

“Como dar sentido al no sentido” en el proyecto europeo ISENSE y su aplicación al diagnóstico cognitivo de fallos de redes de agua

Joseba Quevedo

Departamento de Ingeniería de Sistemas y Automática, Universitat Politècnica de Catalunya, Campus de Terrassa, Rambla S. Nebridi, 10 08222 Terrassa (Barcelona, España)

Resumen

La misión del proyecto europeo “ISense: make sense to non sense” recientemente concluido ha sido el desarrollo de métodos inteligentes de procesamiento de datos para el análisis y la interpretación de los datos de tal manera que los fallos en complejos sistemas se detecten, se aislen y se identifiquen tan pronto como sea posible, y permitan tomar futuras decisiones o acciones correctoras que aseguren la integridad, estabilidad y funcionamiento seguro de los sistemas en fallo.

Palabras Clave:

Diagnóstico cognitivo de fallos, Modelos temporales y espaciales, Validación de datos, Redes de agua..

1. Introducción

La sociedad moderna se basa en la disponibilidad y buen funcionamiento de los sistemas de ingeniería complejos. Los ejemplos incluyen sistemas eléctricos de potencia, redes de distribuciones de agua, procesos de fabricación, sistemas de transporte, sistemas robóticos, edificios inteligentes,... La aparición de sistemas integrados en red de sensores / actuadores ha hecho posible el desarrollo de sistemas de vigilancia y control de aplicaciones sofisticadas, donde un gran cantidad de datos en tiempo real sobre el entorno se recoge y se procesa para activar los actuadores apropiados y alcanzar los objetivos de control deseados. Dependiendo de la aplicación, estos datos pueden tener diferentes características: multi-dimensional, multi-escala y distribuida espacialmente. Por otra parte, los valores de datos pueden ser influenciados por variables controladas, así como por factores ambientales externos. Sin embargo, en muchos casos los datos recogidos pueden no tener mucho sentido. Por ejemplo, en una aplicación de un edificio inteligente, el sensor de temperatura puede registrar rápidamente un aumento de la temperatura, lo que indica posiblemente un incendio, mientras que el detector de humo no ve nada. ¿Qué hace el sistema? Para los humanos, la decisión puede ser fácil porque tenemos la información sensorial redundante que somos capaces de procesar en tiempo real y evaluar la situación. Además, tenemos muy buena confianza en el estado de nuestros órganos sensoriales. Sin embargo, para las máquinas la decisión no es tan fácil.

En general, la existencia de información redundante está limitada por el costo que supone y, además, el estado de los sensores y actuadores no siempre es conocida y varios componentes pueden ir mal.



Figura 1. El proyecto iSense analiza e interpreta datos coherentes.

Por ejemplo, algunas mediciones pueden no llegar por problemas de comunicaciones, el funcionamiento del sensor puede deteriorarse debido al envejecimiento del mismo o por condiciones ambientales extremas, puede haber derivas en los sensores, etc ... En algunos casos, los datos procedentes de diferentes sensores (o actuadores), de la misma unidad (por ejemplo, con diferentes resoluciones) o que residen en una red de sensores, pueden llegar a ser inconsistentes. Al mismo tiempo, el medio ambiente puede ser objeto de fenómenos

transitorios y la electrónica, por ejemplo, en la etapa de acondicionamiento de la señal, es propenso a fallos derivas y "offsets". Este tipo de problemas, lo que generará son datos "sin sentido" y en sistemas realimentados pueden provocar el resultado de algunos fallos que se propagan con la consiguiente parada o avería del sistema completo, lo que puede acarrear pérdidas económicas cuantiosas o incluso un peligro real para su entorno humano y social.

2. Descripción general del proyecto ISENSE

El proyecto ISENSE desarrollado entre 2011 y 2013 coordinado por el profesor Marios Polycarpou de la Universidad de Chipre y con la participación de grupos investigadores de la Universidad Politécnica de Milán, La Universidad de Birmingham, la Universidad Politécnica de Cataluña y la empresa italiana ST microelectrónica presentó las conclusiones finales de su proyecto en el pasado mes de febrero y que fueron evaluadas muy positivamente por los expertos de la UE. Las actividades del proyecto se organizaron en los siguientes paquetes de trabajo:

- WP1 Especificación y Arquitectura del sistema
- WP2 Diagnóstico cognitivo de fallos
- WP3 Adaptación y Aprendizaje
- WP4 Tolerancia a Fallos de control
- WP5 Integración, validación y evaluación de la Plataforma iSense

• Los objetivos del proyecto iSense se pueden detallar a través de los siguientes objetivos científicos y tecnológicos:

1 Desarrollar una formulación rigurosa para el diagnóstico de fallos cognitivos y problemas de control de fallos tolerantes. La formulación desarrollada para el diagnóstico de fallos cognitivos y control tolerante a fallos especifica las características del sistema para facilitar el desarrollo de una base para el diseño de una nueva clase de algoritmos de diagnóstico de fallas. Una categorización de los posibles modelos de fallos se ha formulado, tanto en términos de sus propiedades funcionales, y también en términos de su evolución en el tiempo. Se ha definido un tipo de arquitecturas de sistemas para el diagnóstico de fallos cognitivos y control tolerante a fallos, lo que ha facilitado el diseño y la aplicación de la Plataforma iSense.

2 Diseñar esquemas cognitivos de diagnóstico de fallos que se pueden aplicar de manera efectiva para aplicaciones de monitorización y control de entornos distribuidos inciertos. El diagnóstico cognitivo de fallos es un nuevo enfoque para el

diagnóstico de fallos autónomo que emplea métodos cognitivos y de aprendizaje para mejorar el rendimiento diagnóstico de fallo y hacer que el sistema sea más adaptable y robusto. El uso de métodos de diagnóstico de fallos cognitivos se vuelve más crucial ya que se requieren sistemas de ingeniería de percibir e interactuar con los entornos más estructurados. El marco desarrollado para el diagnóstico de fallos cognitivos se ha logrado a través del diseño de la detección, el aislamiento de fallos y esquemas de identificación de fallos. Por último, se analizan las propiedades de prestaciones de los planes de diagnóstico de fallos cognitivos diseñados.

3 . Desarrollar un conjunto de algoritmos de adaptación y de aprendizaje que se pueden incorporar en el diagnóstico de fallos cognitivos y de fallo esquemas de control tolerantes. El uso de la adaptación y el aprendizaje tiene como objetivo descubrir y explotar las relaciones espacio-temporales que existen en los datos recogidos. Estas relaciones, que se perfeccionan en línea durante el funcionamiento del sistema de sensores inteligentes, mejoran la robustez y tolerancia a eventos de fallos y otras situaciones de campo inesperadas. El aprendizaje con redes neuronales, los métodos de clasificación de adaptación y planes de sensores / actuadores virtuales se han desarrollado en el contexto del diagnóstico cognitivos de fallos.

4 . Investigar el diseño y evaluación de los esquemas de control de tolerancia a fallos. Tan importante es investigar en la detección de fallos y la identificación de determinar la presencia y naturaleza de un fallo, como en última instancia, es de fundamental importancia poder utilizar este conocimiento para la toma de decisiones y adaptar el control del sistema en diversos escenarios de fallos para evitar la propagación de fallos . El control tolerante a fallos se refiere a sistemas de control realimentados que están diseñados para soportar la aparición imprevista de fallos salvaguardando la operación y la seguridad del sistema. Arquitecturas de control pasivas y activas con tolerancia a fallos han sido propuestas y se han examinado las propiedades de estabilidad y convergencia de los esquemas de control de tolerancia a fallos desarrollados.

5. Integrar los diversos componentes y construir un prototipo de sistema para la plataforma iSense que permita demostrar su eficiencia en aplicaciones reales. La eficiencia de la plataforma iSense ha sido validada en cuatro aplicaciones: en una red compleja de agua, en una red de sensores del medio ambiente, en un robot móvil y en un simulador de un edificio inteligente bajo una amplia gama de escenarios de fallos. La mejora en la tolerancia a fallos lograda por el uso de la Plataforma iSense ha sido evaluada, y se han identificado las limitaciones existentes para lograr el diagnóstico de fallos cognitivos y control tolerante a fallos.

3. Diagnóstico basado en aprendizaje de fallos en redes de agua

Como ejemplo ilustrativo desarrollado en este proyecto, se propone un enfoque integrado de la validación de datos / reconstrucción y el diagnóstico de fallos en redes de transporte de agua potable que está detallado en Quevedo (2014). La metodología propuesta se ha implementado en dos etapas. En la primera etapa de fallos de comunicación del sensor se detectan y corrigen, a fin de facilitar un conjunto de datos fiable para llevar a cabo el diagnóstico de fallos del sistema en la segunda etapa. Por un lado, la validación del sensor y la reconstrucción se basan en el uso combinado de modelos de series espaciales y temporales. Los modelos espaciales se aprovechan del balance de masa o relación entre diferentes variables en el sistema, mientras que los modelos de series de tiempo se aprovechan de la redundancia temporal de las variables medidas por medio de modelos Holt Winters (Quevedo, 2014). Por otra parte, el diagnóstico de fallos se basa en el enfoque de aprendizaje - en - modelo de espacio que se implementa mediante el ajuste de una serie de modelos utilizando una serie de segmentos de señal seleccionados con una ventana deslizante. De esta manera, cada segmento de señal puede ser representada por un modelo. Para medir rigurosamente la ‘distancia’ entre los modelos, la distancia en el espacio modelo definido. El enfoque de depósito de la computación determinista es usar la aproximación de un modelo con la dinámica de entrada-salida que explota las correlaciones espacio-temporales existentes en los datos originales. Por último, el enfoque propuesto se ha aplicado con éxito a la red de agua de Barcelona.

3.1. Validación y reconstrucción de datos de la red de agua

3.1.a. Metodología para la validación de datos

La validación de datos consiste en capturar los datos horarios de la base de datos operacional del sistema de telecontrol que permiten conocer el estado de la red (principalmente caudalímetros), de forma periódica (una vez al día) o mediante petición expresa del operador del sistema de telecontrol, analizar con diferentes niveles de test todos los datos del intervalo en cuestión y, del resultado obtenido, etiquetar los datos como datos válidos especificando los tests que han superado o no válidos especificando el test de validación que no han superado y almacenarlos en la misma base de datos operativa del sistema de telecontrol.

El conjunto de test que deben pasar cada uno de los datos horarios del estado de la red está inspirado en los niveles de calidad de datos de las estaciones meteorológicas automáticas definidas en la norma (UNE 500540, 2004).

Secuencia de tests de validación de datos

- Nivel 0: Validación de que no ha habido durante este periodo de tiempo ningún fallo de comunicación. Se comprueba que si no ha llegado el dato es porque no ha habido cambio del valor de medida utilizando el

“polling” periódico que existe entre el SCADA y cada estación remota conectadas a los instrumentos de campo.

- Nivel 1: Validación de los datos según sus límites máximos y mínimos. Se aplicarán los límites que sean más restrictivos (físicos o instrumentales). Cualquier dato fuera de los límites establecidos se considerará como un dato no válido.

- Nivel 2: Validación de la coherencia temporal del dato. En este nivel se compara la tendencia de la medida, calculando la diferencia entre dos datos consecutivos separados por una hora. Si la diferencia excede un valor prefijado, diferente para cada medida de caudal, se considera que el dato es no válido y no supera este test.

- Nivel 3: Validación de la coherencia interna de los datos. En este nivel de validación se tendrán en cuenta las relaciones físicas que existen entre diversas medidas efectuadas en la misma estación y en el mismo instante de tiempo. Por ejemplo: se compara si existe una correlación entre las medidas de caudal y las aperturas de las válvulas que están situadas en la misma tubería.

- Nivel 4: Validación de la coherencia temporal de la serie. Se calculará una serie temporal de cada variable física que será ajustada en tiempo real a medida que se reciban nuevos datos y se olviden datos anteriores y se comparará la predicción a una hora a partir de la serie temporal con el dato leído, si esta diferencia es superior a unos umbrales prefijados, el dato se considera inválido.

- Nivel 5: Validación de la coherencia espacial de los datos. Los valores de una misma variable medidos en el mismo tiempo en estaciones correlacionadas no pueden diferir demasiado las unas de las otras. Para contrastarlas se construirán modelos espaciales que permiten en una red de transporte saber si hay coherencia entre caudalímetros separados físicamente pero que miden el mismo caudal.

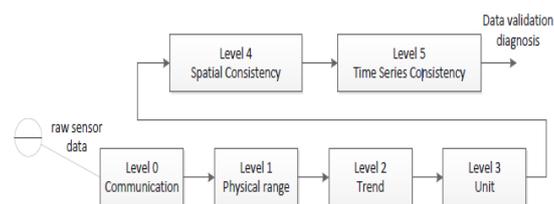


Figura 1. Secuencia de tests para la validación de datos

3.1.b. Reposición de datos

La reposición de datos erróneos se lleva a cabo estimando sus valores con los modelos desarrollados en el nivel 4 (serie temporal) y en el nivel 5 (modelo espacial) y, en particular, se lleva a cabo con el modelo que mejor atina a predecir los valores reales sin fallo. Por ejemplo, si el caudalímetro no supera el nivel 4, se repone el valor no válido con el valor predicho por la serie temporal (nivel 4) si este modelo tiene el mejor índice de predicción de mínimos cuadrados (MSE) en instantes anteriores sin fallo, sino se predice con el modelo espacial (nivel 5).

Sin embargo, si los datos de dos caudalímetros interconectados no superan el nivel 5 de la coherencia espacial antes de reponer los datos, se debe diagnosticar cuál de los dos

datos es el no válido y esto se realiza analizando el nivel 4 en sus series temporales. Si uno de los datos es incoherente en el nivel 4 de su serie temporal, entonces este dato es el no válido, mientras que si el otro supera el nivel 4 de su serie temporal, entonces significa que este último dato es coherente y será útil para estimar con el modelo padre-hijo el dato no válido anterior, tal como se muestra en (J. Blanch, 2009; Quevedo, 2010b y 2012)

4. Resultados en la red de agua de Barcelona

La red de agua de Barcelona que se ha utilizado en el proyecto iSense como caso de estudio subministra agua a cerca de tres millones de consumidores, que se distribuyen en 23 municipios diferentes con una superficie de 424 Km². El agua suministrada se puede extraer tanto de fuentes superficiales como subterráneas, siendo la proveniente del rio Ter (fuente superficial) y Llobregat (tanto superficial como fuente subterránea) las más importantes en términos de capacidad y uso. El agua proveniente de estos fuentes se lleva a cabo a través de aproximadamente 4.645 kilómetros de tuberías a 218 demanda diferentes sectores (DMA) con cerca de 400 puntos de control instalados. Actualmente, el sistema de información de Barcelona recibe datos en tiempo real recogidos por 200 puntos de control, medidores principalmente de caudal y algunos sensores de presión (Quevedo, 2010). La mayoría de estos puntos de control metro se instalan en el punto de suministro único de la DMA, por lo que su medición es muy representativa de toda la demanda de agua DMA.

En resumen, toda la red de transporte de Barcelona sigue el modelo por tanques de almacenamiento 63, 7 fuentes subterráneas, 3 fuentes superficiales, 79 bombas, 50 válvulas, 18 y 88 nodos demandas. En la figura 2, una representación conceptual de toda la red mediante sus elementos constitutivos se representa.

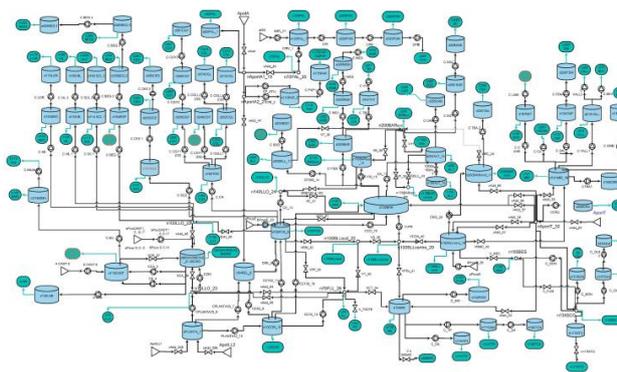


Figura 2. Red de transporte de agua de Barcelona

Para ilustrar las metodologías propuestas en este trabajo, una parte de la red de agua de Barcelona que incluye un subsistema, conocido como el sector Orioles (figura 3).

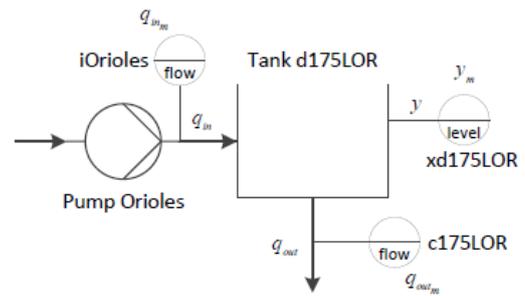


Figura 3. Sector Orioles

En esta sección se presentan resultados de la aplicación de la metodología cuando se produce un error de comunicaciones en el sensor que mide el caudal de entrada iOrioles y en el sensor que mide la demanda c175LOR con una duración de 2 días en o casos. Los datos del mes anterior al fallo de comunicaciones se han utilizado para la formación de modelo (tanto espacial como temporal, como se describe en la Sección 3). La validación y algoritmos de reconstrucción se han implementado de manera on-line, lo que es de suma importancia para un método que se aplica en un sistema en tiempo real.

Cuando se produce el fallo del Nivel 0 se notifica un fallo de comunicación y el proceso de reconstrucción de datos se activa. La reconstrucción se realiza a través de modelos espaciales o modelos temporales, en función de la calidad predictiva del modelo en instantes anteriores sin fallo, tal como se describe en la sección anterior.

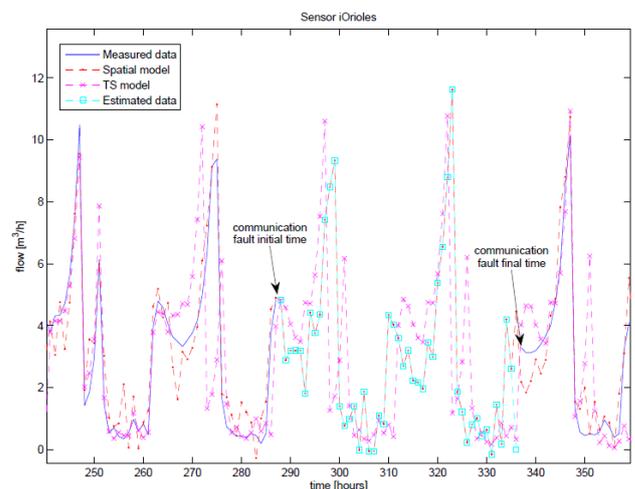


Figura 4. Reconstrucción con el modelo espacial del sensor iOrioles por fallo de comunicaciones

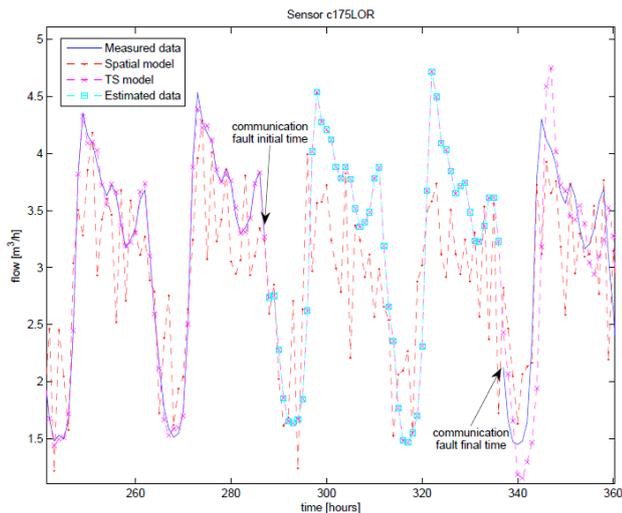


Figura 5. Reconstrucción de los datos del sensor de demanda c175LOR con el modelo temporal

5. Conclusiones

Se presenta un proyecto interesante denominado iSense que analiza e interpreta datos de sistemas dinámicos mediante técnicas cognitivas que es de gran interés para procesos complejos donde se producen fallos no previstos de forma habitual y deben ser gestionados para que los procesos continúen funcionando tolerantes a fallos. Este ha sido el objetivo principal del proyecto europeo iSense que ha finalizado con gran éxito.

Agradecimientos

Este artículo ha podido realizarse gracias al soporte del 7º Programa Marco de la Unión Europea en el proyecto iSense ref. INSFO-ICT-270428.

Referencias

Blanch J., J.; Puig, V.; Saludes, J.; Quevedo J, 2009. ARIMA Models for Data Consistency of Flowmeters in Water Distribution Networks". 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes. pp. 480 – 485.

Quevedo J, H. Chen, M.A. Cuguero, P. Tino, V. Puig, D. García, X. Yao, R. Sarrate, 2014. Combining Learning Fault Diagnosis in Model Space Approach with Data Validation/Reconstruction Prefilter in Critical Infrastructure Systems: Application to the Barcelona Water Network", Engineering Applications of Artificial Intelligence Journal, vol. 30 pp. 18–29

Quevedo J., V. Puig, G. Cembrano, J. Blanch, J. Aguilar, D. Saporta, G. Benito, M. Hedro, A. Molina, 2010. Validation and reconstruction of flowmeter data in the Barcelona water distribution network, Control Engineering Practice 18 (6) 640-651.

Quevedo J ; Pascual, J.; Puig, V.; Saludes, J.; Espin, S.; Roquet, J. 2012. Data validation and reconstruction of flowmeters to provide the annual efficiency of ATLL transport water network in Catalonia. New Developments in IT & Water. Amsterdam, Holanda.

Quevedo J., J.; Blanch, J.; Puig, V.; Saludes, J.; Espin, S.; Roquet, J. 2010b "Methodology of a data validation and reconstruction tool to improve the reliability of the water network supervision", Water Loss Conference 2010, Sao Paulo, Brasil.

UNE, 2004. Redes de estaciones meteorológicas automáticas: directrices para la validación de registros meteorológicos procedentes de redes de estaciones automáticas: validación en tiempo real". AENOR UNE 500540.