




XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Sensor virtual de caudal basado en técnicas de deep learning

Rodríguez-Ossorio, J.R.^{a,*}, González-Herbón, R.^a, González-Mateos, G.^a, Morán, A.^a, Prada, M. A.^a, Díaz, I.^b, Domínguez, M.^a

^a Grupo de investigación en Supervisión, Control y Automatización de Procesos Industriales (SUPPRESS), Esc. de Ing. Industrial e Informática, Universidad de León, Campus de Vegazana s/n, 24007, León, Spain.

^b Departamento de Ingeniería Eléctrica, Electrónica, de Comunicaciones y de Sistemas, Universidad de Oviedo, Edif. Departmental 2, Campus de Viesques s/n, Gijón 33204 Spain.

To cite this article: Rodríguez-Ossorio, J.R., González-Herbón, R., González-Mateos, G., Morán, A., Prada, M. A., Díaz, I., Domínguez, M. 2022. Flow virtual sensor based on deep learning techniques. XVII Simposio CEA de Control Inteligente.

Resumen

En el contexto de la digitalización de la industria, los sensores virtuales resultan muy útiles tanto para construir gemelos digitales, que permiten simular comportamientos que ayudan a optimizar el proceso productivo y prevenir errores, como para ser utilizados en las situaciones en las que un sensor real es muy costoso o directamente no puede ser instalado. En este artículo se propone un método para implementar sensores virtuales utilizando tres de las técnicas de deep learning más comunes: redes convolucionales, redes neuronales densas y redes recurrentes. El método se ha utilizado para construir un sensor virtual de caudal en una maqueta de control de procesos que dispone de instrumentación industrial real.

Palabras clave: Sensor virtual, Deep learning, LSTM, Digitalización, Industria 4.0.

Flow virtual sensor based on deep learning techniques

Abstract

In the context of industry digitalization, virtual sensors are very useful both to develop digital twins, which simulate behaviors that help us to optimize the process and prevent faults, such as to be used on the cases where a real sensor is very expensive or cannot be installed. In this paper, it is proposed a method to develop virtual sensors using three of the most common deep learning techniques: convolutional networks, dense neural networks and recurrent neural networks. The method has been used to develop a flow virtual sensor for a pilot plant that has real industrial instrumentation.

Keywords: Virtual sensor, Deep learning, LSTM, Digitalization, Industry 4.0

1. Introducción

En los últimos años ha surgido un nuevo modelo de producción industrial basado en la digitalización de la industria. Esta digitalización combina los últimos avances en el campo de la automatización industrial (OT) con las tecnologías de la información (IT) (Xu et al., 2018). La integración de ambos campos supone un reto tecnológico que se extiende a todos los niveles de la planta, rompiendo con las estructuras tradicionales, y logra la vinculación del mundo físico al virtual.

El empleo de simulaciones de entornos industriales se ha convertido en un aspecto clave. Los denominados gemelos digitales permiten operar con un sistema virtual de la misma manera que si se hiciera con el sistema real, alcanzando la convergencia entre procesos virtuales y físicos con sus correspondientes datos vinculados (Tao et al., 2018). Las versiones virtuales de los sistemas industriales reales permiten modificar parámetros que, más adelante, ayudan a predecir el comportamiento del sistema, optimizar el proceso productivo y prevenir errores (Babiceanu and Seker, 2016).

* Autor para correspondencia: jrodre@unileon.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

Para que el comportamiento del gemelo digital se asemeje al del sistema real es imprescindible que los modelos de las partes que lo componen sean lo más precisos posibles. En el caso de los sensores, los modelos virtuales permiten predecir u obtener el valor de una determinada variable del sistema a partir de la medición de los datos de otras variables relacionadas. Además, estos sensores virtuales son de suma utilidad en situaciones donde un sensor real es muy costoso o directamente no puede ser instalado (Alonso et al., 2019). Estos modelos se pueden desarrollar, tanto de una forma básica, teniendo en cuenta estados ideales del sistema objetivo, como más avanzada, empleando datos más completos que abarcan diferentes situaciones que pueden ocurrir en el proceso real (Kadlec et al., 2009).

A partir de los datos obtenidos del sistema real es posible recurrir a diferentes métodos para predecir la variable deseada, desde modelos matemáticos simples hasta técnicas más sofisticadas, como las basadas en *deep learning*, que pueden aportar una mayor precisión que otras aproximaciones. Esta última opción es la empleada en el caso de estudio del presente documento, tomando como punto de partida una planta piloto industrial con instrumentación real, que representa un proceso industrial genérico con un fluido circulando entre dos tanques situados a distintas alturas. Para este proceso se ha implementado un sensor virtual de caudal utilizando diferentes técnicas de *deep learning*.

El presente documento se estructura de la siguiente forma: en el apartado 2 se hace una introducción sobre el uso de sensores virtuales en la industria y se analizan algunos métodos para su implementación. A continuación, en el apartado 3, se describe el método propuesto en este artículo para desarrollar un sensor virtual de caudal. En el apartado 4 se describen los experimentos realizados y los resultados alcanzados. Finalmente, el documento termina con el apartado 5 en el que se explican las conclusiones y posibles líneas futuras de trabajo.

2. Estado del arte

Los sensores virtuales son, en esencia, aplicaciones software basadas en modelos matemáticos que permiten predecir u obtener el valor de determinadas variables del sistema a partir de la medición de otras variables relacionadas (Li et al., 2011). Por este motivo, los sensores virtuales son sumamente útiles en situaciones en las que un sensor físico real que puede medir la variable deseada es costoso, impreciso o se encuentra temporalmente fuera de servicio. Además, este tipo de sensores resultan más económicos que otras implementaciones, no son invasivos ni alteran el proceso a estudiar, y no requieren realizar modificación alguna en el sistema (McDonald and Zmeureanu, 2015).

Junto con las características descritas, los sensores virtuales son muy flexibles y pueden ser reconfigurados con relativa facilidad, mientras que los sensores físicos solo pueden cambiarse con una intervención en el sistema que conllevará una consecuente interrupción del proceso (Martin et al., 2021). Además, los sensores virtuales pueden servir

también para corregir ciertas imperfecciones de los sensores reales, como el ruido de las señales o la confianza en que los valores obtenidos sean precisos, teniendo en cuenta que los sensores virtuales basan su medida en las de varios instrumentos distintos. Asimismo, es también conocido que los sensores físicos se pueden hacer más inexactos e imprecisos con el paso del tiempo, debido a su desgaste o a la acumulación de suciedad, defecto que puede ser compensado o amortiguado con el uso de sensores virtuales (Tegen et al., 2019).

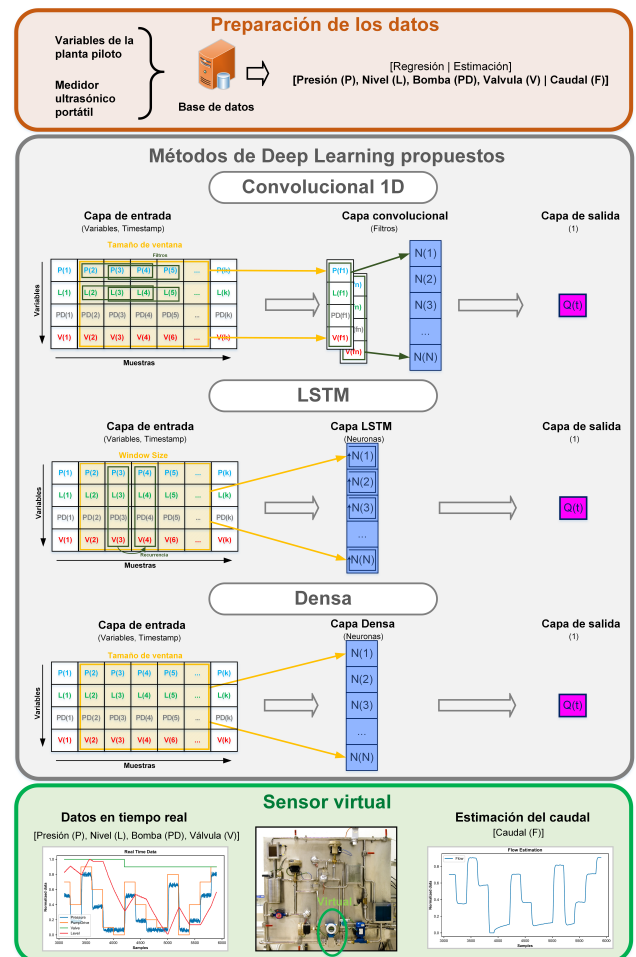


Figura 1: Metodología aplicada.

Existen diferentes metodologías para el desarrollo de sensores virtuales, y de su implementación dependerá el modo en el que estos modelos se comporten con respecto a la variable real medida. Una forma de implementación se trata del análisis estadístico multivariable donde existe alguna característica estadística constante (Abeykoon, 2018). Otra manera de implementación es con los observadores basados en datos e identificación que se basan en la existencia de los estados de sistema. También existen los modelos de primer principio cuya condición de partida es la de modelar el sistema a través de los principios matemáticos y físicos que lo definen (Mattera et al., 2018). Otro método es el filtrado, como es el ejemplo de los filtros de Kalman (Yang et al., 2019), que estiman las variables de estado que definen la dinámica del sistema. Por último,

también están las técnicas de *machine learning*, especialmente las técnicas de *deep learning*, que emplean diferentes estructuras como las redes neuronales densas, las redes LSTM o redes convolucionales, entre otras (Jiang et al., 2021; Márquez-Vera et al., 2021).

Los sensores virtuales están presentes en diferentes ámbitos de la automatización. Más concretamente, en el ámbito de la automatización industrial existen numerosas implementaciones de sensores virtuales, empleados para medir variables como el flujo volumétrico de fluidos no newtonianos (Chhantyal et al., 2018), el pH de un fluido (Thürlimann et al., 2018) o la concentración de ácidos grasos volátiles (Nair et al., 2019). Otro ámbito es el de la automatización de edificios donde uno de los usos es para la mejora en términos de monitorización, diagnóstico y optimización (Li et al., 2011).

3. Descripción del método

Como ya se ha mencionado anteriormente, para el caso de estudio del presente documento se ha optado por emplear aproximaciones de *deep learning* a la hora de desarrollar el sensor de caudal propuesto. En la Figura 1 puede verse una representación esquemática del método empleado.

El proceso comienza con la preparación de los datos de partida, obtenidos de los sensores y actuadores de planta piloto industrial que se explica con detalle en el apartado 4, junto con un caudalímetro portátil conectado externamente. Las variables leídas son: presión, nivel, potencia de la bomba, porcentaje de apertura de la válvula y caudal. Estas variables se almacenan en una base de datos y se normalizan antes de aplicar los modelos de aprendizaje seleccionados.

Más concretamente, los datos disponibles se tratarán con tres aproximaciones de *deep learning* distintas: una red neuronal convolucional, una red neuronal LSTM y una red neuronal densa.

La primera de ellas es una red neuronal convolucional con filtros de dimensión $1 \times n$ que se va desplazando en el eje de las muestras temporales. En el caso de la red LSTM (*Long short-term Memory*) se selecciona también una ventana de muestras sobre el eje temporal. Este tipo de red aplica una cierta recurrencia de forma que se tienen en cuenta los estados previos para obtener la salida más adecuada. Por último, en la red neuronal densa se aplica también una ventana temporal como las descritas anteriormente.

Con la aplicación de estos tres modelos se estima el valor que tendrá el caudal del proceso en función del que toman el resto de las variables seleccionadas, constituyendo de esta forma el sensor virtual buscado.

4. Experimentos

4.1. Descripción de la planta piloto

Los experimentos realizados toman como punto de partida una planta piloto (Domínguez et al., 2010) que incluye

instrumentación industrial real y que cuenta con tres circuitos diferenciados. La maqueta empleada y sus diferentes circuitos aparecen representados en la Figura 2. El circuito principal o de proceso está diseñado para controlar cuatro variables (caudal, nivel, presión y temperatura) de un fluido en circulación entre dos tanques situados a distintas alturas. Además, el líquido es impulsado desde el tanque inferior al superior por medio de una bomba centrífuga, y su flujo a través de las tuberías se regula por medio de una válvula de accionamiento neumático y una electroválvula.

La maqueta industrial cuenta, además, con un circuito de calentamiento, con resistencias eléctricas que permiten calentar agua y transmitir ese calor al proceso por medio de un intercambiador de placas. Por último, la maqueta presenta también un circuito de enfriamiento, que recircula un refrigerante externo y permite enfriar el fluido de proceso por medio de otro intercambiador de placas.



Figura 2: Maqueta industrial empleada.

Para poder implementar lazos de control sobre las cuatro variables mencionadas anteriormente, el circuito de proceso incluye a su vez los correspondientes sensores: un sensor de nivel ultrasónico, una sonda de temperatura PT-100, un sensor de presión diferencial y un caudalímetro electromagnético. Este último sensor, esencial para los experimentos planteados, permite calcular el caudal del fluido de proceso, sabiendo que el voltaje inducido por este cuando circula a través de un campo magnético es proporcional a la velocidad con la que el líquido se mueve.

Con el fin de disponer de otra medida distinta y poder comparar los datos obtenidos y los resultados del sensor virtual, se ha conectado un caudalímetro portátil externo. El principio de funcionamiento del sensor se basa en obtener el caudal del fluido en función del tiempo que tarda un haz de ultrasonidos en llegar desde un emisor a un receptor colocados convenientemente en el exterior de la tubería.

4.2. Descripción de la adquisición y dataset

La adquisición de los datos generados a lo largo de los experimentos planteados se ha realizado mediante el empleo de una aplicación multihilo, desarrollada mediante el lenguaje de programación Python. Dicha aplicación ofrece soporte multiprotocolo, permitiendo una lectura unificada de los datos con independencia de la naturaleza y fabricante de los equipos involucrados en la experimentación. Cada equipo definido en la aplicación se encuentra estrechamente vinculado a un hilo de ejecución, el cual se encargará de realizar la solicitud de los datos especificados, en el intervalo que se considere. Los conjuntos de datos solicitados serán temporalmente almacenados en memoria hasta su volcado definitivo en una base de datos determinada, de donde posteriormente se extraerán para su consulta y manipulación.

En los experimentos desarrollados para el presente caso de estudio, se han realizado solicitudes de datos únicamente sobre un autómatas Modicon M340 de Schneider Electric, utilizando el protocolo ModBus TCP/IP. Dichas solicitudes se realizan de manera recurrente a intervalos de 100 milisegundos.

La estructura de los datos solicitados se compone de un total de 6 variables reales de las cuales 5 se corresponden con una serie de entradas y salidas de la maqueta (presión, caudal de proceso, válvula de proceso, frecuencia de la bomba y nivel), mientras que la sexta variable se encuentra asociada al caudalímetro ultrasónico. Este equipo ofrece una salida 4-20mA que será utilizada como entrada analógica en el autómatas, centralizando y simplificando el proceso de adquisición de datos. Cada solicitud de éste conjunto de variables será provista además del timestamp en el que se produce, con el objetivo de simplificar su clasificación dentro de todo el conjunto de datos del experimento.

Se han realizado un total de 3 experimentos de captura de datos, consistentes en la modificación de la posición de la válvula de proceso, en combinación con la variación de la frecuencia de la bomba que impulsa el fluido de proceso. De esta manera se obtienen una serie de combinaciones aleatorias, que unidas a la inercia asociada al llenado del depósito de la maqueta, ofrecen un conjunto de datos altamente variado. Cada experimento tiene una duración de 1 hora.

Analizando los datos recabados del sistema, se ha comprobado que el tiempo de establecimiento del mismo es de 5 segundos. Teniendo esto en cuenta, se realiza un enventanado de los datos de acuerdo al tiempo de establecimiento, que se traduce en 50 muestras por ventana, dado el intervalo de muestreo de 100 milisegundos utilizado ($T_s=50 \cdot 0.1=5s$). El conjunto de datos totales se ha dividido en 3 partes iguales, destinando 2 de ellas al entrenamiento y validación de los modelos planteados, mientras la restante se utilizará para el testeado del modelo finalmente seleccionado.

El subconjunto de datos destinado a entrenamiento y validación se sirve a los modelos siguiendo un método de validación cruzada de 10 fases (10-fold cross validation): se divide el subconjunto aleatoriamente en 10 partes, uti-

lizando 9 de esas partes para el entrenamiento, mientras que la última parte se destina a la validación. Este procedimiento se repite un total de 10 veces, reservando cada vez una décima parte diferente para la validación. Los diferentes modelos se han parametrizado utilizando los rangos de valores mostrados en la Tabla 1, para evaluar su comportamiento y seleccionar la parametrización óptima.

4.3. Resultados




Figura 3: Predicción del sensor virtual (método 1DCNN) con los datos de test.

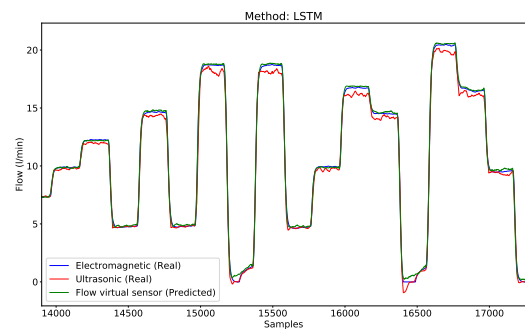


Figura 4: Predicción del sensor virtual (método LSTM) con los datos de test.




Figura 5: Predicción del sensor virtual (método DENSE) con los datos de test.

Se definen un total de 10 épocas de entrenamiento, en cada una de las cuales se baraja la totalidad del conjunto

de muestras y se subdivide en lotes de 32 muestras con las que se alimenta a los diferentes modelos, de esta manera se obtiene un conjunto elevado de posibles combinaciones que garanticen el correcto aprendizaje de los diferentes modelos.

Tras el entrenamiento y validación de los modelos parametrizados con los valores anteriores y en las condiciones definidas, se concluye que la parametrización óptima en cada caso es la mostrada en la última columna de la Tabla 1.

Tabla 1: Hiperparámetros utilizados

Hiperparámetro	Rango	Valor
1DCNN		
Filtros	5,10,20,40,80,160	80
Kernel	3,9,27	3
LSTM		
Neuronas	5,10,20,40,80,160	80
DENSE		
Neuronas	5,10,20,40,80,160	20

Tabla 2: Errores usando los datos de test

Método	MAE	RMSE
1DCNN	0.4547	0.2588
LSTM	0.3844	0.2132
DENSE	0.4453	0.2594

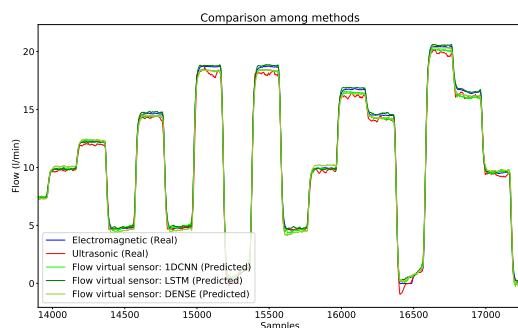


Figura 6: Comparación de los tres métodos (1DCNN, LSTM, DENSE).

Por último, se muestran de forma gráfica los resultados obtenidos con cada modelo, enfrentados a los datos capturados con los caudalímetros empleados (Figura 3, Figura 4, Figura 5), concluyendo con una comparación entre los 3 modelos desarrollados (Figura 6). Dicha comparación se expresa numéricamente en el análisis de los errores cuadrático medio (RMSE) y error absoluto medio (MAE), facilitado en la Tabla 2. Como se ha indicado anteriormente, junto con la medida del caudalímetro integrado en la planta piloto industrial, se utiliza también la lectura aportada por un sensor de caudal ultrasónico externo. Aunque este sensor produce más ruido en la medida, el error de la medida real en comparación con los datos aportados por el sensor virtual es aceptable: con la red LSTM, el MAE es de 0.5740 y el RMSE es de 0.4297.

5. Conclusiones y líneas futuras

En este artículo se presenta un método para desarrollar sensores virtuales que se basa en la utilización de técnicas de *deep learning*. Se han comparado tres implementaciones que usan tres de las arquitecturas más típicas del aprendizaje profundo: redes neuronales, redes convolucionales y redes recurrentes. Los experimentos se han realizado en una planta industrial real que dispone de un transmisor de caudal y en la que se ha instalado otro transmisor adicional de caudal, que es portátil. Los mejores resultados se han obtenido con el método basado en una red LSTM ya que el error cuadrático medio (RMSE) y el error absoluto medio (MAE) son los menores. Además, se han realizado pruebas para evaluar el desempeño del sensor virtual comparado con el sensor de caudal portátil, siendo, como era de esperar, los errores obtenidos superiores, pero aceptables. Como líneas futuras se pretenden sustituir los sensores de los lazos de control de la planta piloto por los sensores virtuales obtenidos con el método propuesto. Adicionalmente, se está trabajando en el desarrollo del gemelo digital de la planta piloto, en el que los sensores se virtualizarán también utilizando este método.

Agradecimientos

Esta publicación ha sido financiada por el Ministerio de Ciencia e Innovación, MCIN/AEI/10.13039/501100011033/, mediante el proyecto PID2020-117890RB-I00. El trabajo de José Ramón Rodríguez-Ossorio y de Guzmán González-Mateos ha sido financiado por una beca del *Programa de Investigación de la Universidad de León*.

Referencias

- Abeykoon, C., 2018. Design and applications of soft sensors in polymer processing: A review. *IEEE Sensors Journal* 19 (8), 2801–2813.
- Alonso, S., Morán, A., Pérez, D., Reguera, P., Díaz, I., Domínguez, M., 2019. Virtual sensor based on a deep learning approach for estimating efficiency in chillers. *Communications in Computer and Information Science* 1000, 307–319.
DOI: 10.1007/978-3-030-20257-6_26
- Babiceanu, R. F., Seker, R., 2016. Big data and virtualization for manufacturing cyber-physical systems: A survey of the current status and future outlook. *Computers in Industry* 81, 128 – 137, emerging ICT concepts for smart, safe and sustainable industrial systems.
DOI: 10.1016/j.compind.2016.02.004
- Chhantyal, K., Jondahl, M. H., Viumdal, H., Mylvaganam, S., 2018. Upstream ultrasonic level based soft sensing of volumetric flow of non-newtonian fluids in open venturi channels. *IEEE Sensors Journal* 18 (12), 5002–5013.
DOI: 10.1109/JSEN.2018.2831445
- Domínguez, M., Fuertes, J. J., Reguera, P., González, J. J., Ramón, J. M., 2010. Maqueta industrial para docencia e investigación. *Revista Iberoamericana de automática e informática industrial* 1 (2), 58–63.
- Jiang, Y., Yin, S., Dong, J., Kaynak, O., 2021. A review on soft sensors for monitoring, control, and optimization of industrial processes. *IEEE Sensors Journal* 21 (11), 12868–12881.
DOI: 10.1109/JSEN.2020.3033153

- Kadlec, P., Gabrys, B., Strandt, S., 2009. Data-driven soft sensors in the process industry. *Computers & Chemical Engineering* 33 (4), 795 – 814.
DOI: 10.1016/j.compchemeng.2008.12.012
- Li, H., Yu, D., Braun, J. E., 2011. A review of virtual sensing technology and application in building systems. *HVAC&R Research* 17 (5), 619–645.
DOI: 10.1080/10789669.2011.573051
- Martin, D., Kühn, N., Satzger, G., 2021. Virtual sensors. *Business & Information Systems Engineering* 63 (3), 315–323.
- Mattera, C. G., Quevedo, J., Escobet, T., Shaker, H. R., Jradi, M., 2018. A method for fault detection and diagnostics in ventilation units using virtual sensors. *Sensors* 18 (11), 3931.
- McDonald, E., Zmeureanu, R., 2015. Development and testing of a virtual flow meter tool to monitor the performance of cooling plants. *Energy Procedia* 78, 1129 – 1134.
DOI: 10.1016/j.egypro.2015.11.071
- Márquez-Vera, M. A., López-Ortega, O., Ramos-Velasco, L. E., Ortega-Mendoza, R. M., Fernández-Neri, B. J., Zúñiga-Peña, N. S., abr. 2021. Diagnóstico de fallas mediante una lstm y una red elástica. *Revista Iberoamericana de Automática e Informática industrial* 18 (2), 160–171.
DOI: 10.4995/riai.2020.13611
- Nair, A. M., Fanta, A., Haugen, F. A., Ratnaweera, H., 08 2019. Implementing an Extended Kalman Filter for estimating nutrient composition in a sequential batch MBBR pilot plant. *Water Science and Technology* 80 (2), 317–328.
URL: <https://doi.org/10.2166/wst.2019.272>
DOI: 10.2166/wst.2019.272
- Tao, F., Cheng, J., Qi, Q., Zhang, M., Zhang, H., Sui, F., feb 2018. Digital twin-driven product design, manufacturing and service with big data. *International Journal of Advanced Manufacturing Technology* 94 (9-12), 3563–3576.
DOI: 10.1007/s00170-017-0233-1
- Tegen, A., Davidsson, P., Mihailescu, R.-C., Persson, J. A., 2019. Collaborative sensing with interactive learning using dynamic intelligent virtual sensors. *Sensors* 19 (3).
URL: <https://www.mdpi.com/1424-8220/19/3/477>
DOI: 10.3390/s19030477
- Thürlimann, C. M., Dürrenmatt, D. J., Villez, K., 2018. Soft-sensing with qualitative trend analysis for wastewater treatment plant control. *Control Engineering Practice* 70, 121–133.
DOI: <https://doi.org/10.1016/j.conengprac.2017.09.015>
- Xu, L. D., Xu, E. L., Li, L., 2018. Industry 4.0: State of the art and future trends. *International Journal of Production Research* 56 (8), 2941–2962.
DOI: 10.1080/00207543.2018.1444806
- Yang, X., Zhang, Y., Shardt, Y. A., Li, X., Cui, J., Tong, C., 2019. A kpi-based soft sensor development approach incorporating infrequent, variable time delayed measurements. *IEEE Transactions on Control Systems Technology* 28 (6), 2523–2531.