

Desarrollo en Python para la evaluación estocástica de armónicos en instalaciones fotovoltaicas

Python development for stochastic evaluation of harmonics in photovoltaic Systems

Johan Manuel Cárdenas-Leal ^A, Josimar Tello-Maita ^B, Agustín Marulanda-Guerra ^C

Modelación Estratégica en Energía y Potencia (MEEP), Universidad Escuela Colombiana de Ingeniería Julio Garavito, Colombia. Orcid: [0000-0001-6895-794X](https://orcid.org/0000-0001-6895-794X)^b, [0000-0001-6739-2641](https://orcid.org/0000-0001-6739-2641)^c. Correo: johan.cardenas@mail.escuelaing.edu.co^a, josimar.tello@escuelaing.edu.co^b, agustin.marulanda@escuelaing.edu.co^c.

Recibido: 08/07/2023. Aceptado: 22/08/2023. Versión final: 27/09/2023

Resumen

Para el análisis de armónicos en sistemas eléctricos de distribución con generación solar fotovoltaica, se hace necesario establecer una metodología estocástica que permita caracterizar, identificar y evaluar el comportamiento de los aportes de corriente de estos sistemas. Este trabajo presenta una metodología basada en las cadenas de Márkov y distribución gaussiana mixta como herramienta de cálculo implementa Python, la cual permite recrear escenarios con alta exigencia computacional debido a los datos obtenidos de irradiancia solar a partir de las mediciones de parámetros eléctricos en el punto común de conexión del sistema fotovoltaico para obtener el comportamiento horario del TDD_i . La metodología propuesta se aplicó en el sistema de generación fotovoltaico de la Universidad Escuela Colombiana de Ingeniería Julio Garavito. Los resultados muestran que los valores de TDD_i están en función de los índices de irradiancia, mientras menor irradiancia se presente mayor será el valor de inyección de corriente armónica.

Palabras clave: Python; Corriente armónica; Sistemas fotovoltaicos; Cadena de Márkov; Distribución Gaussiana.

Abstract

For the analysis of harmonics in electrical distribution systems with solar photovoltaic generation, it is necessary to establish a stochastic methodology to characterize, identify and evaluate the behavior of the current inputs of these systems. This work presents a methodology based on Markov chains and mixed Gaussian distribution as a calculation tool implemented in Python, which allows simulating scenarios with high computational demand due to the data obtained from solar irradiance from the measurements of electrical parameters at the common point of connection of the photovoltaic system to obtain the hourly behavior of the TDD_i . The proposed methodology was applied in the photovoltaic generation system of the Universidad Escuela Colombiana de Ingeniería Julio Garavito. The results show that the TDD_i values are a function of the irradiance indexes; the lower the irradiance, the higher the harmonic current injection value.

Keywords: Python; Current harmonics; Photovoltaic Systems; Markov chains; Mixed Gaussian distribution.

Como citar: J. Cárdenas-Leal, J. Tello-Maita, A. Marulanda-Guerra. “Desarrollo en Python para la evaluación estocástica de armónicos en instalaciones fotovoltaicas” in *XI Simposio Internacional de Calidad de la Energía Eléctrica*, Valledupar: Universidad Nacional de Colombia, Nov. 2023. doi: <https://doi.org/10.15446/sicel.v11.109762>

1. Introducción

Los sistemas fotovoltaicos son una solución a nivel mundial para reducir las emisiones de CO₂ y generar energía eléctrica [1][2]. Sin embargo, se destaca que los inversores electrónicos utilizados en estos sistemas pueden introducir armónicos en la red eléctrica, lo cual puede tener efectos negativos en la calidad de la energía y el funcionamiento de los equipos conectados a dicha red [3]. Para analizar y caracterizar este fenómeno, se propone una metodología estocástica que utiliza un desarrollo basado en funciones de distribución gaussianas mixtas [4][5] y cadenas de Márkov [6][7] implementado en el lenguaje de programación Python. Esto permite recrear escenarios temporales con el fin de caracterizar y predecir el comportamiento de los armónicos en un sistema de distribución de baja tensión con generación solar fotovoltaica.

Existen diferentes condiciones y factores de incertidumbre que se pueden presentar en un sistema de generación solar fotovoltaica, es por ello que se hace necesario aplicar métodos de inferencia estadística que nos permitan realizar predicciones aplicadas a probabilidad, se puede encontrar una función de densidad de probabilidad que muestra de manera gráfica el comportamiento de los datos, sin embargo cuando dicha distribución no es normal se deben evaluar y aplicar un método y de esta forma encontrar el que mejor se ajuste, por ejemplo el modelo estocástico de Márkov y distribución de mezclas gaussianas.

1.1. Planteamiento del problema

En la actualidad existen diversidad de procesos estocásticos que nos permiten calcular probabilidades a partir de una serie de datos o de muestras registradas en el tiempo, en este trabajo se toman en consideración las distribuciones gaussianas mixtas aplicando el algoritmo de esperanza y maximización y las cadenas de Márkov para estimar los índices de contaminación armónica en instalaciones fotovoltaicas mediante el lenguaje de programación Python como un proceso estocástico.

1.2. Revisión de literatura

Debido al auge de la implementación de sistema fotovoltaico en edificaciones, cada vez son más las investigaciones respecto a este tema, es así como en [8] se analizan los parámetros eléctricos fundamentales y los efectos del sistema de distribución eléctrica que se producen al considerar inyección directa de energía eléctrica mediante sistema fotovoltaico, aplicando una metodología que modela un sistema fotovoltaico de 250

kW en MATLAB como caso de estudio, adicionalmente, se emplea la técnica “*Perturb and Observe*”, que consiste en hacer seguimiento del sistema fotovoltaico cuando alcanza la máxima potencia solar, concluyendo que el efecto de sombra en un sistema fotovoltaico generado por las nubes, incrementa el THD en la forma de onda del punto conexión común.

En [9] se caracterizó los potenciales impactos armónicos de un sistema solar fotovoltaica sobre techo conectada a la red en presencia de diversos perfiles de carga residencial no lineales para una red de baja tensión débil. El rendimiento de la red de baja tensión se comparó en función de los niveles de penetración de la energía solar fotovoltaica, que varían de 0 % a 100 % con diferentes generaciones estacionales junto con los datos de carga real. La investigación permitió obtener los valores de THD_v y THD_i, los cuales fueron razonables de acuerdo con el estándar IEEE 519 de 2014.

Por otro lado, en la investigación reportada en [10] se presenta un caso de estudio de una red de distribución radial con un sistema fotovoltaico de 5 MW conectada. El sistema fue modelado y simulado utilizando DigSilent PowerFactory para evaluar la distorsión armónica total (THD) en el punto de conexión. Los resultados mostraron alto nivel de THD en el punto de conexión cuando la penetración fotovoltaica aumenta y el transformador de distribución presenta su mayor carga.

De igual forma, en [11] se presenta una evaluación de la distorsión de las señales de corriente y tensión causada por la penetración fotovoltaica en una red de distribución de baja tensión basada en un *benchmark* CIGRE con configuración europea, que contiene tres subredes, a saber, residencial, industrial y comercial. Los autores proponen diez sistemas fotovoltaicos, cinco en la subred residencial, uno en la industrial y cuatro en la comercial, con cinco escenarios de penetración fotovoltaica (1%, 5%, 15%, 30% o 50%). La simulación se desarrolla en el software OpenDSS junto con Python donde se calcula la distorsión armónica total de corriente y voltaje. Los autores concluyen que los resultados muestran que la distorsión de tensión en los puntos del transformador es demasiado pequeña, sin embargo, la distorsión de corriente supera las condiciones estándar de calidad, especialmente la subred residencial que alcanza una distorsión de corriente alrededor del 80% en el escenario de mayor penetración.

1.3. Contribución

La principal contribución de este artículo consiste en presentar una metodología a partir de dos procesos

estocásticos para evaluar el aporte de armónicos que se inyectan a una red de distribución a la que se encuentra conectado un sistema de generación fotovoltaica. Esta metodología se implementa en Python, con lo cual es posible establecer el comportamiento horario de la contaminación armónica producida por el sistema.

Adicionalmente, se presenta un caso de estudio con un sistema fotovoltaico real, con datos obtenidos de mediciones de armónicos e irradiancia solar realizadas en sitio.

1.4. Organización del trabajo

El resto del artículo está organizado de la siguiente forma. La sección 2 presenta la metodología propuesta para la evaluación estocástica de armónicos en instalaciones fotovoltaicas, mientras que en la sección 3 muestra un caso de estudio donde se aplica la metodología y el algoritmo desarrollado. Por último, las secciones 4 y 5 presentan los resultados y las conclusiones, respectivamente.

2. Metodología

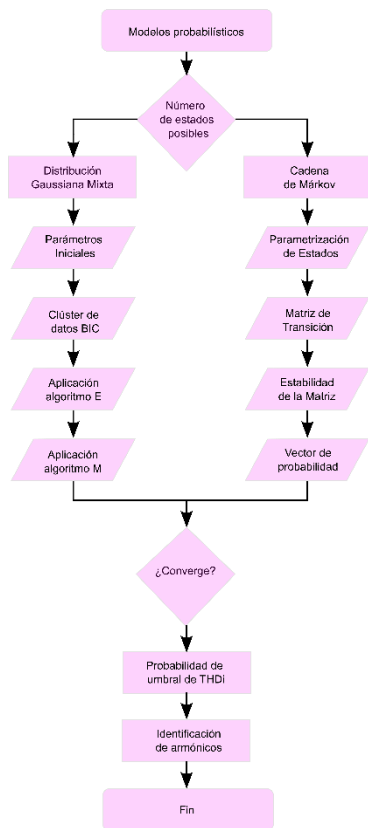


Figura 1. Metodología propuesta para evaluación estocásticas de armónicos. Fuente: elaboración propia.

Una vez registrados los valores según el tipo de medición, es importante aplicar modelos probabilísticos que nos permitan analizar información y representarla de una mejor forma, ya sea a través de diagramas de dispersión aplicando estadística descriptiva que nos representa gráficamente los valores observados.

2.1. Cadenas de Márkov

La figura 2 representa una cadena de Márkov como proceso estocástico que consiste en un número finito de estados en cual la probabilidad de que ocurra un evento depende solamente del evento inmediatamente anterior con unas probabilidades que están estacionarias.




Figura 2. Cadena de Márkov como proceso estocástico. Fuente: elaboración propia.

La probabilidad de transición estacionaria de una cadena de Márkov de pasar del estado S_i al estado S_j en el instante $t + 1$, viene dada por la ecuación (1).

$$P_{\{ij\}(t,t+1)} = P[X_{t+1} = S_j | X_t = S_i] \quad (1)$$

Para la parametrización de los estados en el proceso estocástico de cadenas de Márkov, se deben tomar los umbrales de acuerdo con la IEEE 519 de 2014 [12] y dividirlos en posibles valores que puedan llegar a tomarse como cambios de estado.

Una vez se recorra todos los datos de la serie, iniciando en 1 se aumentará en 1 cada vez que el dato siguiente se compare con el anterior y se determinará su cambio de estado inicial. Posterior a esto, la sumatoria de cada uno de los datos que cambiaron de estado se dividen en su total de datos con el fin de obtener la proporción, de acuerdo con la matriz de transición de la ecuación (2).

$$P = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1k} \\ P_{21} & P_{22} & \dots & P_{2k} \\ P_{31} & P_{32} & \dots & P_{3k} \end{bmatrix} \quad (2)$$

Esta matriz permite determinar la probabilidad de que la cadena pase del estado S_i al estado S_j en m pasos. Por lo cual, se eleva la matriz P a la m potencia con el fin de obtener una estabilidad por medio de un proceso iterativo asignando un criterio de parada como el error de la matriz calculada respecto a la matriz anterior y una ϵ de 0,0001.

Finalmente, una vez se obtiene la matriz P estabilizada en n iteraciones, se establece un vector de probabilidad,

la ecuación (3) permite calcular la probabilidad para el estado de la cadena de Markov.

$$v = [v_1, v_2, \dots, v_k] \quad (3)$$

2.2. Modelo de Gaussianas Mixtas

Las distribuciones gaussianas mixtas permiten modelar una serie de datos por medio de una distribución multivariable como la suma ponderada de M distribuciones gaussianas de la función de densidad de probabilidad f_y [4]. Estos ajustes son realizados a partir del periodo donde el sistema de generación fotovoltaica produce energía. Para determinar el número adecuado de componentes, M , se utiliza el Criterio de Información Bayesiana, CIB, de acuerdo con la siguiente ecuación [13].

$$CIB = k \cdot \log(n) - 2\log(L(\psi)) \quad (4)$$

donde, n es el tamaño de la muestra, k es el número de parámetros independientes que estima su modelo, $L(\psi)$ es la función de verosimilitud del modelo y ψ es el conjunto de parámetros del modelo.

Los datos se ajustan a una distribución con 3 componentes, cuya función de densidad se puede expresar en la ecuación (5).

$$g(y_j | \pi_i, \mu_i, \sigma_i^2) = \pi_1 \phi(y | \mu_1, \sigma_1^2) + \pi_2 \phi(y | \mu_2, \sigma_2^2) + \pi_3 \phi(y | \mu_3, \sigma_3^2) \quad (5)$$

Donde; y es la muestra observada, ϕ representan la función de densidad gaussiana, π es el valor de ponderación entre 0 y 1, σ^2 y μ representan la varianza y la media de las gaussianas mixtas, respectivamente. posteriormente se aplica el algoritmo de esperanza y maximización, con el fin de obtener estimaciones de máxima verosimilitud [14].

3. Caso de estudio

Como caso de estudio se presenta el Edificio I de la Universidad Escuela Colombiana de Ingeniería Julio Garavito, ubicada en la ciudad de Bogotá D.C en las coordenadas GMS N 4° 46' 54.444"; O 74° 2' 41.639", tal como se muestra en la figura (3). La instalación está conforma por 318 paneles solares con una capacidad instalada de 101,76 kilovatios pico en un área aproximada de 640 metros cuadrados, con 4 inversores marca ABB de referencia TRIO las cuales se dividen en 3 inversores TRIO-27.3 Y un inversor TRIO-20.2 [15].



Figura 3. Sistema fotovoltaico de la Universidad Escuela Colombiana de Ingeniería Julio Garavito. Fuente: elaboración propia.

Para el desarrollo de esta investigación se considera fundamentalmente el aporte de armónicos en el periodo de 6:00 a 18:00 horas, la cual presenta captación de radiación solar y en donde el sistema fotovoltaico representa mayor producción de energía. El equipo usado en la medición fue el analizado de calidad energía eléctrica marca Fluke 435 Clase A, tomando una ventana de medición de 12 ciclos (200 ms) tal cómo se muestra en la figura 4.




Figura 4. Esquema de medición y registro de datos. Fuente: elaboración propia.

4. Resultados

A continuación, se presentan los resultados obtenidos en el caso de estudio; es importante resaltar que mediante

las simulaciones se puede evidenciar el comportamiento de la señal de salida de la onda distorsionada por parte del inversor y que se inyecta en el sistema de distribución de baja tensión.

De lo anterior, se plantean procesos estocásticos como lo son las cadenas de Márkov y las Gaussianas Mixtas que nos permiten recrear escenarios para el cálculo de probabilidad para su implementación en Python.

4.1. Cadenas de Márkov

Mediante la aplicación del proceso estocástico Cadenas de Márkov para el escenario número 1 que comprende un sistema aleatorio donde los estados futuros dependen de los pasados podemos obtener la probabilidad entre ellos y hacer predicciones y aprender de las estadísticas de datos secuenciales.

En función de los valores de TDD obtenidos de las mediciones acorde al procedimiento establecido en el Std. IEEE 519 de 2014 [12], se establecen 3 estados a saber;

Estado 1: $0\% < TDD < 3\%$

Estado 2: $3\% < TDD < 5\%$

Estado 3: $TDD > 5\%$

A partir de estos estados, se obtiene la matriz de transición de estados estacionarios para cada una de las fases a, b y c del sistema. Las cuales se muestran en la ecuación (6), respectivamente.

$$\begin{aligned}
 P_a &= \begin{bmatrix} 0,5555 & 0,1777 & 0,2666 \\ 0,0161 & 0,5483 & 0,4354 \\ 0,0390 & 0,1041 & 0,8568 \end{bmatrix} \\
 P_b &= \begin{bmatrix} 0,6097 & 0,2439 & 0,1463 \\ 0,0900 & 0,6100 & 0,3000 \\ 0,0360 & 0,1498 & 0,8144 \end{bmatrix} \\
 P_c &= \begin{bmatrix} 0,5901 & 0,2786 & 0,1311 \\ 0,0564 & 0,6153 & 0,3282 \\ 0,0346 & 0,1435 & 0,8217 \end{bmatrix}
 \end{aligned} \quad (6)$$

Posteriormente, se procede con la implementación del modelo de Márkov por medio de un proceso iterativo tomando como criterio de parada $\epsilon = 0,0001$, se obtiene que las matrices de transición de estados para las fases a, b y c se estabilizan en un número de iteraciones iguales a 14, 22 y 19, respectivamente. Estas matrices estabilizadas se muestran en la ecuación (7).

$$\begin{aligned}
 P_a^{14} &= \begin{bmatrix} 0,0714 & 0,1968 & 0,7316 \\ 0,0714 & 0,1968 & 0,7317 \\ 0,0714 & 0,1968 & 0,7317 \end{bmatrix} \\
 P_b^{22} &= \begin{bmatrix} 0,1223 & 0,2985 & 0,5790 \\ 0,1223 & 0,2985 & 0,5790 \\ 0,1223 & 0,2985 & 0,5790 \end{bmatrix} \\
 P_c^{19} &= \begin{bmatrix} 0,0924 & 0,2954 & 0,6120 \\ 0,0924 & 0,2954 & 0,6120 \\ 0,0924 & 0,2954 & 0,6120 \end{bmatrix}
 \end{aligned} \quad (7)$$

Una vez se obtiene la matriz en condiciones estables se procede a calcular el vector de probabilidad en el estado 1, de acuerdo con la ecuación (8); $v_1 = [1, 0, 0]$.

$$\begin{aligned}
 vP_a &= [0,0714 \quad 0,1968 \quad 0,7316] \\
 vP_b &= [0,1223 \quad 0,2985 \quad 0,5790] \\
 vP_c &= [0,0924 \quad 0,2954 \quad 0,6120]
 \end{aligned} \quad (8)$$

La tabla 1 presenta para cada una de las fases, el número de iteraciones realizadas para alcanzar la estabilidad de la matriz de transición de estado y encontrar la probabilidad de ocurrencia de TDD_i los estados 1, 2 y 3. Esto valores indican que durante el intervalo de 06:00 a 18:00 horas, la probabilidad de que la fase a se encuentre en el estado 1 y pase al estado 3 es del 73,61 %, la probabilidad de que la fase b pase del estado 1 al estado 3 es de 57,90 % y la probabilidad de que la fase c pase del estado 1 al estado 3 es del 61,21 %. Esto indica que su TDD_i es altamente probable que supere 5 % según lo establecido por el Std. IEEE 519 de 2014.

Tabla 1. Resultado de probabilidad.

Fase	<i>i</i>	a_{11}	a_{12}	a_{13}
vP_a	14	0,0714	0,1968	0,7361
vP_b	22	0,1223	0,2985	0,5790
vP_c	19	0,0924	0,2954	0,6121

Fuente: elaboración propia.

El paso siguiente consiste en obtener la corriente de demanda máxima, I_L , de cada una de las fases, es de aclarar que este valor se debe tomar en el periodo medido durante 1 año. La tabla 2 muestra los valores de la corriente de demanda máxima y su relación con la corriente de cortocircuito.

Tabla 2. Resultado de probabilidad.

Fase	<i>a</i>	<i>b</i>	<i>c</i>	I_{sc}/I_L
I_L [A]	72	74	72	55,40

Fuente: elaboración propia.

El valor máximo entre las 3 fases es de 74 A que corresponde a la Fase B si aplicamos la ecuación (9), se obtiene TDD_i , la cual se compara con los valores de la tabla 2 del Std. IEEE 519 de 2014. Estos valores se muestran en la tabla 3, para cada una de las horas en el periodo de 6:00 a 18:00, donde se evidencia que en los periodos de menor irradiancia (15:00 a 18:00 horas) se registran los valores máximos TDD_i . Observe que los valores del TDD_i no son simétricos con respecto a las horas, esto debido al comportamiento horario de la demanda y de la irradiancia.

$$TDD_i = THD_i \frac{I_{rms_i}}{I_L \sqrt{1 + THD_i^2}} \quad (9)$$

Tabla 3. Resultado horario de TDD_i .

Intervalo	TDD_i [%]		
	Fase <i>a</i>	Fase <i>b</i>	Fase <i>c</i>
06:00 – 07:00	49,95	28,32	28,32
07:00 – 08:00	20,00	8,60	8,60
08:00 – 09:00	18,97	6,01	6,01
09:00 – 10:00	15,47	4,39	4,39
10:00 – 11:00	16,37	6,09	6,09
11:00 – 12:00	13,30	4,56	4,56
12:00 – 13:00	14,65	7,23	7,23
13:00 – 14:00	20,63	11,09	11,09
14:00 – 15:00	36,67	26,16	26,16
15:00 – 16:00	130,81	98,28	98,28
16:00 – 17:00	636,53	497,49	497,49
17:00 – 18:00	3999	2010	2010

Fuente: elaboración propia.

4.2. Modelo de Gaussianas Mixtas

Para seleccionar el modelo de mixtura depende de varios factores que emplean técnicas de agrupamiento, donde cada una utiliza diferentes números de componentes

denominado criterios de información, esta investigación considera el criterio de información Bayesiano dada por la ecuación (4).

En las figuras 5, 6 y 7 se evidencia que en la fase *b* muestra un mejor comportamiento de la curva de distribución, esto es debido a que se recrearon escenarios de conexión y desconexión de cargas de manera aleatoria en cada fase, por ende, la distribución de datos es distinta para cada una de las fases.




Figura 5. Densidad de probabilidad de TDD_i para la fase *a*, obtenido del desarrollo en Python. Fuente: elaboración propia.




Figura 6. Densidad de probabilidad de TDD_i para la fase *b*, obtenido del desarrollo en Python. Fuente: elaboración propia.




Figura 7. Densidad de probabilidad de TDD_i para para la fase *c*, obtenido del desarrollo en Python. Fuente: elaboración propia.

También puede evidenciarse, que las tres curvas de distribución de las fases *a*, *b* y *c* presentan 3 componentes gaussianas cada una.

Por otro lado, en las figuras 8 y 9 se muestran las curvas de distribución gaussiana mixta de TDD_i inicial y final, respectivamente, con 3 componentes gaussianas para las tres fases, donde posteriormente se estiman los parámetros mediante el algoritmo de esperanza y maximización.

A partir de la clusterización de 3 componentes para las tres fases, la tabla 4 consigna los parámetros de arranque para dar inicio al algoritmo de esperanza y maximización.

Tabla 4. Parámetros iniciales para el algoritmo de esperanza y maximización.

Fase	π	μ	σ^2	σ
<i>a</i>	0,333	25,244	426,46	20,65
<i>b</i>	0,333	17,793	414,82	20,36
<i>c</i>	0.333	19,164	490,02	22,13

Fuente: elaboración propia.




Figura 8. Distribuciones gaussianas mixta inicial de TDD_i para las tres fases, obtenidas del desarrollo en Python. Fuente: elaboración propia.




Figura 9. Distribuciones gaussianas mixta final de TDD_i para las tres fases, obtenidas del desarrollo en Python. Fuente: elaboración propia.

Tabla 5. Parámetros resultantes de GMM.

Fase	π	μ	σ^2	σ
<i>a</i>	0,3449	20,74	417,96	20,44
<i>b</i>	0,3448	20,72	430,17	20,36
<i>c</i>	0.3448	20,73	364,02	22,13

Fuente: elaboración propia.

Las figuras 10, 11 y 12 muestran los diagramas de Pareto que clasifica los resultados del TDD_i de las fases *a*, *b* y *c* respectivamente, esto nos permite visualizar, identificar y reconocer el comportamiento el aporte de armónicas en un sistema de distribución y focalizarlo para la mitigación de dicho fenómeno, se evidencia que el percentil 95 y 99 los valores se encuentran dentro de los límites establecidos por el Std IEEE 519 de 2014.




Figura 10. Pareto de TDD_i para la fase *a*. Fuente: elaboración propia.




Figura 11. Pareto de TDD_i para la fase *b*. Fuente: elaboración propia.




Figura 12. Pareto de TDD_i para la fase *c*. Fuente: elaboración propia.

Observe que en las figuras 10, 11 y 12 el valor máximo de TDD_i se presenta en el horario de menor producción de energía, esto como consecuencia de la poca irradiancia solar; lo que ocasiona un aumento en la frecuencia de conmutaciones del inversor en la búsqueda de su máxima potencia.

Como se puede evidenciar los armónicos aumentan a medida que disminuye la producción de energía por parte del sistema de generación solar fotovoltaica.

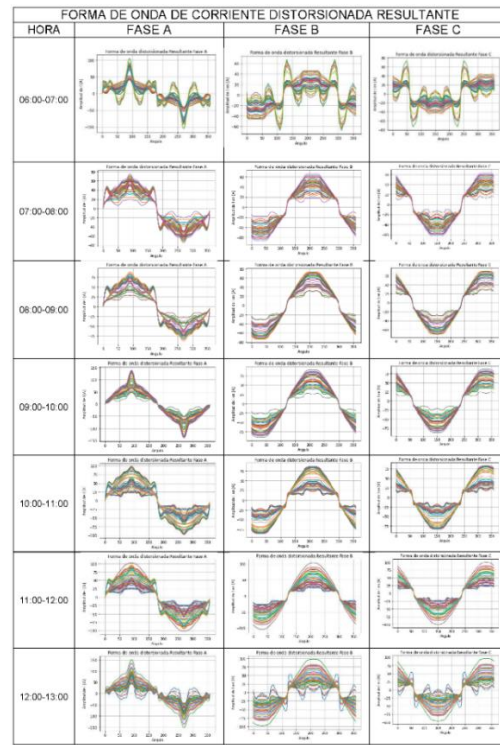


Figura 13. Forma de onda distorsionada de un inversor de seis pulsos en una instalación fotovoltaica en el horario de 13:00 a 16:00 horas. Fuente: elaboración propia.

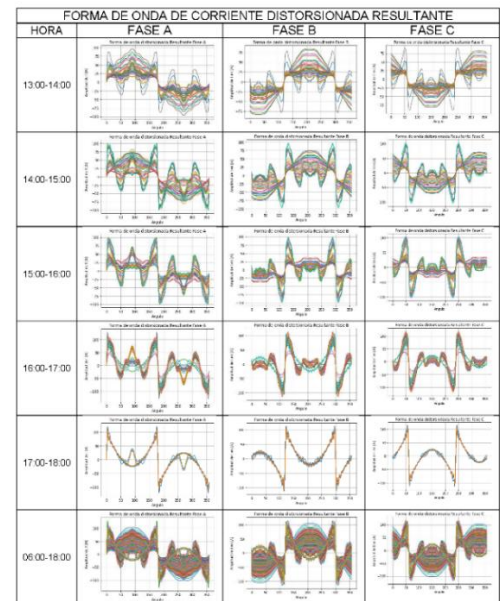


Figura 14. Forma de onda distorsionada de un inversor de seis pulsos en una instalación fotovoltaica en el horario de 13:00 a 16:00 horas. Fuente: elaboración propia.

5. Conclusiones

El uso del lenguaje de programación Python aplicado a modelos probabilísticos como las cadenas de Márkov y los modelos de gaussianas mixtas permiten simular el comportamiento y calcular la probabilidad de superar los límites de TDD_i en sistemas de generación fotovoltaica conectado directamente a redes de distribución de baja tensión, esto permite caracterizar de forma precisa el aporte horario de armónicos del inversor, siendo así una herramienta útil para la gestión de estos sistemas fotovoltaicos debido a su capacidad de procesar datos y comparar las tendencias de las mismas.

De igual forma, esta investigación permitió proponer una metodología a partir de dos procesos estocásticos para caracterizar los inversores y determinar el aporte de armónicos que se inyectan al sistema eléctrico al que se encuentran conectados. Donde pudo observarse, que el aporte de corriente armónica del inversor está en función de los niveles de irradiancia, mientras ésta sea menor el inversor buscará su máximo punto de potencia obligando a un mayor número de conmutación; lo que indica un comportamiento más alejado de la onda senoidal de la corriente.

6. Agradecimientos

Los autores agradecen a la Universidad Escuela Colombiana de Ingeniería Julio Garavito por su apoyo al grupo de investigación MEEP.

7. Referencias

- [1] A. Al-Refaie y N. Lepkova, «Impacts of Renewable Energy Policies on CO2 Emissions Reduction and Energy Security Using System Dynamics: The Case of Small-Scale Sector in Jordan», *Sustainability*, vol. 14, n.º 9, Art. n.º 9, ene. 2022, doi: 10.3390/su14095058.
- [2] K. U. Ehigiamusoe y E. Dogan, «The role of interaction effect between renewable energy consumption and real income in carbon emissions: Evidence from low-income countries», *Renewable and Sustainable Energy Reviews*, vol. 154, p. 111883, feb. 2022, doi: 10.1016/j.rser.2021.111883.
- [3] M. Srivastava, S. K. Goyal, A. Saraswat, R. S. Shekhawat, y G. Gangil, «A Review on Power Quality Problems, Causes and Mitigation Techniques», en *2022 1st International Conference on Sustainable Technology for Power and Energy Systems (STPES)*, jul. 2022, pp. 1-6. doi: 10.1109/STPES54845.2022.10006587.
- [4] F. Najar, S. Bourouis, N. Bouguila, y S. Belghith, «A Comparison Between Different Gaussian-Based Mixture Models», en *2017 IEEE/ACS 14th International Conference on Computer Systems and Applications (AICCSA)*, oct. 2017, pp. 704-708. doi: 10.1109/AICCSA.2017.108.
- [5] A. Chehade, M. Savargaonkar, y V. Krivtsov, «Conditional Gaussian mixture model for warranty claims forecasting», *Reliability Engineering & System Safety*, vol. 218, p. 108180, feb. 2022, doi: 10.1016/j.res.2021.108180.
- [6] Y. Zhao *et al.*, «Spatio-temporal Markov chain model for very-short-term wind power forecasting», *The Journal of Engineering*, vol. 2019, n.º 18, pp. 5018-5022, 2019, doi: 10.1049/joe.2018.9294.
- [7] O. Zarenia, M. J. Salehpour, R. Ghaedi, y M. Shafie-Khah, «Markov-Based Reliability Assessment for Distribution Systems Considering Failure Rates», *IEEE Access*, vol. 11, pp. 10018-10031, 2023, doi: 10.1109/ACCESS.2023.3240778.
- [8] K. Rahimi, S. Mohajeryami, y A. Majzooobi, «Effects of photovoltaic systems on power quality», en *2016 North American Power Symposium (NAPS)*, sep. 2016, pp. 1-6. doi: 10.1109/NAPS.2016.7747955.
- [9] S. M. Ahsan, H. A. Khan, A. Hussain, S. Tariq, y N. A. Zaffar, «Harmonic Analysis of Grid-Connected Solar PV Systems with Nonlinear Household Loads in Low-Voltage Distribution Networks», *Sustainability*, vol. 13, n.º 7, 2021, doi: 10.3390/su13073709.
- [10] R. Sinvula, K. M. Abo-Al-Ez, y M. T. Kahn, «Total Harmonics Distortion (THD) with PV System Integration in Smart Grids: Case Study», en *2019 International Conference on the Domestic Use of Energy (DUE)*, mar. 2019, pp. 102-108.
- [11] J. S. Castellanos A., D. P. Guevara, C. A. Correa-Florez, y G. Ordóñez-Plata, «Assessment of Harmonic Distortion Associated with PV Penetration in a Low Voltage Distribution Network», en *2020 IEEE PES Transmission & Distribution Conference and Exhibition - Latin America (T&D LA)*, sep. 2020, pp. 1-6. doi: 10.1109/TDLA47668.2020.9326177.
- [12] «IEEE Recommended Practice and Requirements for Harmonic Control in Electric Power Systems», *IEEE Std 519-2014 (Revision of IEEE Std 519-1992)*, pp. 1-29, jun. 2014, doi: 10.1109/IEEESTD.2014.6826459.
- [13] P. B. Gohain y M. Jansson, «Robust Information Criterion for Model Selection in Sparse High-Dimensional Linear Regression Models», *IEEE Transactions on Signal Processing*, vol. 71, pp. 2251-2266, 2023, doi: 10.1109/TSP.2023.3284365.

- [14] R. Singh, B. Pal, y R. Jabr, «Statistical representation of distribution system loads using Gaussian Mixture Model», en *IEEE PES General Meeting*, jul. 2010, pp. 1-1. doi: 10.1109/PES.2010.5588085.
- [15] ABB, «TRIO-20.0/27.6-TL-OUTD-W. 20 to 27.6 kW». Especificaciones Técnicas. Accedido: 22 de junio de 2023. [En línea]. Disponible en: https://library.e.abb.com/public/72b3af94435e7255c1257ccf004de9cc/TRIO-20.0-27.6-W_BCD.00471_EN.pdf