el modelo desde los casos expuestos. Nuevamente la asimetría de información existente dentro de la sociedad podría estar incidiendo entre lo pronosticado y lo observado.

4.1.4.2. Contraste de los pronósticos

Las figuras 52 a la 54 muestran el contraste de lo que se observó respecto de lo que el modelo SEIR predijo, evidentemente se puede observar una sobrestimación por parte del modelo para los casos confirmados, recuperados y fallecidos.

A pesar de esta sobrestimación, los picos de casos contagiados, recuperados y fallecidos pronosticados por el modelo están bien ubicados temporalmente respecto de la ubicación temporal real. Es decir, el modelo pronosticó bien el punto de donde se pondría mayor presión al sistema de salud.

La siguiente tabla expone cuales pudieron haber sido las posibles razones de la sobrestimación por parte del modelo.

Tabla XXI. **Posibles razones de la sobrestimación por parte del modelo SEIR**

Razón	Discusión
Asimetría de información.	<p>Una razón que puede influir en el desvío tan alto de la predicción del modelo respecto de lo observado es la asimetría de información existente entre los agentes de la sociedad.</p> <p>Naturalmente el estado no es capaz de poder reportar todos los confirmados de COVID-19, lo que implica que el reporte confirmado, realmente son una porción de lo sucedido realmente.</p> <p>Lo anterior repercute directamente, en que los pronósticos del modelo se vean más altos, a pesar de que el modelo esté sobrestimando, podría ser el caso que el desvío sea menor si se contrastara con los casos ocurridos realmente.</p>
La población susceptible es menor en Guatemala.	<p>Otra posible razón es que la población susceptible en el país realmente sea menor a lo que se utilizó en la fase de experimentación para obtener el resultado.</p> <p>Para la fase de experimentación se eliminó al 37% de la población, el argumento fue que esta porción de la población tenía una menor cantidad de contactos con otras personas de la sociedad por la etapa de vida que estaba viviendo.</p>

Continuación de la tabla XXI.

Razón	Discusión
<p>Utilización de un parámetro R_0 errado.</p>	<p>El parámetro R_0 no está sustentado estadísticamente, más bien la utilización de este está fundamentada en que este fue el parámetro de la variante delta, la cual era predominante en el país para la ventana temporal de análisis.</p> <p>Se podría en otra investigación estimar un parámetro R_0, teniendo en consideración el parámetro gamma que se obtuvo del análisis de S.T., y estimando un parámetro beta que es el producto de la tasa de contacto y el riesgo de infección.</p> <p>El parámetro R_0 final, pudo haber estado sobrestimado.</p> <p>El descenso de este parámetro pudo haber estado bien estimada por el hecho de que los puntos en el tiempo en el que se dan los puntos máximos de contagios, recuperados y fallecidos si están bien predichos por el modelo</p>

Fuente: elaboración propia

Las razones expuestas anteriormente, son las que pueden haber causado que el volumen de personas contagiadas, recuperadas y fallecidas predichas por el modelo hayan sido sobrestimadas, una futura investigación podría cambiar los parámetros iniciales del modelo argumentando nuevos factores sociales considerados, o los que en esta discusión fueron mencionados.

4.1.5. Análisis de correlación entre la actividad económica y la cantidad de casos positivos

Se discutirá la correlación de la actividad económica y casos positivos de COVID en Guatemala en el confinamiento estricto.

4.1.5.1. Correlación entre la actividad económica y casos positivos en confinamiento estricto

La tabla XIV muestra el comportamiento de la transformación propuesta para el IMAE y la cantidad de casos de COVID. Lo expuesto revela que en efecto existió un descenso de la actividad económica en el período del confinamiento estricto, esta caída, fue inducida por las medidas que tenían por objetivo la contención de la dispersión del virus en la sociedad guatemalteca.

La figura 55 muestra, que, para este período, se tenía una relación inversa entre el crecimiento de la cantidad de contagios y el crecimiento de la actividad económica, esto contradice lo que se intuía inicialmente de que la relación era directa.

Una de las razones de tener la relación ya fue expuesta, es que el estado, al inicio de la pandemia en Guatemala, impuso las medidas de confinamiento estricto, esto implicó un decaimiento de la actividad económica, y no permitió que

los casos avanzaran, sin embargo, para efectos del análisis estas medidas no muestran la verdadera relación.

La verdadera relación se hubiese podido observar bien, si como primer punto, no se hubieran puesto medidas de confinamiento, promoviendo un aumento de casos y manteniendo a la actividad económica en sus niveles naturales, para luego introducir las medidas de confinamiento que hubieran implicado una disminución de casos y también la disminución del IMAE.

A pesar de que no se puede observar la verdadera relación existente entre casos positivos y el IMAE por la forma en que se introdujeron las medidas de confinamiento, uno de los papeles del estado es la protección de la vida y por tanto estas medidas fueron las adecuadas.

La relación sintética capturada en la figura 56 es mejor descrita por una línea de tendencia logarítmica, esto implica que la estimación del C.C. estimado a partir de los datos obtenidos no es la mejor forma de medir la asociación, pues la correlación busca grados de asociación lineal y para este caso la relación parece no estar bien explicada de forma lineal.

A pesar de que el C.C. no sea la mejor aproximación para entender la asociación existente, genera una noción de cuan asociadas estuvieron estas dos variables para la ventana temporal elegida.

4.1.5.2. Correlación entre la actividad económica y casos positivos en confinamiento laxo

Para este punto del tiempo, es posible apreciar una relación más intuitiva, que si coincide con aquella que se mencionó al inicio de esta investigación. Una

relación positiva implica que un aumento de casos de COVID-19 en el territorio nacional se asocia con un aumento en el índice del IMAE.

La razón de lo anterior es que la actividad económica es una consecuencia del grado de interacciones que exista entre los agentes económicos de una sociedad y a mayor interacción de los agentes de una sociedad, mayor será la cantidad de agentes expuestos al coronavirus.

La figura 56 muestra la relación positiva existente entre el crecimiento de casos de COVID-19 y el crecimiento del IMAE interanual. La tendencia que mejor explica a la relación no es una tendencia lineal, sino, una tendencia cuadrática.

El resultado anterior implica nuevamente que, el nivel de asociación medido por el C.C. de Pearson, no esté capturando toda la asociación existente entre estas dos variables, no obstante, es una buena forma de entender la relación que existió entre ambas variables.

La tabla XVI de la sección de resultados resume los hallazgos encontrados del análisis de correlación existente entre las variables de casos confirmados y el IMAE para el confinamiento laxo y el estricto, ambos confinamientos muestran que a pesar de que una aproximación lineal no sea la más adecuada para la medición de esta relación, se tiene una alta correlación.

Lo anterior tiene sentido, pues, aunque no se puede hablar de una relación causal, se puede entender que, dada la configuración social necesaria para el crecimiento económico, es necesaria la interacción, misma actividad que promueve el aumento de contagios.

Con el C.C., se logra generar una idea de cuál es el costo económico y social de generar medidas de confinamiento, así como el costo humano de mantener la economía abierta, implicando que son medidas que entran en conflicto.

4.2. Análisis externo

Respecto a la utilización de medidas de confinamiento dinámicas Kolumbu y Nisan, (2021) concluyeron que, en la presencia de nuevas infecciones, este tipo de medidas son más eficientes que las medidas de confinamiento dinámicas, así mismo, el rastreo de infecciones mejora la eficiencia, promoviendo que se reduzca la mortalidad y los costos económicos.

Angulo *et al.*, (2021), mostraron que el modelo SEIR reproducía de forma eficiente el comportamiento dinámico de la pandemia del COVID-19, sin embargo, el agregar un parámetro de percepción de riesgo individual ayuda a mejorar la cantidad de casos por agrupación. Esta percepción de riesgo debería de ser variable y una dependencia de la mortalidad registrada, que a su vez depende del tiempo y del punto de la curva en la cual se esté.

La utilización de medidas de confinamiento estrictas al inicio de cualquier epidemia son una medida efectiva en la contención de los casos, sin embargo, en el largo plazo, no es una solución implementable, pues entra en conflicto con el desempeño de la actividad económica, este precepto es el que guío a la presente investigación. Grimm, Mengel, y Schmidt, (2021) partieron de la misma idea y llegaron a concluir que una combinación de medidas ajustables que busquen la protección de los grupos más vulnerables previene un aumento de los casos mortales dentro de cualquier sociedad.

CONCLUSIONES

1. Se estimaron los parámetros de recuperación y fallecimiento que gobernaron al proceso epidémico del COVID-19 en Guatemala a través de una aproximación paramétrica y con modelos S.T. Los parámetros en confinamiento estricto para la defunción y recuperación oscilan entre 18 y 25 días respectivamente, para el confinamiento laxo los parámetros de defunción y recuperación están entre 12 y 25 días respectivamente, aunque, existen desviaciones entre el análisis paramétrico y de series temporales.
2. El modelo SEIR sobrestima los casos confirmados, recuperados y fallecidos de COVID-19 en Guatemala en el confinamiento laxo, en el punto máximo de casos confirmados, recuperados y fallecidos, el modelo predice 2.5 millones, 120 mil y 3 mil personas respectivamente en el confinamiento laxo. Sin embargo, a pesar de esta sobrestimación, se tiene una buena herramienta para estimar la forma de la dinámica del proceso epidémico, así mismo, esta sobrestimación respecto de lo reportado es dada por la asimetría de información natural dentro de una sociedad.
3. La correlación obtenida entre el aumento de casos positivos y el descenso del IMAE, en el confinamiento laxo, es negativa, esto es por la forma en que el estado abordó la problemática de la pandemia en un inicio, generando que se tenga de forma artificial una relación negativa con un índice de correlación de Pearson de -0.79. Por otro lado, el confinamiento laxo, presenta una relación lineal positiva con un índice de correlación de Pearson de 0.84, que es la esperada, pues se entiende que una mayor

interacción social promueve a la actividad económica, pero también incide sobre la cantidad de casos positivos.

4. Se entiende que las medidas de confinamiento estrictas tienen un impacto negativo en el desempeño de la economía guatemalteca, pero implica una reducción de contagios, por el otro lado, el confinamiento laxo, implica un mejor desempeño de la economía nacional, pero con el costo de una mayor tasa de contagios, que pone mayor presión al sistema nacional. El modelo SEIR alimentado con los parámetros en este trabajo, es una herramienta que si bien, sobrestima la cantidad de casos, permite entender la dinámica del proceso epidémico, promoviendo una mejor toma de decisiones en función del momento del proceso epidémico en el cual se esté, permitiendo que, se puedan proponer medidas de confinamiento dinámicas que respondan a proteger a la población sin sacrificar el desempeño de la economía.

RECOMENDACIONES

1. Mantener un nivel de vigilancia epidemiológica en el país como el que se tenido en los últimos dos años para condiciones o indisposiciones que sean de interés público. De esta manera es posible obtener bases de datos de calidad que permitan realizar estimaciones de parámetros de recuperación y fallecimiento a nivel tanto agregado (país) como granular (departamento o municipio) que faciliten el entendimiento de la demanda de salud pública dentro del país.
2. Utilizar al modelo SEIR y sus pronósticos, como una herramienta que permita entender en que punto del tiempo se podrían presentar los picos de casos positivos, y fallecidos de COVID-19 en Guatemala y de esta manera generar medidas de confinamiento dinámicas que liberen la presión al sistema de salud público.
3. Profundizar en el análisis de correlación existente entre el crecimiento de la cantidad de casos positivos y el crecimiento de la actividad económica a través de métodos no lineales.
4. Utilizar la sistematización propuesta en esta investigación como un método de vigilancia epidemiológica que permita formular medidas de confinamiento dinámicas que puedan anticipar los momentos de mayor presión sobre el sistema de salud.

REFERENCIAS

1. Alarcón, J. (abril 2009). Epidemiología: conceptos, usos y perspectivas. *Revista Peruana de Epidemiología*, 13(1), 1-3. Recuperado de <https://www.redalyc.org/articulo.oa?id=203120866002>
2. Angulo, W., Ramírez, J., Cecchis, D., Primera, J., Pacheco, H., y Rodríguez-Roman, E. (agosto 2021). A modified SEIR model to predict the behavior of the early stage in coronavirus and coronavirus-like outbreaks. *Nature*, 11(16331), 1-12. Recuperado de <https://www.nature.com/articles/s41598-021-95785-y>
3. Beaglehole, R., Bonita, R., y Kjellström, T. (2003). *Epidemiología Básica*. Washington, D.C.: Organización Panamericana de la Salud.
4. Box, G., y Jenkins, G. (junio 1976). Time series analysis: Forecasting and control. *Holden Day*, 12(9) 575-592.
5. Castillo, C., Mujica, O., Loyola, E., Canela, y Jaume. (2011). *Módulo de principios de epidemiología para el control de enfermedades*. Washington: Organización Panamericana de la Salud.
6. Chung, N., y Chew, Y. (mayo 2021). Modelling Singapore COVID-19 pandemic with a SEIR multiplex network model. *Nature*, 11(10122), 1-9. Recuperado de <https://www.nature.com/articles/s41598-021-89515-7>

7. Cox, D., y Box, G. E. (mayo 1964). An Analysis of Transformations. *Research methods meeting of society*, 26(2), 211-252. Recuperado de <https://www.jstor.org/stable/2984418>
8. Enders, W. (2015). *Applied econometric time series*. United States: Wiley.
9. Gandolfo, G. (2009). *Economic dynamics*. Berlín: Springer.
10. Geisser, S., y Johnson, W. (2006). *Models of Parametric Statistical Inference*. Wiley.
11. Grimm, V., Mengel, F., y Schmidt, M. (febrero 2021). Extensions of the SEIR model for the analysis of tailored social distancing and tracing approaches to cope with COVID-19. *Nature*, 11(4214), 1-16. Recuperado de <https://www.nature.com/articles/s41598-021-83540-2>
12. He, D., Dushoff, J., Day, T., y Ma, J. (septiembre 2013). Inferring the causes of three waves of the 1918 influenza in pandemic England and Wales. *Proceedings of the Royal Society B*, 280 (1345), 1-7 Recuperado de <https://royalsocietypublishing.org/doi/10.1098/rspb.2013.1345>
13. Kolumbus, Y., y Nisan, N. (agosto 2021). On the effectiveness of tracking and testing in SEIR models for improving health vs. economy trade-offs. *Nature*. 11(16305), 1-14 Recuperado de <https://www.nature.com/articles/s41598-021-95415-7>

14. Krugman, P. (7 de marzo 2020). El caso de un estímulo permanente. *The New York Times* Recuperado de <https://www.nytimes.com/2020/03/07/opinion/the-case-for-permanent-stimulus-wonkish.html>
15. Lederberg, J. (octubre 1997). Infectious disease as an evolutionary paradigm. *Emerging infectious diseases*, 3 (4), 417-423 Recuperado de <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2640075/>
16. Lin, Q., Zhao, S., Gao, D., Lou, Y., Yang, Y., Musa, S., He, D. (abril 2020). A conceptual model for the coronavirus disease 2019 (COVID-19) outbreak in Wuhan, China with individual reaction and governmental action. *Emerging infectious diseases*, 93(7), 211-216 Recuperado de <https://pubmed.ncbi.nlm.nih.gov/32145465/>
17. Monsalve, A., y Harmath, P. (2015). Introducción al análisis de series de tiempo con aplicaciones a la econometría y finanzas. Venezuela: EMALCA.
18. Organización Panamericana de la Salud (2011). *Módulo de principios de epidemiología para el control de enfermedades*. Washington: D.C. Autor.
19. Ramos Ramalho, E. (2019). *Mathematical Models in Epidemiology: Simulating Chagas Disease Transmission and Evaluating the Control Measure*. (Tesis de doctorado). Universidad Rural de Pernambuco, Brasil. Recuperado de <http://www.tede2.ufrpe.br:8080/tede2/handle/tede2/8158>

20. Rincón, L. (2011). *Introducción a los procesos estocásticos*. Ciudad de México: UNAM.
21. Tian, H., Liu, Y., Li, Y., Wu, Y., y Al., E. (mayo 2020). An investigation of transmission control measures during the first 50 days of the Covid-19 epidemic in China. *Science*, 368 (6491), 638-642. Recuperado de <https://www.science.org/doi/10.1126/science.abb6105>
22. Zhou, J., Dong, S., Ma, C., Wu, Y., y Qiu, X. (junio 2021). Epidemic spread simulation in an area with a high density crowd using a SEIR-based model. *Plos One*, 16 (6), 1-19 Recuperado de <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0253220>

APENDICES

Apéndice 1. **Matriz de consistencia**

TÍTULO: PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA		
Problema	Preguntas Investigación	Objetivos
PROBLEMA	General	General
<p>PRINCIPAL</p> <p>Las medidas de confinamiento laxas implican un mejor desempeño de la actividad económica, sin embargo, también exacerban la cantidad de contagios a nivel nacional. Por otro lado, medidas de confinamiento más estrictas reducen la cantidad de personas contagiadas, con el costo de reducir</p>	<p>¿Cómo los pronósticos de contagio de COVID-19 en Guatemala derivado de las distintas medidas de confinamiento impuestas por el gobierno y la tasa de vacunación, impactan en el índice de actividad económica de Guatemala?</p> <p>Específicas</p> <p>¿Cuáles son los parámetros de contagio, recuperación y letalidad de COVID-19 en Guatemala bajo dos distintos escenarios de confinamiento?</p>	<p>Estimar los parámetros que gobiernan el proceso epidémico de COVID-19 en Guatemala y pronosticar contagios y su repercusión en la actividad económica, a través de análisis de S.T., estadística paramétrica y un modelo SEIR para proponer medidas de confinamiento que no entren en conflicto con las metas de crecimiento económicas nacionales.</p>

Continuación apéndice 1.

TÍTULO: PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA		
Problema	Preguntas Investigación	Objetivos
también la actividad económica, de forma intuitiva se entiende que antes del programa de vacunación existía una relación positiva entre la cantidad de contagios y la actividad económica nacional.	<p>¿Cuáles son los pronósticos de contagio, recuperación y muertes de COVID-19 basado en medidas de confinamiento estrictas y totalmente laxas?</p> <p>¿Cómo sería el índice mensual de actividad económica bajo medidas de confinamiento estrictas y totalmente laxas?</p>	<p>Específicos</p> <p>Estimar los parámetros de recuperación y fallecimiento de COVID-19 en Guatemala a través de análisis de S.T. y estadística paramétrica para entender y poder predecir cuál será la dinámica de contagios de COVID-19 en Guatemala, bajo dos escenarios de confinamiento distintos.</p> <p>Pronosticar contagios de COVID-19 en Guatemala a través de un modelo SEIR para obtener la cantidad de casos positivos</p>

Continuación apéndice 1.

TÍTULO: PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA		
Problema	Preguntas Investigación	Objetivos
		<p>recuperados e índice de mortalidad bajo el escenario de confinamiento laxo.</p> <p>Estimar la correlación existente entre el número de casos positivos en Guatemala y la actividad económica basado los dos escenarios de confinamiento propuestos.</p>

Fuente: elaboración propia.

Apéndice 2. **Matriz de coherencia**

TÍTULO: PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA		
Metodología	Conclusiones	Recomendaciones
<p>Enfoque de la investigación: Mixto</p> <p>Diseño de la investigación: No Experimental</p>	<p>Se estimaron los parámetros de recuperación y fallecimiento que gobernaron al proceso epidémico del covid-19 en Guatemala a través de una aproximación paramétrica y con modelos S.T. A pesar de tener leves desviaciones en los resultados, ambas aproximaciones tienden a converger a los mismos parámetros tanto para el confinamiento estricto como para el confinamiento laxo.</p> <p>El modelo SEIR sobrestima los casos confirmados, recuperados y fallecidos de COVID-19 en Guatemala en el confinamiento laxo, sin embargo, el pronóstico del momento en los que se darán los máximos de</p>	<p>Mantener un nivel de vigilancia epidemiológica en el país como el que se tenido en los últimos dos años para condiciones o enfermedades que sean de interés público. De esta manera es posible obtener bases de datos de calidad que permitan realizar estimaciones de parámetros de recuperación y fallecimiento a nivel tanto agregado (país) como granular (departamento o municipio) que faciliten el entendimiento de la demanda de salud pública dentro del país.</p> <p>Utilizar al modelo SEIR y sus pronósticos, como</p>

Continuación apéndice 2.

TÍTULO: PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA		
Metodología	Conclusiones	Recomendaciones
	<p>casos confirmados, recuperados y fallecidos no se desvían de lo observado, esto implica que es una buena herramienta para entender los momentos en los que el sistema de salud puede estar expuesto a una mayor presión.</p> <p>La correlación obtenida entre el aumento de casos positivos y el descenso del IMAE, en el confinamiento laxo, es negativa, esto es por la forma en que el estado abordó la problemática de la pandemia en un inicio, generando que se tenga de forma artificial una relación negativa de con un índice de correlación de Pearson de -0.79. Por otro lado, el confinamiento laxo, presenta</p>	<p>una herramienta que permita entender en que punto del tiempo se podrían presentar los picos de casos positivos, y fallecidos de COVID-19 en Guatemala y de esta manera generar medidas de confinamiento dinámicas que liberen la presión al sistema de salud público.</p> <p>Profundizar en el análisis de correlación existente entre el crecimiento de la cantidad de casos positivos y el crecimiento de la actividad económica a través de métodos no lineales.</p>

Continuación apéndice 2.

TÍTULO: PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA		
Metodología	Conclusiones	Recomendaciones
	<p>una relación lineal positiva con un índice de correlación de Pearson de 0.84, que es la esperada, pues se entiende que una mayor interacción social promueve a la actividad económica, pero también incide sobre la cantidad de casos positivos.</p> <p>La metodología propuesta para la predicción de la dinámica del COVID-19 en Guatemala, resultó en una herramienta que en efecto permite pronosticar el punto del tiempo que representará mayor presión sobre el sistema de salud y por tanto se puedan generar medidas de confinamiento dinámicas que no entren en conflicto con las metas de crecimiento económico ni</p>	<p>Utilizar la sistematización propuesta en esta investigación como un método de vigilancia epidemiológica que permita formular medidas de confinamiento dinámicas que puedan anticipar los momentos de mayor presión sobre el sistema de salud.</p>

Continuación apéndice 2.

TÍTULO: PRONÓSTICOS DE CONTAGIOS DE COVID-19 EN GUATEMALA Y SU CORRELACIÓN CON EL ÍNDICE MENSUAL DE ACTIVIDAD ECONÓMICA		
Metodología	Conclusiones	Recomendaciones
	pongan presión sobre el sistema de salud.	

Fuente: elaboración propia.