



# Modelo multivariante basado en datos para monitorear la condición de turbinas a vapor de 100 MW

## Data-Driven Multivariate Model for condition monitoring of 100 MW Steam Turbines

Francisco A. de la Torre Silva<sup>1†</sup> , Evelio Palomino Marín<sup>1\*</sup> , Armando Díaz Concepción<sup>1</sup> ,  
Alejandra García Toll<sup>1</sup> , Alexander Alfonso Álvarez<sup>2</sup> , Joel Guillen García<sup>3</sup> 

1. Universidad Tecnológica de la Habana José Antonio Echeverría. Centro de Estudios en Ingeniería de Mantenimiento, CEIM. La Habana, Cuba.
2. Universidad de La Serena. Facultad de Ingeniería, Departamento de Ingeniería Mecánica. La Serena, Chile.
3. Universidad Técnica de Manabí. Puerto Viejo. Ecuador.

\*Autor de correspondencia: [evelio.palomino@gmail.com](mailto:evelio.palomino@gmail.com)

Este documento posee una [licencia Creative Commons Reconocimiento-No Comercial 4.0 internacional](https://creativecommons.org/licenses/by-nc/4.0/)



Recibido: 30 de mayo de 2025

Aceptado: 28 de julio de 2025

Publicado: 30 de julio de 2025

### Resumen

Se desarrolló un modelo diagnóstico basado en datos para turbinas a vapor de 100 MW, integrando el análisis de componentes principales (ACP) y el control estadístico multivariable de procesos (MSPC) con el propósito de caracterizar la variabilidad funcional-dinámica normal del sistema y detectar desviaciones operativas incipientes. Se utilizaron bases de datos históricas del sistema de monitoreo en línea, que contenían mediciones vibratorias y tecnológicas tomadas durante más de dos años de operación continua. El proceso metodológico incluyó las etapas de preprocesamiento, acondicionamiento, depuración y validación de los datos, seguidas de la construcción del modelo multivariante y la definición de la muestra patrón de referencia. Los resultados evidenciaron la

estabilidad estadística del modelo y su capacidad para discriminar condiciones anómalas mediante los estadísticos  $T^2$  de Hotelling y Q-residuals. Se comprobó que el enfoque propuesto mejora la detección temprana de fallos y contribuye a la implementación de estrategias de mantenimiento predictivo basadas en condición, proporcionando una herramienta eficaz para el diagnóstico funcional de turbinas industriales de gran potencia y una base metodológica transferible a otros sistemas térmicos rotativos.

**Palabras claves:** diagnóstico basado en datos, modelado multivariante, análisis de componentes principales, mantenimiento predictivo, turbinas a vapor de 100 MW.

### Abstract

A data-driven diagnostic model was developed for 100 MW steam turbines, integrating Principal Component Analysis (PCA) and Multivariate Statistical Process Control (MSPC) to characterize the normal functional-dynamic variability of the system and to detect early operational deviations. Historical databases from the online monitoring system, containing vibration and technological measurements acquired over more than two years of continuous operation, were used. The methodological process included data preprocessing, conditioning, cleaning, and validation, followed by the construction of the multivariate model and the definition of a reference pattern sample. Results demonstrated the statistical stability of the model and its ability to discriminate

abnormal conditions using Hotelling's  $T^2$  and Q-residuals statistics. The proposed approach improved early fault detection and contributed to the implementation of condition-based predictive maintenance strategies, providing an effective tool for functional diagnostics of high-power industrial turbines and establishing a methodological framework that can be extended to other rotating thermal systems.

**Key words:** data-driven diagnostics, multivariate modeling, principal component analysis, predictive maintenance, 100 MW steam turbines.

### Cómo citar este artículo, norma Vancouver:

de la Torre Silva FA, Palomino Marín E, Díaz Concepción A, García Toll AE, Alfonso Álvarez A, Guillen García J. Modelo multivariante basado en datos para monitorear la condición de turbinas a vapor de 100 MW. Ingeniería Mecánica. 2025;28:e711. <https://goo.su/MX4il>

## 1. Introducción

El mantenimiento predictivo se ha convertido en un componente esencial para mejorar la confiabilidad y disponibilidad en centrales termoeléctricas, especialmente en turbinas a vapor, que operan bajo condiciones extremas de temperatura, presión y vibración [1]. Las exigencias de operación continua, la necesidad de

optimizar costos y minimizar tiempos de parada, así como la evolución hacia plantas más inteligentes, han impulsado la adopción de enfoques basados en datos (*data-driven diagnostics*) para el monitoreo de condición (*condition-based monitoring*) [2]. En este contexto, la evaluación del comportamiento mecánico dinámico funcional de turbinas a vapor de 100 MW presenta desafíos significativos, particularmente en el análisis integrado de los parámetros de proceso y tecnológicos.

La literatura científica refleja un esfuerzo considerable por anticipar fallos en componentes críticos mediante modelos estadísticos multivariantes. Se han desarrollado modelos aleatorios de regresión para predecir la calidad de superficies en rodamientos, logrando una exactitud del 94 % con el estadístico  $T^2$  de Hotelling [1, 2], habiéndose propuesto nuevos KPI para plantas hidroeléctricas y se han aplicado técnicas similares para el monitoreo en sistemas ferroviarios que superan a los gráficos de control multivariantes convencionales [3, 4]. Otros estudios se han enfocado en modelos de degradación para sistemas de operación continua [5], en el uso de series temporales para investigar desbalances en cojinetes [6], y en la detección de fallos mediante la digitalización y seguimiento de valores de proceso [7]. Así mismo, se ha avanzado en el monitoreo de procesos usando cartas de control chi-cuadrado con parámetros variables [8] y en métodos para predecir la vida útil remanente de sistemas con fallos severos [9].

Más recientemente, la tendencia se ha inclinado hacia la aplicación de técnicas de machine learning. Por ejemplo, estudios han empleado XGBoost para detectar condiciones de fallo en turbinas [10], se han propuesto gemelos digitales de desempeño (*performance digital twin*) para la detección de anomalías [11], y se han utilizado redes neuronales para localizar anomalías térmicas en turbinas a vapor de baja presión [12] y para predecir el consumo de energía eléctrica [13]. Todos estos enfoques demuestran el potencial de los métodos basados en datos para el diagnóstico industrial.

Dentro de estas metodologías, el Análisis de Componentes Principales, ACP, integrado en el marco del Control Estadístico Multivariable de Procesos (*Multivariate Statistical Process Control*, MSPC), ha ofrecido ventajas notables para reducir la dimensionalidad de los datos y detectar desviaciones respecto al comportamiento normal del sistema [5]. Sin embargo, la aplicación de MSPC no está exenta de retos, como la necesidad de asegurar la normalidad de los datos mediante pruebas como Anderson-Darling o Shapiro-Wilk [14] y de tratar la autocorrelación presente en los datos de proceso, para la cual se han propuesto modificaciones a las gráficas de control de Shewhart [15]. La literatura también señala el desarrollo de modelos que integran el Mantenimiento Basado en Condición (*Condition Based Maintenance*, CBM) con el Control Estadístico de Procesos (*Statistical Process Control*, SPC) [16].

A pesar de estos avances, una revisión de la bibliografía denota que persisten desafíos en la aplicación de estos modelos a turbinas de gran potencia (100 MW), relacionados con la calidad de los datos, la selección de variables correlacionadas y la construcción de muestras patrón robustas [6]. Específicamente, se identifica una ausencia en el tratamiento de una muestra de datos para el análisis conjunto de variables síntomas de turbinas a vapor de 100 MW empleando un modelo MSPC, incluyendo el preprocesamiento y procesamiento riguroso de la base de datos.

Para abordar esta brecha, este artículo propone un enfoque diagnóstico basado en datos para la caracterización multivariante de los parámetros síntoma de turbinas a vapor de 100 MW. El objetivo principal es desarrollar un modelo matemático de Análisis de Componentes Principales, ACP (*Principal Component Analysis*, PCA) integrado al marco del Control Estadístico Multivariable de Procesos (MSPC), que permita representar la variabilidad funcional normal del comportamiento mecánico dinámico de la turbina. Para ello, se establecieron criterios rigurosos para la selección, preprocesamiento y validación de una muestra de datos patrón obtenida de sistemas de monitoreo en línea. El modelo resultante busca servir como una base sólida para mejorar las estrategias de mantenimiento predictivo y optimizar la operación de estas turbinas industriales.

## 2. Métodos y Materiales

Los materiales empleados en esta investigación provinieron de las bases de datos generadas por el sistema de monitoreo en línea instalado en las tres turbinas a vapor de 100 MW pertenecientes a una central termoeléctrica. Dichas bases de datos contienen registros históricos de variables vibratorias y tecnológicas que reflejan el comportamiento dinámico funcional de cada turbina durante un periodo prolongado de operación.

El método aplicado consistió en el desarrollo de un modelo de diagnóstico basado en datos que integra el enfoque de *Multivariate Statistical Process Control*, MSPC, con el *Principal Component Analysis*, PCA. Para ello se establecieron criterios rigurosos para la definición de las muestras de trabajo y de la muestra patrón, asegurando la representatividad estadística y la calidad de los datos analizados. El procedimiento metodológico incluyó las siguientes etapas: preprocesamiento de datos, acondicionamiento de la muestra de trabajo, selección de la muestra patrón, y análisis estadístico multivariante.

### 2.1. Muestra y población

Se elaboró un modelo grupal correspondiente a la turbina número 2, seleccionada por presentar el comportamiento operativo más estable. Este modelo se conformó con los valores de 22 parámetros identificados como variables síntoma del comportamiento mecánico dinámico funcional de la turbina. Entre ellos se incluyen las vibraciones relativas del rotor respecto al alojamiento en las direcciones de medición X y Y; las expansiones

diferenciales axiales del rotor respecto al cilindro, tanto del lado regulador como del lado generador; las expansiones relativas en los cilindros de alta, media y baja presión; y la expansión axial total del conjunto turbogenerador. La configuración de las zonas de medición se muestra en la figura 1.

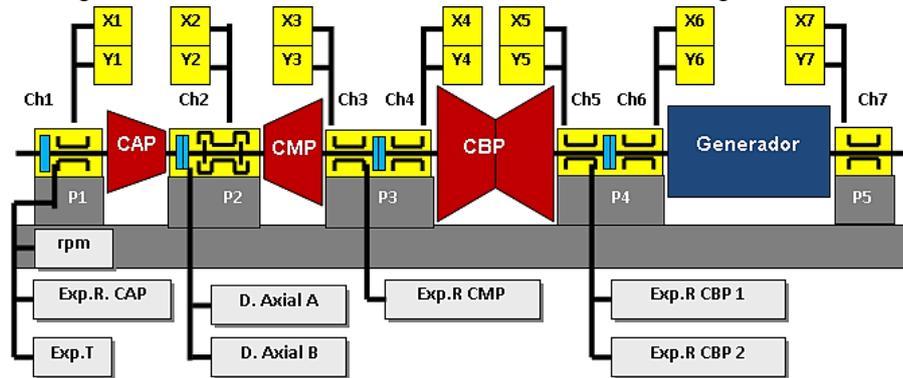


Fig. 1. Zonas de medición de los parámetros del modelo grupal turbina. Fuente: autores

### 2.1.1. Obtención de la muestra de datos de trabajo para el modelo MSPC

La muestra de datos de trabajo se obtuvo a partir de la descarga y depuración de la base de datos histórica correspondiente al período comprendido entre el 23 de junio de 2020 y el 3 de noviembre de 2022. Las tareas de acondicionamiento y limpieza permitieron obtener una muestra semielaborada para el posterior procesamiento estadístico de las tres turbinas analizadas. Durante esta etapa se verificó el cumplimiento de los requisitos de instalación, calibración y mantenimiento de la instrumentación [2]. Se estima que las labores de preprocesamiento y procesamiento de datos representan aproximadamente el 60 % del tiempo total de desarrollo de un proyecto basado en datos industriales.

### 2.1.2. Acondicionamiento de la muestra de datos

El acondicionamiento de la muestra requirió organizar y estructurar los datos de las tres turbinas en hojas de cálculo diferenciadas, correspondientes a las 22 variables vibratorias y tecnológicas medidas con un intervalo temporal de 10 minutos. Debido a factores de automatización y comunicación, se presentaron pérdidas de lectura y tramos incompletos, por lo cual fue necesario cotejar las instancias temporales de medición y corregir inconsistencias. La tabla 1 resume los resultados del acondicionamiento de la muestra de trabajo para la turbina 2, validados por especialistas en diagnóstico, mantenimiento, automática, operación e inspección de turbinas.

Tabla 1. Acondicionamiento de la muestra de datos de trabajo observada de la población. Fuente: autores

Parámetro	Turbina 2. 100 MW
Vibraciones relativas	3039 instancias de los atributos X1, Y1, X2, Y2, X3, Y3, X4, Y4, X5, Y5, X6, Y6, X7, Y7. (14 atributos en total).
Tecnológicos	2947 instancias de los atributos Exp Rel CAP, Exp Rel CMP, Exp Rel CBP 1, Exp Rel CBP 2, Axial A, Axial B, Exp Total. (7 atributos en total). <i>Nota:</i> fue desechado el atributo velocidad de rotación por su inconsistencia y poca cantidad de instancias de medición.
Proceso	n/d
Resumen cotejado	Cotejados: 2798 instancias de medición con 21 atributos en total <i>Nota:</i> excluidos 92 instancias de los atributos vibraciones relativas, por no existir lecturas de medición. Fueron sesgadas 149 instancias de medición correspondientes a las interrupciones de funcionamiento y estadías de girador. Se evidencian problemas en grupos de días de instancias de medición. Excluido el atributo Vel Rot por su inconsistencia en las mediciones.

A partir del análisis de esta muestra se observó irregularidad en la cantidad de instancias por mes, atribuida a interrupciones operativas o fallos en los sistemas de adquisición. Considerando la consistencia y estabilidad operacional, se seleccionó finalmente la turbina 2 como caso de estudio, con 2798 instancias de medición correspondientes a 21 variables. Esta unidad había recibido mantenimiento capital y modernización de sus sistemas automáticos, lo cual garantizó condiciones estables de operación durante el periodo analizado.

### 2.1.3. Selección, limpieza y transformación de los datos

El tratamiento de la muestra no se limitó a su limpieza inicial; fue indispensable asegurar la integridad, completitud y consistencia de los datos antes del análisis. Las características generales del acondicionamiento de la muestra se muestran en la tabla 2.

**Tabla 2.** Resumen de las características del acondicionamiento de la muestra de datos de trabajo, para la turbina 2. Fuente: autores

Muestra cotejada de datos de trabajo	Fecha		Cantidad total		Atributos		
	Desde-hasta	Meses	Instancias	Atributos	Vibratorios	Tecnológicos	Proceso
Tur2_XYT_2798-21	23/06/20-03/11/22	30	2798	21	14	7	n/d
Tur2_P_45224-76	05/05/22-23/01/23	9	45224	76	n/d	n/d	76

Leyenda: XYT: atributos vibratorios y tecnológicos. P: atributos de proceso. n/d: atributos no disponibles

Durante la depuración se eliminaron valores inconsistentes y se aplicaron métodos de sustitución basados en medias o interpolaciones lineales. Los registros agrupados con fallos simultáneos fueron corregidos mediante imputación estadística, preservando la desviación estándar de cada variable. Este proceso garantizó la obtención de una base de datos confiable para la fase de modelado multivariante.

#### 2.1.4. Análisis de valores perdidos y duplicados

El análisis de valores faltantes (missing values) se realizó mediante software estadístico especializado. En la muestra principal (Tur2\_XYT\_2798-21) no se detectaron campos vacíos, mientras que en la muestra secundaria (Tur2\_P\_45224-76) se identificó un 0,3 % de celdas con valores ausentes. Los valores duplicados y erróneos fueron sustituidos según procedimientos de imputación controlada. Se evitó eliminar datos que pudieran contener información relevante sobre comportamientos anómalos o estados transitorios de operación.

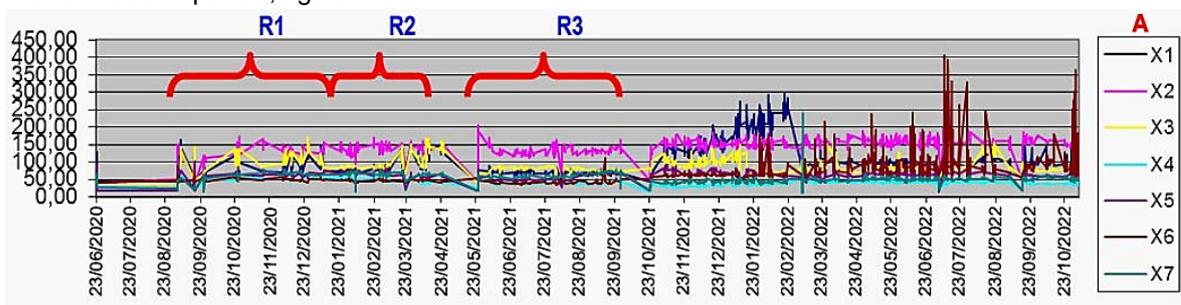
#### 2.1.5. Análisis de valores nulos y atípicos

Los valores nulos no superaron el 0,25 % en la muestra Tur2\_XYT\_2798-21 y el 0,022 % en la muestra Tur2\_P\_45224-76. Estos fueron reemplazados por los valores promedio o interpolados, según el caso. Los valores anómalos o extremos (outliers) fueron preservados cuando su presencia representaba condiciones potencialmente significativas para la detección de estados no estacionarios de la turbina, siendo analizados posteriormente en la definición de la muestra patrón.

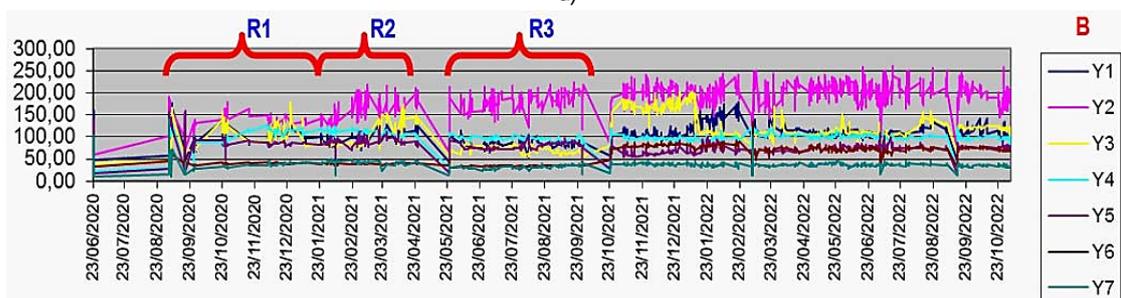
### 2.2. Definición de la muestra de datos patrón

Se definió como muestra patrón el conjunto de instancias de medición representativas de la condición normal de operación de la turbina. Dichas instancias, medidas simultáneamente para todas las variables, correspondieron a períodos estables entre mantenimientos, libres de incidencias mecánicas, tecnológicas o dinámicas que alteraran la condición funcional. La selección se realizó conforme a las normas ISO 10816-2:1996, ISO 7919-2:1996 y ISO 13380:2002, relativas a la evaluación de vibraciones y al monitoreo de condición de máquinas.

Los tramos de operación seleccionados (R1, R2 y R3) se identificaron mediante análisis visual y validación con registros históricos de interrupciones. Tras la exclusión de instancias afectadas por fallos o paradas, la muestra patrón final incluyó 442 instancias, equivalentes al 15,79 % del total, abarcando un periodo de 13 meses sin mantenimientos registrados. La tabla 3 resume las características estadísticas de las muestras utilizadas para conformar la muestra patrón, figura 2.



a)



b)

**Fig. 2.** Comportamiento en el tiempo del parámetro vibración relativa, para la muestra de datos de trabajo Tur2\_XYT\_ 2798-21, a) en la dirección de medición X, b) en la dirección de medición Y. Fuente: autores**Tabla 3.** Resumen de las características de la muestra de datos de trabajo patrón. Fuente: autores

Muestra de datos	Fecha		Cantidad total			Atributos
	Desde-hasta	Meses	Instancias	% del Total	Atributos	Para todas las muestras
Tur2_XYT_ 2798-21	23/06/20-03/11/22	30	2798	100	21	Vibratorios: 14 Tecnológicos: 7 Proceso: n/d
Patrón_XYT_ 442-21	25/09/20-27/09/21	13	442	15.79	21	
R1_XYT_ 173-21	25/09/20-23/01/21	5	173	6.18	21	
R2_XYT_ 210-21	24/01/21-25/04/21	4	210	7,50	21	
R3_XYT_ 59-21	04/06/21-27/09/21	4	59	2.10	21	

Leyenda: XYT: atributos vibratorios y tecnológicos, n/d: atributos no disponibles para procesar

### 3. Resultados y Discusión

#### 3.1. Análisis de la distribución de los atributos

La verificación de la normalidad en la distribución de los atributos pertenecientes a la muestra patrón permitió validar la aplicabilidad del modelo ACP dentro del enfoque MSPC. Se realizaron pruebas de Kolmogórov-Smirnov, Lilliefors y Shapiro-Wilk para cada variable, utilizando software estadístico especializado. Los resultados obtenidos se presentan de forma resumida en la tabla 4.

Los valores del estadístico D de Kolmogórov-Smirnov y los p-values asociados indicaron que las variables X2, Y2, Y5, Axial A, Axial B y Exp Total no siguieron una distribución normal, lo que llevó a su exclusión del conjunto principal de atributos. En cambio, para las 15 variables restantes (X1, Y1, X3, Y3, X4, Y4, X5, X6, Y6, X7, Y7, Exp Rel CAP, Exp Rel CMP, Exp Rel CBP1 y Exp Rel CBP2) se comprobó la normalidad, permitiendo su inclusión en el modelo multivariante.

**Tabla 4.** Resumen de la prueba de normalidad de Kolmogórov-Smirnov, Lilliefors y Shapiro-Wilk para los atributos de la muestra patrón correspondiente al tramo R1. Fuente: autores

Variable	Tests of Normality (Spreadsheet3_21 by 173 Normal patrón tramo R1)					
	N	max D	K-S p	Lilliefors p	W	p
Var1_x1	173	0,051475	p > .20	p > .20	0,991281	0,377039
Var2_y1	173	0,054601	p > .20	p > .20	0,990749	0,326896
Var3_x2	173	0,106860	p < ,05	p < ,01	0,941834	0,000002
Var4_y2	173	0,132113	p < ,01	p < ,01	0,924406	0,000000
Var5_x3	173	0,037881	p > .20	p > .20	0,986149	0,085292
Var6_y3	173	0,048007	p > .20	p > .20	0,992132	0,468686
Var7_x4	173	0,050055	p > .20	p > .20	0,994590	0,781385
Var8_y4	173	0,048944	p > .20	p > .20	0,991571	0,406747
Var9_x5	173	0,046658	p > .20	p > .20	0,993526	0,643113
Var10_y5	173	0,092207	p < ,15	p < ,01	0,886514	0,000000
Var11_x6	173	0,054273	p > .20	p > .20	0,987580	0,131073
Var12_y6	173	0,045802	p > .20	p > .20	0,994910	0,820111
Var13_x7	173	0,040872	p > .20	p > .20	0,990693	0,321946
Var14_y7	173	0,040618	p > .20	p > .20	0,994535	0,774444
Var15_AxialA	173	0,091990	p < ,15	p < ,01	0,979091	0,010418
Var16_AxialB	173	0,087580	p < ,15	p < ,01	0,984059	0,045388
Var17_ExpRelCAP	173	0,055501	p > .20	p > .20	0,993523	0,642706
Var18_ExpRelCMP	173	0,055518	p > .20	p > .20	0,984396	0,050233
Var19_ExpRelCBP1	173	0,041473	p > .20	p > .20	0,986273	0,088528
Var20_ExpRelCBP2	173	0,050125	p > .20	p > .20	0,989457	0,227494
Var21_ExpTotal	173	0,169559	p < ,01	p < ,01	0,909749	0,000000

Los resultados evidenciaron que la distribución de estas variables presentó una dispersión acotada en torno a sus medias, lo que representa un comportamiento funcional estable y típico de condiciones de operación normal. Dicho comportamiento se corroboró mediante los histogramas de frecuencia y los gráficos Normal P-Plot, en los cuales se observó un ajuste satisfactorio a la distribución teórica. La tabla 5 resume los valores de la media y la desviación estándar correspondientes a la variabilidad natural del comportamiento funcional normal de la turbina.

**Tabla 5.** Resumen de los estadísticos obtenidos para los atributos de la muestra patrón (tramo R1) que cumplieron la condición de normalidad en la distribución de los datos. Fuente: autores

Variable	Descriptive Statistics (Spreadsheet3_21 by 173 Normal patrón tramo R1)					
	Valid N	Mean	Minimum	Maximum	Variance	Std.Dev.
Var1_x1	173	85,9836	53,30000	120,1000	204,3148	14,29387
Var2_y1	173	109,7183	68,15000	153,7000	318,8010	17,85500
Var5_x3	173	106,1265	68,15000	145,1900	331,3471	18,20294
Var6_y3	173	107,7164	51,70000	158,3000	447,7299	21,15963
Var7_x4	173	51,7255	40,45000	64,5100	20,7367	4,55376
Var8_y4	173	100,1580	70,27000	126,3000	141,2215	11,88366
Var9_x5	173	64,5940	50,86000	79,9800	29,3292	5,41565
Var11_x6	173	51,6513	41,36000	59,1500	11,9736	3,46029
Var12_y6	173	39,8609	34,28000	44,6800	4,1447	2,03585
Var13_x7	173	64,8702	42,47000	78,3600	38,2329	6,18328
Var14_y7	173	35,5298	24,82000	46,4100	18,6227	4,31540
Var17_ExpRelCAP	173	0,1427	-0,44210	0,7250	0,0420	0,20503
Var18_ExpRelCMP	173	-0,1702	-1,31100	0,7783	0,2167	0,46555
Var19_ExpRelCBP1	173	-0,8637	-1,68800	-0,1040	0,1239	0,35200
Var20_ExpRelCBP2	173	2,8271	1,74700	4,1890	0,2349	0,48466

### 3.2. Validación del modelo MSPC

Con base en las 15 variables que cumplieron los criterios de normalidad, se procedió a la construcción del modelo multivariante mediante el ACP. El modelo permitió identificar las combinaciones lineales de variables (componentes principales) que explican la mayor parte de la varianza observada en el sistema. Este proceso de reducción dimensional facilitó la detección de correlaciones ocultas y la identificación de las variables con mayor influencia sobre el comportamiento global de la turbina.

Para la validación del modelo, se empleó el estadístico  $T^2$  de Hotelling, ampliamente utilizado en el control estadístico multivariable de procesos [1, 3]. La verificación del umbral de control (LCS) se realizó considerando la distribución normal multivariante de los atributos, de manera que los valores del estadístico se mantuvieran dentro de los límites de confianza del 95 %. Los resultados confirmaron la estabilidad del modelo y su capacidad para representar de forma adecuada el estado operativo normal de la turbina.

Los gráficos de control obtenidos a partir del estadístico  $T^2$  evidenciaron la ausencia de puntos fuera de los límites establecidos para la muestra patrón, lo cual validó la consistencia interna del modelo. Este comportamiento confirmó que las variaciones observadas correspondieron a fluctuaciones aleatorias inherentes al proceso, sin presencia de anomalías estructurales o funcionales.

### 3.3. Interpretación de los resultados y discusión técnica

El análisis multivariante demostró que el modelo ACP-MSPC desarrollado constituye una herramienta eficaz para la caracterización de la condición operativa de turbinas a vapor. Al integrar variables vibratorias y tecnológicas dentro de un marco común de modelado estadístico, fue posible identificar relaciones interdependientes entre los parámetros síntoma que resultan invisibles al análisis univariado tradicional.

Los resultados muestran que la metodología propuesta permite establecer un patrón de referencia de la condición funcional estable, frente al cual pueden compararse nuevos conjuntos de datos obtenidos durante la operación de la turbina. Esto abre la posibilidad de implementar esquemas de diagnóstico automatizado basados en la comparación entre el comportamiento actual y el comportamiento patrón.

Asimismo, el enfoque propuesto mejora la capacidad de detección temprana de desviaciones asociadas a fallos incipientes, tales como desbalances, holguras o variaciones térmicas anómalas. Este tipo de análisis constituye la base para la transición hacia sistemas de mantenimiento predictivo basados en datos, en los cuales la vigilancia continua del estado mecánico y termodinámico de la turbina se convierte en un proceso automatizado y autoajutable.

En comparación con los métodos tradicionales de monitoreo, el modelo ACP-MSPC ofrece ventajas adicionales: reducción del ruido estadístico, mejor manejo de la multicolinealidad entre variables y generación de indicadores sintéticos (componentes principales) que simplifican la interpretación del estado operativo. Estos resultados se encuentran en correspondencia con los obtenidos en investigaciones recientes sobre mantenimiento inteligente de turbinas [10-12].

Finalmente, el análisis confirma que la metodología de preprocesamiento, acondicionamiento y modelado multivariante desarrollada permite construir modelos diagnósticos robustos capaces de describir el comportamiento normal de las turbinas de 100 MW con alta confiabilidad. Los resultados obtenidos constituyen un aporte relevante al desarrollo de estrategias de supervisión y diagnóstico basadas en datos en el contexto de las centrales termoeléctricas modernas.

## Conclusiones

El desarrollo del modelo de diagnóstico basado en datos para turbinas a vapor de 100 MW permite establecer un procedimiento metodológico sólido para la caracterización y evaluación del comportamiento funcional-dinámico de estos sistemas. La integración del análisis de componentes principales (ACP) con el control estadístico multivariable de procesos (MSPC) es una herramienta efectiva para identificar desviaciones respecto a la condición operativa normal, constituyendo una base científica para el diagnóstico temprano de fallos.

## Referencias

- Ahmer M, Sandin F, Marklund P, Berglund K. Using Multivariate Quality Statistic for Maintenance Decision Support in a Bearing Ring Grinder. *Journals Machines. Section Machines Testing and Maintenance*. 2022;10(9):794-804. <https://doi.org/10.3390/machines10090794>
- Barriento VF, Achcar JA. Statistical analysis of equipment maintenance time in the food industry: a case study to identify sources of impact on performance. *Ingeniare. Revista chilena de ingeniería*. 2019;27(1):151-163. <http://dx.doi.org/10.4067/S0718-33052019000100151>
- Betti A, Crisostomi E, Paolinelli G, Piazzi A, Ruffini F. Condition monitoring and predictive maintenance methodologies for hydropower plants equipment. *Renewable Energy*. 2021;171(6):246-253. <https://doi.org/10.1016/j.renene.2021.02.102>
- Braga J, Andrade AR. Multivariate statistical aggregation and dimensionality reduction techniques to improve monitoring and maintenance in railways: The wheel set component. *Reliability Engineering & System Safety*. 2021;216(12):107932-107942. <https://doi.org/10.1016/j.ress.2021.107932>
- Duc Hanh D, Phuc D, Tao QB, Si Hung NH. Degradation modelling and opportunistic maintenance for two-component systems with an intermittent operation component. *Computers & Industrial Engineering*. 2023;185(11):109698-109708. <https://doi.org/10.1016/j.cie.2023.109698>
- Falekas G, Karlis A, Antonino-Daviu JA. Industrial Steam Turbine Generator Predictive Maintenance Based on Measurement Availability. In: *IEEE Energy Conversion Congress and Exposition (ECCE)*. Nashville, EU: IEEE; 2023. <https://doi.org/10.1109/ECCE53617.2023.10362627>
- Helin, M. Fault detection in steam turbines using data-driven methods. AEE - Master's Programme in Automation and Electrical Engineering. ELEC3025. 2020. Aalto University, Finlandia.
- Jalal T, Hiwa F, Hasan R. An integrated Markov chain model for the economic-statistical design of adaptive multivariate control charts and maintenance planning. *European Journal of Industrial Engineering*. 2022;17(1):1-28. <https://doi.org/10.1504/EJIE.2023.10044732>
- Man J, Zhou, Q. Prediction of hard failures with stochastic degradation signals using Wiener process and proportional hazards model. *Computers & Industrial Engineering*. 2018;125(11):480-489. <https://doi.org/10.1016/j.cie.2018.09.015>
- Santiago RA, Barbosa NB, Mergulhão HG, Carvalho TF, Santos AAB, Medrado RC, et al. Data-Driven Models Applied to Predictive and Prescriptive Maintenance of Wind Turbine: A Systematic Review of Approaches Based on Failure Detection, Diagnosis, and Prognosis. *Energies*. 2024;17(5):1010. <https://doi.org/10.3390/en17051010>
- Graves R, Pankaj P, Kuruvilla VJ, Johnson R, Inoue M. Data-driven prognostics and diagnostics of industrial machinery—a turbofan engine case study. En *PHM Society Asia-Pacific Conference*. 2023. <https://doi.org/10.36001/phmap.2023.v4i1.3690>
- Chapelin J, Voisin A, Rose B, Lung B, Steck L, Chaves L, et al. Data-driven drift detection and diagnosis framework for predictive maintenance of heterogeneous production processes: Application to a multiple tapping process. *Engineering Applications of Artificial Intelligence*. 2025;139:109552. <https://doi.org/10.1016/j.engappai.2024.109552>
- Pincay Ponce JI, Angulo Murillo NG, Herrera Tapia JS, Delgado Muentes WR. Técnicas de minería de datos como soporte para la gestión de un sistema de comercialización de energía eléctrica. *Mikarimin, Revista Científica Multidisciplinaria*. 2020;6(2):19-34.
- Flores Tapia CE, Flores Cevallos KL. Pruebas para comprobar la normalidad de datos en procesos productivos: Anderson-Darling, Ryan-Joiner, Shapiro-Wilk y Kolmogórov-Smirnov. *Societas. Revista de Ciencias Sociales y Humanísticas. Universidad de Panamá*. 2021;23(2):83-106. <https://revistas.up.ac.pa/index.php/societas/article/view/2302>
- Montgomery DC, Friedman DJ. *Statistical process control in a computer-integrated manufacturing environment. Statistical process control in automated manufacturing*. Florida, USA: CRC Press; 1988. [https://api.pageplace.de/preview/DT0400\\_9781000103724\\_A40688518/preview-9781000103724\\_A40688518.pdf](https://api.pageplace.de/preview/DT0400_9781000103724_A40688518/preview-9781000103724_A40688518.pdf)
- Rasay H, Fallahnezhad MS, ZareMehrdardi Y. Application of multivariate control charts for condition-based maintenance. *International Journal of Engineering*. 2018;31(4):597-604. <https://doi.org/10.5829/ije.2018.31.04a.11>

### Editores:

Alberto Julio Rodríguez Piñeiro, Vladimir T. González Fernández.  
Universidad Tecnológica de La Habana José Antonio Echeverría

### Conflicto de intereses

Los autores declaran que no existen conflictos de intereses

### Contribución de los autores

#### Francisco A. de la Torre Silva.

Participó en el diseño de la investigación, recolección de los datos, procesamiento de los datos recogidos para el estudio, análisis de los resultados e interpretación de los datos, investigación bibliográfica y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.

#### Evelio Palomino Marín.

Trabajó en el diseño de la investigación, recolección de los datos, procesamiento de los datos recogidos para el estudio, análisis de los resultados e interpretación de los datos, revisión del estado del arte y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.

**Armando Díaz Concepción.**

Participó en el diseño de la investigación, recolección de los datos, procesamiento de los datos recogidos para el estudio, análisis de los resultados e interpretación de los datos y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.

**Alejandra Elena García Toll.**

Participó en la recolección de los datos, procesamiento de los datos recogidos para el estudio y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.

**Alexander Alfonso Álvarez.**

Trabajó en la recolección de los datos, procesamiento de los datos recogidos para el estudio y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.

**Joel Guillen García.**

Trabajó en la recolección de los datos, procesamiento de los datos recogidos para el estudio y en la revisión crítica de su contenido así como en la redacción y aprobación del informe final.