



Universidade de Vigo

Trabajo Fin de Máster

Modelos para a detección de fallos en dispositivos.

Paula Lema Dourado

Máster en Técnicas Estadísticas

Curso 2025-2026

Propuesta de Trabajo Fin de Máster

Título en galego: Modelos para a detección de fallos en dispositivos.
Título en español: Modelos para la detección de fallos en dispositivos.
English title: Models for failure detection in devices.
Modalidad: Modalidad B
Autor/a: Paula Lema Dourado, Universidade Santiago de Compostela
Director/a: Salvador Naya Fernández, Universidade da Coruña; Javier Tarrío Saavedra, Universidade da Coruña
Tutor/a: Diego Arufe Castro, Cofrico S.L.;
Breve resumen del trabajo: Detección de anomalías en dispositivos de instalacións frigoríficas mediante técnicas estadísticas e aprendizaxe automática, comparando kNN con XGBoost e gráficos EWMA/MEWMA, e aplicando a metodoloxía a casos reais e á súa implementación nun motor de detección.
Recomendaciones:
Otras observaciones:

Don/doña Salvador Naya Fernández, profesor de la Universidade da Coruña, don/doña Javier Tarrío Saavedra, profesor de la Universidade da Coruña, don/doña Diego Arufe Castro, Desarrollador I+D+i de Cofrico S.L., informan que el Trabajo Fin de Máster titulado

Modelos para a detección de fallos en dispositivos.

fue realizado bajo su dirección por don/doña Paula Lema Dourado para el Máster en Técnicas Estadísticas. Estimando que el trabajo está terminado, dan su conformidad para su presentación y defensa ante un tribunal. Además, Don/doña Salvador Naya Fernández, don/doña Javier Tarrío Saavedra y don/doña Paula Lema Dourado

sí no

autorizan a la publicación de la memoria en el repositorio de acceso público asociado al Máster en Técnicas Estadísticas.

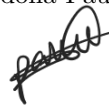
En Coruña, a 3 de xuño de 2026.

El/la director/a:
Don/doña Salvador Naya Fernández

El/la director/a:
Don/doña Javier Tarrío Saavedra

El/la tutor/a:
Don/doña Diego Arufe Castro

El/la autor/a:
Don/doña Paula Lema Dourado



Declaración responsable. Para dar cumplimiento a la Ley 3/2022, de 24 de febrero, de convivencia universitaria, referente al plagio en el Trabajo Fin de Máster (Artículo 11, [Disposición 2978 del BOE núm. 48 de 2022](#)), **el/la autor/a declara** que el Trabajo Fin de Máster presentado es un documento original en el que se han tenido en cuenta las siguientes consideraciones relativas al uso de material de apoyo desarrollado por otros/as autores/as:

- Todas las fuentes usadas para la elaboración de este trabajo han sido citadas convenientemente (libros, artículos, apuntes de profesorado, páginas web, programas,...)
- Cualquier contenido copiado o traducido textualmente se ha puesto entre comillas, citando su procedencia.
- Se ha hecho constar explícitamente cuando un capítulo, sección, demostración,... sea una adaptación casi literal de alguna fuente existente.

Y, acepta que, si se demostrara lo contrario, se le apliquen las medidas disciplinarias que correspondan.

Agradecementos

En primeiro lugar, gustaríame agradecer á Cofrico S.L. a oportunidade de realizar este Traballo Fin de Máster na súa empresa. Quero agradecer a todos os meus compañeiros, en especial a Laura e Mario, pola súa acollida, axuda e paciencia dedicada durante estes meses.

Aos meus titores Salvador e Javier polo apoio académico brindado neste tempo e Diego Arufe como titor adoptivo na empresa.

Por último, quero agradecer aos meus pais o seu apoio constante, non só durante a realización deste traballo, senón ao longo de toda a miña formación. Grazas pola confianza, pola paciencia e por estar aí para todo.

A todos vós, polo voso apoio e axuda, grazas.

Índice xeral

Resumo	XI
Prefacio	XIII
1. Contextualización do problema	1
1.1. Sobre a empresa	1
1.2. Formulación do traballo	2
1.3. O ciclo do frío	3
2. Métodos estatísticos empregados	7
2.1. XGBoost e MEWMA	7
2.1.1. Modelo XGBoost	8
2.1.2. Gráficos de control EWMA e MEWMA	11
2.2. K-veciños máis próximos	14
3. Simulación	19
3.1. Obxectivo da simulación	19
3.2. Xeración dos datos	20
3.3. Aplicación dos métodos	22
3.4. Resultados da simulación	24
4. Caso práctico	31
4.1. Xeo no evaporador	31
4.1.1. Aplicación dos métodos de detección	33
4.2. Presencia de incondensables na instalación	36
4.2.1. Aplicación dos métodos de detección	37
4.3. Fallo de bombeo de refrixerante	39
4.3.1. Aplicación dos métodos de detección	41
4.4. Conclusións dos casos prácticos	43
5. Implementación da metodoloxía	45
5.1. Contexto informático do sistema	45
5.2. Recursos utilizados	46
5.3. Xustificación da metodoloxía implementada	47
5.4. Estrutura xeral do motor de detección	49
5.5. Adestramento dos modelos	49
5.6. Detección de anomalías	50
5.7. Análise da contribución das variables	50
5.8. Servizos principais do sistema	51
5.9. Librerías de Python empregadas	51
5.10. Endpoints e orquestración do sistema	52

5.11. Integración coa xeración de eventos	52
6. Conclusións	55
Bibliografía	57
Código empregado na simulación	61

Resumo

Resumo en galego

Este Traballo Fin de Máster aborda a detección de anomalías en dispositivos de instalacións frigoríficas industriais mediante técnicas estatísticas e de aprendizaxe automática. O obxectivo principal é estudar metodoloxías capaces de aprender o comportamento normal de activos como compresores e evaporadores, co fin de identificar desviacións que poidan estar asociadas á aparición de fallos ou perdas de eficiencia. Para iso, considéranse dous enfoques complementarios: un método baseado en k -veciños máis próximos, aplicado sobre as variables orixinais e adaptado aos distintos modos de funcionamento, e unha metodoloxía baseada en modelos XGBoost combinados con gráficos de control EWMA ou MEWMA sobre os residuos do modelo.

En primeiro lugar, realízase un estudo de simulación que permite avaliar cuantitativamente o comportamento de ambos métodos nun escenario controlado con etiquetas coñecidas. Posteriormente, as técnicas aplícanse a varios casos reais procedentes de instalacións frigoríficas, incluíndo a formación de xeo nun evaporador, a presenza de gases incondensables e un fallo no sistema de bombeo de refrixerante. Os resultados mostran que ambos enfoques permiten detectar desviacións coherentes cos fallos analizados, aínda que presentan comportamentos diferentes en termos de sensibilidade, persistencia temporal e interpretación. Finalmente, descríbese a implementación da metodoloxía dentro dun motor de detección integrado nunha plataforma de monitorización industrial.

English abstract

This Master's Thesis addresses anomaly detection in devices from industrial refrigeration systems using statistical and machine learning techniques. The main objective is to study methodologies capable of learning the normal behaviour of assets such as compressors and evaporators, in order to identify deviations that may be associated with faults or efficiency losses. Two complementary approaches are considered: a method based on k -nearest neighbours, applied to the original variables and adapted to the different operating modes, and a methodology based on XGBoost models combined with EWMA or MEWMA control charts applied to model residuals.

First, a simulation study is carried out to quantitatively evaluate the performance of both methods in a controlled scenario with known labels. Then, the techniques are applied to several real cases from refrigeration installations, including ice formation in an evaporator, the presence of non-condensable gases and a failure in the refrigerant pumping system. The results show that both approaches are able to detect deviations consistent with the analysed faults, although they exhibit different behaviours in terms of sensitivity, temporal persistence and interpretability. Finally, the implementation of the methodology within a detection engine integrated into an industrial monitoring platform is described.

Prefacio

O presente Traballo Fin de Máster enmárcase no ámbito da detección de anomalías en instalacións frigoríficas industriais mediante o uso de técnicas estatísticas e de aprendizaxe automática. O traballo xorde a partir dunha necesidade práctica identificada nun contexto empresarial real: reforzar os sistemas de mantemento preventivo e predictivo xa existentes mediante métodos capaces de aprender o comportamento normal dos equipos e sinalar desviacións que poidan estar asociadas á aparición de fallos.

As instalacións frigoríficas actuais dispoñen dunha ampla rede de sensores que permite monitorizar de forma continua variables como temperaturas, presións, intensidades eléctricas ou estados de funcionamento dos distintos activos. Esta dispoñibilidade de datos abre a posibilidade de aplicar técnicas estatísticas para caracterizar o funcionamento habitual dos dispositivos e detectar situacións anómalas antes de que deriven en avarías graves ou perdas de eficiencia. Porén, o tratamento destes datos presenta diversas dificultades, como a presenza de ruído, datos faltantes, cambios de réxime operativo e ausencia de etiquetas fiables que indiquen de forma sistemática cando existe ou non un fallo.

Neste contexto, o obxectivo principal deste traballo é estudar e aplicar metodoloxías de detección de anomalías que poidan empregarse en dispositivos frigoríficos, concretamente en compresores e evaporadores. En particular, considéranse dúas aproximacións complementarias. Por unha banda, analízase unha metodoloxía baseada na combinación de modelos XGBoost e gráficos de control EWMA ou MEWMA, aplicada sobre os residuos obtidos ao estimar o comportamento esperado das variables monitorizadas. Por outra banda, emprégase un método baseado en k -veciños máis próximos, que permite identificar observacións afastadas do comportamento normal aprendido a partir dunha mostra de referencia.

A estrutura do traballo é a seguinte. No primeiro capítulo preséntase o contexto do problema, descríbese brevemente a empresa e introdúcense os fundamentos básicos do ciclo frigorífico, co obxectivo de facilitar a interpretación física dos fallos estudados. No segundo capítulo expóñense os métodos estatísticos empregados, incluíndo a formulación dos gráficos EWMA e MEWMA, o modelo XGBoost e o método k NN aplicado á detección de anomalías. No terceiro capítulo realízase un estudo de simulación que permite avaliar o comportamento dos métodos nun escenario controlado, onde se coñece a etiqueta real das observacións. No cuarto capítulo aplícanse as metodoloxías propostas a varios casos prácticos reais, correspondentes á formación de xeo nun evaporador, á presenza de incondensables nunha instalación e a un fallo no sistema de bombeo de refrixerante. Finalmente, no quinto capítulo descríbese a implementación computacional da metodoloxía dentro dun motor de detección integrado nun sistema de monitorización.

Deste xeito, o traballo combina unha parte metodolóxica, unha avaliación mediante simulación e unha aplicación práctica sobre datos reais. A finalidade última non é só comprobar a capacidade das técnicas para detectar desviacións, senón tamén valorar a súa utilidade operativa nun contorno industrial, onde a interpretabilidade, a redución de falsas alarmas e a integración cos sistemas existentes resultan aspectos fundamentais.

Capítulo 1

Contextualización do problema

1.1. Sobre a empresa

Fundada en 1985 en Burela, Cofrico é un referente nacional no deseño, instalación e mantemento de sistemas de refrixeración e climatización. A día de hoxe, a súa sede central atópase en Bergondo (Figura 1.1) e conta con 10 delegacións repartidas por todo o territorio nacional: Barcelona, Málaga, Madrid, Biscaia, Valladolid, Asturias, Lugo, Burela, Vigo e Coruña.



Figura 1.1: Sede central de Cofrico en Bergondo.

A actividade de Cofrico abrangue clientes de distintos sectores, especialmente de distribución alimentaria, plataformas loxísticas, industria alimentaria e climatización industrial. Diversas empresas de renome do ámbito alimentario e comercial, como Carrefour, Lidl, Logista ou Helios, confían nos seus servizos para a conservación dos seus produtos e o mantemento das súas instalacións, tanto en España como en Europa. Para dar soporte a toda esta actividade, a empresa conta cun *Service Center* desde o que se realiza a monitorización e xestión dos problemas e inconvenientes que poidan xurdir en calquera instalación.

A orientación cara á innovación tecnolóxica e a aposta pola eficiencia enerxética con dúas patentes

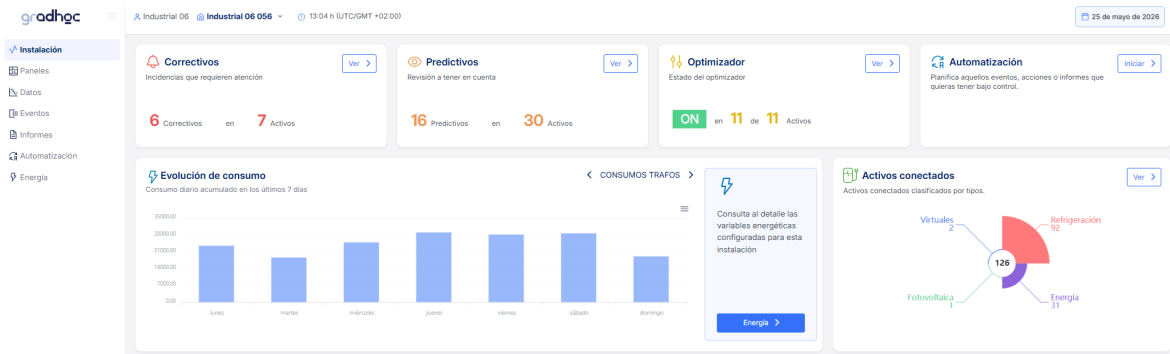


Figura 1.2: Información no inicio da plataforma para unha instalación.

registradas neste ámbito sitúan a esta empresa como unha das principais no sector da refrixeración. Para levar a cabo estes avances, a empresa conta cun departamento propio de I+D+i, desde o cal se impulsou o desenvolvemento de solucións dixitais aplicadas á refrixeración industrial e comercial.

Neste contexto xorde Gradhoc Smart, inicialmente como un proxecto de I+D+i desenvolvido arredor do ano 2016 dentro dun grupo industrial con ampla experiencia en refrixeración industrial, comercial e sistemas HVAC. O obxectivo inicial deste proxecto era aproveitar o coñecemento técnico acumulado no sector da refrixeración e combinalo con tecnoloxías dixitais avanzadas para mellorar a monitorización, o control e a eficiencia das instalacións. Tras varios anos de desenvolvemento tecnolóxico e validación en contornos reais de operación, Gradhoc Smart evolucionou en 2023 ata constituírse como unha empresa tecnolóxica independente.

Na actualidade, Gradhoc Smart céntrase no desenvolvemento de solucións dixitais para a supervisión, control e optimización de instalacións de refrixeración comercial e industrial. Esta plataforma permite transformar os datos operativos xerados polas instalacións en accións concretas de xestión, facilitando a detección de desviacións, a optimización do consumo enerxético e a implantación de estratexias de mantemento preventivo e predictivo. Para iso, integra tecnoloxías como IoT, xemelgos dixitais e aprendizaxe automática, dentro dun sistema orientado á xestión da refrixeración en tempo real. Na Figura 1.2 inclúese unha captura con parte da información que aparece na plataforma ao iniciar sesión.

Aínda que a súa orixe está ligada á experiencia industrial de Cofrico, Gradhoc Smart conta actualmente cunha actividade propia como empresa especializada no desenvolvemento de software para a xestión intelixente de activos frigoríficos. As súas solucións están orientadas a instalacións industriais e comerciais nas que a continuidade operativa, a eficiencia enerxética, a seguridade alimentaria e a anticipación de fallos resultan aspectos críticos. É neste último ámbito, o do mantemento predictivo baseado na análise de datos, onde se desenvolven as actividades realizadas neste Traballo de Fin de Máster.

Para máis información sobre as empresas poden consultarse as súas páxinas web [Cofrico](#) (s.f.) e [Gradhoc](#) (s.f.).

1.2. Formulación do traballo

Como se indicou anteriormente, a empresa dispón dunha plataforma que permite controlar e monitorizar as instalacións frigoríficas en tempo real. Sobre esta infraestrutura desenvólense algoritmos heurísticos baseados no coñecemento dos expertos frigoristas, cuxo obxectivo é xerar eventos de carácter predictivo cando se detectan condicións de funcionamento potencialmente anómalas. Estes algoritmos baséanse en regras técnicas definidas a partir da experiencia acumulada no mantemento de instalacións reais.

Porén, este enfoque presenta certas limitacións, xa que depende en gran medida do coñecemento experto e pode non recoller toda a variabilidade asociada ao funcionamento normal dos equipos.

Ademais, en instalacións industriais complexas, unha mesma variable pode presentar comportamentos distintos segundo o modo de operación, a carga de traballo, as condicións ambientais ou o estado da propia instalación. Por este motivo, xorde a necesidade de complementar estas deteccións con métodos estatísticos e de aprendizaxe automática que permitan reforzar a validez dos eventos xerados e detectar anomalías non sempre recollidas polas regras previamente definidas.

A idea principal do traballo consiste en aprender o comportamento normal dun dispositivo frigorífico para, posteriormente, identificar cambios ou desviacións respecto a ese funcionamento de referencia. Estas anomalías poden estar asociadas á rotura dalgunha das pezas que compoñen a máquina, ao desgaste progresivo dos compoñentes, a problemas de regulación ou a factores externos que alteren o seu funcionamento habitual. Ao dispoñer dun conxunto de datos considerado baixo condicións normais de operación, o problema pode formularse como un caso de detección de anomalías semisupervisada. Neste enfoque, os modelos adéstranse con datos baixo control e posteriormente aplícanse sobre novas observacións para determinar se corresponden a un funcionamento normal ou anómalo.

O emprego de sensores permite estudar e observar o comportamento dos dispositivos a través do xemelgo dixital da instalación. Para que esta monitorización en tempo real sexa posible, as instalacións frigoríficas contan cunha rede de hardware industrial embebida nos equipos. Esta rede inclúe sondas e sensores de distinta natureza, como sensores de temperatura, sensores de presión, termistores ou sinais eléctricos, situados nos elementos principais da instalación.

Todos os sinais recollidos concéntranse e procesáanse nun PLC (*Programmable Logic Controller* ou Controlador Lóxico Programable), que actúa como o cerebro local da instalación. No sector da refrixeración industrial é habitual o emprego de electrónica e automatismos de fabricantes líderes como [Danfoss \(2024\)](#) ou similares. Estes equipos encárganse de dixitalizar as lecturas das sondas e comunicalas á plataforma na nube. Deste xeito, recóllense distintos tipos de datos, que poden ser binarios, categóricos ou continuos, en función do sinal rexistrado.

Non obstante, o uso de datos reais procedentes de instalacións industriais presenta diversas dificultades. É frecuente a presenza de ruído nas medicións, datos faltantes derivados de cortes de comunicación ou fallos de telemetría, cambios nos modos de funcionamento dos equipos e ausencia de etiquetas fiables sobre o estado real dos equipos. Estes aspectos fan que a detección automática de anomalías sexa un problema complexo. Os modelos deben ser capaces de distinguir entre a variabilidade propia do funcionamento normal e as desviacións realmente relevantes desde o punto de vista operativo.

Neste contexto, o presente traballo propón estudar metodoloxías estatísticas e de aprendizaxe automática para caracterizar o comportamento normal de dispositivos frigoríficos e identificar observacións que se afastan dese patrón de referencia. O obxectivo é avaliar a súa utilidade como ferramenta complementaria aos sistemas de detección existentes e contribuír á mellora do mantemento preventivo e predictivo das instalacións.

1.3. O ciclo do frío

Antes de comezar coa presentación do problema e as técnicas resolutivas, cómpre coñecer o contexto no que se sitúa o problema. Por isto, empezamos explicando de xeito esquemático e simple o ciclo de refrixeración nunha instalación. Tomando como referencia os fundamentos técnicos expostos por [Romero Gómez \(2022\)](#), o ciclo básico de compresión componse esencialmente de catro elementos que permiten o aporte de frío a unha cámara pechada. Realmente, sendo exactos, o sistema non achega frío a cámara, senón que extrae a calor dela. Este proceso de quitar calor faise a través do ciclo de refrixeración, que permite mover a calor do interior da cámara cara ao exterior mediante un ciclo pechado sen perda de fluído refrixerante no proceso. Os catro elementos básicos que compoñen o ciclo colocados de xeito seguido tal e como percorrería o refrixerante o ciclo son:

1. **Compresor:** aspira o fluído refrixerante en estado gaseoso para comprimilo, e pasar dun gas a baixa a alta presión, o que supón unha subida drástica da súa temperatura.

2. **Condensador:** o gas a alta presión pasa polas súas bobinas e transmite a calor do fluído refrixerante (moi quente) ao exterior (normalmente ao aire libre) perdendo temperatura e condensando o fluído a estado líquido a alta presión.
3. **Válvula de expansión:** o líquido a alta presión atravesa un orificio cara a unha zona de menor presión. Como consecuencia, expándese de forma brusca e parte do líquido evapórase rapidamente. Este cambio de estado require enerxía, que o refrixerante toma de si mesmo, provocando unha caída da súa temperatura. Nesta etapa, o refrixerante atópase como unha mestura de líquido e vapor a baixa presión.
4. **Evaporador:** situado no interior da cámara, permite absorber a calor dentro dela debido a que esta se atopa a maior temperatura que o refrixerante. Con este intercambio, o refrixerante absorbe a calor o que fai que este se quente e se evapore, volvendo a estado gaseoso a baixa presión.



Figura 1.3: Ciclo de refrigeración.

Representamos os elementos básicos deste ciclo na Figura 1.3. As tuberías vermellas da *Liña de Descarga* representan o refrixerante moi quente en forma gaseosa e con alta presión, debido á calor absorbido polo sistema e ao traballo do compresor. A *Liña de Líquido* en cor azul escuro representa o refrixerante en estado líquido a alta presión que se produce ao expulsar a calor ao pasar polo condensador. Seguidamente o refrixerante pasa pola válvula de expansión sufrindo unha brusca baixada de temperatura e presión, dando lugar a unha mestura de líquido-vapor a baixa presión, *Liña de Expansión*. A liña de cor azul claro representa a *Liña de Aspiración* co refrixerante frío en proceso de absorber a calor da cámara. A dirección das frechas exteriores ao ciclo de frío indican a dirección dos intercambios de calor co entorno. A frecha do evaporador indica a absorción da calor do sistema, mentres que a frecha do condensador indica a expulsión da calor ao exterior.

Como acabamos de ver, no ciclo de refrigeración máis sinxelo interveñen diversos compoñentes. Non obstante, nunha instalación real o número de dispositivos e compoñentes é moito maior e diverso, dando lugar a ciclos moito mais sofisticados e eficientes. Porén, o estudo a realizar neste traballo estará enfocado á detección de anomalías no funcionamento de evaporadores e compresores que son os elementos máis básicos e críticos dentro dunha instalación. Por iso, para entender a natureza do obxecto de estudo faise necesario a comprensión dos modos de operación destes sistemas.

- **Compresores:** neste caso é importante recalcar que o funcionamento desta máquina non é constante, só cando a demanda o solicita. Ademais, por cada instalación pode haber varios compresores que se alternan para suplir a demanda da instalación ou da cámara de frío. Cando o compresor

é requerido, este pode axustar a súa capacidade de funcionamento en función tamén da demanda da instalación. Cando non se precisa da súa intervención, este pode permanecer habilitado. As variables que adoitan estar presentes no compresor son a temperatura de descarga, temperatura de aspiración, temperatura do aceite, presión de descarga, presión de aspiración, presión do aceite, requecemento do compresor, a intensidade requirida e a capacidade do traballo do compresor. Neste sentido, a capacidade do compresor está relacionada coa porcentaxe de fluído gasoso que comprime nese momento. Por tanto, as variables, relaciónanse directamente con esta variable, pois a máis traballo adoitan xurdir problemas derivados do uso prolongado.

- **Evaporadores:** os modos de operación dos evaporadores son máis complexos que os dos compresores. Estes equipos poden atoparse en funcionamento, absorbendo calor da cámara; en repouso ou habilitados á espera de que a temperatura da cámara requira unha nova achega de frío (corte por termóstato); ou en modo de desescarche, no que se achega calor ao evaporador co obxectivo de eliminar o xeo acumulado pola humidade ambiental. As variables máis importantes para a detección son a temperatura de fin de desescarche, temperatura de impulsión, temperatura de retorno, temperatura do aire e o estado que marca o evaporador.

Desde o punto de vista da detección de anomalías, tanto os compresores como os evaporadores presentan un interese especial debido á súa relevancia no funcionamento global da instalación e á variedade de sinais dispoñibles para a súa monitorización. Estes equipos non operan sempre baixo as mesmas condicións, senón que o seu comportamento depende da demanda térmica, do estado da cámara, das condicións ambientais, dos ciclos de funcionamento e dos modos de operación activos en cada momento. Isto provoca que as variables rexistradas polos sensores poidan presentar patróns diferentes sen que necesariamente exista un fallo.

Por este motivo, a detección non debe basearse só na análise illada dunha variable nin na superación puntual dun limiar fixo. É necesario interpretar cada observación en relación co comportamento normal aprendido a partir dos datos históricos e tendo en conta o modo de funcionamento do equipo. Esta formulación permite distinguir entre variacións propias da operación habitual e desviacións potencialmente asociadas a anomalías.

Capítulo 2

Métodos estadísticos empregados

Este capítulo centrase principalmente en expoñer dúas técnicas estadísticas que permitan a detección de anomalías en dispositivos industriais. Primeiramente, na Sección 2.1.2 explicarase a metodoloxía baseada na combinación dun modelo XGBoost con gráficos de control EWMA e MEWMA, sendo este último o caso multivariante do gráfico EWMA. Neste enfoque, XGBoost emprégase para modelizar o comportamento esperado do sistema e os gráficos de control aplícanse posteriormente sobre os residuos obtidos. Seguidamente, na Sección 2.2 presentarase un método máis recente que permita obter un gráfico de control baseándose na técnica de k -veciños máis próximos, no caso aplicado de detección de anomalías. Para mostrar o interese e validez destes métodos, no Capítulo 4 estudaranse tres casos prácticos de fallos detectados en instalacións que permiten mostrar a aplicación de ambas técnicas.

2.1. XGBoost e MEWMA

A detección de fallos en contornos industriais multivariantes presenta unha dificultade esencial: distinguir entre a variabilidade do funcionamento normal dun proceso e as desviacións provocadas por anomalías reais. Esta tarefa complícase debido a que os sistemas industriais adoitan operar en diferentes modos de funcionamento, o que implica que as variables medidas polos sensores presentan comportamentos non estacionarios e fortes dependencias entre elas.

Neste contexto, a aplicación directa de gráficos de control clásicos sobre as variables observadas resulta pouco efectiva, xa que pode dar lugar a un elevado número de falsas alarmas ao non ter en conta a variabilidade asociada aos distintos modos de operación.

Co obxectivo de superar esta limitación, propónse unha metodoloxía en dúas fases. En primeiro lugar, emprégase un modelo de aprendizaxe automática, concretamente XGBoost, para modelizar o comportamento esperado do sistema en condicións normais de funcionamento. A continuación, calcúlanse os residuos como a diferenza entre os valores observados e os estimados polo modelo, eliminando así a variabilidade estrutural do proceso.

Nunha segunda fase, estes residuos son monitorizados mediante gráficos de control baseados en medias móbiles exponencialmente ponderadas (EWMA) e a súa extensión multivariante (MEWMA), co obxectivo de detectar desviacións significativas respecto ao comportamento de referencia.

Desta maneira, seguindo as ideas de [Qin \(2003\)](#) o modelo XGBoost encárgase de capturar a complexidade do proceso industrial e modelizar a relación conxunta entre as variables baixo condicións normais de funcionamento. A partir das predicións obtidas, calcúlanse os residuos como a diferenza entre os valores observados polos sensores e os valores estimados polo modelo. Se o proceso está baixo control, espérase que estes residuos se comporten como unha serie centrada en cero e sen tipo de tendencia.

Unha vez illado o comportamento do sistema, aplícase un gráfico de control MEWMA para realizar a supervisión estatística dos residuos multivariantes. Deste modo, monitorízase de forma conxunta

a estabilidade do sistema, co obxectivo de detectar desviacións significativas respecto ao estado de referencia que poidan indicar a aparición dun fallo.

Esta estratexia de combinar modelos de aprendizaxe automática con gráficos de control aplicados aos residuos foi empregada recentemente en distintos contextos de monitorización. [Aisy et al. \(2025\)](#) propoñen unha metodoloxía baseada en regresión XGBoost e gráficos de control individuais e de rangos móbiles para a monitorización do crecemento do produto interior bruto, empregando os residuos do modelo como sinal de control. De forma semellante, [Alfasanah et al. \(2025\)](#) analizan a monitorización da calidade do aire mediante gráficos individuais e EWMA aplicados aos residuos obtidos a partir de modelos XGBoost e outras técnicas.

A continuación descríbense detalladamente os fundamentos matemáticos de ambas técnicas. En primeiro lugar, abórdase o modelo XGBoost empregado para a estimación do comportamento esperado do sistema. Posteriormente, introdúcense os gráficos de control EWMA e MEWMA, utilizados para a monitorización estatística dos residuos e a detección de anomalías.

2.1.1. Modelo XGBoost

Tal e como se indicou na sección anterior, a primeira fase da metodoloxía proposta consiste en modelizar o comportamento esperado do sistema mediante XGBoost. A partir das predicións obtidas polo modelo calcúlanse os residuos, que posteriormente serán monitorizados mediante gráficos de control EWMA ou MEWMA.

Para levar a cabo esta tarefa, emprégase o algoritmo XGBoost (*eXtreme Gradient Boosting*), unha técnica de aprendizaxe automática baseada en conxuntos de árbores de decisión que destaca pola súa capacidade para modelizar relacións non lineais complexas entre variables.

A elección do modelo XGBoost fronte a outras alternativas está motivada polas características propias do problema. En primeiro lugar, os sistemas industriais presentan relacións complexas e non lineais entre as variables, o que limita a aplicabilidade de modelos lineais clásicos, que requiren a especificación previa destas relacións.

Por outra banda, métodos baseados en series temporais, como os modelos ARIMA, resultan menos adecuados neste contexto ao centrarse fundamentalmente na dependencia temporal dunha única variable ou dun número reducido delas, dificultando a modelización conxunta dun sistema multivariante con múltiples modos de operación.

En canto ás redes neuronais, aínda que presentan unha elevada capacidade de modelización, requiren un maior volume de datos, son máis custosas computacionalmente e presentan unha menor interpretabilidade, o que pode ser unha limitación en contornos industriais onde se precisa comprender o comportamento do sistema.

Tendo en conta estas limitacións, XGBoost constitúe unha alternativa equilibrada para este problema. As razóns fundamentais que xustifican a súa aplicación son:

- **Modelización de non linealidades e interaccións:** Debido á natureza do proceso, as variables non se comportan de xeito illado. Existen interaccións complexas entre elas que o algoritmo é capaz de aprender de forma automática sen necesidade de especificar transformacións previas.
- **Robustez ante datos ruidosos:** En contornos industriais, as lecturas dos sensores poden presentar valores atípicos. Ademais, a función obxectivo de XGBoost inclúe un termo de regularización que axuda a suavizar os pesos aprendidos, evitando o sobreaxuste do modelo.
- **Xestión de datos faltantes:** O algoritmo conta cunha estratexia propia para tratar a perda de datos causados pola falla de comunicación na lectura de datos.
- **Estrutura flexible e poda:** A diferenza doutros métodos, XGBoost constrúe as árbores ata a profundidade máxima indicada e despois aplica unha poda inversa (*backward pruning*).
- **Eficiencia mediante paralelización:** O algoritmo permite paralelizar o proceso de construción das árbores, facilitando o tratamento de grandes volumes de datos históricos de forma eficiente.

Unha vez xustificada a idoneidade de XGBoost para o contorno industrial, cómpre analizar a súa formulación matemática seguindo o traballo de [Chen e Guestrin \(2016\)](#). No contexto deste traballo, para cada observación i , o vector x_i recolle as variables explicativas dispoñibles no dispositivo, mentres que y_i representa a variable monitorizada que se desexa estimar. Unha vez obtida a predición \hat{y}_i mediante o modelo XGBoost, defínese o residuo asociado como

$$e_i = y_i - \hat{y}_i.$$

Baixo condicións normais de funcionamento, espérase que estes residuos estean aproximadamente centrados en cero e non presenten unha tendencia sistemática. Pola contra, residuos persistentemente afastados de cero poden indicar que o comportamento observado xa non é coherente co patrón aprendido polo modelo.

A partir desta notación, descríbese a formulación do modelo XGBoost. Dado un conxunto de datos con n observacións e m características $\mathcal{D} = \{(x_i, y_i)\}_{i=1}^n$ onde $x_i \in \mathbb{R}^m$ e $y_i \in \mathbb{R}$, un modelo de conxunto de árbores emprega K funcións aditivas (árbores de regresión) para predicir a saída, de xeito que:

$$\hat{y}_i = \phi(x_i) = \sum_{k=1}^K f_k(x_i), \quad f_k \in \mathcal{F},$$

onde \mathcal{F} é o espazo de árbores de regresión, definido como $\mathcal{F} = \{f(x) = w_{q(x)}\}$. Neste caso, q representa a estrutura da árbore, que asigna cada observación a unha folla, é dicir, $q : \mathbb{R}^m \rightarrow \{1, \dots, T\}$, sendo T o número de follas da árbore, e $w \in \mathbb{R}^T$ o vector de pesos asociado ás mesmas. Deste xeito, cada función f_k corresponde a unha árbore de regresión independente, na que cada folla asigna un valor constante ás observacións que pertencen a ela. A predición final obtense como a suma das contribucións de todas as árbores do modelo, o que permite aproximar relacións complexas entre as variables explicativas e a variable resposta.

Co obxectivo de aprender o conxunto de funcións que mellor aproximan a relación entre as variables, minimízase a seguinte función obxectivo:

$$\mathcal{L}(\phi) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k),$$

onde l é unha función de perda convexa e diferenciable que mide a diferenza entre a predición \hat{y}_i e o valor observado y_i . O termo de regularización defínese como:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2.$$

Este termo penaliza tanto a complexidade estrutural da árbore (T) como a magnitude dos pesos das follas (w), favorecendo modelos máis simples e mellorando a capacidade de xeneralización ao reducir o sobreaxuste, tal e como se describe en [Chen e Guestrin \(2016\)](#). O obxectivo desta regularización é a selección dun modelo con funcións simples e predictivas. Cando os parámetros de regularización se establecen a cero ($\gamma = \lambda = 0$) o modelo coincide co *Gradient Tree Boosting*.

O adestramento realízase de forma aditiva. Sexa $\hat{y}_i^{(t)}$ a predición da observación i na iteración t . En cada paso engádesse unha nova función f_t co obxectivo de minimizar:

$$\mathcal{L}^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t). \quad (2.1)$$

Este procedemento corresponde a un esquema de *gradient boosting*, no que se engaden sucesivamente árbores que melloran o modelo existente.

Para facilitar a optimización da ecuación 2.1, emprégase unha aproximación de Taylor de segunda orde da función de perda, obténdose:

$$\mathcal{L}^{(t)} \approx \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t),$$

onde g_i e h_i representan respectivamente o gradiente de primeira e segunda orde da función de perda respecto ás predicións anteriores.

Eliminando os termos constantes, obtemos a función obxectivo simplificada:

$$\tilde{\mathcal{L}}^{(t)} = \sum_{i=1}^n [g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t).$$

Definindo $I_j = \{i \mid q(x_i) = j\}$ como o conxunto de observacións asignadas á folla j , o valor óptimo do peso asociado a cada folla obtense como:

$$w_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda}.$$

Substituíndo este resultado na función obxectivo, obtense unha expresión que permite avaliar a calidade dunha estrutura de árbore q :

$$\tilde{\mathcal{L}}^{(t)}(q) = -\frac{1}{2} \sum_{j=1}^T \frac{\left(\sum_{i \in I_j} g_i\right)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T.$$

Esta expresión utilízase na práctica para seleccionar as mellores divisións durante a construción das árbores, de xeito análogo ás medidas de impureza empregadas nas árbores de decisión, pero adaptada a unha función obxectivo máis xeral.

Como normalmente non é posible enumerar todas as estruturas de árbore posibles, XGBoost emprega un procedemento voraz (*greedy*) que parte dunha única folla e vai engadindo divisións de forma iterativa. Para avaliar cada posible división, supóñase que I_L e I_R son os conxuntos de observacións asignadas, respectivamente, ao nodo esquerdo e ao nodo dereito tras a partición, sendo $I = I_L \cup I_R$. A redución da perda asociada a dita división vén dada por:

$$\mathcal{L}_{div} = \frac{1}{2} \left[\frac{\left(\sum_{i \in I_L} g_i\right)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{\left(\sum_{i \in I_R} g_i\right)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{\left(\sum_{i \in I} g_i\right)^2}{\sum_{i \in I} h_i + \lambda} \right] - \gamma.$$

Esta expresión emprégase para avaliar os candidatos a división, seleccionando aquela partición que produce unha maior redución da función obxectivo. O termo γ actúa como penalización pola creación dunha nova folla, polo que unha división só se considera favorable se a mellora obtida compensa o incremento de complexidade do modelo.

Ademais do obxectivo regularizado, XGBoost incorpora dúas técnicas adicionais para reducir o sobreaxuste. A primeira é a taxa de aprendizaxe ou *shrinkage*, que consiste en escalar os pesos das novas árbores mediante un factor η despois de cada iteración. Deste xeito, redúcese a influencia individual de cada árbore e déixase marxe para que árbores posteriores melloren progresivamente o modelo. A segunda técnica é o submuestreo de variables (*column subsampling*), que introduce aleatoriedade no proceso de aprendizaxe e contribúe a mellorar a capacidade de xeneralización.

Finalmente, seguindo a [Qin \(2003\)](#), o uso dos residuos dun modelo de aprendizaxe automática resulta especialmente axeitado en contornos industriais con múltiples modos de operación. Ao traballar cos residuos (definidos como a diferenza entre valores observados e estimados) elimínase a variabilidade asociada ao funcionamento normal do proceso, permitindo identificar de forma máis precisa desviacións relevantes e reducindo a proliferación de falsas alarmas. Así, o modelo non se emprega directamente para a detección de anomalías, senón como unha ferramenta para caracterizar o comportamento normal do sistema e obter unha estimación do seu comportamento esperado. A detección realízase posteriormente mediante a monitorización estatística dos residuos.

2.1.2. Gráficos de control EWMA e MEWMA

Unha vez obtidas as predicións do modelo XGBoost, calcúlanse os residuos como a diferenza entre os valores observados e os valores estimados polo modelo. Estes residuos representan a parte do comportamento do sistema que non foi explicada polo modelo de referencia. Polo tanto, se o modelo foi axustado empregando datos correspondentes a condicións normais de funcionamento e consegue describir adecuadamente as relacións entre as variables, espérase que os residuos presenten un comportamento aproximadamente centrado en cero, sen tendencias sistemáticas nin desviacións persistentes.

Esta propiedade é fundamental para a aplicación de gráficos de control. Ao traballar cos residuos, a variabilidade estrutural asociada aos distintos modos de operación, á carga de traballo ou ás condicións habituais do proceso queda parcialmente absorbida polo modelo XGBoost. Deste xeito, os gráficos EWMA e MEWMA non monitorizan directamente os valores orixinais das variables, senón as discrepancias entre o comportamento observado e o comportamento esperado baixo condicións normais. Como consecuencia, unha desviación sostida dos residuos respecto a cero pode interpretarse como un indicio de que o sistema se afasta do patrón aprendido polo modelo.

Neste contexto, optouse polo uso de gráficos EWMA e MEWMA fronte a outras alternativas clásicas como os gráficos de Shewhart ou o estatístico T^2 de Hotelling.

En primeiro lugar, diversos autores sinalan que os gráficos de Shewhart presentan unha boa capacidade para detectar cambios bruscos de gran magnitude. Non obstante, resultan pouco sensibles a desviacións pequenas ou graduais, xa que se basean unicamente na información da observación máis recente. Ademais, empregan límites de control fixos definidos a partir da media do proceso e da súa variabilidade, estimada mediante a desviación típica, como se describe en [Montgomery \(2019\)](#).

Pola contra, os gráficos EWMA incorporan información histórica mediante un mecanismo de suavizado exponencial. Isto permite detectar cambios persistentes de pequena magnitude de forma máis eficiente, tal e como propuxo [Roberts \(1959\)](#). Esta característica resulta especialmente relevante no contexto dos residuos, onde as anomalías adoitan manifestarse como desviacións sutís respecto a un comportamento esperado aproximadamente centrado.

En segundo lugar, esta idea esténdese de forma natural ao ámbito multivariante. O gráfico MEWMA constitúe a extensión multivariante do EWMA, permitindo integrar tanto a dependencia temporal como a correlación entre variables.

Fronte ao estatístico T^2 de Hotelling, que se basea unicamente na observación actual, o MEWMA acumula información ao longo do tempo. Isto mellora a capacidade de detección de cambios pequenos e correlacionados, como mostran [Lowry et al. \(1992\)](#). Esta propiedade resulta fundamental ao traballar con residuos multivariantes procedentes de sistemas industriais, nos que poden existir dependencias entre variables incluso tras a modelización previa.

Ademais, no marco da monitorización estatística de procesos baseada en modelos, é habitual aplicar gráficos de control sobre residuos co obxectivo de eliminar a variabilidade estrutural e facilitar a detección de desviacións relevantes, como sinala [Qin \(2003\)](#). Baixo estas condicións, os gráficos EWMA/MEWMA presentan un comportamento próximo ao óptimo, xa que están deseñados para monitorizar series aproximadamente estacionarias e centradas, como se espera dos residuos dun modelo ben axustado.

En consecuencia, a combinación de residuos procedentes de XGBoost con gráficos de control EWMA/MEWMA permite aproveitar simultaneamente a capacidade de modelización de relacións complexas e a sensibilidade dos métodos de control estatístico para a detección temperá de anomalías.

Unha vez xustificada a elección destes gráficos, introdúcese a formulación matemática do estatístico EWMA. Este gráfico baséase na construción dunha media móbil exponencialmente ponderada, na que se asigna maior peso ás observacións máis recentes, mentres que o peso das observacións pasadas decrece xeometricamente no tempo, tal e como foi proposto por [Roberts \(1959\)](#).

No contexto deste traballo, a monitorización realízase sobre a serie temporal de residuos obtidos a partir do modelo XGBoost, de xeito que a observación X_t corresponde ao residuo e_t no instante t . O estatístico EWMA defínese recursivamente como:

$$Z_t = rX_t + (1 - r)Z_{t-1}, \quad t \geq 1,$$

onde $0 < r \leq 1$ é o parámetro de suavizado que controla o peso relativo da observación actual, e Z_0 adoita tomarse igual á media do proceso baixo control, μ_0 .

Esta formulación permite interpretar o estatístico como unha combinación convexa entre a observación actual e o valor previo do EWMA. De forma equivalente, pode expresarse como unha suma ponderada de todas as observacións pasadas:

$$Z_t = rX_t + r(1 - r)X_{t-1} + r(1 - r)^2X_{t-2} + \dots,$$

o que evidencia que o peso asignado ás observacións decrece xeometricamente co tempo.

Baixo a hipótese de que as observacións X_t son independentes e teñen media μ_0 e varianza constante, o estatístico Z_t presenta esperanza μ_0 e unha varianza que converxe a:

$$\sigma_Z^2 = \frac{r}{2 - r} \sigma_X^2.$$

A partir desta expresión, constrúense os límites de control como:

$$\mu_0 \pm L\sigma_Z,$$

onde L é un factor que determina o nivel de confianza do gráfico. Este parámetro determina a distancia dos límites de control respecto á media do proceso. Habitualmente, escóllese un valor de referencia similar ao empregado nos gráficos clásicos, como $L = 3$, o que permite identificar observacións afastadas máis de tres desviacións típicas como posibles anomalías. Non obstante, este parámetro pode modificarse co obxectivo de facer o gráfico máis ou menos restritivo, dependendo do equilibrio desexado entre detección de fallos e número de falsas alarmas, e é por este motivo polo cal se elixiu tomar $L = 6$ para obter un comportamento equilibrado do fallo.

O parámetro r xoga un papel fundamental no comportamento do método. Valores elevados de r dan maior peso ás observacións recentes, facendo o gráfico máis sensible a cambios bruscos. Pola contra, valores pequenos de r producen unha maior suavización, incrementando a capacidade de detectar cambios pequenos e persistentes no proceso. Neste traballo tomouse $r = 0,5$, co obxectivo de manter un equilibrio entre a conservación de certa memoria do proceso e evitar unha excesiva sensibilidade a pequenas variacións que non representan un cambio real no funcionamento da máquina.

Por outra parte, o gráfico MEWMA (*Multivariate Exponentially Weighted Moving Average*) constitúe a extensión multivariante do gráfico EWMA para a monitorización simultánea de varias variables correlacionadas. Este método permite incorporar tanto a dependencia temporal como a estrutura de correlación entre as variables, resultando especialmente axeitado en contornos industriais con múltiples sinais medidas de forma conxunta.

No contexto multivariante, a monitorización realízase sobre o vector de residuos asociado ás p variables consideradas. Mantendo a notación habitual do gráfico MEWMA, denótase este vector por $\mathbf{X}_t = \mathbf{e}_t \in \mathbb{R}^p$, onde \mathbf{e}_t recolle os residuos obtidos a partir do modelo de referencia no instante t . Baixo condicións normais de funcionamento, espérase que este vector presente media aproximadamente nula e unha matriz de covarianzas estable.

Na aplicación práctica deste traballo, antes de calcular o estatístico MEWMA, estes residuos foron estandarizados empregando a media e a desviación típica estimadas na mostra de adestramento. Esta transformación permite que todas as variables contribúan ao estatístico nunha escala comparable, evitando que aquelas con maior variabilidade ou unidades de medida dominen a detección. A mesma transformación aplícase posteriormente aos residuos obtidos no período analizado, garantindo que a comparación co comportamento de referencia se realice baixo os mesmos criterios.

De forma análoga ao caso univariante, o vector MEWMA defínese recursivamente como:

$$\mathbf{Z}_i = R\mathbf{X}_i + (I - R)\mathbf{Z}_{i-1}, \quad i = 1, 2, \dots \quad (2.2)$$

onde $R = \text{diag}(r_1, \dots, r_p)$ é unha matriz diagonal de parámetros de suavizado, con $0 < r_j \leq 1$. Dado que neste traballo a monitorización se realiza sobre residuos aproximadamente centrados en cero, tómase $\mathbf{Z}_0 = \mathbf{0}$ como valor inicial do estatístico. No caso máis habitual, considérase $r_1 = \dots = r_p = r$, simplificando a expresión a:

$$\mathbf{Z}_i = r\mathbf{X}_i + (1 - r)\mathbf{Z}_{i-1}. \quad (2.3)$$

Esta formulación constitúe unha extensión directa do estatístico EWMA ao ámbito multivariante, mantendo a idea de acumulación exponencial do histórico de datos.

O gráfico MEWMA considera unha observación fóra de control cando o estatístico:

$$T_i^2 = \mathbf{Z}_i^\top \Sigma_Z^{-1} \mathbf{Z}_i \quad (2.4)$$

supera un determinado límite de control h , onde Σ_Z representa a matriz de covarianzas do vector MEWMA. Na práctica, adoita empregarse a súa forma asíntótica:

$$\Sigma_Z = \frac{r}{2 - r} \Sigma, \quad (2.5)$$

o que permite simplificar o cálculo do estatístico.

Cómpre destacar que, do mesmo xeito que no caso univariante, o parámetro r controla a sensibilidade do método. Valores pequenos de r resultan máis efectivos na detección de cambios pequenos na media do proceso, mentres que valores elevados permiten unha resposta máis rápida ante cambios bruscos.

Ademais, cando $r = 1$, o gráfico MEWMA redúcese ao estatístico T^2 de Hotelling, polo que este método non é máis que unha xeneralización natural dos gráficos clásicos.

Para determinar o límite de control do gráfico MEWMA, calcúlase inicialmente o estatístico T_i^2 sobre a mostra de calibración, formada por observacións consideradas baixo condicións normais de funcionamento. Dado que este estatístico resume a desviación multivariante do proceso respecto ao seu comportamento de referencia, o límite de control establécese a partir da súa distribución empírica na mostra de calibración. En particular, considérase como límite superior

$$h = \overline{M} + \varphi \sigma_M,$$

onde \overline{M} representa a media dos valores do estatístico T_i^2 obtidos na mostra de calibración, σ_M é a súa desviación típica e φ é un factor de sensibilidade que permite regular a amplitude do límite. Deste xeito, valores maiores de φ producen límites máis amplos e reducen a aparición de falsas alarmas, mentres que valores menores incrementan a sensibilidade do gráfico fronte a pequenas desviacións do funcionamento normal. Unha nova observación considérase fóra de control cando o seu estatístico MEWMA supera o valor h .

En canto á interpretación dos sinais fóra de control, esta resulta máis complexa no ámbito multivariante debido á posible correlación entre variables. [Lowry et al. \(1992\)](#) recomendan analizar de forma complementaria as compoñentes individuais do vector MEWMA ou empregar gráficos univariantes asociados, co obxectivo de identificar que variables contribúen á desviación detectada.

Finalmente, seguindo as ideas [Yao et al. \(2022\)](#), neste traballo o gráfico MEWMA aplícase sobre os residuos obtidos a partir dun modelo de referencia baseado en XGBoost. Estes residuos calcúlanse como a diferenza entre os valores observados e as predicións do modelo para cada variable, eliminando así a variabilidade asociada ao comportamento normal do sistema. A monitorización destes residuos mediante gráficos de control permite detectar desviacións con respecto ao funcionamento esperado, considerando o proceso baixo control cando o estatístico se mantén dentro dos límites establecidos. Esta aproximación combina a capacidade de modelización de relacións complexas coa monitorización estatística multivariante, facilitando a detección temperá de anomalías en contornos industriais.

2.2. K-veciños máis próximos

Na actualidade a teoría k -veciños máis próximos (*K Nearest Neighbours* ou pola abreviatura en inglés kNN) é unha técnica amplamente empregada para a clasificación de datos, monitorización de procesos, detección de fallos, procesamento de imaxes, caracterizada por ser un método non paramétrico baseado en medidas de proximidade no espazo de características.

No presente traballo, emprégase unha aproximación baseada en kNN como método semisupervizado de detección de anomalías, onde só se dispón de datos de funcionamento normal do dispositivo [Chandola et al. \(2007\)](#). Neste contexto, o obxectivo non sería asignar etiquetas de clase, senón determinar se unha nova observación se desvía significativamente do comportamento normal aprendido a partir dos datos de adestramento. No Capítulo 3 obteremos métricas sobre a eficiencia deste método de detección que nos permitan avaliar a súa eficacia nun contorno simulado.

Primeiramente, recórdase o funcionamento do método como técnica de clasificación. Dada unha mostra \mathbf{x} sen etiquetas, a regra kNN busca os k -ésimos veciños máis próximos no conxunto e asígnalle a \mathbf{x} á clase coa que aparece con máis frecuencia no k -subconxunto. Trasladando esta idea á detección de anomalías, este criterio substitúese por unha medida de distancia ou densidade. Así, a técnica baséase na suposición de que os datos obtidos en instancias normais tenden a agruparse en veciñanzas densas, mentres que as anomalías ocorren máis illadas e lonxe dos seus veciños. Unha nova observación será considerada normal se se atopa suficientemente próxima aos datos de adestramento, mentres que valores elevados de distancia indicarán posibles desviacións do comportamento esperado.

A clave da detección reside, polo tanto, en como se agrupan os datos no espazo de características. Para traducir esta idea de proximidade á aplicación do método, cómpre definir unha medida de distancia que permita cuantificar o afastamento entre observacións. Dado que esta distancia se calcula a partir de variables que poden estar expresadas en unidades e escalas diferentes, resulta necesario estandarizalas previamente para que todas contribúan de forma comparable ao estatístico de detección.

Este enfoque de natureza non supervisada resulta especialmente útil en detección de anomalías, xa que non require asumir unha distribución específica dos datos nin dispoñer de exemplos etiquetados de todos os posibles fallos [Chandola et al. \(2007\)](#). Deste xeito, o método pode adaptarse a distintos tipos de datos sempre que se defina unha medida de distancia adecuada. Non obstante, como contrapartida, [Guo et al. \(2018\)](#) salientan a sensibilidade do índice de detección aos datos atípicos neste tipo de métodos, debido a que depende directamente das distancias.

Neste sentido, a elección do parámetro k resulta fundamental para garantir un equilibrio adecuado entre sensibilidade fronte a desviacións locais e estabilidade fronte ao ruído.

Dado que a mostra de adestramento contén exclusivamente datos en condicións normais de funcionamento, é posible definir un limiar de decisión baseado na distribución empírica das distancias. Deste modo, unha nova observación será considerada normal se a súa distancia aos seus veciños é inferior a un determinado cuantil.

Para a aplicación do método, defínense os seguintes elementos:

1. k : número de veciños considerados. A súa elección implica un compromiso entre sesgo e varianza ([Hastie et al. \(2009\)](#)). Segundo [He e Wang \(2007\)](#), a elección de k non resulta un paso crítico, aínda que valores pequenos de k poden facer o modelo máis sensible ao ruído, mentres que valores elevados suavizan as estimacións podendo dificultar a detección de anomalías locais.

Na aplicación sobre datos reais optouse por $k = 50$, valor determinado experimentalmente tras avaliar diferentes configuracións. Esta elección proporciona un equilibrio entre estabilidade e capacidade de detección, reducindo a influencia do ruído sen perder sensibilidade ante desviacións significativas. No estudo de simulación empregárase un valor menor de k , debido ao menor volume de datos dispoñible nese escenario, tal e como se xustifica no Capítulo 3.

Ademais, en lugar de empregar unicamente a distancia ao k -ésimo veciño, considérase a media das distancias aos k veciños máis próximos, o que proporciona maior robustez fronte á variabilidade dos datos, seguindo a idea proposta por [Angiulli e Pizzuti \(2002\)](#).

2. $n_j(x_i)$: o j -ésimo veciño máis próximo á observación x_i .

En relación coa métrica de distancia, optouse polo uso da distancia euclídea tras a estandarización previa das variables. Aínda que a distancia de Mahalanobis permite incorporar a estrutura de correlación entre variables, o seu uso require a estimación e inversión da matriz de covarianza, tal e como se desprende da súa formulación:

$$MD_i = (x_i - \bar{x})^T C_x^{-1} (x_i - \bar{x}), \quad (2.6)$$

onde x_i representa o vector de observacións, \bar{x} é o vector de medias e C_x^{-1} é a inversa da matriz de covarianza das variables. Este feito pode introducir problemas numéricos cando a matriz está mal condicionada ou en presenza de multicolinealidade [De Maesschalck et al. \(2000\)](#), ademais de incrementar o custo computacional, especialmente en contextos de alta dimensión ou en aplicacións con grandes volumes de datos.

En contornos industriais, onde os sistemas deben operar con restricións de tempo e recursos, resulta preferible o uso de métricas máis simples e escalables. Tras a estandarización das variables, a distancia euclídea constitúe unha aproximación habitual e efectiva en métodos baseados en veciñanza [Hastie et al. \(2009\)](#), permitindo reducir a complexidade computacional sen unha perda significativa de rendemento.

Destá forma, considérase unha mostra de adestramento $X_{n \times m}$, onde n é o número de observacións e m o número de variables. O procedemento seguido, baseado en [Wang et al. \(2019\)](#), é o seguinte:

1. Estandarización dos datos: para cada variable réstase a súa media e divídese pola súa desviación típica. Este paso é fundamental en métodos baseados en distancia, xa que evita que variables con maior escala dominen o cálculo da distancia ([Hastie et al. \(2009\)](#)).
2. Para cada observación, identifícanse os seus k veciños máis próximos empregando a distancia euclídea.
3. Defínese o estatístico de distancia como a media das distancias ao cadrado aos k veciños máis próximos:

$$D_k^2(x_i) = \frac{1}{k} \sum_{j=1}^k \|x_i - n_j(x_i)\|^2.$$

Cómpre destacar que esta definición constitúe unha variante do estatístico proposto en [Wang et al. \(2019\)](#), onde se emprega a suma das distancias ao cadrado aos k veciños máis próximos. A versión utilizada neste traballo baséase na media destas distancias, o que resulta equivalente dende un punto de vista proporcional, xa que ambas definicións só difiren por un factor constante $1/k$. Esta modificación non altera o comportamento do método pois non é máis que a normalización do estatístico orixinal proposto.

4. Determínase un limiar D_α^2 a partir dun cuantil da distribución empírica das distancias na mostra de adestramento, interpretado como un nivel de confianza $(1 - \alpha)$.

Para unha nova observación x_{new} , o procedemento de detección é:

1. Estandarizar a observación utilizando os parámetros da mostra de adestramento.
2. Calcular o estatístico $D_k^2(x_{\text{new}})$.
3. Comparar co limiar D_α^2 : se $D_k^2(x_{\text{new}}) \leq D_\alpha^2$, considérase funcionamento normal; en caso contrario, identifícase como anomalía.

Antes de aplicar este procedemento, é necesario tratar os posibles valores faltantes presentes nas series temporais. Dado que os datos proceden de sistemas de monitorización real, é habitual a presenza de perdas puntuais de información debidas a fallos de comunicación ou de telemetría. Cando o intervalo sen rexistro é reducido, pódese reconstruír a continuidade do sinal mediante diferentes estratexias, tal

e como se comenta en [Lepot et al. \(2017\)](#). Neste traballo emprégase interpolación lineal para completar as observacións faltantes nas variables continuas, mentres que nas variables discretas ou categóricas se emprega o valor do veciño máis próximo. Esta decisión fundaméntase na simplicidade do procedemento e no seu baixo custo computacional.

Na aplicación práctica do método kNN, a clasificación dunha observación illada como anómala non implica automaticamente a xeración dunha alarma. Co obxectivo de reducir o número de falsas alarmas, introdúcese un criterio adicional de persistencia temporal antes de activar o evento. En particular, requírese que a condición anómala se manteña durante cinco observacións consecutivas. Deste xeito, limítase o efecto de fluctuacións puntuais, ruído de medida ou incidencias breves na transmisión dos datos que poderían dar lugar a alarmas espurias. Dado que os sinais empregados teñen frecuencia minutal, este criterio equivale a esixir unha persistencia mínima aproximada de cinco minutos. Como contrapartida, esta regra introduce un pequeno atraso na xeración da alarma, polo que o fallo non é comunicado de forma instantánea no momento da primeira observación anómala. Non obstante, considérase que este atraso é asumible. Aínda que existen formulacións máis complexas e flexibles para a configuración de alarmas, como os *generalized delay-timers* estudados por [Adnan et al. \(2013\)](#), neste traballo optouse por unha regra máis sinxela e facilmente interpretable.

Ademais da clasificación dunha observación como normal ou anómala, o método kNN permite obter unha medida interpretativa da contribución de cada variable á desviación detectada. Esta análise resulta especialmente relevante no contexto industrial, xa que a xeración dunha alarma debe ir acompañada, na medida do posible, dunha explicación sobre que sinais son as principais responsables do afastamento respecto ao comportamento normal. A definición destas contribucións segue a idea dos gráficos de contribución de variables baseados en kNN propostos por [Wang et al. \(2019\)](#) e seguindo as ideas de [Zhou et al. \(2019\)](#). Unha vez detectada unha observación anómala, avalíase a achega de cada variable á desviación total respecto ás observacións normais máis próximas.

Para iso, unha vez identificada unha observación como anómala, compárase cos seus k veciños normais máis próximos na mostra de referencia. A contribución de cada variable calcúlase a partir da diferenza ao cadrado entre o valor da observación anómala e os valores correspondentes dos seus veciños normais. Deste xeito, se x_i representa unha observación anómala e $n_{j,l}(x_i)$ o seu j -ésimo veciño máis próximo, a desviación asociada á variable l pode expresarse como:

$$C_l(x_i) = \frac{1}{k} \sum_{j=1}^k (x_{i,l} - n_{j,l}(x_i))^2.$$

A contribución porcentual da variable l defínese entón como:

$$P_l(x_i) = \frac{C_l(x_i)}{\sum_{r=1}^m C_r(x_i)} \cdot 100,$$

onde m é o número total de variables consideradas. As variables con maior valor de $P_l(x_i)$ son aquelas que explican en maior medida o afastamento da observación respecto ao comportamento normal.

No caso de que se analicen secuencias anómalas formadas por varias observacións consecutivas, como ocorre nas aplicacións prácticas deste traballo, as contribucións poden agregarse mediante a media das contribucións porcentuais ao longo da secuencia. Deste xeito, obtense unha medida resumo que permite identificar que variables explican principalmente cada episodio anómalo detectado.

Finalmente, dado que os sistemas industriais poden operar en distintos modos (parado, arranque, funcionamento, desescarce, etc.), as distribucións das variables poden variar significativamente entre réximes. Este comportamento implica que o proceso non pode considerarse estacionario ao longo do tempo, senón que presenta diferentes condicións de operación.

En procesos industriais, estas variacións operativas poden afectar significativamente ao comportamento das variables monitorizadas, dificultando o uso dun único modelo global. Por este motivo, sempre que sexa posible identificar os diferentes modos de operación, divídese a mostra segundo estes e constrúense modelos e limiares específicos para cada un deles, permitindo adaptar a detección ás características propias de cada réxime de funcionamento.

Non obstante, en moitas aplicacións reais non se dispón dunha clasificación previa dos modos de operación. Nestes casos, o método pode aplicarse igualmente empregando un único modelo global, asumindo unha maior variabilidade nos datos e, potencialmente, unha menor precisión na detección de anomalías.

Por último, cómpre destacar que os métodos baseados en veciñanza como kNN poden verse afectados pola chamada maldición da dimensionalidade, fenómeno polo cal, a medida que aumenta o número de variables, as distancias entre observacións tenden a concentrarse, reducindo a capacidade discriminativa das métricas de proximidade [Hastie et al. \(2009\)](#). Isto é debido a que as métricas estándar, como a distancia euclídea, asumen implicitamente unha relevancia similar en todas as dimensións, trazando veciñanzas de forma esférica. Este feito pode dificultar a identificación de anomalías, especialmente en contornos de alta dimensión.

Para mitigar este efecto, na literatura propóñense técnicas de redución de dimensionalidade, como a Análise de Compoñentes Principais (PCA), que permiten proxectar os datos nun subespazo de menor dimensión conservando a maior parte da variabilidade ([Jolliffe \(2002\)](#)). Non obstante, estas técnicas implican a transformación das variables orixinais en combinacións lineais, o que dificulta a súa interpretación directa desde un punto de vista físico.

Ademais, en contornos industriais reais, os datos poden presentar comportamentos non lineais ou multimodais asociados aos distintos modos de operación do sistema, situacións nas que métodos lineais como PCA poden non capturar adecuadamente a estrutura subxacente dos datos [He e Wang \(2007\)](#). Pola contra, métodos baseados en veciñanza como kNN permiten adaptarse de forma máis flexible a estas características ao basear a detección en patróns locais.

Dado que un dos obxectivos principais deste traballo é identificar que variables contribúen ás desviacións detectadas no sistema, optouse por non empregar técnicas de redución de dimensionalidade, mantendo o espazo de características orixinal. Esta decisión permite preservar a interpretabilidade dos resultados, asumindo como contrapartida as limitacións asociadas á alta dimensionalidade.

En situacións nas que o número de variables é elevado, pode resultar conveniente realizar unha selección previa das mesmas. Neste traballo, esta selección baséase no coñecemento experto do sector da refrixeración, priorizando aquelas variables que resultan máis relevantes para o funcionamento do sistema e a detección de anomalías, e prescindindo daquelas cun menor interese operativo. Deste xeito, redúcese a dimensionalidade do problema mantendo a interpretabilidade e o significado físico das variables consideradas.

Capítulo 3

Simulación

Neste capítulo preséntase un estudo de simulación co obxecto de avaliar os métodos estatísticos para a detección de anomalías descritos no Capítulo 2. A motivación deste capítulo vén dada pola necesidade de validar as técnicas propostas nun contorno controlado. Dado que os datos reais dispoñibles carecen dun etiquetado de normalidade ou fallo, a inclusión dun estudo de simulación permite obter algunhas métricas para validar o uso dos métodos para a detección.

Deste xeito, o estudo non pretende reflectir fielmente a realidade dunha instalación frigorífica, aínda que os datos xerados intentarán recoller os trazos máis relevantes das variables, mantendo algunhas características físicas do seu comportamento, neste caso dun compresor. Nesta simulación consideraranse datos multivariantes non lineais con ruído similar ao lido nun sensor e dous estados de funcionamento que influirán no valor das variables. Desta forma poderemos analizar a capacidade de ambos métodos para distinguir a variabilidade propia do funcionamento normal dunha anomalía real.

Para isto empregaranse distintas métricas para medir a capacidade de clasificación dos métodos aproveitando os datos simulados xa clasificados. Con estas métricas seremos capaces de medir características como a sensibilidade, especificidade ou precisión das técnicas tanto da aplicación de MEWMA sobre os residuos do modelo XGBoost como do método kNN. Deste modo, obteremos estimacións da capacidade de ambos métodos de detectar unha anomalía como da xeración de falsas alarmas pola técnica.

3.1. Obxectivo da simulación

O obxectivo da simulación é construír un escenario controlado no que se poida avaliar o rendemento dos métodos propostos baixo condicións coñecidas. Para iso, xéranse dous conxuntos de datos diferenciados: un conxunto de adestramento, formado por observacións baixo funcionamento normal, e un conxunto de test, no que se introducen bloques de anomalías coñecidas. Esta estrutura reproduce a formulación semisupervisada considerada neste traballo, na que os modelos aprenden o comportamento de referencia a partir de datos considerados normais e posteriormente avalían se novas observacións se afastan significativamente dese patrón.

No procedemento de simulación, o conxunto de adestramento emprégase exclusivamente para axustar os métodos e estimar os parámetros necesarios para a detección. No caso do método kNN, este conxunto permite construír a referencia de funcionamento normal para cada estado operativo e calcular os limiares asociados ás distancias. No caso da metodoloxía baseada en XGBoost e MEWMA, emprégase para axustar os modelos de predición, obter os residuos baixo funcionamento normal e establecer o limiar do estatístico de control.

Pola súa banda, o conxunto de test resérvase para a avaliación final. Sobre este conxunto introdúcense anomalías artificiais en intervalos temporais coñecidos, combinando cambios na estrutura latente dos datos con desprazamentos en determinadas variables. Deste xeito, as anomalías non forman parte

da fase de adestramento, senón que aparecen unicamente no momento de avaliar a capacidade dos métodos para detectar desviacións respecto ao comportamento aprendido.

A principal vantaxe deste deseño é que, ao tratarse dun escenario simulado, coñécese de antemán a etiqueta real de cada observación do conxunto de test. Isto permite comparar as deteccións obtidas polos métodos coas anomalías realmente introducidas e calcular métricas derivadas da matriz de confusión, como a sensibilidade, a especificidade, a taxa de falsas alarmas, o F1-score ou a precisión balanceada. Estas medidas permiten valorar non só a capacidade dos métodos para detectar anomalías, senón tamén o seu comportamento fronte á xeración de falsas alarmas, aspecto especialmente relevante nun contexto industrial.

3.2. Xeración dos datos

Para a xeración dos datos terase en conta a existencia de diferentes modos de funcionamento. Neste caso considerárase un escenario sinxelo con dous estados operativos, representativos de dous modos de operación dun compresor. Así, a xeración das variables observadas estará condicionada polo estado no que se atope o sistema en cada instante. Como consecuencia, os datos asociados a cada estado presentarán distribucións diferentes, polo que a identificación do modo de funcionamento resulta fundamental antes de aplicar os métodos de análise. En caso contrario, poderían interpretarse como anomalías observacións que, en realidade, corresponden a un cambio normal no modo de operación.

Unha vez fixada a secuencia de estados, xéranse seis variables continuas que representan algún dos sinais monitorizados no sistema: presión de aspiración, presión de descarga, presión de aceite, temperatura de descarga, temperatura de impulsión e temperatura de aceite. A elección destas variables está inspirada nas magnitudes habituais rexistradas en compresores, aínda que os valores xerados non deben interpretarse como medicións reais nin calibradas fisicamente. Na Figura 3.1 representamos graficamente a simulación destas variables por estado.

Para construír as variables simuladas emprégase unha variable latente non observada, denotada por t . Esta variable non representa directamente unha magnitude física medida, senón que se introduce como un mecanismo auxiliar para xerar dependencia entre as variables observadas. Deste xeito, as seis variables simuladas non se constrúen de forma independente, senón a partir dun factor común que permite reproducir unha estrutura multivariante nos datos.

Baixo funcionamento normal, a distribución da variable latente depende do estado. Para o estado 0, t xérase arredor de dous centros principais, situados aproximadamente en $-2,5$ e $2,5$, con probabilidades diferentes. Para o estado 1, emprégase unha estrutura análoga, con centros arredor de -2 e 2 . Esta formulación permite simular que, dentro dun mesmo modo operativo, o compresor pode presentar subreximes normais de funcionamento. Polo tanto, as observacións normais non se concentran arredor dun único punto, senón que forman varias rexións de alta densidade dentro de cada estado.

Unha vez xerada a variable latente, constrúense as variables observadas. Por exemplo, algunhas magnitudes dependen linealmente de t , outras incorporan termos cuadráticos e outras seguen funcións trigonométricas. Así, pequenas modificacións na variable latente poden afectar simultaneamente a varias variables, aínda que non todas o fagan na mesma dirección nin coa mesma intensidade.

O conxunto de adestramento xérase unicamente a partir deste mecanismo baixo funcionamento normal. Pola contra, no conxunto de test introdúcense tres bloques temporais anómalos. A elección de bloques, e non de observacións illadas, permite representar fallos persistentes no tempo, máis próximos aos que poden aparecer nun dispositivo industrial.

A construción destas anomalías baséase na idea de que os datos anómalos poden situarse en zonas de baixa densidade respecto ao comportamento normal. Deste xeito, en lugar de empregar os mesmos centros que no funcionamento normal, a maior parte das observacións anómalas xéranse arredor dunha zona distinta, próxima a cero. Isto sitúa as observacións nunha rexión pouco habitual respecto á distribución normal de cada estado, especialmente porque baixo funcionamento normal a variable latente tende a concentrarse arredor dos centros negativos e positivos definidos anteriormente. Como as variables observadas dependen de t , este cambio altera o patrón conxunto das seis magnitudes

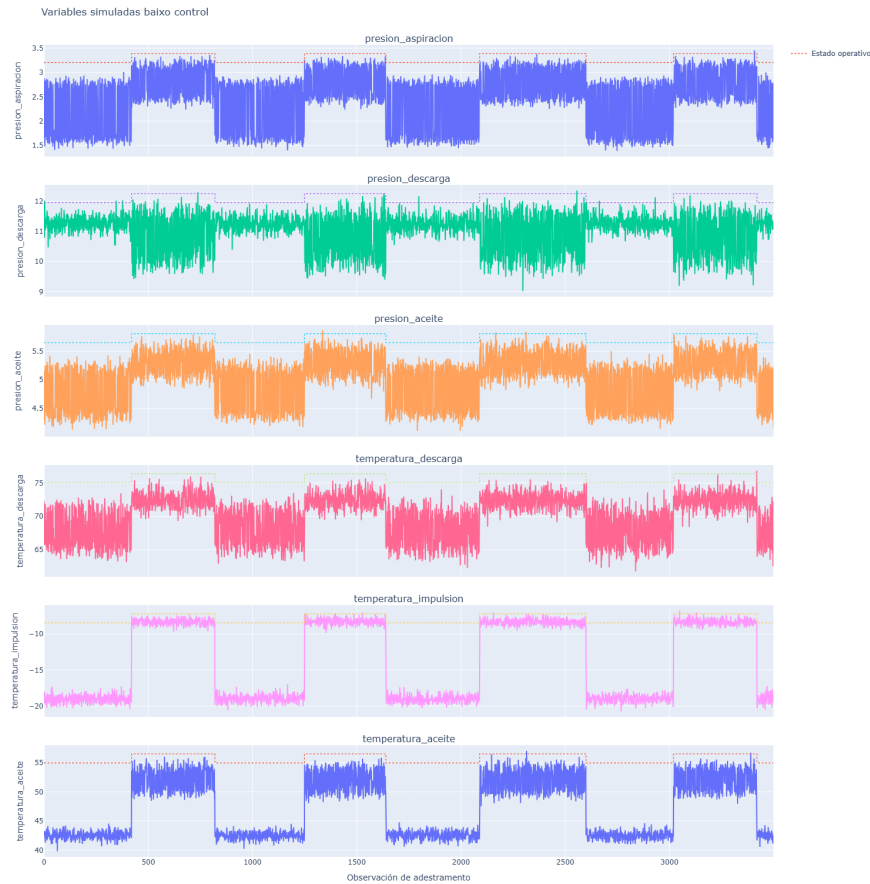


Figura 3.1: Representación das variables de control simuladas. A liña discontinua representa os distintos modos de operación.

simuladas.

Ademais, para evitar que a anomalía sexa completamente separable, introdúcese unha pequena proporción de observacións ambiguas dentro de cada bloque anómalo. Estas observacións xéranse arredor dos centros normais de cada estado, polo que quedan máis próximas ao funcionamento ordinario. Deste xeito, non todas as observacións etiquetadas como anómalas presentan a mesma intensidade de desviación, o que fai que o problema de detección sexa máis realista no que algunhas observacións poidan presentar unha clasificación incerta.

Finalmente, sobre as observacións dos bloques anómalos engádense desprazamentos explícitos nalgunhas variables concretas. Estes desprazamentos representan cambios de nivel asociados ao fallo simulado. No primeiro bloque, correspondente ao estado 0, incrementáanse a temperatura de descarga e a temperatura de impulsión. No segundo bloque, tamén asociado ao estado 0, incrementáanse a presión de descarga e a temperatura de aceite, mentres que diminúe a presión de aceite. No terceiro bloque, correspondente ao estado 1, diminúe a presión de aspiración e incrementáanse a temperatura de descarga e a temperatura de aceite.

Deste modo, as anomalías simuladas combinan dous tipos de desviación: por unha banda, un cambio no comportamento latente que modifica a estrutura multivariante das observacións; por outra, desprazamentos directos en variables específicas que facilitan a interpretación do fallo. Todas as observacións pertencentes a estes tres bloques reciben a etiqueta real de anomalía, mentres que o resto das

observacións do conxunto de test se consideran normais. Esta etiqueta permite avaliar posteriormente o rendemento dos métodos mediante a comparación entre as anomalías introducidas e as deteccións obtidas.

Na Figura 3.2 represéntanse as desviacións das variables, sombreando aquelas rexións onde se simulan as anomalías. Deste xeito, a simulación permite avaliar se os métodos son capaces de detectar tanto desviacións individuais nalgunhas variables como cambios no comportamento conxunto do compresor.

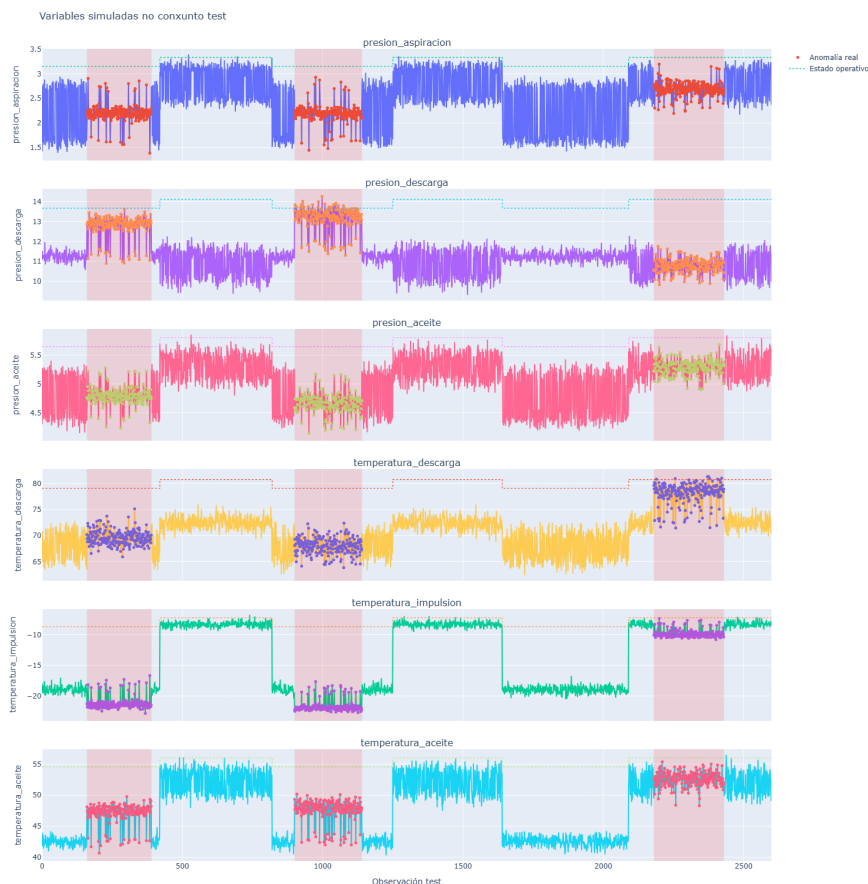


Figura 3.2: Representación gráfica das variables con anomalías, sombreadas as zonas anómalas e en liña descontinua os distintos modos de operación.

3.3. Aplicación dos métodos

Nesta sección preséntase a aplicación dos métodos de detección de anomalías ao conxunto de datos simulado. En ambos os casos tense en conta a existencia de distintos modos de funcionamento do compresor, aínda que a información do estado operativo se incorpora de maneira diferente segundo o método considerado. No método de detección baseado en k veciños máis próximos, a análise realízase de forma separada para cada estado, construíndo un modelo independente coas observacións normais correspondentes a cada réxime. Pola contra, no método baseado en MEWMA, o modo de funcionamento incorpórase como unha variable categórica dentro do modelo XGBoost empregado para describir o comportamento esperado das variables, e a detección realízase posteriormente sobre os residuos xerados por este modelo. Deste xeito, en ambos enfoques evítase que os cambios normais de réxime operativo

sexan confundidos con comportamentos anómalos, aínda que a estratexia empregada para facelo sexa distinta.

O primeiro método considerado é o baseado en k veciños máis próximos descrito na Sección 2.2. Neste caso, a mostra de adestramento divídese segundo o estado operativo do compresor e , para cada estado, axústase un modelo kNN independente empregando unicamente as observacións dese réxime. Esta formulación permite que cada nova observación sexa comparada co comportamento normal do seu propio modo de funcionamento, evitando que as diferenzas estruturais entre estados influan no cálculo do estatístico de detección.

Antes de calcular as distancias, as variables son estandarizadas utilizando a media e a desviación típica da mostra de adestramento de cada estado. Este paso é necesario porque as variables simuladas, igual que ocorre nos datos reais, teñen escalas diferentes. Se non se realizase esta transformación, as variables con maior variabilidade dominarían o cálculo da distancia.

Unha vez estandarizadas as observacións, calcúlase para cada punto a distancia ao seu k -ésimo veciño máis próximo. Esta distancia elevada ao cadrado e logo calculando a media emprégase como estatístico de detección. Posteriormente, defínese un limiar a partir dun cuantil da distribución empírica dos estatísticos obtidos na mostra de adestramento. Unha nova observación considérase anómala se o seu estatístico supera este limiar.

Nesta simulación emprégase un valor de $k = 5$. A elección deste valor responde, por unha banda, á menor cantidade de datos dispoñible no escenario simulado en comparación coa situación real. No caso real, dispónese dun volume de datos considerablemente maior, correspondente aproximadamente a dúas semanas de funcionamento empregadas para o adestramento, o que permite traballar con valores máis elevados de k sen perder representatividade local. Por outra banda, neste contexto de simulación traballaremos con menos datos polo que un valor reducido de k resulta máis axeitado para preservar a sensibilidade fronte a desviacións locais e evitar unha suavización excesiva do estatístico. Ademais, para a elección do limiar, empregamos o percentil 89 da distribución dos estatísticos de adestramento. Nun sistema operativo, o nivel do limiar podería axustarse en función do tipo de activo, do custo asociado ás falsas alarmas e do grao de sensibilidade desexado para detectar desviacións respecto ao funcionamento normal.

O segundo método considerado combina un modelo XGBoost cun gráfico de control MEWMA aplicado aos residuos. A diferenza do caso anterior, non se axusta un modelo independente para cada estado, senón que o modo de funcionamento se introduce como unha variable explicativa categórica no modelo XGBoost. Deste xeito, o modelo aprende o comportamento esperado das variables tendo en conta o réxime operativo no que se atopa o compresor. Posteriormente, os residuos entre os valores observados e os valores estimados polo modelo empréganse como entrada ao procedemento MEWMA, permitindo detectar desviacións persistentes respecto ao comportamento esperado.

O procedemento consta de dúas fases. En primeiro lugar, para cada variable axústase un modelo XGBoost empregando como preditores o resto de variables e o estado de funcionamento. A partir das predicións obtidas calcúlanse os residuos, definidos como a diferenza entre o valor observado e o valor estimado polo modelo. Baixo condicións normais, se o modelo captura adecuadamente as relacións entre variables, estes residuos deberían manterse próximos aos valores observados durante o adestramento. Pola contra, a aparición dunha anomalía pode alterar a estrutura de dependencia entre variables, dando lugar a residuos de maior magnitude.

Nunha segunda fase, os residuos son estandarizados e monitorizados mediante o estatístico MEWMA multivariante. Este estatístico permite acumular información ao longo do tempo, polo que resulta especialmente axeitado para detectar desviacións persistentes respecto ao comportamento esperado. Por este motivo, emprégase un valor reducido do parámetro de suavizado, favorecendo que o método responda á presenza dunha desviación sostida no tempo en lugar de reaccionar unicamente ante cambios puntuais.

O limiar de detección do MEWMA establécese a partir da media e da desviación típica dos estatísticos obtidos na mostra de adestramento. En particular, defínese como a media dos estatísticos máis un múltiplo da súa desviación típica, determinado polo parámetro `int_sigma`. Deste xeito, constrúese unha referencia do comportamento esperado baixo condicións normais, de maneira que unha obser-

vación será considerada anómala cando o seu estatístico MEWMA supere o valor deste limiar. Ao tratarse dun escenario simulado, a elección deste parámetro debe interpretarse como unha calibración experimental orientada a obter unha sensibilidade axeitada fronte ás desviacións introducidas nos datos.

3.4. Resultados da simulación

Unha vez aplicados os dous métodos ao conxunto de test, avalíase o seu comportamento mediante métricas derivadas da matriz de confusión. Aproveitando que na simulación se coñecen cales das observacións son realmente anómalas e cales normais, podemos distinguir perfectamente cales das observacións foron clasificadas correcta e incorrectamente.

Esta comparación dá lugar á matriz de confusión, que resume o comportamento do método a través de catro cantidades fundamentais. Os verdadeiros positivos, TP , representan as observacións anómalas correctamente detectadas polo método. Os verdadeiros negativos, TN , corresponden ás observacións normais correctamente identificadas como normais. Os falsos positivos, FP , son observacións normais clasificadas incorrectamente como anómalas, é dicir, falsas alarmas. Finalmente, os falsos negativos, FN , representan anomalías reais que non foron detectadas polo método. Esta matriz constitúe a base habitual para a definición de medidas de avaliación en problemas de clasificación, como a sensibilidade, a especificidade, a precisión ou o F_1 -score. No caso deste traballo, considérase a clase anómala como clase positiva e o funcionamento normal como clase negativa, polo que a estrutura da matriz de confusión pode representarse como na Táboa 3.1.

	Real: anomalía	Real: normal
Predición: anomalía	Verdadeiro positivo TP	Falso positivo FP
Predición: normal	Falso negativo FN	Verdadeiro negativo TN

Táboa 3.1: Matriz de confusión para a detección de anomalías.

A partir destas catro cantidades calcúlanse as métricas empregadas para avaliar o rendemento dos métodos de detección empregando como referencia os artigos de [Sokolova e Lapalme \(2009\)](#) e [Brodersen et al. \(2010\)](#).

■ **Sensibilidade:**

$$\text{TPR} = \frac{TP}{TP + FN}.$$

Mide a capacidade do método para detectar anomalías reais, é dicir, a proporción de positivos (anomalías) que foron ben detectados.

■ **Especificidade:**

$$\text{TNR} = \frac{TN}{TN + FP}.$$

Analogamente ao caso anterior, mide a capacidade do método para recoñecer correctamente o funcionamento normal, é dicir, a proporción de negativos ou datos normais ben detectados.

■ **Precisión global:**

$$\text{ACC} = \frac{TP + TN}{TP + FN + TN + FP}.$$

Representa a proporción de observacións ben clasificadas no conxunto total.

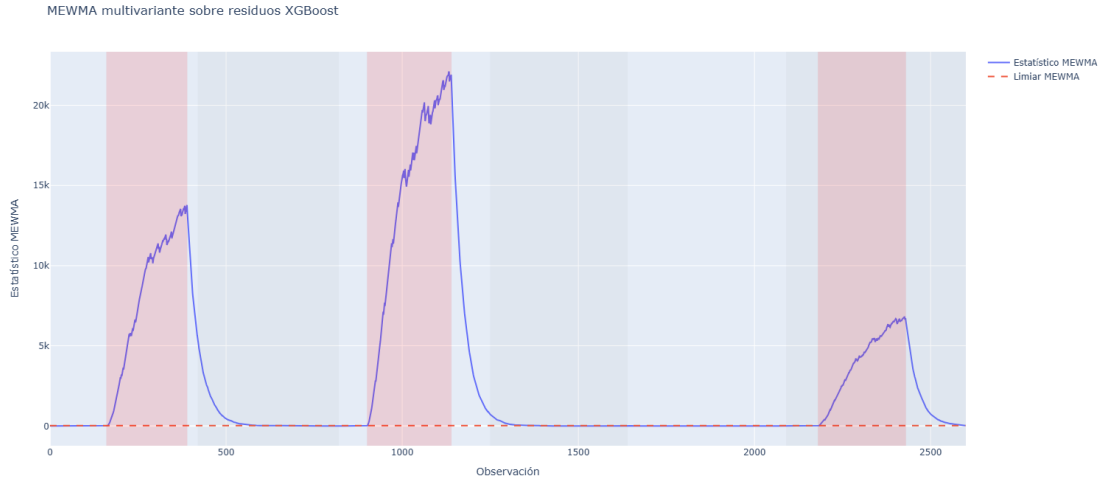


Figura 3.3: Gráfico de control MEWMA xerado a partir dos residuos do modelo XGBoost. En azul a representación do estatístico, en liña descontinua vermella o limiar calculado a partir da mostra de adestramento e o sombreado é a zona real da anomalía simulada.

- **Precisión balanceada:**

$$BA = \frac{TPR + TNR}{2}.$$

No caso de que as clases sexan desbalanceadas (hai unha desproporción entre os datos da clase positiva e negativa), a métrica da precisión non se fai axeitada. Nese caso óptase por empregar a precisión balanceada, como a media entre sensibilidade e especificidade .

- **F_1 -score:**

$$F_1 = \frac{2TP}{2TP + FP + FN}.$$

Resume nun único valor o equilibrio entre a detección de anomalías e a fiabilidade das alarmas xeradas, penalizando tanto os falsos positivos como os falsos negativos. Por tanto, un valor elevado de F_1 indica que o método consegue detectar unha proporción alta das anomalías reais sen xerar un número excesivo de falsas alarmas. Pola contra, o valor de F_1 redúcese tanto cando existen moitos falsos negativos, é dicir, anomalías non detectadas, como cando existen moitos falsos positivos, é dicir, falsas alarmas.

Polo tanto, para estudar o rendemento dos métodos deben terse en conta as distintas métricas explicadas para avaliar a eficiencia do método. Unha técnica adecuada para a detección de anomalías debe manter un equilibrio entre a detección de anomalías e a xeración de falsas alarmas que dificulten a interpretación das anomalías e diminúan a confianza no sistema.

Antes de analizar as matrices de confusión e as métricas asociadas de ambos os métodos de detección, represéntase na Figura 3.4 e 3.3 a evolución temporal dos estatísticos de detección obtidos polas técnicas de kNN e MEWMA respectivamente. En ambos gráficos, a liña azul representa o valor do estatístico en cada observación do conxunto de test, mentres que a liña vermella descontinua representa o limiar de control. No caso do método kNN este limiar é variable por estado de funcionamento, mentres que para o gráfico MEWMA é o mesmo para todo o conxunto de datos. As rexións sombreadas indican os bloques temporais nos que se introduciron anomalías artificialmente.

No caso do método combinado XGBoost e MEWMA, obsérvase na Figura 3.3 que o estatístico aumenta de forma progresiva durante os bloques anómalos, acadando valores moi superiores ao limiar.

Este comportamento reflicte o carácter acumulativo do gráfico MEWMA, que incorpora información temporal e responde con intensidade ante desviacións persistentes. Non obstante, tamén se aprecia que, unha vez finalizado cada bloque anómalo, o estatístico descende de forma gradual, polo que algunhas observacións posteriores seguen sendo sinaladas como anómalas debido ao efecto de memoria do método.

Pola súa banda, na Figura 3.4 o método kNN por estados mostra incrementos claros do estatístico durante os tres bloques anómalos, superando o limiar de detección na maior parte das observacións afectadas. A diferenza do MEWMA, a resposta é máis local e irregular, xa que cada observación se avalía segundo a súa distancia aos veciños máis próximos da mostra baixo control. Ademais, cando remata un bloque anómalo, o estatístico volve rapidamente a valores próximos ao funcionamento normal, debido a que non se produce un arrastre temporal.

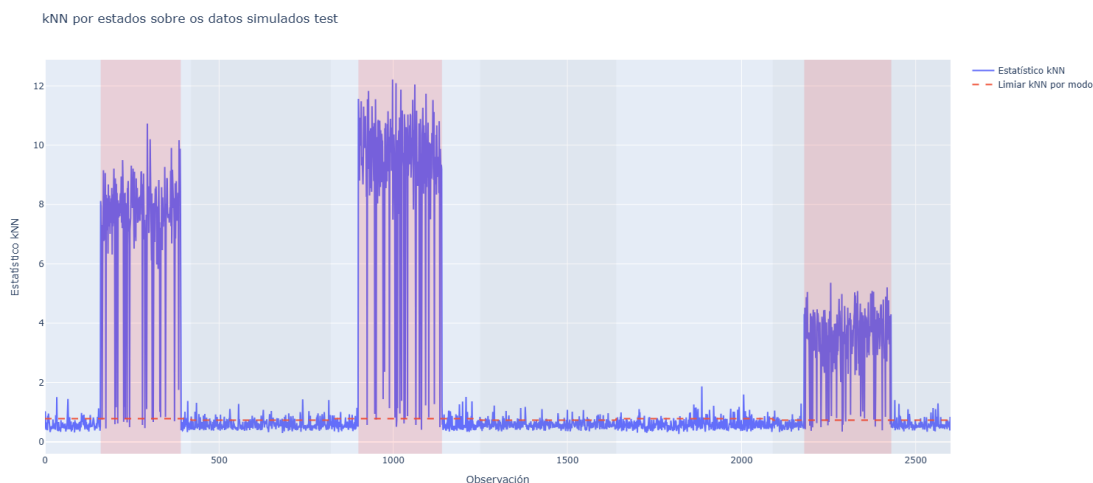


Figura 3.4: Gráfico de control obtido mediante o método kNN por estados. A liña azul representa o estatístico de detección, a liña vermella descontinua indica o limiar de control estimado para cada estado operativo, e as rexións sombreadas sinalan os bloques anómalos simulados.

Neste método tamén se observan algúns valores illados do estadístico por fóra do limiar fóra dos bloques anómalos. Estas observacións corresponden a falsas alarmas puntuais, que poden aparecer debido á variabilidade natural do proceso ou ao ruído presente nos datos. Por este motivo, nunha aplicación real non resulta recomendable activar un evento a partir dunha única observación fóra de control. En lugar disto, emprégase un criterio adicional de persistencia temporal, por exemplo esixir que varias observacións consecutivas superen o limiar antes de xerar unha alarma. Deste xeito, redúcese a probabilidade de activar eventos por desviacións illadas e mellórase a estabilidade do sistema de detección reducindo o número de falsas alarmas.

A comparación visual de ambos gráficos permite anticipar os resultados cuantitativos obtidos posteriormente. O enfoque XGBoost e MEWMA presenta unha maior sensibilidade fronte ás anomalías, xa que responde con forza ante as desviacións persistentes. Porén, esta mesma capacidade de acumulación pode aumentar o número de falsas alarmas fóra dos bloques anómalos debido á persistencia temporal do estatístico. Pola contra, o método kNN por estados ofrece un comportamento máis equilibrado, mantendo unha alta capacidade de detección e unha maior estabilidade durante os períodos de funcionamento normal.

Nas Táboas 3.2 e 3.3 recóllense os valores da matriz de confusión obtidos nunha simulación para os métodos de detección usando kNN e a combinación de XGBoost con MEWMA. Por outra banda, na Táboa 3.4 recóllense os resultados das métricas obtidas nunha simulación individual. O conxunto de test está formado por 2600 observacións, das cales 720 corresponden a anomalías introducidas artificial-

kNN por modo		
	Anom.	Normal
Pred. anom.	682	280
Pred. normal	38	1600

Táboa 3.2: Matriz de confusión obtida na simulación individual para o método kNN.

XGBoost e MEWMA		
	Anom.	Normal
Pred. anom.	709	651
Pred. normal	11	1229

Táboa 3.3: Matriz de confusión obtida na simulación individual para o método combinado XGBoost e MEWMA.

mente e 1880 a funcionamento normal. Ademais, os dous modos de operación aparecen equilibrados, con 1300 observacións en cada un.

Método	Sensibilidade	Especificidade	Precisión	F_1	Prec. balanceada
kNN por modo	0,9472	0,8511	0,8777	0,8109	0,8991
XGBoost e MEWMA	0,9847	0,6537	0,7454	0,6817	0,8192

Táboa 3.4: Métricas globais obtidas nunha simulación individual.

Os resultados da Táboa 3.4 mostran que ambos métodos son capaces de detectar unha proporción elevada das anomalías simuladas. O método combinado XGBoost e MEWMA detecta 709 das 720 observacións anómalas, o que se traduce nunha sensibilidade de 0,9847. Pola outra banda, o método kNN por modo detecta 682 anomalías, cunha sensibilidade de 0,9472. Polo tanto, desde o punto de vista estrito da detección de fallos, XGBoost e MEWMA presenta unha sensibilidade superior.

Non obstante, a gran sensibilidade dos métodos vén acompañada dun incremento importante no número de falsas alarmas. O método combinado XGBoost e MEWMA clasifica como anómalas 651 observacións que en realidade son normais, mentres que o kNN por modo produce 280 falsas alarmas. Isto reflíctese na especificidade: o kNN acada unha especificidade de 0,8511, fronte a 0,6537 no caso de XGBoost e MEWMA. En termos prácticos, isto significa que o método baseado en residuos é máis propenso a sinalar como anómalas observacións pertencentes ao funcionamento normal do sistema. Traducindo a especificidade ao campo de falsas alarmas, no caso do kNN, aproximadamente o 14,89 % das observacións normais son clasificadas incorrectamente como anómalas. Pola contra, no método XGBoost e MEWMA esta porcentaxe ascende ao 34,63 %.

En canto a termos de precisión, no método de kNN e de aproximadamente 0,8777, é dicir, que o 87,77 % das observacións sinaladas como anómalas corresponden realmente a anomalías. No caso de XGBoost e MEWMA, esta proporción descende ao 68,18 %. É dicir, aínda que XGBoost e MEWMA detecta máis anomalías, unha parte considerable das súas deteccións corresponden a observacións normais. Porén, ao estar traballando con clases desbalanceadas, esta métrica non resulta realmente fiable, polo que é mellor fixarnos na precisión balanceada, que é de aproximadamente 0,8991 para o método kNN e de 0,8192 para a combinación de XGBoost e MEWMA.

O F1-score, que combina precisión e sensibilidade, favorece claramente ao método kNN. O valor obtido por kNN é 0,8109, fronte a 0,6817 para XGBoost e MEWMA. Isto indica que o kNN ofrece un mellor compromiso entre detectar anomalías e evitar alarmas incorrectas.

En consecuencia, na simulación individual obsérvanse dous comportamentos diferenciados. A combinación XGBoost con MEWMA é máis sensible e deixa sen detectar menos anomalías, pero a cambio xera un número elevado de falsas alarmas. Pola contra, o kNN por modo mantén unha sensibilidade alta, próxima ao 95 %, e presenta unha especificidade, precisión, F1-score e precisión balanceada

superiores. Desde o punto de vista operativo, este segundo comportamento resulta máis equilibrado.

Co obxectivo de comprobar que a fiabilidade dos resultados obtidos non dependen dunha única de simulación, realizouse un estudo Monte Carlo con 50 réplicas independentes. En cada réplica xerouse un novo conxunto de adestramento e de proba, mantendo a mesma estrutura xeral da simulación, e calculáronse de novo as métricas de avaliación para ambos métodos.

Na Táboa 3.5 recóllense as medias das métricas calculadas semellantes ás da simulación individual. O método combinado XGBoost e MEWMA presenta unha sensibilidade media moi elevada, igual a 0,9914, polo que detecta practicamente todas as observacións anómalas. Non obstante, esta elevada sensibilidade vai acompañada dunha menor especificidade, cun valor medio de 0,6677.

Pola contra, o método kNN por modo obtén unha sensibilidade media tamén elevada, de 0,9429, aínda que inferior á de XGBoost e MEWMA. Porén, presenta unha especificidade media claramente superior, de 0,8438 polo que o método xera bastantes menos falsas alarmas. Isto indica que o método kNN mantén unha boa capacidade de detección das anomalías, pero cun comportamento máis estable durante os períodos de funcionamento normal.

Esta diferenza tamén se reflicte nas métricas que combinan detección e control de falsas alarmas. O kNN acada un F1-score medio de 0,8024 e unha precisión balanceada media de 0,8933, superiores aos valores obtidos por XGBoost e MEWMA, que son 0,6937 e 0,8296, respectivamente.

Método	Sensibilidade	Especificidade	Precisión	F1	Prec. balanceada
kNN por modo	0,9429	0,8438	0,8712	0,8024	0,8933
XGBoost e MEWMA	0,9914	0,6677	0,7574	0,6937	0,8296

Táboa 3.5: Métricas medias obtidas mediante 50 réplicas Monte Carlo.

Ademais das medias das métricas, calculáronse intervalos de confianza Monte Carlo ao 95% co obxectivo de cuantificar a variabilidade asociada ao procedemento de simulación. Para unha métrica xenérica m , sexan m_1, \dots, m_R os valores obtidos nas $R = 50$ réplicas independentes. A media Monte Carlo defínese como

$$\bar{m} = \frac{1}{R} \sum_{r=1}^R m_r,$$

e a desviación típica entre réplicas denótase por s_m . Dado o número de réplicas empregado, os intervalos construíronse mediante a aproximación normal:

$$IC_{95\%}(\bar{m}) = \bar{m} \pm 1,96 \frac{s_m}{\sqrt{R}}.$$

Na Táboa 3.6 preséntanse os intervalos de confianza Monte Carlo ao 95% para as principais métricas de avaliación. Obsérvase que os intervalos correspondentes á sensibilidade son estreitos en ambos métodos, especialmente no caso de XGBoost e MEWMA, o que confirma a súa elevada capacidade de detección das anomalías simuladas. Con todo, os intervalos de especificidade, precisión, F1-score e precisión balanceada sitúanse claramente por riba dos correspondentes ao método XGBoost e MEWMA. En conclusión, XGBoost e MEWMA resulta máis sensible á presenza de anomalías, mentres que kNN presenta un comportamento máis equilibrado e unha menor tendencia á xeración de falsas alarmas.

Ademais da posición dos intervalos, resulta útil analizar a súa amplitude, xa que esta proporciona unha medida da variabilidade Monte Carlo asociada a cada métrica. En xeral, obsérvase que os intervalos son estreitos en todas as métricas, o que indica unha elevada estabilidade dos resultados ao longo das 50 réplicas. Cómpre destacar que a sensibilidade presenta un intervalo máis estreito, indicando que a capacidade de detección das anomalías é bastante estable entre réplicas.

No caso de XGBoost e MEWMA, a métrica con maior amplitude é a especificidade, polo que a súa variabilidade é maior. Isto indica que a variabilidade deste método se concentra principalmente

Método	Sensibilidade	Especificidade	Precisión	F1	Prec. balanceada
kNN por modo	[0,9414, 0,9444]	[0,8399, 0,8477]	[0,8684, 0,8740]	[0,7990, 0,8058]	[0,8913, 0,8953]
XGBoost e MEWMA	[0,9907, 0,9921]	[0,6629, 0,6725]	[0,7539, 0,7609]	[0,6907, 0,6967]	[0,8272, 0,8320]

Táboa 3.6: Intervalos de confianza Monte Carlo ao 95% das métricas medias obtidas mediante 50 réplicas, empregando a aproximación normal.

no comportamento durante os períodos normais, é dicir, na súa tendencia a xerar falsas alarmas. En cambio, a sensibilidade presenta o intervalo máis estreito, e por tanto menor variabilidade, o que confirma que o método detecta as anomalías simuladas de forma moi consistente. Deste modo, a análise da amplitude dos intervalos reforza a conclusión de que XGBoost e MEWMA é moi estable na detección de anomalías, mentres que kNN ofrece un comportamento máis equilibrado entre detección e control de falsas alarmas.

Capítulo 4

Caso práctico

Neste capítulo preséntase a aplicación das metodoloxías propostas a casos reais de problemas e fallos en instalacións frigoríficas. A diferenza do estudo de simulación presentado no capítulo anterior, no que se dispoñía dun escenario controlado e de etiquetas coñecidas, neste caso trabállase con datos procedentes da monitorización real das instalacións. Isto supón unha dificultade engadida, xa que as anomalías non sempre aparecen de forma illada nin perfectamente delimitadas no tempo, senón que adoitan manifestarse como desviacións progresivas ou cambios no comportamento conxunto das variables medidas polos sensores.

O obxectivo deste capítulo é avaliar a utilidade práctica dos métodos de detección de anomalías descritos no Capítulo 2. En particular, considéranse tres tipos de incidencias: a formación de xeo no evaporador, a presenza de gases incondensables no interior da instalación e un fallo no sistema de bombas que impedía a correcta refrixeración da cámara. Estes problemas presentan naturezas distintas, afectan a compoñentes diferentes do sistema e maniféstanse a través de patróns tamén diferentes nas variables rexistradas.

En cada caso, en primeiro lugar, comezase describindo brevemente o funcionamento esperado do equipo e o modo no que o fallo altera ese comportamento, apoiándose nas representacións gráficas das sinais monitorizadas. Estas figuras permitirán observar de forma visual as desviacións producidas respecto ao comportamento habitual da instalación, así como relacionar ditas desviacións coa interpretación física do problema.

Posteriormente, aplicaranse os dous enfoques estatísticos propostos neste traballo. Primeiro, aplicarase o método baseado en k -veciños máis próximos, identificando observacións afastadas do patrón normal aprendido a partir dunha mostra de referencia. En segundo lugar, empregarase a metodoloxía baseada en XGBoost e MEWMA, na que o modelo XGBoost permite estimar o comportamento esperado das variables baixo condicións normais de funcionamento e o gráfico de control se aplica sobre os residuos do modelo. Deste xeito, poderase comparar o comportamento de ambos métodos ante diferentes tipos de fallo e valorar a súa capacidade para xerar sinais de alerta coherentes coas incidencias observadas.

4.1. Xeo no evaporador

Un dos fallos estudados neste capítulo corresponde á formación de xeo no evaporador dunha cámara frigorífica. Como se describiu no Capítulo 1, o evaporador é o compoñente encargado de absorber calor do interior da cámara, permitindo así manter a temperatura dentro dos rangos establecidos. Durante o seu funcionamento, é habitual que a humidade presente no ambiente se deposite sobre a superficie do evaporador, podendo dar lugar á formación de xeo. Para evitar que esta acumulación degrade o rendemento do equipo, o sistema realiza periodicamente ciclos de desescarche, nos que se achega calor ao evaporador co obxectivo de derreter o xeo acumulado.

A acumulación de xeo sobre o evaporador ten consecuencias directas sobre o rendemento térmico da instalación. En primeiro lugar, o xeo actúa como unha capa illante entre o aire da cámara e a superficie de intercambio, dificultando a transferencia de calor. Como consecuencia, o evaporador perde capacidade para extraer calor da cámara e o sistema precisa permanecer máis tempo en funcionamento para acadar a mesma demanda de frío, o que leva a un maior consumo de enerxía. Se a acumulación de xeo é persistente no tempo, o proceso de evaporación pode chegar a non completarse e, en consecuencia, pode retornar líquido ao compresor, provocando unha avaría grave, xa que o compresor non está deseñado para comprimir líquidos.

Na Figura 4.1 represéntanse, no gráfico superior, as dúas variables dispoñibles máis relevantes para a análise do evaporador: en cor verde, a temperatura do aire da cámara e, en cor azul, a temperatura de fin de desescarche, medida mediante unha sonda situada no interior do evaporador. Na parte inferior da figura móstrase un gráfico de cores que indica os distintos modos de funcionamento do equipo: en cor verde, o corte por termóstato; en violeta, a regulación normal; e en rosa, o desescarche.

Un dos aspectos clave para identificar a posible presenza de xeo no evaporador consiste en comprobar se, durante os períodos de desescarche, a temperatura de fin de desescarche acada valores superiores a 0 °C. Cando isto ocorre, considérase que existen condicións favorables para a fusión do xeo acumulado na superficie do evaporador. Pola contra, se durante o desescarche esta temperatura non supera os 0 °C, o proceso pode non ser suficiente para eliminar completamente o xeo presente no equipo. Tal e como se observa na figura, en varios dos períodos nos que o evaporador entra en modo de desescarche, a temperatura de fin de desescarche non logra acadar os 0 °C.

Podería pensarse que a temperatura da cámara de conxelados tamén debería reflectir este funcionamento anómalo. Non obstante, neste caso a cámara conta con varios evaporadores, polo que o efecto dun único equipo funcionando de forma deficiente pode quedar parcialmente compensado polo resto. Por este motivo, a temperatura da cámara pode non presentar necesariamente unha desviación clara, aínda que un dos evaporadores estea afectado pola presenza de xeo.



Figura 4.1: Datos das variables para a presenza de xeo no evaporador: temperatura de fin de desescarche (liña azul), temperatura do aire (liña verde) e estado do evaporador, representado no gráfico de cores da parte inferior da imaxe.

Unha vez descrito o comportamento observado das variables, procédese á aplicación dos dous métodos de detección de anomalías propostos no Capítulo 2. O obxectivo é comprobar se as metodoloxías son capaces de identificar como anómalos os períodos nos que o evaporador presenta un comportamen-

to compatible coa presenza de xeo. Para iso, analízanse conxuntamente os resultados obtidos mediante o método kNN e a combinación de XGBoost e MEWMA.

4.1.1. Aplicación dos métodos de detección

Neste caso, seleccionouse inicialmente un período no que o evaporador presentaba un funcionamento considerado correcto cunha duración de dúas semanas. Esta selección realizouse tendo en conta tanto as alarmas reportadas polo propio dispositivo como as regras heurísticas xa implementadas na plataforma. O obxectivo era empregar como mostra de adestramento datos representativos dun comportamento normal.

A mostra de adestramento empregouse como referencia para os dous métodos propostos. No caso do método kNN, permitiu definir a rexión de funcionamento normal do evaporador a partir das distancias entre observacións separando os datos por estado. No caso da metodoloxía baseada en XGBoost e MEWMA, empregouse para axustar o modelo que estima o comportamento esperado das variables e para o cálculo da distribución dos residuos baixo condicións normais de funcionamento. O estatístico MEWMA calculouse sobre estes residuos, previamente estandarizados coa media e a desviación típica obtidas na mostra de adestramento, de modo que as distintas variables contribuísen nunha escala comparable.

No caso do método kNN, adestróuse o modelo considerando $k = 50$ veciños máis próximos. A partir da mostra de adestramento calculouse, para cada observación, a distancia media aos seus 50 veciños máis próximos, obtendo así a distribución empírica do estatístico baixo condicións normais. Esta distribución empregouse para definir o limiar de decisión de cada modo operativo. Dado que os períodos de desescarche son breves e menos frecuentes que o resto de estados, neste modo empregouse como limiar o percentil 90 da mostra de adestramento, mentres que para os demais modos se considerou o percentil 99. Esta diferenza responde á menor dispoñibilidade de observacións nos períodos de desescarche, onde un limiar excesivamente alto podería dificultar a identificación de desviacións relevantes.

Unha vez fixados os limiares, aplicouse aos datos do período analizado o mesmo escalado estimado na mostra de adestramento, antes de calcular o estatístico kNN. Para cada nova observación, calculouse a distancia media aos 50 veciños máis próximos da mostra de adestramento correspondente ao seu modo de funcionamento. Finalmente, comparouse o valor do estatístico co limiar asociado ao modo operativo no que se atopaba o evaporador. Deste xeito, unha observación foi clasificada como anómala cando o estatístico superou o limiar correspondente.

Este procedemento foi aplicado no resto de casos prácticos que se presentan neste capítulo, polo que se omitirá no resto de casos.

Na Figura 4.2 represéntase o resultado obtido mediante o método kNN para o caso do evaporador con presenza de xeo. A liña azul mostra a evolución do estatístico de distancia, calculado a partir da proximidade de cada observación aos seus k veciños máis próximos dentro da mostra de referencia. Pola súa parte, a liña vermella representa o limiar de decisión estimado a partir dos datos considerados baixo funcionamento normal, variable segundo o modo de operación. Cando o estatístico supera este limiar, a observación considérase afastada do comportamento habitual aprendido polo modelo.

Desde o punto de vista do método, valores baixos do estatístico indican que a combinación de variables rexistrada nun determinado instante é semellante ás observacións normais empregadas no adestramento. Pola contra, valores elevados indican que a observación se sitúa nunha rexión pouco densa do espazo de características, é dicir, nunha zona na que apenas existen rexistros normais próximos.

No caso analizado, obsérvase que o estatístico permanece durante a maior parte do período por debaixo do limiar de decisión, o que indica que o comportamento do evaporador é, en xeral, próximo ao patrón normal aprendido. Non obstante, aparecen varios incrementos do estatístico, algúns deles con superación clara do limiar, que sinalan instantes nos que a combinación de variables rexistrada se afasta do comportamento esperado. Estas desviacións concéntranse especialmente arredor dalgúns períodos de desescarche, coincidindo con aqueles momentos onde se observaban desviacións na variable temperatura de fin de desescarche.




Figura 4.2: Detección usando kNN. En azul o estatístico de monitorización e en vermello o limiar por estado. As zonas sombreadas representan as anomalías detectadas.

Cómpre destacar que o método non identifica como anómalo calquera ciclo de desescarche, senón aqueles nos que a evolución das variables non se corresponde co patrón habitual deste modo de funcionamento. Isto obsérvase no feito de que algúns desescarches non producen unha superación relevante do limiar, mentres que outros si xeran un incremento notable do estatístico. Polo tanto, o kNN parece distinguir entre o desescarche como parte do funcionamento normal do equipo e os desescarches cun comportamento térmico irregular.

Tamén se observan algúns picos illados do estatístico que non se prolongan no tempo. Estes incrementos puntuais poden estar asociados a transicións entre modos de funcionamento, a variacións bruscas nas lecturas das sondas ou ao ruído propio do sistema de sondas. Por este motivo, a aplicación dun criterio de persistencia temporal para a xeración da alarma resulta relevante, xa que evita que desviacións moi breves dean lugar a eventos espurios. Así, a detección considérase máis robusta cando a superación do limiar se mantén durante varias observacións consecutivas. Este criterio tamén se manterá para o resto de casos prácticos e para o método de detección usando o gráfico EWMA ou MEWMA.

No caso da metodoloxía baseada en XGBoost cómpre sinalar que neste exemplo non se aplica o gráfico MEWMA, senón a súa versión univariante EWMA. Isto é debido a que este evaporador só dispoñía de dúas variables continuas relevantes: a temperatura do aire da cámara e a temperatura de fin de desescarche. Dado que unha delas se emprega como variable explicativa para estimar o comportamento esperado da outra, a monitorización final realízase sobre un único residuo. En consecuencia, o uso dun gráfico EWMA resulta máis axeitado que a formulación multivariante MEWMA.

Na Figura 4.3 represéntase o resultado obtido mediante a metodoloxía baseada en XGBoost e EWMA para o caso de xeo no evaporador. A liña azul mostra a evolución do estatístico EWMA calculado sobre os residuos do modelo, mentres que as liñas vermellas representan os límites de control superior e inferior. As zonas sombreadas indican os períodos nos que o estatístico supera algún dos límites establecidos e, polo tanto, se identifica un comportamento anómalo respecto ao patrón aprendido en condicións normais.

Neste caso, o estatístico presenta principalmente desviacións cara ao límite inferior, o que indica que, durante determinados instantes, os valores observados da variable resposta sitúanse por debaixo do comportamento esperado polo modelo. Estas desviacións tamén aparecen especialmente arredor dalgúns ciclos de desescarche, coincidindo cos períodos nos que a temperatura de fin de desescarche mostra unha evolución irregular, identificando zonas e intervalos similares ao método kNN.




Figura 4.3: Detección usando EWMA. En azul o estatístico de monitorización e en vermello o límite obtido cos residuos do modelo XGBoost para a variable temperatura fin de desescarche. As zonas sombreadas representan as anomalías detectadas.

O feito de que as deteccións se produzan maioritariamente no límite inferior resulta coherente coa interpretación do fallo. A presenza de xeo no evaporador dificulta o intercambio térmico e pode provocar que a temperatura medida na punta do evaporador durante o desescarche sexa inferior á esperada para as condicións de funcionamento observadas. Deste modo, o residuo xerado polo modelo afástase do comportamento normal e o estatístico EWMA, ao acumular esta desviación ao longo do tempo, supera o límite de control.

Comparando este resultado co obtido mediante o método kNN, obsérvase que ambos enfoques sinalan anomalías en períodos próximos aos ciclos de desescarche, polo que as dúas metodoloxías resultan coherentes coa natureza do fallo estudado. Non obstante, existen diferenzas na forma na que cada método identifica a anomalía. O kNN detecta observacións afastadas do patrón normal no espazo definido polas variables e o modo de funcionamento, polo que é especialmente sensible a combinacións pouco habituais entre a temperatura do aire, a temperatura de fin de desescarche e o estado operativo do evaporador. En cambio, o EWMA actúa sobre o residuo do modelo XGBoost, polo que a súa detección depende da diferenza entre o valor observado e o valor esperado segundo a relación aprendida entre as variables.

No gráfico kNN aparecen picos máis localizados do estatístico, algúns deles asociados a transicións entre modos de funcionamento ou a variacións bruscas nas variables. Pola súa parte, o EWMA mostra unha resposta máis suavizada, xa que acumula a información dos residuos ao longo do tempo. Isto fai que o método sexa menos reactivo ante desviacións illadas, pero máis estable cando a desviación persiste durante varias observacións. Cabe destacar que, a pesar de incluír un criterio de persistencia temporal, ambos métodos presentan deteccións illadas en momentos diferentes que poden interpretarse como falsas alarmas no comportamento do evaporador.

Neste caso concreto, o kNN parece detectar con maior intensidade certos instantes nos que a combinación de variables se afasta de forma clara do comportamento normal, mentres que o EWMA permite interpretar a dirección da desviación a través do signo do residuo.




Figura 4.4: Datos de dúas variables no compresor para a detección de incondensables: temperatura de descarga (liña azul) e presión de descarga (liña verde).

4.2. Presencia de incondensables na instalación

Outro dos casos analizados neste capítulo corresponde á presenza de gases incondensables no interior da instalación frigorífica. Denomínanse gases incondensables aqueles gases que, nas condicións habituais de presión e temperatura do ciclo frigorífico, non condensan xunto co refrixerante no condensador. É dicir, mentres que o refrixerante está deseñado para cambiar de estado ao longo do ciclo, pasando de gas a líquido durante a condensación, estes gases permanecen en estado gasoso e non participan de forma útil no proceso de intercambio térmico.

Estes incondensables poden entrar no circuíto a través de pequenas fisuras, poros ou unións defectuosas, sobre todo en zonas de baixa presión do ciclo de frío. A diferenza de presión nos casos mencionados provoca a entrada de aire exterior cara ao interior do circuíto. Unha vez dentro, estes gases adoitan arrastrarse a zonas de alta presión e a concentrarse no condensador. A acumulación de gases provoca a perda de capacidade de refrixeración, elevando a presión de condensación, o que obriga ao compresor a traballar contra unha maior presión. Este esforzo ten como consecuencia o incremento da temperatura de descarga, da presión de descarga e o aumento do consumo eléctrico da máquina. Non obstante, neste caso, o indicio atopado para o diagnóstico do fallo foi a superación de temperaturas de descarga superiores a 85°C durante o funcionamento do compresor, superando o intervalo habitual de operación, situado aproximadamente entre os 60 e 80°C .

Desde o punto de vista operativo, este tipo de fallo resulta especialmente relevante porque pode non manifestarse inicialmente como unha perda inmediata da temperatura da cámara. A instalación pode continuar producindo frío durante certo tempo, pero faino en condicións menos eficientes e máis esixentes para o compresor, incrementando notablemente a probabilidade de avaría da máquina.

Na Figura 4.4 represéntanse algunhas das variables durante o período analizado. O aspecto máis destacable é que a temperatura de descarga acada valores superiores a 85°C , que, como ben dicíamos, neste caso foi empregado como indicio principal para identificar a presenza de incondensables na instalación. As variacións en forma de picos que aparecen no gráfico corresponden coa variación producida polo cambio de funcionamento do compresor de parado a aceso, o que fai que aumenten os valores das variables.

Aínda así, a anomalía non se identifica unicamente a partir dunha única variable illada, senón a partir da relación entre o resto de variables dispoñibles, o funcionamento esperado do ciclo frigorífico e a evolución observada nas variables monitorizadas. Unha vez descrito o comportamento físico asociado á presenza de incondensables, procédese á aplicación dos métodos estatísticos de detección de anomalías propostos neste traballo, co obxectivo de comprobar se son capaces de sinalar como anómalo o período no que a temperatura de descarga supera os valores considerados admisibles respecto a un funcionamento normal.

4.2.1. Aplicación dos métodos de detección

Na Figura 4.5 represéntase o resultado obtido mediante o método kNN para o caso da presenza de incondensables na instalación. Para esta análise empregáronse as variables dispoñibles do compresor que permiten caracterizar o seu estado de funcionamento: a capacidade mecánica do compresor, a intensidade AC, a presión de aspiración, a presión de descarga, a presión do aceite, a temperatura de descarga e a temperatura do aceite.

Obsérvase que o estatístico kNN supera o limiar en varios momentos ao longo do período analizado. Non obstante, esta superación non se produce de forma continua nin coa mesma intensidade durante todo o intervalo de tempo estudado. Nos primeiros momentos do 17 de novembro aparece unha zona sombreada, que poden interpretarse como desviacións puntuais asociadas ao cambio de estado do compresor. Neste caso, o equipo viña de permanecer parado durante un longo período de tempo, polo que o inicio do funcionamento pode dar lugar a unha fase transitoria na que as variables non se axustan completamente ao patrón considerado normal.

A partir do mediodía do día 17, cando o compresor permanece acendido durante períodos máis prolongados, o estatístico comeza a superar o limiar con maior frecuencia e persistencia. Baixo funcionamento continuado, a combinación das variables do compresor afástase de maneira máis clara do comportamento aprendido na mostra de adestramento. A presenza de incondensables e o funcionamento prolongado baixo condicións máis esixentes poden provocar unha alteración progresiva das presións, temperaturas e demais variables asociadas ao compresor, levando a unha desviación do estatístico por riba do limiar.

Neste caso, o método detecta os períodos nos que o compresor está aceso como anómalos. Ademais, detecta algunhas desviacións breves e illadas tamén fóra deste réxime operativo.

Cómpre destacar que o método non xera unha única detección continua durante todo o período analizado, senón varias rexións anómalas separadas por intervalos nos que o estatístico descende por debaixo do limiar. Isto pode deberse a que o compresor non traballa sempre no mesmo modo de funcionamento, variando condicións de carga ou capacidade, polo que a manifestación do fallo varía segundo o réxime de funcionamento. En determinados momentos, as observacións poden volver situarse temporalmente preto do comportamento normal, aínda que o problema siga presente no sistema. Este comportamento é habitual nos métodos baseados en distancia, xa que cada observación se avalía de forma local segundo a súa proximidade aos datos de adestramento.

En conxunto, o gráfico indica que o método kNN é capaz de sinalar como anómalos os períodos nos que o compresor presenta un funcionamento compatible coa presenza de incondensables. As superacións sostidas do limiar, especialmente no día 17 de novembro, mostran que o comportamento multivariante do equipo se afasta de forma clara do funcionamento normal aprendido.

Neste caso, xa que se dispoñen de varias variables para a detección é interesante obter a contribución das variables que máis se desvían en cada detección. Na Táboa 4.1 recóllense as tres variables con maior porcentaxe de contribución en cada unha das secuencias detectadas.

Os resultados da Táboa 4.1 mostran que as variables térmicas son as que explican a maior parte das desviacións detectadas. En particular, a temperatura de descarga e a temperatura do aceite aparecen de forma recorrente entre as tres variables con maior contribución en case todas as secuencias. A presenza de incondensables dificulta o proceso de condensación e obriga o compresor a traballar nun réxime máis esixente, o que pode traducirse nun incremento das temperaturas asociadas ao funcionamento do equipo.

A temperatura de descarga destaca especialmente nas secuencias 2 e 5, cunha contribución superior ao 50% en ambos casos. Estes dous intervalos corresponden a períodos nos que o compresor permanece acendido durante un tempo máis prolongado, polo que a desviación térmica resulta máis evidente. Deste xeito, obsérvase que, cando o compresor traballa de forma continuada baixo condicións anómalas, a temperatura de descarga pasa a ser a variable que máis contribúe ao afastamento respecto ao comportamento normal.

A temperatura do aceite tamén presenta unha contribución elevada en varias secuencias, chegando a ser a variable principal nas secuencias 1, 6, 7 e 8. Isto indica que o fallo non afecta unicamente

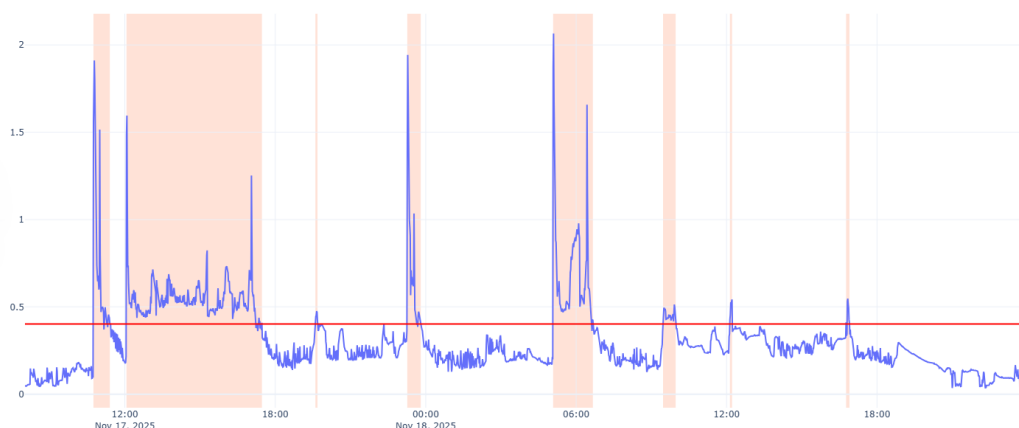


Figura 4.5: Detección usando kNN. En azul o estatístico de monitoreo e en vermello o limiar por estado. As zonas sombreadas representan as anomalías detectadas.

á temperatura do gas descargado polo compresor, senón tamén ao comportamento térmico interno do equipo. A presenza de temperaturas do aceite afastadas do patrón normal pode estar relacionada co maior esforzo mecánico e térmico ao que se ve sometido o compresor cando traballa en condicións de condensación desfavorables.

Por outra banda, a presión de aspiración aparece tamén de forma recorrente entre as variables máis relevantes. A súa contribución é especialmente elevada na secuencia 3, onde representa o 38,95% da desviación, e tamén nas secuencias 7 e 8. Isto suxire que algunhas deteccións non están explicadas só por un aumento das temperaturas, senón tamén por unha alteración das condicións de presión na entrada do compresor. Este comportamento resulta plausible nun sistema frigorífico, onde os cambios nas condicións de condensación poden modificar o equilibrio global do circuíto e afectar ás presións rexistradas, especialmente en períodos próximos a transicións de funcionamento.

En cambio, a intensidade AC e a capacidade mecánica do compresor presentan unha contribución menor na maioría das secuencias. Isto non implica que non sexan variables útiles para caracterizar o funcionamento do equipo, senón que, neste caso concreto, a anomalía detectada polo método kNN está dominada principalmente polas variables térmicas e, en menor medida, polas presións. Polo tanto, a análise das contribucións permite orientar a interpretación do fallo cara ao comportamento térmico do compresor, especialmente cara á temperatura de descarga e á temperatura do aceite.

Por outra banda, na Figura 4.6 represéntase o resultado obtido mediante a metodoloxía baseada en XGBoost e MEWMA para o caso da presenza de incondensables na instalación. As variables empregadas nesta análise son as mesmas que no caso do método kNN.

A liña azul da figura representa a evolución do estatístico MEWMA calculado sobre os residuos multivariantes, mentres que a liña vermella continua indica o limiar de control obtido a partir do período de calibración. Cando o estatístico supera este limiar, considérase que o comportamento conxunto dos residuos se afasta do patrón esperado baixo condicións normais. As zonas sombreadas sinalan os intervalos nos que esta superación se mantén con suficiente persistencia temporal como para ser considerada unha anomalía relevante.

O resultado mostra varias superacións claras do limiar ao longo do período analizado. A diferenza do método kNN, onde o estatístico presentaba unha evolución máis local e dependente da proximidade de cada observación ás mostras de adestramento, neste caso o MEWMA presenta incrementos máis abruptos e, en determinados intervalos, unha persistencia máis prolongada por enriba do limiar. Este comportamento é consecuencia da memoria temporal propia do gráfico MEWMA, que acumula

Sec.	Variable 1	%	Variable 2	%	Variable 3	%
1	Temp. aceite	35,83	Temp. descarga	28,03	Pres. aspiración	14,65
2	Temp. descarga	52,69	Temp. aceite	16,84	Cap. mecánica	11,01
3	Pres. aspiración	38,95	Temp. aceite	28,52	Temp. descarga	20,05
4	Temp. descarga	33,57	Temp. aceite	27,13	Pres. aspiración	14,57
5	Temp. descarga	51,41	Temp. aceite	15,24	Pres. aspiración	10,36
6	Temp. aceite	27,56	Pres. aceite	23,22	Pres. descarga	19,41
7	Temp. aceite	42,02	Pres. aspiración	28,66	Temp. descarga	14,58
8	Temp. aceite	41,02	Pres. aspiración	26,84	Temp. descarga	15,18

Táboa 4.1: Tres variables con maior contribución media nas secuencias anómalas detectadas mediante kNN no caso de presenza de incondensables.

información dos residuos ao longo do tempo e, polo tanto, responde con maior intensidade cando a desviación respecto ao modelo normal se mantén durante varias observacións consecutivas.

É deste xeito que o método detecta as desviacións producidas polo mal funcionamento do compresor cando este permanece aceso, nos mesmos períodos que no caso anterior. Así mesmo, a diferenza da técnica de kNN, a detección da desviación é máis prolongada que a producida por kNN. Porén, non se detectan desviacións máis illadas como as estudadas por kNN.

En conxunto, o gráfico MEWMA mostra unha detección coherente coa presenza de incondensables na instalación. As superacións amplas e persistentes do limiar indican que o comportamento multivariante do compresor se desvía de forma significativa respecto ao funcionamento normal aprendido polos modelos XGBoost. Por tanto, o estatístico MEWMA é capaz de capturar unha resposta anómala no conxunto das variables monitorizadas debido á presenza de incondensables, que alteran as condicións de condensación e obriga o compresor a traballar nun réxime máis esixente.

4.3. Fallo de bombeo de refrixerante

Outro dos fallos analizados neste capítulo corresponde a un problema no sistema de bombeo de refrixerante que alimenta a batería do evaporador. Como se describiu no Capítulo 1, o evaporador é o compoñente encargado de absorber calor do interior da cámara, para o cal resulta necesario que o refrixerante circule correctamente polo seu interior. En condicións normais de funcionamento, o fluído refrixerante chega ao evaporador en condicións de baixa presión e temperatura, permitindo que a superficie da batería se manteña a unha temperatura inferior á do aire da cámara e favorecendo así o intercambio térmico entre ambos medios.

Neste caso, o fallo produciuse porque as bombas de líquido encargadas de alimentar a batería non arrancaban correctamente ao atoparse descebadadas. Como consecuencia, o evaporador deixaba de recibir o caudal de refrixerante necesario para realizar a transferencia de calor de forma efectiva. Ao non circular refrixerante polo evaporador, a batería perde capacidade para manterse a unha temperatura suficientemente baixa respecto ao aire da cámara.

Na Figura 4.7 represéntanse dúas das variables dispoñibles para analizar este comportamento: en cor verde, a temperatura do aire da cámara, e en cor azul, a temperatura de fin de desescarche, asociada




Figura 4.6: Detección usando MEWMA. En azul o estatístico de monitoreo e en vermello o limiar obtido cos residuos do modelo XGBoost para as distintas variables empregadas. As zonas sombreadas representan as anomalías detectadas.

á temperatura medida na batería do evaporador. En condicións normais de funcionamento, agárdase que a temperatura da batería se manteña por debaixo da temperatura do aire, xa que esta diferenza térmica é a que permite a extracción de calor da cámara. Polo tanto, a existencia dunha separación clara entre ambas variables constitúe un indicio de que o intercambio térmico se está producindo correctamente. As pequenas montañas en forma de serra na variable temperatura fin de desescarche que aparecen antes do gran pico, corresponden ao momento no que o evaporador non está funcionando correctamente. Estas elevacións corresponden ao encendido dos ventiladores da cámara que moven o aire para intentar homoxeneizar a temperatura da cámara. O gran pico que se observa tamén é un cambio no modo de operativo, concretamente corresponde a un desescarche do evaporador. Despois deste desescarche, o problema parece estar arranzado e as variables volven ter un comportamento normal.




Figura 4.7: Datos das variables no evaporador: temperatura de fin de desescarche (azul) e temperatura do aire (verde).

Porén, tal e como se observa na Figura 4.7, durante varios intervalos a temperatura de fin de desescarche tende a aproximarse á temperatura do aire da cámara. Este comportamento indica que a batería do evaporador non está a traballar como unha superficie fría capaz de absorber calor. Pola contra, ao non recibir alimentación suficiente de líquido refrixerante, a temperatura medida na batería

acaba igualándose progresivamente coa temperatura ambiente da cámara.

Unha vez descrito o comportamento físico do fallo, procédese á aplicación dos métodos estatísticos de detección de anomalías propostos neste traballo, co obxectivo de comprobar se son capaces de identificar como anómalos os períodos nos que o evaporador presenta un comportamento compatible cun fallo no sistema de bombeo.

4.3.1. Aplicación dos métodos de detección

A Figura 4.8 mostra a evolución do estatístico de detección kNN para o caso de fallo de bombeo. A liña azul representa o estatístico monitorizado, calculado a partir da distancia media de cada observación respecto aos seus veciños máis próximos no conxunto de funcionamento normal. A liña vermella continua representa o limiar de decisión: cando a puntuación supera este valor, a observación considérase anómala. As franxas verticais en cor salmón indican os intervalos nos que se detectan secuencias anómalas persistentes.




Figura 4.8: Detección usando kNN. En azul o estatístico de monitoreo e en vermello o limiar por estado. As zonas sombreadas representan as anomalías detectadas.

Neste caso, o método kNN detecta anomalías principalmente ata as 8 da mañá cando se soluciona o problema aproximadamente. Durante este intervalo, o estatístico supera repetidamente o limiar, especialmente nos tramos nos que a liña azul presenta picos elevados. Isto indica que o comportamento observado se afasta do patrón aprendido como funcionamento normal. A detección non aparece como un único bloque continuo, senón como varias rexións alternas, o que suxire que o fallo se manifesta de forma intermitente ou asociado a determinados momentos do ciclo de operación do evaporador, con forma similar ao observado nas variables en crudo.

Cando as bombas de líquido non alimentan correctamente a batería do evaporador, a temperatura de fin de desescarche tende a aproximarse á temperatura do aire. O encendido de ventiladores que removen o aire provocan ademais ese aumento de temperatura que se ve tanto na representación das variables como esos picos como na detección con kNN. Esta perda de separación térmica modifica a relación normal entre ambas variables, facendo que as observacións se sitúen lonxe das veciñanzas habituais do conxunto de adestramento. Por este motivo, o estatístico kNN aumenta e supera o limiar de control. Ademais, o desescarche producido ás 06:00 é tamén detectado como un comportamento anómalo ao alcanzar temperaturas inferiores ao normal.

A partir das 7:30, o valor do estatístico descende de forma clara e permanece por debaixo do limiar durante a maior parte do período restante. Isto indica que, para o modelo kNN, as observacións poste-

rios volven parecerse ao comportamento considerado normal, ou polo menos deixan de presentar unha desviación suficientemente intensa como para activar a alarma. A ausencia de novas rexións anómalas persistentes na segunda metade da gráfica suxire unha recuperación parcial do comportamento térmico ou unha redución clara da intensidade do fallo.

En conxunto, a gráfica indica que o método kNN é capaz de identificar o período problemático asociado ao fallo de bombeo, detectando como anómalos os momentos nos que a relación entre a temperatura do aire e a temperatura da batería se aparta do funcionamento esperado. Non obstante, a detección aparece fragmentada en varios intervalos, polo que convén interpretala como un sinal de fallo persistente pero con intensidade variable ao longo do tempo.

A Figura 4.9 mostra a detección obtida mediante o método EWMA aplicado aos residuos da variable temperatura fin de desescarxe. Ao igual que no fallo por xeo no evaporador, neste ao caso ao só dispoñer de dúas variables, en vez aplicar un gráfico MEWMA aplicamos o estatístico EWMA ao só dispoñer dos residuos XGBoost dunha das variables, xa que a outra se usa como única explicativa. Analogamente ao resto de casos, a liña azul representa a evolución do estatístico EWMA, mentres que as dúas liñas vermellas continuas indican os límites de control superior e inferior. Cando o estatístico supera algún destes límites, considérase que o comportamento da variable se afasta do funcionamento esperado. As rexións verticais en cor salmón sinalan os intervalos nos que se detectan anomalías persistentes.




Figura 4.9: Detección usando EWMA. En azul o estatístico de monitoreo e en vermello o limiar obtido cos residuos do modelo XGBoost para a variable temperatura fin de desescarxe. As zonas sombreadas representan as anomalías detectadas.

Neste caso, o EWMA detecta principalmente unha desviación negativa moi clara entre as 01:15 e as 05:45 aproximadamente, intervalo no que o estatístico permanece durante bastante tempo por debaixo do límite inferior. Este comportamento indica que os residuos presentan unha desviación sistemática respecto ao patrón aprendido como normal. É dicir, non se trata só de observacións illadas, senón dunha alteración continuada na dinámica da variable.

Nun evaporador correctamente alimentado, a temperatura da batería debería manterse por debaixo da temperatura do aire para que exista intercambio térmico efectivo. Cando as bombas de líquido non alimentan correctamente a batería, esta deixa de recibir refrixerante e a súa temperatura tende a aproximarse á temperatura do aire da cámara. Esa perda do salto térmico provoca unha modificación persistente da relación esperada entre as variables, o que se traduce nunha acumulación de residuos anómalos no EWMA.

Tamén se observa un cambio brusco arredor das 05:45–06:30, onde o estatístico pasa rapidamente de valores negativos moi baixos a valores positivos, chegando incluso a superar o límite superior. Este comportamento pode interpretarse como unha transición no estado do sistema: tras un período no que a variable presentaba unha desviación clara respecto ao funcionamento normal, prodúcese unha variación repentina que tamén se afasta do patrón esperado. Neste caso esta transición pode estar asociadas ao cambio no ciclo de funcionamento do evaporador ou a intentos de recuperación parcial da alimentación de líquido.

A partir das 07:00–07:30, o estatístico tende progresivamente cara á zona baixo control e permanece dentro dos límites durante o tempo restante. Isto suxire que, segundo o EWMA, o comportamento posterior se aproxima de novo ao esperado, ou polo menos deixa de presentar unha desviación sostida suficientemente intensa como para activar a detección.

Comparando este resultado co obtido mediante kNN, obsérvase que ambos métodos identifican como problemático un intervalo similar, concentrado principalmente entre o inicio da serie e arredor das 07:00–07:30. Polo tanto, os dous métodos son coherentes ao sinalar que a parte inicial do rexistro contén o comportamento anómalo asociado ao fallo de bombeo.

Non obstante, a forma da detección é diferente. No caso de kNN, a anomalía aparece máis fragmentada, con varias rexións anómalas intercaladas con períodos aparentemente normais. Isto débese a que kNN avalía cada observación segundo a súa proximidade ao conxunto de funcionamento normal. Por tanto, cando unha observación concreta se parece suficientemente aos datos de adestramento, o estatístico pode baixar por debaixo do limiar, aínda que o fallo siga presente de fondo.

Pola contra, o EWMA incorpora memoria temporal mediante o suavizado exponencial. Isto fai que sexa máis sensible a desviacións pequenas pero persistentes. Por esa razón, neste caso o EWMA amosa unha rexión anómala máis continua e prolongada, especialmente cando o estatístico permanece por debaixo do límite inferior durante varias horas. Esta característica resulta especialmente adecuada para un fallo como o de bombeo, xa que a perda de alimentación de refrixerante non ten por que manifestarse como un cambio instantáneo e illado, senón como unha degradación sostida do comportamento térmico do evaporador.

En conxunto, ambos métodos detectan o fallo, pero ofrecen información complementaria. O kNN identifica os instantes nos que as observacións se afastan localmente do patrón normal, mentres que o EWMA permite visualizar mellor a persistencia temporal da desviación. Para este caso concreto, a detección mediante EWMA parece máis estable e máis acorde coa natureza do fallo, xa que o problema de bombeo provoca unha alteración mantida na relación entre a temperatura da batería e a temperatura do aire, máis que unha sucesión de anomalías illadas.

4.4. Conclusións dos casos prácticos

A aplicación das metodoloxías propostas aos tres casos prácticos permite extraer unha serie de conclusións sobre o seu comportamento en datos procedentes de instalacións frigoríficas. En primeiro lugar, obsérvase que tanto o método baseado en k-veciños máis próximos como a metodoloxía baseada en XGBoost con gráficos EWMA ou MEWMA son capaces de identificar desviacións coherentes coa natureza física dos fallos analizados. Nos tres casos estudados, as deteccións obtidas aparecen en períodos nos que as variables monitorizadas presentan un comportamento afastado do funcionamento considerado normal, xa sexa pola acumulación de xeo nun evaporador, pola presenza de incondensables nun compresor ou por un fallo no bombeo de refrixerante.

Un aspecto especialmente relevante é que ambos métodos resultan eficaces mesmo cando as variables de estado do activo non están completamente rexistradas ou dispoñibles. Nunha situación ideal, cada observación debería estar asociada de forma precisa ao modo de funcionamento real da máquina, como regulación, parada, desescarche, arranque ou habilitado. Esta información permite construír modelos específicos para cada estado e comparar cada observación unicamente co patrón normal correspondente ao seu réxime operativo. Porén, nos datos reais non sempre se dispón desta información de forma completa ou directamente asociada ao activo analizado.

A pesar desta limitación, os métodos seguen proporcionando resultados coherentes porque as variables físicas medidas polos sensores conteñen información indirecta sobre o estado de funcionamento da máquina. É dicir, aínda que o estado non estea explicitamente rexistrado, os patróns de temperatura, presión, capacidade, intensidade ou evolución temporal permiten distinguir parcialmente os distintos réximes operativos. Por exemplo, un compresor parado, un compresor en funcionamento continuado ou un evaporador en desescarche presentan combinacións de variables claramente diferentes. Deste xeito, os métodos estatísticos poden captar parte desa estrutura a través das propias variables observadas.

No caso do kNN, esta capacidade explícase porque o método compara cada nova observación coas observacións máis próximas da mostra de adestramento. Se os datos de referencia conteñen exemplos representativos dos distintos comportamentos normais do activo, a nova observación tenderá a atopar veciños próximos cando pertenza a un réxime xa observado, aínda que o estado non estea explicitamente identificado. Pola contra, cando a combinación de variables se afasta das rexións habituais do espazo de características, o estatístico de distancia aumenta e pode superar o limiar de detección. Así, o método non necesita coñecer necesariamente o estado formal da máquina para detectar que unha observación é pouco habitual respecto ao funcionamento aprendido.

No caso da metodoloxía baseada en XGBoost e EWMA ou MEWMA, o funcionamento tamén pode manterse aínda sen unha variable de estado perfectamente rexistrada, xa que o modelo aprende as relacións existentes entre as variables dispoñibles baixo condicións normais. Cando o sistema funciona correctamente, estas relacións adoitan manterse estables: determinadas presións, temperaturas ou intensidades evolucionan de forma coherente entre si. Se aparece un fallo, esa relación esperada pode romperse, xerando residuos máis elevados ou cunha estrutura temporal diferente. O gráfico EWMA ou MEWMA permite entón detectar a desviación acumulada deses residuos respecto ao comportamento de referencia.

Non obstante, a ausencia dunha variable de estado ben definida tamén introduce limitacións. En particular, pode aumentar a variabilidade da mostra de adestramento, xa que poden mesturarse observacións procedentes de diferentes réximes operativos nunha mesma mostra. Isto pode facer que os limiares sexan máis amplos e que algunhas desviacións sexan máis difíciles de detectar. Ademais, certas transicións normais entre modos de funcionamento poden xerar incrementos puntuais dos estatísticos, dando lugar a posibles falsas alarmas. Por este motivo, cando a información de estado está dispoñible, a súa incorporación segue sendo recomendable.

Os resultados obtidos mostran tamén a importancia de aplicar criterios de persistencia temporal antes de xerar unha alarma. Nos gráficos dos casos prácticos aparecen algunhas superacións illadas dos limiares que poden deberse a ruído, transicións de estado ou variacións puntuais das sondas. A esixencia de que a anomalía se manteña durante varias observacións consecutivas permite reducir este tipo de falsas alarmas e fai que a detección sexa máis robusta desde un punto de vista operativo.

Capítulo 5

Implementación da metodoloxía

Neste capítulo descríbese a implementación computacional da metodoloxía proposta para a detección de anomalías en dispositivos frigoríficos. Unha vez presentados no Capítulo 2 os fundamentos estatísticos empregados neste traballo, resulta necesario explicar como se trasladan estes métodos a un sistema operativo capaz de traballar con datos reais procedentes das instalacións.

O desenvolvemento realizouse dentro do ecosistema de Gradhoc, integrándose cos repositorios e servizos funcionais que xa existen na plataforma. Para isto, o sistema comunícase cos repositorios que proporcionan as lecturas das instalacións, cos servizos que permiten coñecer a información dos activos, variables e estados de funcionamento, e cos motores encargados de xerar os eventos. Deste xeito, o motor pode extraer e procesar os datos necesarios, adestrar os modelos de referencia, aplicar a detección sobre novas observacións e, cando se identifica unha anomalía, enviar a activación correspondente para que esta quede reflectida como un evento dentro da plataforma.

O motor desenvolvido recibe o nome de `python-machine-learning` e é o encargado da detección de anomalías mediante técnicas de aprendizaxe automática. A súa finalidade é modelizar o comportamento normal de activos concretos, como evaporadores ou compresores, tendo en conta os distintos estados de operación nos que poden atoparse. A partir desa caracterización do funcionamento normal, o sistema permite detectar desviacións significativas e estimar que variables contribúen en maior medida á anomalía observada.

5.1. Contexto informático do sistema

Como se comentou na introdución, as instalacións frigoríficas monitorizadas xeran de forma continua unha gran cantidade de datos procedentes das sondas e controladores instalados nos equipos. Estes datos inclúen variables físicas, como temperaturas ou presións, así como variables de estado que indican o modo de funcionamento no que se atopa cada activo. Polo tanto, a implementación da metodoloxía debe adaptarse a un contexto de series temporais multivariantes, con presenza de datos faltantes, ruído e cambios de comportamento asociados aos distintos modos de operación.

En primeiro lugar, o motor comunícase cun repositorio de series temporais, no que se almacenan as lecturas históricas das variables monitorizadas. A partir deste repositorio extráense os datos necesarios para as fases de adestramento e detección. En segundo lugar, empréganse servizos de información da instalación, que permiten coñecer a topoloxía dos equipos, as relacións entre activos, os identificadores das variables e os posibles estados operativos de cada dispositivo. Finalmente, o sistema intégrase cun planificador de tarefas, encargado de organizar a execución dos procesos de avaliación de novos datos.

Esta arquitectura permite que a metodoloxía poida aplicarse sobre diferentes instalacións e equipos sen modificar a lóxica estatística principal. Deste xeito, o motor recibe como entrada a información correspondente a unha instalación, un activo ou un conxunto de activos, e encárgase de executar o fluxo completo de procesamento, modelización e detección.

5.2. Recursos utilizados

Neste apartado descríbense os principais recursos empregados no desenvolvemento e integración do motor de detección de anomalías. Estes recursos non forman parte directamente da metodoloxía estatística, mais resultan fundamentais para que os algoritmos poidan ser aplicados sobre datos reais, executarse de forma automatizada e comunicarse co resto dos compoñentes.

- **Python** [Python Software Foundation \(s.f.\)](#). O desenvolvemento do motor realizouse en Python, linguaxe de programación amplamente empregada no ámbito da análise de datos, a estatística computacional e a aprendizaxe automática. A súa elección vén motivada pola dispoñibilidade de librerías especializadas e, sobre todo, pola súa integración co ecosistema xa existente dentro da empresa.

Neste traballo, Python emprégase para implementar o fluxo completo da metodoloxía: a extracción e tratamento das series temporais, a estandarización das variables, o adestramento dos modelos, o cálculo dos limiares, a detección de anomalías e a estimación das contribucións das variables. Ademais, tamén se utiliza para definir os servizos que permiten executar estes procesos desde outros compoñentes da plataforma.

- **Bases de datos.** Unha parte esencial do funcionamento de Gradhoc baséase no almacenamento e consulta das lecturas procedentes da sensórica das instalacións. Estes sensores rexistran valores de distintas variables cunha frecuencia relativamente alta, polo que resulta necesario dispoñer dunha infraestrutura de datos que permita acceder de forma eficiente á información histórica e en tempo real.

No contexto do motor desenvolvido, as bases de datos cumpren dúas funcións diferenciadas. Por unha banda, permiten recuperar as series temporais das variables asociadas aos activos que se queren analizar. Por outra, proporcionan información estrutural sobre as instalacións, como a relación entre os dispositivos, os identificadores unívocos das variables ou os estados operativos dispoñibles.

- **Git** ([Git \(s.f.\)](#)) e **GitHub** ([GitHub \(s.f.\)](#)). Para o control de versións do código emprégase Git, ferramenta que permite manter un historial dos cambios realizados durante o desenvolvemento do proxecto. Este tipo de sistema resulta especialmente útil en proxectos de software, xa que facilita a creación de ramas de traballo, a revisión de modificacións e a recuperación de versións anteriores no caso de que sexa necesario.

O repositorio do proxecto organízase mediante GitHub, que actúa como plataforma para almacenar o código e facilitar a colaboración no desenvolvemento. O uso de control de versións é especialmente relevante nun proxecto en desenvolvemento continuo, xa que permite incorporar novas funcionalidades, corrixir erros e manter unha trazabilidade clara da evolución do motor.

- **Redis.** Sistema de almacenamento en memoria baseado nun esquema clave-valor ([Redis \(s.f.\)](#)). A súa utilidade principal dentro dunha arquitectura de servizos é facilitar a comunicación rápida entre distintas pezas de software, xa que permite gardar e recuperar información de forma eficiente. A efectos prácticos, pode entenderse como un gran dicionario no que cada clave identifica un determinado obxecto ou conxunto de datos.

No contexto da plataforma, Redis emprégase como mecanismo intermedio para compartir información entre motores. No caso deste motor de detección de anomalías, o seu uso está relacionado coa publicación da información necesaria para a xeración de eventos. Unha vez que o sistema identifica unha anomalía e se determina que debe activarse un evento, créase unha estrutura de datos asociada á instalación correspondente, na que se recollen diversos elementos asociados á detección.

- **RabbitMQ.** Trátase dun sistema de colas de mensaxería que permite a comunicación asíncrona entre servizos ([RabbitMQ \(s.f.\)](#)). A diferenza dunha chamada directa entre dous compoñentes,

unha cola permite que un servizo publique unha mensaxe e que outro a consuma cando estea dispoñible. Isto mellora a robustez do sistema e evita que o funcionamento dun motor dependa de forma inmediata da resposta doutro.

- **API e servizos web.** O motor desenvólvese como un servizo accesible mediante unha API, o que permite que outros compoñentes da plataforma poidan lanzar procesos de adestramento, consultar información de activos ou executar rutinas de detección. Esta estrutura é especialmente adecuada nun sistema distribuído, xa que separa a lóxica estatística da interface desde a que se solicita a execución dos procesos.

Para a construción desta API emprégase FastAPI, un *framework* de Python orientado ao desenvolvemento de servizos web (FastAPI (s.f.)). A través desta interface defínense os *endpoints* que permiten planificar o adestramento dunha instalación, modificar a lista de activos incluídos no *scheduler* ou executar probas do fluxo principal.

A utilización dunha API permite que o motor non dependa dunha execución manual, senón que poida integrarse nun fluxo automatizado de mantemento predictivo. Así, os modelos poden ser adestrados ou executados baixo demanda desde a propia plataforma ou mediante tarefas programadas.

- **Scheduler.** O *scheduler* ou planificador de tarefas encárgase de organizar a execución periódica dos procesos do motor. Este compoñente permite automatizar a avaliación de novas observacións evitando que este proceso dependa dunha intervención manual constante.

No caso do motor de detección, o *scheduler* permite manter unha lista de activos sobre os que se deben executar procesos de detección. Esta funcionalidade é especialmente importante cando se traballa con instancias reais, xa que a idea é a avaliación periódica dos equipos monitorizados.

5.3. Xustificación da metodoloxía implementada

A elección da metodoloxía finalmente implementada neste traballo debe entenderse tendo en conta a experiencia previa acumulada na empresa. A aproximación baseada na combinación de modelos de aprendizaxe automática con gráficos de control tipo EWMA e MEWMA non constitúe unha aproximación completamente nova dentro do contexto da empresa. Esta liña de traballo xa fora estudada e implementada previamente en dous Traballos Fin de Máster anteriores desenvolvidos no mesmo ámbito empresarial en Domínguez Basteiro (2022) e Díaz Cao (2023). Nestes traballos estudouse a aplicación de técnicas de control estatístico de procesos para a detección de anomalías en instalacións frigoríficas e chegou a desenvolverse unha primeira implementación orientada á súa integración na plataforma de monitorización.

Esta experiencia previa resulta especialmente relevante, xa que permitiu avaliar a metodoloxía non só desde o punto de vista estatístico, senón tamén desde unha perspectiva operativa. O enfoque baseado en EWMA e MEWMA presentaba interese metodolóxico, ao permitir monitorizar desviacións respecto ao comportamento esperado das variables e incorporar información temporal mediante medias móbiles exponencialmente ponderadas. Porén, tras a súa implementación e posta en funcionamento, o seu uso non acabou de consolidarse como solución satisfactoria para o motor de detección. A metodoloxía resultaba válida como ferramenta de análise, pero a súa explotación continuada dentro dun sistema industrial real presentaba dificultades que limitaron a súa utilidade práctica.

Un dos principais problemas detectados foi a complexidade da cadea de detección. O uso da metodoloxía EWMA e MEWMA non se aplica directamente sobre as observacións rexistradas polos sensores, senón sobre residuos obtidos a partir de modelos predictivos. Isto implica que, antes de avaliar unha posible anomalía, é necesario dispoñer dun modelo capaz de estimar o comportamento esperado de cada variable ou conxunto de variables. Polo tanto, o sistema debe executar unha secuencia formada polo adestramento dos modelos, a xeración de predicións, o cálculo dos residuos e a posterior avaliación

dos estatísticos de control. Esta estrutura fixo que a metodoloxía fose máis difícil de manter e escalar que outras alternativas máis directas.

A isto engádesse o custo asociado ao almacenamento e á xestión dos modelos. A metodoloxía require conservar non só os modelos de aprendizaxe automática, senón tamén os parámetros estatísticos necesarios para a aplicación dos gráficos de control: medias de referencia, matrices de covarianzas, parámetros de suavizado e límites de control. Estes elementos deben manterse asociados a cada dispositivo, configuración ou modo de funcionamento, polo que o número de compoñentes a almacenar, versionar e actualizar pode crecer rapidamente a medida que aumenta o número de equipos monitorizados. Esta necesidade introducía unha complexidade arquitectónica pouco desexable para unha solución de produción.

Tamén durante a fase de detección o enfoque presentaba unha maior esixencia computacional. Para cada nova observación era necesario obter as predicións correspondentes, calcular os residuos, actualizar o estatístico EWMA ou MEWMA e comprobar se se superaban os límites de control establecidos. No caso multivariante, a avaliación do estatístico MEWMA require ademais considerar a estrutura de covarianzas dos residuos, o que incrementa a complexidade cando se traballa con varios sinais e con rexistros continuos no tempo. Deste modo, o custo da metodoloxía non se concentraba unicamente no adestramento inicial, senón que se mantiña durante toda a explotación do motor de detección.

Por estes motivos, e a partir da experiencia obtida coas implementacións anteriores, a metodoloxía baseada en EWMA e MEWMA non acabou de convencer como solución principal de produción e foi retirada do fluxo operativo do motor de detección. Esta decisión debe interpretarse como unha consecuencia das dificultades observadas ao trasladalo a un sistema industrial que debe funcionar de maneira continua, escalable e facilmente mantible, non como unha falla de interese estatístico.

Neste contexto, o presente traballo reformula a elección metodolóxica tendo en conta tanto os resultados estatísticos como a viabilidade da súa implementación. A metodoloxía baseada en k -veciños máis próximos ofrece unha alternativa máis sinxela desde o punto de vista arquitectónico, xa que permite comparar directamente as novas observacións co comportamento normal aprendido a partir dunha mostra de referencia. Deste xeito, evítase a necesidade de manter modelos predictivos específicos para cada variable, calcular residuos de forma continua e avaliar estatísticos multivariantes adicionais antes de xerar unha sinal de anomalía.

A elección de kNN non se fundamenta unicamente nesta simplificación operativa, senón tamén nos resultados obtidos ao longo do traballo. No estudo de simulación do Capítulo 3 obsérvase que tanto a combinación de XGBoost con MEWMA como kNN son capaces de detectar unha proporción elevada das anomalías introducidas. Non obstante, o método kNN por modo presenta un comportamento máis equilibrado, especialmente no control das falsas alarmas. Aínda que XGBoost e MEWMA acadan unha maior sensibilidade, tamén clasifica como anómalas un maior número de observacións normais. Pola contra, kNN por modo mellora a especificidade, a precisión, o F1-score e a precisión balanceada, aspectos especialmente relevantes nun sistema de monitorización no que un exceso de alarmas pode reducir a confianza dos usuarios e dificultar a priorización dos eventos realmente importantes.

Os casos prácticos do Capítulo 4 reforzan esta conclusión. Ao aplicar os métodos sobre datos reais, obsérvase que as desviacións deben interpretarse no contexto propio das instalacións frigoríficas, onde existen ruído nas medicións, cambios de estado, transicións operativas e variacións puntuais das sondas. Isto fai que a utilidade dun método non dependa só da súa capacidade para sinalar desviacións, senón tamén da posibilidade de incorporalo nun fluxo de detección robusto, interpretable e compatible con criterios operativos como a persistencia temporal das anomalías antes da xeración dun evento.

En consecuencia, a implementación desenvolvida neste traballo céntrase no método kNN, deixando EWMA e MEWMA como referencia metodolóxica e punto de comparación. Esta decisión non supón descartar o interese estatístico dos gráficos de control, senón asumir as limitacións observadas na súa explotación práctica dentro da plataforma. A experiencia previa coa metodoloxía EWMA/MEWMA mostrou que a súa posta en produción resultaba difícil de manter, debido á necesidade da avaliación constante dos modelos, almacenar configuracións específicas e avaliar de forma continua estatísticos de control. Fronte a isto, kNN ofrece unha solución máis directa, cunha arquitectura máis sinxela e cun comportamento competitivo nos estudos realizados.

5.4. Estrutura xeral do motor de detección

O funcionamento do motor pode entenderse como unha cadea de procesos que comeza coa extracción dos datos e remata coa identificación de posibles anomalías. Aínda que a metodoloxía estatística se basea principalmente no algoritmo kNN descrito na Sección 2.2, a súa aplicación práctica require unha serie de pasos adicionais que condicionan de forma importante o comportamento final do sistema.

En primeiro lugar, extráense as lecturas históricas correspondentes ao activo que se quere analizar. Estas lecturas están asociadas a identificadores únicos das variables rexistradas, polo que é necesario empregar a información estrutural da instalación para seleccionar correctamente as variables de interese. No caso dos evaporadores, por exemplo, poden considerarse variables relacionadas coa temperatura de retorno, temperatura de impulsión, temperatura do aire ou temperatura de fin de desescarche. No caso dos compresores, adoitan ser relevantes variables como temperaturas, presións, capacidade de traballo ou intensidade requirida.

Unha vez extraídos os datos, realízase un preprocesado das series temporais. Este paso é imprescindible debido á forma de extracción. Como xa se comentou en capítulos anteriores, os sistemas de recompilación poden presentar interrupcións na comunicación, rexistros incompletos ou valores faltantes. Por este motivo, antes de aplicar calquera algoritmo, os datos son ordenados temporalmente, tratados para corrixir valores ausentes e homoxeneizados para que as distintas variables poidan compararse nun mesmo marco temporal.

Un aspecto especialmente relevante da implementación é a segmentación segundo o estado operativo do activo, sempre e cando sexa posible. En instalacións frigoríficas, o comportamento dunha máquina non é constante ao longo do tempo. Un evaporador, por exemplo, non presenta a mesma dinámica cando está regulando normalmente que cando se atopa parado por termostato ou en proceso de desescarche. Do mesmo xeito, un compresor pode atoparse en funcionamento ou permanecer habilitado sen estar traballando activamente. Polo tanto, mesturar todos estes rexistros nun único modelo podería provocar que o algoritmo interpretase como anomalías cambios que en realidade responden a transicións normais de funcionamento.

Para evitar este problema, o motor separa os datos en función do estado do activo. Deste xeito, constrúense modelos específicos para cada réxime de funcionamento sempre que a información dispoñible o permita.

5.5. Adestramento dos modelos

A fase de adestramento ten como obxectivo construír unha representación do comportamento normal do activo. Para iso, empréganse datos históricos correspondentes a períodos nos que se considera que o dispositivo funcionou correctamente. Esta selección é unha parte fundamental do procedemento, xa que o modelo resultante só será útil se a mostra empregada como referencia representa adecuadamente o funcionamento baixo control.

Durante esta fase, o sistema elimina aqueles períodos nos que o activo se atopaba en situación de alarma ou nos que existen indicios dun comportamento anómalo. O obxectivo é evitar que o modelo aprenda como normais patróns asociados a fallos ou degradacións do funcionamento. Isto é especialmente importante nun enfoque semi-supervisado, onde se dispón principalmente de datos de funcionamento correcto e a detección se basea na comparación das novas observacións con ese patrón de referencia.

Unha vez seleccionada a mostra de adestramento, as variables son estandarizadas. Este paso resulta necesario porque as magnitudes rexistradas polos sensores poden estar expresadas en escalas moi diferentes. Por exemplo, unha temperatura, unha presión e unha porcentaxe de apertura dunha válvula poden presentar rangos numéricos completamente distintos. Se se aplicase directamente unha medida de distancia sobre estas variables sen ningún tipo de transformación, aquelas con maior escala dominarían o cálculo da proximidade entre observacións. Para evitar este efecto, emprégase unha estandarización univariante, gardando a media e a desviación típica calculadas na mostra de adestramento para reutilizalas posteriormente na fase de detección.

Tras a estandarización, adéstrase o modelo baseado en k veciños máis próximos. Na implementación desenvolvida emprégase un valor de $k = 50$, en liña co criterio explicado na Sección 2.2. O modelo non se utiliza como clasificador supervisado, senón como unha ferramenta para medir a distancia dunha nova observación respecto ao conxunto de observacións consideradas normais. Así, unha observación será máis sospeitosa canto máis afastada se atope dos seus veciños máis próximos dentro da mostra de referencia.

A partir das distancias obtidas na propia mostra de adestramento, calcúlase un limiar de decisión. Este limiar establécese mediante un percentil da distribución empírica das distancias, de modo que só aquelas observacións cunha distancia superior a este limiar serán consideradas como posibles anomalías. A elección deste percentil pode variar segundo o tipo de activo ou o estado operativo analizado. Por exemplo, en estados pouco frecuentes ou de curta duración, como o desescarche dun evaporador, pode ser necesario empregar criterios distintos aos utilizados en estados con maior volume de datos.

Finalmente, o servizo de adestramento garda tanto o modelo kNN como o escalador asociado e o limiar calculado. Este paso permite que a fase de detección poida executarse posteriormente sen repetir o proceso de adestramento, reducindo o custo computacional e facilitando a aplicación periódica do sistema sobre novas observacións.

5.6. Detección de anomalías

Unha vez adestrados os modelos, o sistema está en disposición de avaliar novos datos. A fase de detección segue unha lóxica análoga á do adestramento, comparando as novas observacións co comportamento previamente aprendido.

En primeiro lugar, extráense as lecturas correspondentes ao período que se quere analizar. Estas observacións son sometidas ao mesmo preprocesado que os datos de adestramento, garantindo que as series temporais teñan unha estrutura compatible coa esperada polo modelo. A continuación, os datos son separados segundo o estado operativo do activo, xa que cada observación debe ser comparada co modelo correspondente ao estado no que se atopaba a máquina nese momento.

Posteriormente, as variables son transformadas utilizando o escalador gardado durante o adestramento. Este punto é importante, xa que non se recalculan a media nin a desviación típica sobre os datos de detección. Pola contra, empréganse os parámetros estimados na mostra de referencia.

Para cada nova observación calcúlase a súa distancia media aos k veciños máis próximos da mostra de adestramento. Esta distancia constitúe o estatístico de detección empregado polo sistema. Se o valor obtido supera o limiar previamente definido para ese activo e estado operativo, a observación considérase anómala. En caso contrario, interprétase que o comportamento observado é compatible co funcionamento normal aprendido polo modelo.

5.7. Análise da contribución das variables

A detección dunha anomalía por si soa non sempre é suficiente para a súa utilidade práctica. Nun contexto industrial, é necesario proporcionar información adicional que axude a interpretar o motivo polo que o sistema considera anómala unha observación. Por este motivo, o motor desenvolvido incorpora un procedemento para estimar a contribución de cada variable á anomalía detectada.

Cando unha observación supera o limiar de detección, o sistema compara o punto anómalo cos seus veciños normais máis próximos. A partir desta comparación calcúlase, para cada variable, a diferenza ao cadrado entre o valor observado e os valores correspondentes nos veciños de referencia.

Unha vez obtida a desviación por variable, calcúlase a proporción que representa cada unha delas respecto ao total da desviación observada. Deste xeito, obtense unha porcentaxe de contribución asociada a cada variable. As variables con maior porcentaxe son aquelas que máis explican a distancia elevada do punto respecto ao comportamento normal.

Este procedemento resulta especialmente útil desde o punto de vista operativo, xa que permite orientar a análise técnica posterior. Por exemplo, se unha anomalía nun evaporador está explicada

maioritariamente pola temperatura de fin de desescarche, a interpretación será distinta que se a maior contribución procede da temperatura de retorno ou do estado do equipo. Polo tanto, a análise de contribucións constitúe unha ponte entre a detección estatística e a interpretación física do fallo.

5.8. Servizos principais do sistema

Desde o punto de vista da implementación, o motor estrutúrase arredor de dous servizos principais: o servizo de adestramento e o servizo de detección. Esta separación permite diferenciar claramente as tarefas de construción dos modelos das tarefas de inferencia sobre novos datos.

O servizo de adestramento é o encargado de coordinar a descarga masiva de lecturas históricas, aplicar o preprocesado correspondente, separar os datos segundo o estado operativo e adestrar os modelos asociados a cada activo. Ademais, este servizo xestiona o cálculo dos limiares e a persistencia dos obxectos necesarios para a detección posterior. No caso dos evaporadores, a lóxica de adestramento contempla estados como regulación normal, corte por termostato ou desescarche. No caso dos compresores, a segmentación céntrase principalmente nos estados de funcionamento e parada.

Pola súa banda, o servizo de detección encárgase de cargar os modelos xa adestrados e aplicalos sobre novos conxuntos de datos. Este servizo realiza a transformación das variables, calcula as puntuacións de anomalía e determina se cada observación supera ou non o limiar establecido. Ademais, cando se produce unha detección, calcula as contribucións porcentuais das variables implicadas.

Esta división en servizos facilita o mantemento do código e permite que o sistema poida evolucionar de forma modular. Por exemplo, é posible modificar a estratexia de adestramento sen alterar a lóxica de detección, ou incorporar novos tipos de activos mantendo a estrutura xeral do motor.

5.9. Librarías de Python empregadas

O sistema foi desenvolvido integramente en Python e fai uso de diferentes librarías especializadas para o tratamento de datos, a aprendizaxe automática, a persistencia dos modelos e a construción da API. En particular, empregáronse *Pandas* ([Pandas Developers \(s.f.\)](#)), *NumPy* ([NumPy Developers \(s.f.\)](#)), *Scikit-learn* ([Scikit-learn Developers \(s.f.\)](#)), *Joblib* ([Joblib Developers \(s.f.\)](#)), *FastAPI* ([FastAPI \(s.f.\)](#)), *Pydantic* ([Pydantic \(s.f.\)](#)) e *APScheduler* ([Grönholm \(s.f.\)](#)):

- ***Pandas***: emprégase para o tratamento e manipulación dos datos mediante estruturas tipo `DataFrame`, especialmente axeitadas para organizar series temporais multivariantes con marcas temporais, variables monitorizadas e estados de operación.
- ***NumPy***: utilízase como soporte para operacións numéricas, cálculo vectorial e manipulación eficiente de arrays, servindo de base para moitos dos procedementos de transformación e preparación dos datos.
- ***Scikit-learn***: constitúe a base da parte de aprendizaxe automática. En particular, emprégase `StandardScaler` para a estandarización das variables e `NearestNeighbors` para a construción do modelo baseado en veciños máis próximos. Esta librería permite calcular distancias de forma eficiente e recuperar os veciños máis próximos empregados no estatístico de detección.
- ***Joblib***: utilízase para gardar os modelos adestrados mediante a serialización de obxectos de Python. Deste xeito, os modelos, escaladores e estruturas necesarias para a inferencia poden almacenarse e recuperarse posteriormente sen repetir o proceso de adestramento.
- ***FastAPI***: emprégase para desenvolver a API que permite a comunicación do motor co resto do ecosistema. Esta ferramenta facilita a definición de rutas para lanzar procesos de adestramento, consultar información dos activos ou executar probas do fluxo principal.

- **Pydantic**: utilízase para a validación dos datos de entrada da API. Permite definir esquemas e comprobar que as peticións recibidas teñen a estrutura esperada antes de ser procesadas polo motor.
- **APScheduler**: permite planificar e executar automaticamente tarefas periódicas dentro do motor. Programa a detección recorrente de anomalías, de modo que os activos monitorizados poidan ser avaliados periodicamente sen intervención manual.

5.10. Endpoints e orquestración do sistema

A implementación do motor como unha API inclúe diferentes *endpoints* que permiten a súa administración e execución desde outros compoñentes da plataforma. Unha das funcionalidades principais é a xestión da axenda de activos que deben ser adestrados periodicamente. Para iso, o sistema permite engadir ou eliminar activos da lista empregada polo planificador, facilitando así o control sobre que equipos deben ser incluídos nos procesos automáticos de readestramento.

Ademais, existen *endpoints* orientados á consulta de información dos activos e á planificación do adestramento dunha instalación completa. Estes servizos reciben como entrada os identificadores da instalación e os rangos temporais correspondentes, permitindo lanzar a xeración de modelos para un conxunto de equipos. Tamén se inclúe un *endpoint* de proba que permite executar o fluxo principal do motor, útil durante as fases de desenvolvemento e validación.

5.11. Integración coa xeración de eventos

Unha vez realizada a detección de anomalías, o motor non se limita a devolver un resultado numérico ou unha clasificación interna, senón que comunica a activación dun evento ao sistema encargado da xestión de avisos da plataforma. Deste xeito, a metodoloxía deixa de ser un procedemento illado de análise de datos e pasa a integrarse dentro do fluxo operativo de Gradhoc.

Cando o servizo de detección identifica que unha ou varias observacións superan o limiar establecido para un activo e estado operativo determinado, xérase a información necesaria para caracterizar a anomalía. Esta información inclúe o activo afectado, o instante temporal no que se produce a desviación, o estado operativo no que se atopaba a máquina, o valor do estatístico de distancia e as contribucións das variables implicadas. A partir destes elementos, o motor prepara unha saída estruturada que permite activar o evento correspondente.

Evento	Fecha activación	Fecha límite cuarentena	Prioridad
Sala de Máquinas 2 (Danfoss) > Cámara 7 > Cam7 evap2 Esclavo Tiempo de desescarche excesivo	27/05/2026 15:27 h	-	3
Sala de Máquinas 2 (Danfoss) > Cámara 7 > Cam7 evap2 Esclavo Cantidad excesiva de desescarches	27/05/2026 15:27 h	-	2
Sala de Máquinas 1 (Cáms. 1,2,3 y 4) > Camara CP3A > Evaporador 6 Hielo en el evaporador	27/05/2026 15:12 h	-	1
Sala de Máquinas 1 (Cáms. 1,2,3 y 4) > Camara 1 > Cam1 evap3 Maestro Tiempo de desescarche excesivo	27/05/2026 06:33 h	-	3
Sala de Máquinas 2 (Danfoss) > Cámara 8 > Cam8 evap3 Esclavo Lectura de variables importantes constantes	27/05/2026 06:03 h	-	2

Figura 5.1: Pantalla da sección de eventos da plataforma Gradhoc.

Así, cando se detecta unha desviación relevante, esta pode ser incorporada á sección de eventos da plataforma, onde o persoal técnico pode consultar a información asociada e valorar a actuación correspondente. Na Figura 5.1 móstrase a actual pantalla de eventos que existe na plataforma.

Esta integración segue a mesma filosofía que outros desenvolvementos de Gradhoc, nos que a lóxica de detección ou avaliación dun algoritmo remata coa xeración dun evento interpretable polo usuario. A diferenza fundamental neste caso é que a activación non procede dunha regra heurística definida manualmente, senón dun modelo estatístico baseado no comportamento normal aprendido a partir dos datos históricos do propio activo.

Deste xeito, o fluxo completo do sistema pode resumirse como unha cadea que parte da lectura das series temporais, continúa co preprocesado e segmentación por estados, aplica o modelo kNN correspondente, compara o estatístico co limiar de referencia, calcula as contribucións das variables e, finalmente, activa un evento cando a desviación detectada é suficientemente significativa.

Desta forma a integración coa xeración de eventos permite, ademais, conectar directamente a análise estatística co fluxo real de mantemento predictivo da plataforma. Así, as anomalías detectadas polo motor poden transformarse en avisos operativos, facendo posible que os resultados do modelo sexan utilizados de forma práctica dentro do sistema de monitorización.

Capítulo 6

Conclusiones

Neste Traballo Fin de Máster estudouse a aplicación de técnicas estatísticas e de aprendizaxe automática para a detección de anomalías en dispositivos de instalacións frigoríficas industriais. O traballo partiu dunha necesidade práctica: reforzar os sistemas de mantemento preventivo e predictivo mediante metodoloxías capaces de aprender o comportamento normal dos equipos e sinalar desviacións potencialmente asociadas a fallos ou perdas de eficiencia.

Ao longo do traballo consideráronse dous enfoques principais. Por unha banda, empregouse un método baseado en k -veciños máis próximos, aplicado sobre as variables orixinais e adaptado, sempre que foi posible, aos distintos modos de funcionamento dos activos. Por outra banda, analizouse unha metodoloxía baseada na combinación de modelos XGBoost con gráficos de control EWMA ou MEWMA aplicados sobre os residuos do modelo. Deste xeito, comparouse unha aproximación baseada na distancia respecto ao funcionamento normal cunha aproximación baseada na modelización do comportamento esperado das variables e na monitorización estatística das desviacións.

Cómpre sinalar que a metodoloxía baseada en XGBoost e EWMA/MEWMA xa fora considerada previamente no contexto do motor de detección, polo que neste traballo non se analiza só como unha alternativa estatística, senón tamén como referencia fronte á que valorar unha solución máis operativa. Aínda que este enfoque presenta interese pola súa capacidade para modelizar o comportamento esperado das variables e detectar desviacións persistentes nos residuos, a súa posta en produción resulta máis custosa. En particular, require manter modelos predictivos, calcular residuos de forma continua e xestionar parámetros e estatísticos adicionais para cada activo ou configuración. Neste sentido, o método kNN constitúe unha alternativa máis sinxela, interpretable e escalable, ao comparar directamente cada nova observación co comportamento normal aprendido a partir dunha mostra de referencia.

En primeiro lugar, o estudo de simulación permitiu avaliar ambos os métodos nun escenario controlado, no que se coñecía a etiqueta real das observacións. Os resultados obtidos amosaron que as dúas metodoloxías son capaces de detectar unha proporción elevada das anomalías introducidas artificialmente. Non obstante, tamén se observaron diferenzas relevantes entre elas. O enfoque XGBoost e MEWMA presentou unha sensibilidade moi elevada, detectando practicamente todas as anomalías simuladas, pero xerou un número maior de falsas alarmas. Pola contra, o método kNN por modo mantivo unha sensibilidade alta e acadou mellores resultados en especificidade, F1-score e precisión balanceada. Por tanto, no escenario simulado, o kNN ofreceu un comportamento máis equilibrado entre a detección de anomalías e o control das falsas alarmas.

En segundo lugar, a aplicación a datos reais permitiu comprobar a utilidade práctica das metodoloxías propostas en situacións de distinta natureza. No caso da formación de xeo nun evaporador, ambos métodos identificaron desviacións coherentes cos períodos nos que a temperatura de fin de desescarche non presentaba o comportamento esperado. No caso da presenza de incondensables, detectáronse alteracións no comportamento multivariante do compresor, especialmente en períodos nos que as condicións de traballo se afastaban do funcionamento considerado normal. Finalmente, no fallo de bombeo de refrixerante, tanto o kNN como o EWMA sinalaron o intervalo problemático no que a

relación entre a temperatura da batería e a temperatura do aire se vía alterada pola falta de alimentación adecuada de refrixerante. Estes resultados mostran que o método kNN é capaz de identificar, tamén en datos reais, desviacións coherentes coas detectadas mediante EWMA ou MEWMA e coa interpretación física dos fallos analizados. Ademais, fronte aos gráficos EWMA e MEWMA, que incorporan memoria temporal e resultan especialmente útiles para detectar desviacións persistentes ou progresivas, o kNN ofrece unha interpretación máis directa baseada na proximidade entre rexistros e permite analizar a contribución das variables á anomalía detectada. Deste xeito, os casos prácticos apoian o seu uso como método estatístico para a detección de anomalías, ao combinar aplicabilidade práctica, sinxeleza e interpretabilidade nun contexto operativo.

Non obstante, o traballo presenta algunhas limitacións. A principal é a ausencia dun etiquetado exhaustivo nos datos reais, polo que a avaliación cuantitativa só puido realizarse no estudo de simulación e, nos casos prácticos, a validación apoiouse na interpretación física das variables e no coñecemento experto. Ademais, a calidade da detección depende da representatividade da mostra de adestramento e da correcta elección dos limiares e parámetros, aspectos que poden variar segundo o tipo de activo, a instalación e o nivel de sensibilidade desexado.

Como liñas futuras, será interesante continuar ampliando a validación dos métodos sobre un maior número de instalacións e tipos de fallo, co obxectivo de axustar mellor os limiares de detección e avaliar a robustez da metodoloxía en diferentes condicións de operación. Tamén resultará conveniente avanzar na incorporación automática e fiable dos modos de funcionamento dos activos, xa que esta información pode mellorar a comparación das observacións co seu patrón normal correspondente. Outra liña de traballo será profundar na combinación dos métodos estudados co coñecemento experto e coas regras heurísticas xa existentes, de forma que as deteccións estatísticas poidan actuar como apoio ou verificación dos eventos xerados pola plataforma. Finalmente, poderán explorarse mecanismos adicionais para xestionar a fiabilidade das alarmas e automatizar certas accións posteriores á detección, sempre que a natureza do evento e as condicións da instalación o permitan.

En conxunto, os resultados obtidos permiten concluír que o kNN constitúe un método estatístico axeitado para a detección de anomalías en dispositivos frigoríficos, especialmente cando se adapta aos modos de funcionamento dos activos e se combina con criterios de persistencia temporal. A súa utilidade non reside só no rendemento obtido fronte ás anomalías analizadas, senón tamén na súa sinxeleza, interpretabilidade e maior facilidade de integración nun sistema de monitorización industrial escalable. Aínda que a súa aplicación require unha calibración coidadosa e unha validación progresiva con novos casos reais, o traballo mostra que esta metodoloxía pode contribuír á mellora do mantemento predictivo, á redución de falsas alarmas e á detección temperá de fallos nas instalacións frigoríficas.

Bibliografía

- Adnan, N. A., Cheng, Y., Izadi, I., & Chen, T. (2013). Study of generalized delay-timers in alarm configuration. *Journal of Process Control*, *23*, 382–395.
- Aisy, R. R., Zulfa, L., Rahim, Y., & Ahsan, M. (2025). Residual XGBoost regression—Based individual moving range control chart for Gross Domestic Product growth monitoring. *PLOS One*. <https://doi.org/10.1371/journal.pone.0321660>
- Alfasanah, Z., Niam, M. Z. H., Wardiani, S., Ahsan, M., & Lee, M. H. (2025). Monitoring air quality index with EWMA and individual charts using XGBoost and SVR residuals. *MethodsX*, *14*, 103107. <https://doi.org/10.1016/j.mex.2024.103107>
- Angiulli, F., & Pizzuti, C. (2002). Fast outlier detection in high dimensional spaces. En *Principles of Data Mining and Knowledge Discovery* (Lecture Notes in Computer Science, Vol. 2431). Springer. https://doi.org/10.1007/3-540-45681-3_2
- Brodersen, K. H., Ong, C. S., Stephan, K. E., & Buhmann, J. M. (2010). The balanced accuracy and its posterior distribution. En *Proceedings of the 20th International Conference on Pattern Recognition* (pp. 3121–3124). <https://doi.org/10.1109/ICPR.2010.764>
- Chandola, V., Banerjee, A., & Kumar, V. (2007). *Anomaly detection: A survey*. Technical Report TR 07-017, Department of Computer Science and Engineering, University of Minnesota, Minneapolis.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. En *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794).
- Cofrico. (s. f.). *Expertos en refrigeración e climatización eficiente*. <https://www.cofrico.com/>
- Danfoss. (2024). *Electronic temperature control: Features and benefits*. Danfoss Cooling Solutions. <https://www.danfoss.com/en/products/dcs/electronic-controls/products/electronic-temperature-control/>
- De Maesschalck, R., Jouan-Rimbaud, D., & Massart, D. L. (2000). The Mahalanobis distance. *Chemometrics and Intelligent Laboratory Systems*, *50*, 1–18.
- Díaz Cao, M. (2023). *Técnicas estadísticas y herramientas de visualización aplicadas al Business Intelligence*. Trabajo Fin de Máster, Máster en Técnicas Estadísticas, Universidade da Coruña.
- Domínguez Basteiro, M. (2022). *Detector de fallos en maquinaria mediante Técnicas Estadísticas y Machine Learning*. Trabajo Fin de Máster, Máster en Técnicas Estadísticas, Universidade da Coruña.
- FastAPI. (s. f.). *FastAPI documentation*. <https://fastapi.tiangolo.com/>
- Git. (s. f.). *Git documentation*. <https://git-scm.com/doc>
- GitHub. (s. f.). *GitHub Docs*. <https://docs.github.com/>

- Gradhoc. (s. f.). *Gradhoc*. <https://gradhoc.com/es/>
- Grönholm, A. (2025). *Advanced Python Scheduler (APScheduler) documentation*. Read the Docs. <https://apscheduler.readthedocs.io/>
- Guo, J., Wang, X., & Li, Y. (2018). kNN based on probability density for fault detection in multimodal processes. *Journal of Chemometrics*, *32*, e3021.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2.^a ed.). Springer.
- He, Q. P., & Wang, J. (2007). Fault detection using the k-nearest neighbor rule for semiconductor manufacturing processes. *IEEE Transactions on Semiconductor Manufacturing*, *20*, 345–354.
- Inference. (2025). *Feature scaling in machine learning*. <https://inference.net/content/feature-scaling-in-machine-learning>. Consultado o 16 de marzo de 2026.
- Joblib Developers. (s. f.). *Joblib documentation*. <https://joblib.readthedocs.io/>
- Jolliffe, I. T. (2002). *Principal component analysis* (2.^a ed.). Springer. <https://doi.org/10.1007/b98835>
- Lepot, M., Aubin, J. B., & Clemens, F. H. L. R. (2017). Interpolation in time series: An introductory overview of existing methods, their performance criteria and uncertainty assessment. *Water*, *9*(10), 796. <https://doi.org/10.3390/w9100796>
- Lowry, C. A., Woodall, W. H., Champ, W. C., & Rigdon, S. E. (1992). A multivariate exponentially weighted moving average control chart. *Technometrics*, *34*(1), 46–52.
- Montgomery, D. C. (2019). *Introduction to statistical quality control* (8.^a ed.). John Wiley & Sons.
- NumPy Developers. (s. f.). *NumPy documentation*. <https://numpy.org/doc/>
- Pandas Developers. (s. f.). *Pandas documentation*. <https://pandas.pydata.org/docs/>
- Pydantic. (s. f.). *Pydantic documentation*. <https://docs.pydantic.dev/>
- Python Software Foundation. (s. f.). *Python documentation*. <https://docs.python.org/>
- Qin, S. J. (2003). Statistical process monitoring: Basics and beyond. *Journal of Chemometrics*, *17*, 480–502.
- RabbitMQ. (s. f.). *RabbitMQ documentation*. <https://www.rabbitmq.com/docs>
- Redis. (s. f.). *Redis documentation*. <https://redis.io/docs/latest/>
- Roberts, S. W. (1959). Control chart tests based on geometric moving averages. *Technometrics*, *1*(3), 239–250. <https://doi.org/10.2307/1266443>
- Romero Gómez, S. (2022). *Mantenimiento preventivo de instalaciones frigoríficas. IMAR0108* (2.^a ed.). IC Editorial. <https://elibro-net.ezbusc.usc.gal/es/lc/busc/titulos/221042>
- Scikit-learn Developers. (s. f.). *Scikit-learn documentation*. <https://scikit-learn.org/stable/>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, *45*(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Wang, G.-Z., Li, J., Hu, Y.-T., Li, Y., & Du, Z.-Y. (2019). Fault identification of chemical processes based on k-NN variable contribution and CNN data reconstruction methods. *Sensors*, *19*(4), 929. <https://doi.org/10.3390/s19040929>

- Yao, W., Li, D., & Gao, L. (2022). Fault detection and diagnosis using tree-based ensemble learning methods and multivariate control charts for centrifugal chillers. *Journal of Building Engineering*, *51*, 104243.
- Zhou, Z., Li, Z., Cai, Z., & Wang, P. (2019). Fault identification using fast k-nearest neighbor reconstruction. *Processes*, *7*(6), 340. <https://doi.org/10.3390/pr7060340>

Código empregado na simulación

Neste apéndice recóllese o código principal empregado para a simulación descrita no Capítulo 3. Non se inclúen as funcións auxiliares de representación gráfica nin a exportación de resultados, xa que non modifican a metodoloxía estatística aplicada.

```
1 # =====
2 # Código principal empregado na simulación
3 # kNN por estados vs XGBoost + MEWMA sobre residuos
4 # =====
5
6 import numpy as np
7 import pandas as pd
8
9 from sklearn.preprocessing import StandardScaler
10 from sklearn.neighbors import NearestNeighbors
11 from sklearn.metrics import (
12     confusion_matrix,
13     balanced_accuracy_score,
14     f1_score
15 )
16
17 from xgboost import XGBRegressor
18
19
20 # =====
21 # 1. Xeración dos datos simulados
22 # =====
23
24 variables = [
25     "presion_aspiracion",
26     "presion_descarga",
27     "presion_aceite",
28     "temperatura_descarga",
29     "temperatura_impulsion",
30     "temperatura_aceite"
31 ]
32
33
34 def xerar_secuencia_estados(n):
35     segmentos = [
36         (0, 420),
37         (1, 400),
38         (0, 430),
39         (1, 390),
40         (0, 450),
41         (1, 510)
42     ]
43
44     estados = []
45
46     while len(estados) < n:
47         for estado, lonxitude in segmentos:
48             estados.extend([estado] * lonxitude)
49
50             if len(estados) >= n:
51                 break
52
53     return np.array(estados[:n])
54
55
56 def xerar_variable_latente(estado, n, rng, anomala=False):
```

```

57     if not anomala:
58         if estado == 0:
59             centros = np.array([-2.5, 2.5])
60             probabilidades = np.array([0.55, 0.45])
61             desviacion = 0.18
62         else:
63             centros = np.array([-2.0, 2.0])
64             probabilidades = np.array([0.50, 0.50])
65             desviacion = 0.17
66
67         centro = rng.choice(centros, size=n, p=probabilidades)
68         return centro + rng.normal(0, desviacion, n)
69
70     n_ambiguas = int(0.10 * n)
71     n_claras = n - n_ambiguas
72
73     if estado == 0:
74         t_claras = rng.normal(0, 0.18, n_claras)
75         centros = np.array([-2.5, 2.5])
76         t_ambiguas = rng.choice(centros, n_ambiguas) + rng.normal(0, 0.22, n_ambiguas)
77     else:
78         t_claras = rng.normal(0, 0.16, n_claras)
79         centros = np.array([-2.0, 2.0])
80         t_ambiguas = rng.choice(centros, n_ambiguas) + rng.normal(0, 0.21, n_ambiguas)
81
82     t = np.concatenate([t_claras, t_ambiguas])
83     rng.shuffle(t)
84
85     return t
86
87
88 def xerar_valores(estado, t, rng, escala_ruido=1.0):
89     n = len(t)
90     X = np.zeros((n, 6))
91
92     if estado == 0:
93         X[:, 0] = 2.20 + 0.23 * t + rng.normal(0, 0.065 * escala_ruido, n)
94         X[:, 1] = 12.00 + 0.95 * np.cos(t) + rng.normal(0, 0.22 * escala_ruido, n)
95         X[:, 2] = 4.80 + 0.16 * t + rng.normal(0, 0.085 * escala_ruido, n)
96         X[:, 3] = 68.00 + 4.30 * np.sin(t) + rng.normal(0, 0.95 * escala_ruido, n)
97         X[:, 4] = -22.00 + 0.48 * t**2 + rng.normal(0, 0.30 * escala_ruido, n)
98         X[:, 5] = 45.00 + 2.60 * np.cos(1.2 * t) + rng.normal(0, 0.70 * escala_ruido, n)
99
100    else:
101        X[:, 0] = 2.80 + 0.17 * t + rng.normal(0, 0.080 * escala_ruido, n)
102        X[:, 1] = 10.80 + 0.80 * np.sin(t) + rng.normal(0, 0.26 * escala_ruido, n)
103        X[:, 2] = 5.30 + 0.11 * t + rng.normal(0, 0.100 * escala_ruido, n)
104        X[:, 3] = 74.00 + 3.80 * np.cos(t) + rng.normal(0, 1.05 * escala_ruido, n)
105        X[:, 4] = -10.00 + 0.42 * t**2 + rng.normal(0, 0.34 * escala_ruido, n)
106        X[:, 5] = 52.00 + 2.30 * np.sin(1.1 * t) + rng.normal(0, 0.80 * escala_ruido, n)
107
108    return X
109
110
111 def xerar_dados_normais(n, rng):
112     estados = xerar_secuencia_estados(n)
113     X = np.zeros((n, len(variables)))
114
115     for estado in np.unique(estados):
116         indices = np.where(estados == estado)[0]
117         t = xerar_variavel_latente(estado, len(indices), rng, anomala=False)
118         X[indices] = xerar_valores(estado, t, rng)
119
120     dados = pd.DataFrame(X, columns=variables)
121     dados["estado"] = estados
122
123     return dados
124
125
126 def simular_dados_industriais(
127     n_adestramento=3500,
128     n_test=2600,
129     semente=123
130 ):
131     rng = np.random.default_rng(semente)
132
133     dados_adestramento = xerar_dados_normais(n_adestramento, rng)

```

```

134 datos_test = xerar_datos_normais(n_test, rng)
135
136 datos_test["anomalia_real"] = 0
137
138 bloques = [
139     (160, 390, 0),
140     (900, 1140, 0),
141     (2180, 2430, 1)
142 ]
143
144 for inicio, fin, estado in bloques:
145     indices = np.arange(inicio, fin)
146     n_bloque = len(indices)
147
148     t = xerar_variable_latente(
149         estado=estado,
150         n=n_bloque,
151         rng=rng,
152         anomala=True
153     )
154
155     X_bloque = xerar_valores(
156         estado=estado,
157         t=t,
158         rng=rng,
159         escala_ruido=0.90
160     )
161
162     if inicio == 160:
163         X_bloque[:, 3] += rng.normal(1.55, 0.55, n_bloque)
164         X_bloque[:, 4] += rng.normal(0.50, 0.20, n_bloque)
165
166     elif inicio == 900:
167         X_bloque[:, 1] += rng.normal(0.42, 0.16, n_bloque)
168         X_bloque[:, 2] += rng.normal(-0.13, 0.05, n_bloque)
169         X_bloque[:, 5] += rng.normal(0.50, 0.22, n_bloque)
170
171     else:
172         X_bloque[:, 0] += rng.normal(-0.09, 0.04, n_bloque)
173         X_bloque[:, 3] += rng.normal(1.05, 0.38, n_bloque)
174         X_bloque[:, 5] += rng.normal(0.60, 0.25, n_bloque)
175
176     datos_test.loc[indices, variables] = X_bloque
177     datos_test.loc[indices, "anomalia_real"] = 1
178
179     return datos_adestramento, datos_test, variables
180
181
182 # =====
183 # 2. Detector kNN por estado
184 # =====
185
186 class DetectorKNNPorEstado:
187     def __init__(self, k=5, alpha=0.11):
188         self.k = k
189         self.alpha = alpha
190         self.modelos = {}
191
192     def fit(self, X, estados):
193         self.modelos = {}
194
195         for estado in np.unique(estados):
196             indices = estados == estado
197             X_estado = X[indices]
198
199             escalador = StandardScaler()
200             X_estado_escalado = escalador.fit_transform(X_estado)
201
202             n_vecinos = min(self.k, len(X_estado))
203
204             modelo = NearestNeighbors(
205                 n_neighbors=n_vecinos,
206                 metric="euclidean"
207             )
208
209             modelo.fit(X_estado_escalado)
210

```

```

211     distancias, _ = modelo.kneighbors(X_estado_escalado)
212     estatistico = np.mean(distancias**2, axis=1)
213
214     limiar = np.quantile(estatistico, 1 - self.alpha)
215
216     self.modelos[estado] = {
217         "escalador": escalador,
218         "modelo": modelo,
219         "limiar": limiar,
220         "n_vecinos": n_vecinos
221     }
222
223     return self
224
225     def predict(self, X, estados):
226         prediccion = np.zeros(len(X), dtype=int)
227         estatistico = np.zeros(len(X))
228         limiares = np.zeros(len(X))
229
230         for estado, obxecto in self.modelos.items():
231             indices = estados == estado
232
233             if indices.sum() == 0:
234                 continue
235
236             X_estado = obxecto["escalador"].transform(X[indices])
237
238             distancias, _ = obxecto["modelo"].kneighbors(
239                 X_estado,
240                 n_neighbors=obxecto["n_vecinos"]
241             )
242
243             estat_estado = np.mean(distancias**2, axis=1)
244             limiar = obxecto["limiar"]
245
246             estatistico[indices] = estat_estado
247             limiares[indices] = limiar
248             prediccion[indices] = (estat_estado > limiar).astype(int)
249
250         return prediccion, estatistico, limiares
251
252     # =====
253     # 3. Detector XGBoost + MEWMA sobre residuos
254     # =====
255
256     class DetectorXGBoostMEWMAResiduos:
257         def __init__(self, lam=0.015, int_sigma=5.5, semente=123):
258             self.lam = lam
259             self.int_sigma = int_sigma
260             self.semente = semente
261
262             self.variables = None
263             self.columna_estado = None
264             self.modelos = []
265             self.columnas_modelo = {}
266             self.matriz_cov = None
267             self.limiar = None
268
269         def _parametros_xgboost(self):
270             return {
271                 "n_estimators": 260,
272                 "max_depth": 3,
273                 "learning_rate": 0.030,
274                 "subsample": 0.98,
275                 "colsample_bytree": 0.98,
276                 "reg_lambda": 4.0,
277                 "objective": "reg:squarederror",
278                 "random_state": self.semente,
279                 "n_jobs": -1
280             }
281
282         def _crear_preditores(self, datos, variable_resposta, axuste=True):
283             preditores = [
284                 v for v in self.variables
285                 if v != variable_resposta
286             ]
287

```

```

288
289     X = datos[preditores + [self.columna_estado]].copy()
290     X[self.columna_estado] = X[self.columna_estado].astype(str)
291
292     X = pd.get_dummies(
293         X,
294         columns=[self.columna_estado],
295         drop_first=False
296     )
297
298     if axuste:
299         self.columnas_modelo[variable_resposta] = X.columns.tolist()
300     else:
301         columnas = self.columnas_modelo[variable_resposta]
302         X = X.reindex(columns=columnas, fill_value=0)
303
304     return X
305
306 def _calcular_residuos_adestramento(self, datos):
307     residuos = np.zeros((len(datos), len(self.variables)))
308     self.modelos = []
309
310     for j, variable in enumerate(self.variables):
311         X = self._crear_preditores(
312             datos,
313             variable_resposta=variable,
314             axuste=True
315         )
316
317         y = datos[variable].values
318
319         modelo = XGBRegressor(**self._parametros_xgboost())
320         modelo.fit(X, y)
321
322         prediccion = modelo.predict(X)
323         residuos[:, j] = y - prediccion
324
325         self.modelos.append({
326             "variable": variable,
327             "modelo": modelo
328         })
329
330     return pd.DataFrame(residuos, columns=self.variables)
331
332 def _calcular_residuos_novos(self, datos):
333     residuos = np.zeros((len(datos), len(self.variables)))
334
335     for j, obxecto in enumerate(self.modelos):
336         variable = obxecto["variable"]
337         modelo = obxecto["modelo"]
338
339         X = self._crear_preditores(
340             datos,
341             variable_resposta=variable,
342             axuste=False
343         )
344
345         y = datos[variable].values
346         prediccion = modelo.predict(X)
347
348         residuos[:, j] = y - prediccion
349
350     return pd.DataFrame(residuos, columns=self.variables)
351
352 def _calcular_estadistico_mewma(self, residuos):
353     n_variables = len(self.variables)
354     z = np.zeros(n_variables)
355     estadisticos = []
356
357     for i in range(len(residuos)):
358         x = residuos.iloc[i].values
359
360         z = self.lam * x + (1 - self.lam) * z
361
362         factor = (
363             self.lam / (2 - self.lam)
364         ) * (

```

```

365         1 - (1 - self.lam) ** (2 * (i + 1))
366     )
367
368     matriz_cov_z = factor * self.matriz_cov
369
370     estatistico = z.T @ np.linalg.pinv(matriz_cov_z) @ z
371     estatisticos.append(estatistico)
372
373     return np.array(estatisticos)
374
375     def fit(self, datos, variables, columna_estado="estado"):
376         self.variables = variables
377         self.columna_estado = columna_estado
378
379         residuos = self._calcular_residuos_adestramento(datos)
380
381         self.matriz_cov = np.array(residuos.cov())
382
383         estatistico = self._calcular_estatistico_mewma(residuos)
384
385         self.limiar = (
386             estatistico.mean()
387             + self.int_sigma * estatistico.std()
388         )
389
390         return self
391
392     def predict(self, datos):
393         residuos = self._calcular_residuos_novos(datos)
394
395         estatistico = self._calcular_estatistico_mewma(residuos)
396
397         prediccion = (estatistico > self.limiar).astype(int)
398
399         return prediccion, estatistico
400
401
402 # =====
403 # 4. Metricas empregadas na comparacion
404 # =====
405
406 def calcular_metricas(y_real, y_predito, metodo):
407     tn, fp, fn, tp = confusion_matrix(
408         y_real,
409         y_predito
410     ).ravel()
411
412     sensibilidad = tp / (tp + fn)
413     especificidade = tn / (tn + fp)
414     taxa_falsas_alarmas = fp / (fp + tn)
415
416     return {
417         "metodo": metodo,
418         "TP": tp,
419         "TN": tn,
420         "FP": fp,
421         "FN": fn,
422         "sensibilidad": sensibilidad,
423         "especificidade": especificidade,
424         "taxa_falsas_alarmas": taxa_falsas_alarmas,
425         "f1_score": f1_score(y_real, y_predito),
426         "balanced_accuracy": balanced_accuracy_score(y_real, y_predito)
427     }
428
429
430 # =====
431 # 5. Execucion dunha simulacion
432 # =====
433
434 def executar_simulacion(
435     semente=123,
436     n_adestramento=3500,
437     n_test=2600,
438     k=5,
439     alpha_knn=0.11,
440     lam=0.015,
441     int_sigma=5.5

```

```

442 ):
443     datos_adestramento, datos_test, variables = simular_datos_industriais(
444         n_adestramento=n_adestramento,
445         n_test=n_test,
446         semente=sememente
447     )
448
449     y_real = datos_test["anomalia_real"].values
450
451     # kNN por estado.
452     detector_knn = DetectorKNNPorEstado(
453         k=k,
454         alpha=alpha_knn
455     )
456
457     detector_knn.fit(
458         datos_adestramento[variables].values,
459         datos_adestramento["estado"].values
460     )
461
462     pred_knn, estat_knn, limiar_knn = detector_knn.predict(
463         datos_test[variables].values,
464         datos_test["estado"].values
465     )
466
467     # XGBoost + MEWMA.
468     detector_mewma = DetectorXGBoostMEWMAResiduos(
469         lam=lam,
470         int_sigma=int_sigma,
471         semente=sememente
472     )
473
474     detector_mewma.fit(
475         datos_adestramento,
476         variables=variables,
477         columna_estado="estado"
478     )
479
480     pred_mewma, estat_mewma = detector_mewma.predict(datos_test)
481
482     resultados = pd.DataFrame([
483         calcular_metricas(
484             y_real,
485             pred_knn,
486             "kNN por estado"
487         ),
488         calcular_metricas(
489             y_real,
490             pred_mewma,
491             "XGBoost + MEWMA"
492         )
493     ])
494
495     datos_test = datos_test.copy()
496
497     datos_test["pred_knn"] = pred_knn
498     datos_test["pred_mewma"] = pred_mewma
499     datos_test["estadistico_knn"] = estat_knn
500     datos_test["estadistico_mewma"] = estat_mewma
501     datos_test["limiar_knn"] = limiar_knn
502     datos_test["limiar_mewma"] = detector_mewma.limiar
503
504     return resultados, datos_test
505
506
507 # =====
508 # 6. Exemplo de uso
509 # =====
510
511 if __name__ == "__main__":
512
513     resultados, datos_test = executar_simulacion(
514         semente=123,
515         n_adestramento=3500,
516         n_test=2600,
517         k=5,
518         alpha_knn=0.11,

```

```
519     lam=0.015,  
520     int_sigma=5.5  
521 )  
522   
523 print(resultados.round(4).to_string(index=False))
```

Código 1: Código principal empregado na simulación.