

Módulo 5.4

Detección de averías


SHaKE – Intercambio de calor y conocimientos sobre comunidades energéticas
Erasmus+ KA220-HED: Asociaciones de cooperación en la educación superior
Institución responsable: Mines Paris – PSL
Autor: Dr. Antoine Fabre
Fecha: marzo de 2026
Versión 1.0



SHaKE
Sharing Knowledge on Energy Communities



1. Introducción



[Mansson et al., 2019]



Solo el 26 % de las subestaciones funciona correctamente

[Gadd y Werner, 2015]




Los fallos más graves son:

- Válvulas de control defectuosas
- Sistemas de red secundaria inadecuados
- Sistema de suministro de agua caliente sanitaria inadecuado

[Zinko et al., 2005]

2. ¿Qué es un fallo de funcionamiento?



Datos disponibles:



Datos legales:

- Temperatura de impulsión y retorno de la red principal
- Temperatura de impulsión secundaria
- Caudal másico primario
- Potencia intercambiada en la subestación



Muy necesario:

- Temperatura de retorno secundaria
- Caudal másico secundario




Útil:

- Temperatura de retorno en cada emisor



¿Cómo detectar si hay averías?

2. ¿Qué es un fallo de funcionamiento?



Métodos de detección de averías utilizados por los operadores



Comprobaciones mensuales de los datos de facturación de los clientes



Índice de calidad basado en el rendimiento de la instalación



Análisis de los niveles de temperatura de retorno



Análisis de los caudales



Método de consumo excesivo

2. ¿Qué es un fallo de funcionamiento?

Detección de anomalías

Patrones en los datos que no se ajustan a una noción previamente definida de comportamiento esperado y «normal»

Valores atípicos

Desviaciones

Comportamiento atípico

Patrones anormales



¿Fallos? ¿Uso ineficiente? ¿Cambio en el comportamiento del usuario?


Detección de fallos

Cambio en un sistema que hace que ya no funcione satisfactoriamente ni cumpla con los requisitos de sus usuarios

Necesidad de medidas correctivas

Determinación de las causas

2. ¿Qué es un fallo de funcionamiento?




Estos métodos de detección de anomalías o fallos pueden utilizarse por separado o en combinación

3. Detección de anomalías




Visualización y
Análisis manual



Los expertos examinan las mediciones de la subestación o los parámetros derivados con la ayuda de herramientas de visualización → Gran flexibilidad, pero subjetivo

3. Detección de anomalías


Comportamiento
correcto



Comportamientos
diferentes de la
subestación en
comparación con una
subestación de
referencia



Comportamiento
incorrecto




[Gadd y Werner, 2015]

3. Detección de anomalías




Umbrales



Un umbral se utiliza para determinar el estado de una subestación. Los umbrales pueden ser establecidos manualmente por un experto humano en función de la tasa de error o del análisis estadístico

3. Detección de anomalías



Correlación entre la apertura de la válvula de control medida y la simulada por un modelo de aprendizaje automático sin fallos

Cálculo del residuo normalizado entre la apertura de la válvula simulada y la medida para varios casos de incrustaciones


Se detecta un ensuciamiento cuando se supera el umbral

El umbral se basa en la tasa de falsas alarmas (inferior al 3 %) para el funcionamiento normal

3. Detección de anomalías




Regresión



La regresión tiene como objetivo estimar la relación entre una variable dependiente y una o más variables independientes. La regresión se utiliza habitualmente para predecir una determinada variable y evaluar la desviación entre los valores previstos y los medidos

3. Detección de anomalías



En el caso de un intercambiador de calor, existe una regresión lineal entre la potencia intercambiada y el coeficiente global de transferencia de calor UA

$$UA = \frac{1}{DTLM} * \phi = a * \phi$$

La acumulación de incrustaciones en el intercambiador de calor modifica la pendiente de la curva lineal.


Se definen tres umbrales en función de la variación de la pendiente:

- <15 % → Condiciones de limpieza
- 15 % < x < 25 % → Condiciones de ensuciamiento parcial
- >25 % → ensuciamiento elevado

3. Detección de anomalías




Clasificación




Tarea de aprendizaje automático que consiste en asignar un elemento a una de varias clases dadas (por ejemplo, funcionamiento normal o funcionamiento anómalo). A diferencia de la regresión, el resultado de un clasificador es la asignación de un elemento representado por un número entero


3. Detección de anomalías



Fuga



Fallo del sensor




Las redes bayesianas pueden utilizarse para describir de forma probabilística las relaciones de causa y efecto entre magnitudes conocidas con el fin de detectar automáticamente fallos

Aquí se muestra la comparación de la medición de presión en una tubería

3. Detección de anomalías




Agrupación



La agrupación se parece a la clasificación, pero en lugar de aprender a partir de ejemplos etiquetados, organiza los elementos de tal forma que compartan propiedades más similares con los elementos de sus grupos. De este modo, se pueden identificar y analizar los valores atípicos o los grupos marginales

3. Detección de anomalías



[Xue et al., 2017]

El análisis de agrupamiento permite identificar los patrones operativos estacionales y diarios


Se identifican diferentes estrategias de regulación:

- Relación entre la diferencia de temperatura primaria y el calor intercambiado
- Relación entre el caudal másico secundario y el calor intercambiado
- Relación entre el caudal másico secundario y la diferencia de presión secundaria
- Relación entre el calor intercambiado en el lado primario y en el secundario


Cuando uno de los patrones no se corresponde con un clúster, se detecta un fallo

3. Detección de anomalías

Todos estos métodos se basan en el mismo concepto: comparar los datos medidos con los datos de funcionamiento normal para detectar desviaciones



3. Detección de anomalías



Método del caudal excesivo

$$V_{excess} = V_{mes} - V_{target}$$

$$V_{excess} = \frac{\dot{Q}_{mes}}{\rho C_p} \left(\frac{1}{T_{sup,mes} - T_{ret,mes}} - \frac{1}{T_{sup,mes} - T_{ret,target}} \right)$$

Cuanto mayor es el exceso de flujo, más reduce la subestación el rendimiento global de la red

El método del flujo excedente permite clasificar las subestaciones (SST) y, de este modo, seleccionar aquellas que deben investigarse con prioridad



Se necesitan pocos datos

Priorizar la investigación




¿Cómo elegir la temperatura de referencia?

No es una herramienta de uso diario

No da pistas sobre el origen de la avería

3. Detección de anomalías



[Gadd y Werner, 2014]



Se necesitan pocos datos

Detección rápida de anomalías

Método de la firma térmica

Basado en las siguientes medidas:

$$\Delta T_{prim,moy} = a T_{out} + b$$

$$Threshold_{high} = \Delta T_{prim,moy} = +3 \sigma$$

$$Threshold_{low} = \Delta T_{prim,moy} = -3 \sigma$$

Cuando un valor medido de « » supera un umbral, se detecta una anomalía. Este indicador no funciona si la subestación solo suministra agua caliente sanitaria (ACS)

¿Cómo elegir el comportamiento de referencia?

No hay pistas sobre el origen de la avería



Based on measure:

$$\Delta T_{prim,moy} = T_{in} - T_{out}$$

$$Threshold_{high} = \Delta T_{prim,moy} + 3\sigma$$

$$Threshold_{low} = \Delta T_{prim,moy} - 3\sigma$$

3. Detección de anomalías



[Manson et al., 2018]

Mejora del método de la firma térmica:

- Regresión lineal diferente en función de la temperatura exterior
- Mismo umbral basado en la desviación estándar
- Se han utilizado nuevos datos (intercambio de energía y temperatura de retorno)



Se necesitan pocos datos


Detección rápida de anomalías



¿Cómo elegir el comportamiento de referencia?


No hay pistas sobre el origen de avería

3. Detección de anomalías



Mejora del método de la firma térmica:

- Agrupación de los distintos patrones de carga térmica (diferentes tipos de usuarios finales)
- Diferentes regresiones lineales en función de la temperatura exterior
- Umbral adaptativo basado en el grupo



[Theusch et al., 2021]



Se necesitan pocos datos


Rápida detección de anomalías



Necesidad de datos de calidad y conocimiento sobre los usuarios finales

No hay indicios sobre el origen de la avería

3. Detección de anomalías



Mejora del método de la firma térmica:

- Agrupación de los diferentes patrones de carga térmica (diferentes tipos de usuarios finales)
- Umbral adaptativo basado en el grupo

[Farouq et al., 2020]



Se necesitan pocos datos


Detección rápida de anomalías



Necesidad de datos de calidad y conocimiento sobre los usuarios finales

No hay indicios sobre el origen de la avería

4. Detección de fallos



[Bahlawan et al., 2022]

Comparación entre los datos medidos y los datos de una simulación.

Se detecta un fallo a través de la diferencia relativa entre los datos medidos y los simulados

$$\delta T_s = \frac{T_{s,mes} - T_{s,simu}}{T_{s,simu}}$$

El diagnóstico se realiza mediante índices de estado calculados gracias a un algoritmo de optimización



Detección rápida de anomalías


Diagnóstico de la anomalía



Necesidad de datos de calidad

Necesidad de un gemelo digital de la red

4. Detección de fallos



Se utiliza un algoritmo de aprendizaje automático para:

- Aprender el comportamiento normal de funcionamiento (datos experimentales de laboratorio)
- Aprender la firma específica de varios fallos (patrón y valor estadístico)

[Van Dreven et al., 2024]



Detectar rápidamente anomalías

Realizar el diagnóstico de la anomalía




Necesidad de datos de calidad

Necesidad de datos etiquetados sobre fallos

4. Detección de averías




Averías analizadas:



4. Detección de fallos

➔ Válvula del lado primario obstruida



Observación: inestabilidad del caudal másico

Indicador propuesto:



Cálculo de la variación del caudal másico

$$D_m = \frac{\dot{m}_{t+\Delta t} - \dot{m}_t}{\dot{m}_{t+\Delta t}}$$




Criterios: si se produce más de 4 veces al día, existe un problema de regulación

[Fabre, 2020]

4. Detección de fallos

➔ Incrustaciones en el intercambiador de calor



Observación: un aumento de la resistencia térmica en función de la relación de caudales másicos



Cálculo de la resistencia térmica tras una limpieza:

$$R_{HEX,without\ fouling} = DTLM/\dot{Q}$$

$$R_{HEX,without\ fouling} = A \dot{M} + B$$

$$\dot{M} = \frac{\dot{m}_p^{0,8} + \dot{m}_s^{0,8}}{\dot{m}_p^{0,8} \dot{m}_s^{0,8}}$$




Criterios: para un dado, si

$$R_{HEX} > 1,4 R_{HEX,without\ fouling}$$

[Fabre, 2020]

4. Detección de averías

➔ Válvula del lado secundario bloqueada



Observación: las variaciones del DTLM del radiador se suavizan



Cálculo del DTLM del radiador:

$$DTLM = \ln \left(\frac{T_{in} - T_{int}}{T_{out} - T_{int}} \right)$$




Criterios:

si la variación relativa del DTLM es inferior al 10 %

[Fabre, 2020]

4. Detección de averías

- Temperatura de retorno del agua caliente sanitaria [Fabre, 2020]



Observación: la temperatura de retorno en el lado primario del HEX de agua caliente sanitaria es elevada

Supuesto:

$$T_{recirc} = 55^{\circ}\text{C}$$

$$Designed\ F = \dot{m}_{recirc} / \dot{m}_{demand}$$



Cálculo:

$$T_{p,out} = (1 - E) T_{p,in} + \frac{E}{1 + F} (T_{recirc} F + T_{CW})$$



Criterios: Trazar el gráfico de ambas temperaturas del lado primario. Comprobar si los gráficos se sitúan por encima de la línea gris que representa una eficiencia $E = 0,8$, por ejemplo

- **S. Månsson, P. O. Johansson Kallioniemi, M. Thern, T. Van Oevelen y K. Sernhed**, «Averías en las instalaciones de los clientes de calefacción urbana y formas de abordarlas: experiencias de las empresas de servicios públicos suecas», *Energy*, vol. 180, pp. 163-174, 2019
- **H. Gadd y S. Werner**, «Detección de averías en subestaciones de calefacción urbana», *Applied Energy*, pp. 51-59, 2015, <http://dx.doi.org/10.1016/j.apenergy.2015.07.061>
- **R. Kim, Y. Hong, Y. Choi y S. Yoon**, «Detección de incrustaciones a nivel de sistema en subestaciones de calefacción urbana mediante un sistema de automatización de edificios asistido por sensores virtuales», *Energy*, vol. 227, p. 120515, 2021, <https://doi.org/10.1016/j.energy.2021.120515>
- **E. Guelpa y V. Verda**, «Detección automática de incrustaciones en subestaciones de calefacción urbana: metodología y ensayos», *Applied Energy*, vol. 258, pp. 114059, 2020, <https://doi.org/10.1016/j.apenergy.2019.114059>
- **P. Xue, Z. Zhou, X. Fang, X. Chen, L. Liu, Y. Liu, J. Liu**, «Detección de fallos y optimización del funcionamiento en subestaciones de calefacción urbana basadas en técnicas de minería de datos», *Applied Energy*, vol. 205, pp. 926-940, 2017, <http://dx.doi.org/10.1016/j.apenergy.2017.08.035>
- **H. Zinko, H. Lee, B.-K. Kim, Y.-H. Kim, Y.-H. Kim, A. Loewen, A. Loewen, H. Walletun, M. Wigbels**, «Mejora de las diferencias de temperatura de funcionamiento en los sistemas de calefacción urbana», Agencia Internacional de la Energía. Anexo VII de la IEA sobre calefacción y refrigeración urbanas y cogeneración. 2005
- **H. Gadd y S. Werner**, «Cómo conseguir bajas temperaturas de retorno en las subestaciones de calefacción urbana», *Applied Energy*, vol. 136, pp. 59-67, 2014, <http://dx.doi.org/10.1016/j.apenergy.2014.09.022>

- **S. Månsson, K. Davidsson, P. Lauenburg y M. Thern**, «Métodos estadísticos automatizados para la detección de averías en instalaciones de clientes de calefacción urbana», *Energies*, vol. 12, p. 113, 2018, <https://doi.org/10.3390/en12010113>
- **F. Theusch, P. Klein, R. Bergmann, W. Wilke, W. Bock y A. Weber**, «Detección de fallos y monitorización del estado en la calefacción urbana mediante datos de contadores inteligentes», *Conferencia Europea de la PHM Society*, vol. 6, p. 11, 2021, <https://doi.org/10.36001/phme.2021.v6i1.2786>
- **S. Farouq, S. Byttner, M.-R. Bouguelia, N. Nord y H. Gadd**, «Monitorización a gran escala de subestaciones de calefacción urbana con operaciones diversas: un enfoque basado en grupos de referencia», *Aplicaciones de ingeniería de la inteligencia artificial*, pp. 90, 2020. <https://doi.org/10.1016/j.engappai.2020.103492>
- **H. Bahlawan, N. Ferraro, A. Gambarotta, E. Losi, L. Manservigi, M. Morini, C. Saletti, P. Ruggero Spina y M. Venturini**, «Detección e identificación de fallos en una red de calefacción urbana», **Energy Conversion and Management**, vol. 266, pág. 115837, 2022, <https://doi.org/10.1016/j.enconman.2022.115837>
- **J. Van Dreven, V. Boeva, S. Abghari, H. Grahn y J. Al Koussa**, «Un enfoque sistemático para la generación de datos para la detección y el diagnóstico inteligentes de averías en la calefacción urbana», *Energy*, vol. 307, pp. 132711, 2024, <https://doi.org/10.1016/j.energy.2024.132711>
- **A. Fabre**, «Desarrollo de indicadores de rendimiento y detección de fallos en las redes de calefacción con el objetivo de optimizar su gestión», Tesis doctoral, Mines Paris PSL, 2020 <https://doi.org/10.70675/656cda46z6318z424bz8417za6c460641433>



¡Gracias!

Módulo 5.4 – Detección de averías

SHaKE – Intercambio de calor y conocimientos sobre comunidades energéticas

<https://www.shakeproject-dhc.eu/>

Desarrollado por Mines Paris – PSL

Antoine Fabre | antoine.fabre@minesparis.psl.eu

Pascal Stabat | pascal.stabat@minesparis.psl.eu

