

04-040

IMPROVING WWTP PRETREATMENT BY PREDICTING INLET WATER PARAMETERS.

Mateo Pérez, Vanesa ⁽¹⁾; Mesa Fernández, José Manuel ⁽¹⁾; Villanueva Balsera, Joaquín ⁽¹⁾;
Terrados Cristos, Marta ⁽¹⁾

⁽¹⁾ Universidad de Oviedo

The wastewater treatment facilities collect large and diverse basins, in which water from various runoffs, urban, commercial and industrial waters are mixed. Therefore, typical urban wastewater contains various components such as suspended solids, organic matter, oils and fats, but usually not present dangerous substances. As a consequence of the growing environmental demands, the improvement of the operation of these plants and each one of the different treatment stages is the subject of many researches. However, the initial pretreatment stage, which treats wastewater on arrival at the plant, has received less attention. This work analyzes the prediction of different fractions present in the inlet water, that is, sands, fats and roughing solids, as a means to improve this pretreatment stage.

Keywords: Pretreatment; wastewater; treatment plant; inlet water; parameters.

MEJORA DEL PRETRATAMIENTO DE UNA EDAR MEDIANTE LA PREDICCIÓN DE PARÁMETROS DEL AGUA DE ENTRADA.

Las instalaciones de depuración de aguas residuales recogen cuencas de gran dimensión y diversidad, en las que se mezclan aguas que proceden de diversas escorrentías, aguas de tipo urbano, comercial e industrial. Por tanto, las aguas residuales urbanas típicas contienen distintos componentes como sólidos en suspensión, materia orgánica, aceites y grasas, aunque no suelen presentar sustancias peligrosas. Como consecuencia de las crecientes exigencias medioambientales, la mejora del funcionamiento de estas plantas y de cada una de las distintas etapas de tratamiento es objeto de numerosas investigaciones. Sin embargo, la etapa inicial de pretratamiento que trata el agua residual a su llegada a la planta, ha recibido una menor atención. Sin embargo, su influencia en el rendimiento, la gestión operativa y el mantenimiento de estas instalaciones es considerable. En este trabajo se analiza la predicción de distintas fracciones presentes en el agua de entrada, es decir, las arenas, grasas y sólidos de desbaste, como medio para la mejora de esta etapa de pretratamiento.

Palabras claves: Pretratamiento; aguas residuales; estación depuradora; parámetros de entrada.

Correspondencia: José Manuel Mesa Fernández jmmesa@uniovi.es

Agradecimientos: Agradecer la colaboración en este trabajo de Aguas de las Cuencas de España (ACUAES) y de la UTE formada por las empresas Dragados S.A. y Drace Infraestructuras S.A.



1. Introducción

Las aguas residuales urbanas típicas contienen distintos componentes como sólidos en suspensión, materia orgánica, arenas, aceites y grasas, aunque no suelen presentar sustancias peligrosas. Esta composición es consecuencia de que la mayoría de los colectores suelen ser unitarios, es decir, no solo recogen aguas domiciliarias sino también todo tipo de residuos de las calles arrastradas por el agua de lluvia, riego o limpieza municipal.

Las características del agua residual de entrada en la planta dependen de las características del área a la que presta servicio, la población o la presencia de actividades de carácter industrial y se ven afectadas por factores como la estacionalidad y los fenómenos meteorológicos. Distintos trabajos han estudiado casos en los que el funcionamiento de las plantas se aleja de las condiciones de trabajo para las que fueron diseñadas debido por ejemplo a las tormentas. En estas ocasiones el rendimiento de la instalación empeora y distintos procesos de tratamiento pueden verse afectados (El-Din & Smith, 2002).

Aunque, como indican varios autores (L. He et al., 2019; Prado & Campos, 2009), se han estudiado más las siguientes etapas de las plantas depuradoras dada su gran incidencia en la recuperación del agua, la fase inicial de pretratamiento tiene una gran importancia de cara al correcto funcionamiento de estas instalaciones (Borges et al., 2015). En dicho pretratamiento se realizan varias operaciones que tratan de eliminar residuos como:

- Los sólidos de desbaste (toallitas, residuos sanitarios, bastoncillos, etc.) generan problemas tanto en las depuradoras como en los propios colectores, llegando a provocar severos atascos tal como se muestra en múltiples referencias (Brown, D.M. et al., 1996; Butler et al., 2005; Digman et al., 2012; Eren & Karadagli, 2012; Walski et al., 2011).
- Las arenas: englobadas dentro de esa denominación de “arenas” (sewage grit) se incluyen distintos componentes inorgánicos (arena, grava, cenizas, asfalto, hormigón, ...) y orgánicos (Office of Water, 2003). La práctica general (Metcalf & Eddy Inc. et al., 2002) indica que los sistemas desarenadores recuperan el 95 % de las arenas por encima de las 200 micras y, por tanto, eliminan la mayor parte de los posibles problemas operativos de las instalaciones (Prado & Campos, 2009). Sin embargo, en días lluviosos, con mayor caudal de entrada y un aumento de la cantidad de arenas, se incrementa su paso a las etapas siguientes de tratamiento y se generan problemas como abrasión en los equipos de la línea de fangos o que afectan al rendimiento de los procesos biológicos (L. He et al., 2019).
- Las grasas son el resultado de las actividades de preparación de alimentos, tanto en procesos comerciales e industriales como domésticos, y es una preocupación cada vez mayor para los municipios y los operadores de instalaciones depuradoras, debido a su tendencia a causar graves obstrucciones en las tuberías y alcantarillado (Arthur, S. & Blanc, J., 2013; X. He et al., 2017; Husain et al., 2014; Wallace et al., 2017). Su composición y características pueden variar considerablemente en función de su origen (Awe et al., 2018; Salama et al., 2019). Una vez en las depuradoras, las grasas y aceites que no se eliminan en el proceso de desengrasado del pretratamiento pueden causar atascos y otros problemas en las infraestructuras de estas (tuberías, bombas, tanques, digestores, sensores ...). Como consecuencia, se utilizan distintos métodos para eliminar dichas grasas y aceites al inicio de los procesos de depuración (Collin et al., 2020; Khuntia et al., 2020).

La correcta operación y control de las estaciones depuradoras de aguas residuales está recibiendo cada vez mayor atención debido a la creciente preocupación social en aspectos medioambientales (M.M. et al., 2004). Como consecuencia, distintas estrategias avanzadas de control de planta están siendo implementadas. Muchas de ellas se basan

fundamentalmente en la monitorización de distintos parámetros de las instalaciones (Dürrenmatt & Gujer, 2012). Así, las variaciones en la composición y cantidad del agua residual de entrada, así como la propia complejidad de los procesos de tratamiento, hacen necesario modelizar distintos parámetros para mejorar el control operativo de la instalación (Yel & Yalpir, 2011). Con ese objetivo, y aprovechando la disponibilidad de datos procedentes de los sistemas de control de las instalaciones (SCADA), se han empleado distintas técnicas de modelización para la predicción de distintas fracciones presentes en el agua de entrada, es decir, las arenas, grasas y sólidos de desbaste, como medio para la mejora de esta etapa de pretratamiento. Para ello, en el apartado siguiente se presentan las características principales del caso de estudio empleado. A continuación, en la sección 3 se analizan distintos factores que intervienen en la llegada de las distintas fracciones de residuos anteriormente mencionadas. Posteriormente se describen el proceso de modelización empleado.

2. Caso de estudio

La Estación Depuradora de Aguas Residuales de Villapérez, está situada al noreste de la ciudad de Oviedo (Asturias, España) y ocupa una extensión cercana a las 21 hectáreas (Figura 1). Proporciona servicio a una población aproximada de 723.000 habitantes equivalentes. La red de colectores que alimenta a la depuradora es unitaria. La línea de proceso de esta EDAR incluye pretratamiento, tratamiento de tormentas, decantación primaria, tratamiento biológico, decantación secundaria y tratamiento terciario de afino.

Figura 1: Vista en planta de la EDAR de Villapérez (Asturias, España)



El pretratamiento tiene capacidad para tratar un caudal de $8,5 \text{ m}^3/\text{s}$ y comienza con dos pozos de gruesos, equipados con una cuchara bivalva de 500 litros de capacidad. A continuación, la instalación dispone de cuatro canales de desbaste, que incluyen en cada uno de ellos una reja de limpieza automática de 60 mm de luz de paso y un tamiz de finos autolimpiable de 3 mm de luz de paso e inclinado 50° . Tras la etapa de desbaste, el agua llega a las instalaciones de separación de grasas y arenas del agua bruta que constan de 5 desarenadores rectangulares con un volumen útil unitario de $449,8 \text{ m}^3$. Dichas unidades de desarenado garantizan la eliminación de partículas de tamaño igual o superior a 0,2 milímetros. En el canal de desarenado se realiza una inyección de aire mediante difusores de burbuja gruesa en el primer tercio de la longitud y aireadores sumergidos en los dos tercios restantes, que aseguran un flujo giratorio y la flotación de las grasas. Este sistema persigue emulsionar las grasas en

el agua, transformándolas en espumas y la separación de los flotantes además de ayudar a la decantación y limpieza de las arenas.

Los datos empleados en este trabajo se recogieron en el periodo temporal desde el 1/03/2017 al 24/06/2019 y proceden de distintas fuentes:

- Los relativos al agua residual se obtuvieron mediante el software SCADA (Supervisory Control and Data Acquisition) de la EDAR. Este sistema registra cada 9 minutos 226 parámetros procedentes de equipos de medida y sensores distribuidos por la estación depuradora. De ese conjunto de datos se utilizaron los datos asociados a la medición de parámetros de entrada en el agua bruta en el pretratamiento. Los parámetros medidos en el agua bruta son el caudal de entrada, el pH, la temperatura del agua bruta, conductividad y amonio. Los datos asociados a esas variables se identifican mediante la hora y la fecha de medición del dato.
- Los datos de los distintos residuos (arenas, sólidos de desbaste y grasas) se recogieron a partir de los albaranes de retirada de los respectivos contenedores donde figura el dato real de peso total del residuo retirado en cada contenedor.
- Los datos de clima proceden de la página de Agencia Estatal de Meteorología (Aemet) de España y los datos pluviométricos (precipitación instantánea y precipitación acumulada) se obtienen de los registrados por la estación meteorológica de la propia planta. Todos ellos se agrupan también teniendo en cuenta los intervalos de llenado de los contenedores. A partir de esos datos se crea además una variable calculada a partir de la precipitación instantánea, correspondiente al número de días previos sin lluvia.

3. Modelización de parámetros

Algunos de los efectos más relevantes que influyen en variaciones en el contenido de cada una de las tres fracciones objeto de estudio en el agua de entrada en la estación depuradora son los que se indican en la Tabla 1.

Tabla 1: Origen y principales efectos de cada fracción

Residuo	Origen	Efectos o problemas derivados
Sólidos gruesos	Origen doméstico	Atascos de las bombas generando vertidos de agua sin tratar
Arenas	Arrastre por el agua de lluvia	Abrasión en los equipos de etapas posteriores si no se eliminan adecuadamente
Grasas	Origen doméstico e industrial	La presencia de grasa en las aguas del biológico impide la adecuada transferencia de oxígeno a las bacterias

Disponer de una mejor estimación de las características del agua de entrada, en cuanto a la presencia de estos residuos, permite mejorar distintos aspectos operativos de la EDAR, así como reducir posibles problemas de mantenimiento y asegurar un buen rendimiento de los tratamientos posteriores de la EDAR. También permite anticiparse a lo que va a suceder poniendo en marcha líneas adicionales del pretratamiento.

Se han desarrollado modelos de predicción del contenido de cada una de las fracciones estudiadas, obteniendo buenos resultados mediante la aplicación de modelos basados en datos. En los tres casos se partió del mismo conjunto de datos con un importante trabajo inicial de tratamiento del mismo para eliminar casos erróneos, completar aquellos incompletos o

detectar factores. Las características y técnicas concretas empleadas en cada uno de los casos se describen a continuación.

3.1 Sólidos de desbaste

Para la predicción de los sólidos de desbaste, el modelo utilizado se basa en el método SVM (Support Vector Machine) (Vapnik, 1998). El modelo desarrollado permite predecir las toneladas de sólidos de desbaste que van a llegar a la depuradora (Mateo Pérez, Mesa Fernández, Ortega Fernández, et al., 2021).

En este caso se utilizan 165 casos que se corresponden con las 165 veces que se llenó el contenedor de sólidos de desbaste en el periodo analizado. Para poder calcular el algoritmo se utilizaron las 20 variables más significativas para la predicción de dichos sólidos.

Las variables que resultaron más significativas la predicción de los sólidos de desbaste fueron la semana y el día del año, relacionadas con la componente estacional de esta variable. Por otro lado, es necesario mencionar la lluvia debido a que aumento de la cantidad de precipitación supone un mayor arrastre de los sólidos depositados en los colectores. Otra variable influyente es el pH, este es relativamente constante en el agua residual urbana y sus variaciones vienen dadas por la componente industrial del agua residual, lo que lo convierte en un indicador de la llegada de agua residual de origen industrial.

En la siguiente figura se puede ver como el modelo es capaz de predecir los cambios de tendencia en la llegada de sólidos de desbaste, es mucho más importante predecir esta tendencia que el valor exacto de dichos sólidos.

En la Figura 2 se puede observar el buen comportamiento del modelo de sólidos obtenido tanto en etapa entrenamiento como en test.

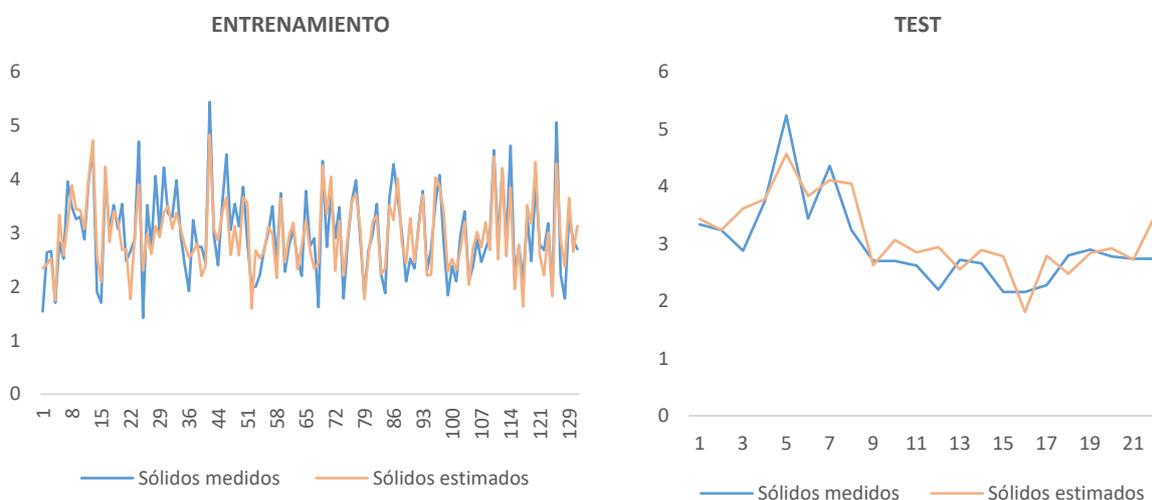


Figura 2: Predicción del modelo de sólidos de desbaste en entrenamiento y test

3.2 Arenas

El algoritmo utilizado en este caso para el desarrollo del modelo fue MARS (Multivariate Adaptive Regression Splines) (Friedman, 1991). El conjunto de datos obtenidos después del procesamiento inicial (187 casos) fue dividido en dos grupos. El 80 % de los datos fueron utilizados en el entrenamiento y el 20 % restante se reservó para la validación de este. Los

resultados obtenidos indican que es posible predecir cambios de tendencia en la producción de la arena en función de cambios en variables de entrada (Mateo Pérez et al., 2020).

Como se esperaba, la principal variable que condiciona la cantidad de arena que llega a la depuradora es el caudal, aunque esta relación no es directamente proporcional al mismo. El contenido en arena de las aguas residuales es relativamente bajo, mientras que es más elevado en las aguas pluviales, por lo que la precipitación también aparece como significativa. La experiencia indica que, en épocas de lluvia continuada, la llegada de arenas es constante y no existe un efecto lavado del colector.

El pH es otra variable relevante ya que en tiempo seco la composición del agua residual es bastante constante, mientras que cuando llueve, el valor de pH registrado se modifica por el efecto de la dilución. Por otra parte, el comportamiento es diferente en función de la época del año, es decir, hay una cierta estacionalidad, en épocas más lluviosas o con mayor probabilidad de aguaceros se produce mayor cantidad de arena.

Al igual que el pH, el amonio es una variable condicionada por la dilución del agua, pero también por la actividad industrial. Es decir, durante los días laborables, cuando se produce una mayor actividad industrial el valor medio de amonio de incrementa. Sin embargo, este efecto con el pH no se detecta porque determinadas actividades industriales reducen el pH y mientras que otras lo incrementan.

Los resultados del modelo de arenas en entrenamiento y test se muestran en la Figura 3.

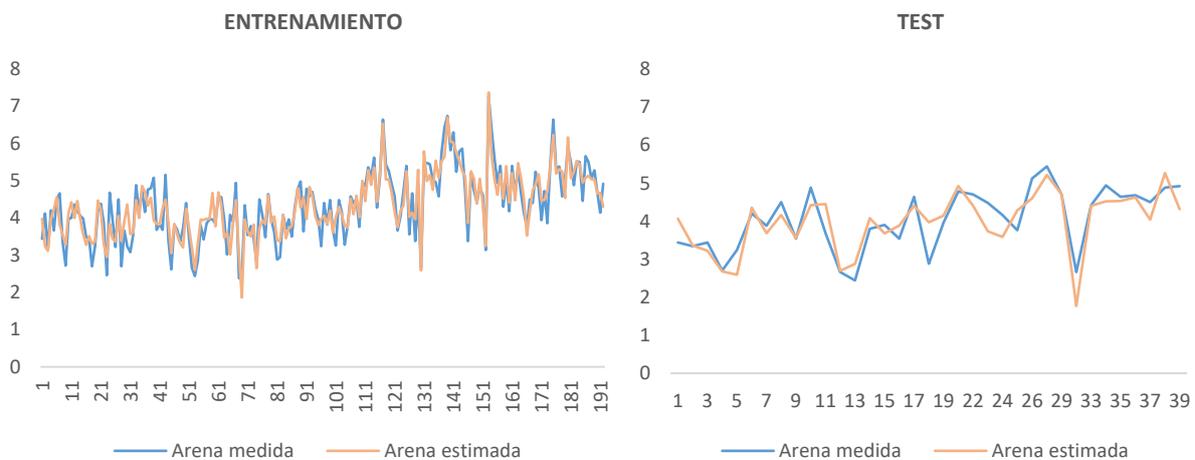


Figura 3: Predicción del modelo de arenas en entrenamiento y test

3.3 Grasas

En este caso, se utilizó el algoritmo RF (Random Forest) (Breiman, 2001) con un número de patrones total más reducido (89 casos), por lo que se optó por utilizar el 90% para entrenamiento y el 10 % restante para test. Inicialmente se introdujeron 22 variables para la generación del modelo, de las cuales 11 fueron descartadas durante el proceso de entrenamiento ya que no se utilizan en ninguna de las divisiones generadas en el modelo

(Mateo Pérez, Mesa Fernández, Villanueva Balsera, et al., 2021). El resultado permite valorar la importancia relativa de las variables del modelo:

- Las variables con mayor relevancia en este caso son las relacionadas con el amonio, lo que podría estar relacionado con los vertidos de la lechería atendida por la EDAR Villapérez.
- También es significativa la precipitación máxima. Una mayor precipitación implica que las grasas llegan más disueltas, lo que dificulta su remoción en el proceso de pretratamiento.
- Las aguas residuales urbanas tienen una conductividad aproximadamente constante, por lo que es posible asociar las variaciones y relevancia de esta variable con los vertidos industriales.
- Las variables relacionadas con el número de días previos sin lluvia indican que como hay menos afluencia a tratar, las grasas están menos disueltas y es posible eliminarlas en mayor proporción.
- Las aguas residuales urbanas tienen un pH relativamente estable, por lo que las variaciones en este indicador se pueden considerar también asociadas a los vertidos industriales.
- La temperatura media proporciona información sobre la situación estacional en el momento del análisis. Una temperatura más alta facilita la emulsión de las grasas y por tanto su eliminación es más eficaz.
- Finalmente, la relevancia de la variable de caudal medio se puede explicar de la misma forma que la precipitación o el número de días previos sin lluvia mencionados anteriormente.

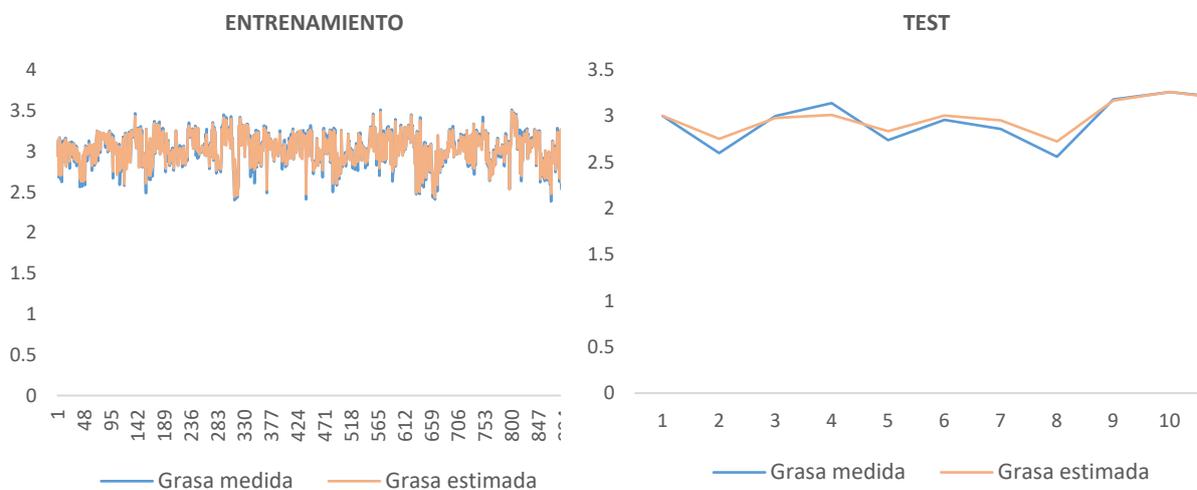


Figura 4: Predicción del modelo de grasas en entrenamiento y test

En las tablas siguientes (Tabla 2 y Tabla 3) se recogen los principales indicadores de los tres modelos desarrollados para el tratamiento.

Tabla 2: Resumen de la modelización entrenamiento

Residuo	Método	R2	MSE
Sólidos gruesos	SVM	0.70	0.42
Arenas	MARS	0.74	0.44
Grasas	RF	0.98	0.02

Tabla 3: Resumen de la modelización test

Residuo	Método	R ²	MSE
Sólidos gruesos	SVM	0.68	0.43
Arenas	MARS	0.70	0.46
Grasas	RF	0.93	0.06

4. Conclusiones

Aunque el pretratamiento en las depuradoras ha sido estudiado en relativamente pocos trabajos de investigación, constituye una de las etapas más afectadas por los vertidos de agua sin tratar y de la que además depende en gran medida el rendimiento y la durabilidad del resto de la planta. No completar correctamente el proceso de pretratamiento, es decir, no retirar los residuos de mayor tamaño, las arenas y las grasas, genera necesariamente importantes problemas en los restantes tratamientos aguas abajo en la instalación.

En este trabajo se presenta la modelización de las tres fracciones sólidas no disueltas más importantes presentes en el agua de entrada de cualquier planta depuradora de aguas residuales: los sólidos de desbaste, las arenas y las grasas. Mediante el empleo de tres técnicas diferentes, SVM, MARS y RF, ha sido posible obtener modelos de predicción con buenos resultados que permitirán mejorar la operatividad de la etapa inicial de pretratamiento de la depuradora objeto de estudio.

Disponer de información anticipada permitirá adoptar medidas como abrir o cerrar líneas de pretratamiento, retirar contenedores en previsión de su desborde o ajustar la inyección de aire para facilitar la retirada de grasas o arenas del proceso. Como consecuencia de esas actuaciones, se mejorará el rendimiento en conjunto de la instalación, reduciendo el consumo energético o los gastos de mantenimiento, reduciendo problemas de atascos o desbordamientos y mejorando la calidad del agua de entrada a los distintos tratamientos aguas abajo.

5. Bibliografía

- Arthur, S. & Blanc, J. (2013). *Management and Recovery of FOG (fats, oils and greases)*. CREW – Scotland's Centre of Expertise for Waters. https://www.crew.ac.uk/sites/www.crew.ac.uk/files/sites/default/files/publication/CREW_FOG.pdf
- Awe, O. W., Zhao, Y., Nzihou, A., Minh, D. P., & Lyczko, N. (2018). Anaerobic co-digestion of food waste and FOG with sewage sludge – realising its potential in Ireland. *International Journal of Environmental Studies*, 75(3), 496-517. <https://doi.org/10.1080/00207233.2017.1380335>
- Borges, N. B., Campos, J. R., & Pablos, J. M. (2015). Characterization of residual sand removed from the grit chambers of a wastewater treatment plant and its use as fine

- aggregate in the preparation of non-structural concrete. *Water Practice and Technology*, 10(1), 164-171. <https://doi.org/10.2166/wpt.2015.018>
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Brown, D.M., Butler, D., Orman, N.R., & Davies, J.W. (1996). Gross solids transport in small diameter sewers. *Water Science and Technology*, 33(9), 25-30. [https://doi.org/10.1016/0273-1223\(96\)00366-6](https://doi.org/10.1016/0273-1223(96)00366-6)
- Butler, D., Littlewood, K., & Orman, N. (2005). A model for the movement of large solids in small sewers. *Water Science and Technology: A Journal of the International Association on Water Pollution Research*, 52(5), 69-76.
- Collin, T. D., Cunningham, R., Asghar, M. Q., Villa, R., MacAdam, J., & Jefferson, B. (2020). Assessing the potential of enhanced primary clarification to manage fats, oils and grease (FOG) at wastewater treatment works. *Science of The Total Environment*, 728, 138415. <https://doi.org/10.1016/j.scitotenv.2020.138415>
- Digman, C. J., Littlewood, K., Butler, D., Spence, K., Balmforth, D. J., Davies, J., & Schütze, M. (2012). A Model to Predict the Temporal Distribution of Gross Solids Loading in Combined Sewerage Systems. *Global Solutions for Urban Drainage*, 1-13. [https://doi.org/10.1061/40644\(2002\)102](https://doi.org/10.1061/40644(2002)102)
- Dürrenmatt, D. J., & Gujer, W. (2012). Data-driven modeling approaches to support wastewater treatment plant operation. *Environmental Modelling & Software*, 30, 47-56. <https://doi.org/10.1016/j.envsoft.2011.11.007>
- El-Din, A. G., & Smith, D. W. (2002). A neural network model to predict the wastewater inflow incorporating rainfall events. *Water Research*, 36(5), 1115-1126. [https://doi.org/10.1016/s0043-1354\(01\)00287-1](https://doi.org/10.1016/s0043-1354(01)00287-1)
- Eren, B., & Karadagli, F. (2012). Physical Disintegration of Toilet Papers in Wastewater Systems: Experimental Analysis and Mathematical Modeling. *Environmental Science & Technology*, 46(5), 2870-2876. <https://doi.org/10.1021/es203589v>
- Friedman, J. H. (1991). Multivariate Adaptive Regression Splines. *The Annals of Statistics*, 19(1), 1-67. <https://doi.org/10.1214/aos/11176347963>
- He, L., Tan, T., Gao, Z., & Fan, L. (2019). The Shock Effect of Inorganic Suspended Solids in Surface Runoff on Wastewater Treatment Plant Performance. *International Journal of Environmental Research and Public Health*, 16(3), 453. <https://doi.org/10.3390/ijerph16030453>
- He, X., De los Reyes, F., & Ducoste, J. (2017). A critical review of fat, oil, and grease (FOG) in sewer collection systems: Challenges and control. *Critical Reviews in Environmental Science and Technology*, 47. <https://doi.org/10.1080/10643389.2017.1382282>
- Husain, I. A. F., Alkhatib, M. F., Jammi, M. S., Mirghani, M. E. S., Zainudin, Z. B., & Hoda, A. (2014). Problems, Control, and Treatment of Fat, Oil, and Grease (FOG): A Review. *Journal of Oleo Science*, 63(8), 747-752. <https://doi.org/10.5650/jos.ess13182>
- Khuntia, H. K., Janardhana, N., & Chanakya, Hoysall. N. (2020). Fractionation of FOG (fat, oil, grease), wastewater and particulate solids based on low-temperature solidification and

- stirring. *Journal of Water Process Engineering*, 34, 101167. <https://doi.org/10.1016/j.jwpe.2020.101167>
- Mateo Pérez, V., Mesa Fernández, J. M., Ortega Fernández, F., & Morán Palacios, H. (2020). Sand Content Prediction in Urban WWTPs Using MARS. *Water*, 12(5), 1357. <https://doi.org/10.3390/w12051357>
- Mateo Pérez, V., Mesa Fernández, J. M., Ortega Fernández, F., & Villanueva Balsera, J. (2021). Gross Solids Content Prediction in Urban WWTPs Using SVM. *Water*, 13(4), 442. <https://doi.org/10.3390/w13040442>
- Mateo Pérez, V., Mesa Fernández, J. M., Villanueva Balsera, J., & Alonso Álvarez, C. (2021). A Random Forest Model for the Prediction of FOG Content in Inlet Wastewater from Urban WWTPs. *Water*, 13(9), 1237. <https://doi.org/10.3390/w13091237>
- Metcalf & Eddy Inc., Tchobanoglous, G., Burton, F., & Stensel, H. D. (2002). *Wastewater Engineering: Treatment and Reuse*. McGraw-Hill Education.
- M.M., H., M.G., K., & E.A., H. (2004). Prediction of wastewater treatment plant performance using artificial neural networks. *ENVIRONMENTAL MODELLING & SOFTWARE*, 19(10), 919-928.
- Office of Water. (2003). *Wastewater Technology Fact Sheet: Screening and Grit Removal* (p. 11). Environmental Protection Agency (EPA). United States.
- Prado, G. S. do, & Campos, J. R. (2009). O emprego da análise de imagem na determinação da distribuição de tamanho de partículas da areia presente no esgoto sanitário. *Engenharia Sanitaria e Ambiental*, 14(3), 401-409. <https://doi.org/10.1590/S1413-41522009000300014>
- Salama, E.-S., Saha, S., Kurade, M. B., Dev, S., Chang, S. W., & Jeon, B.-H. (2019). Recent trends in anaerobic co-digestion: Fat, oil, and grease (FOG) for enhanced

biomethanation. *Progress in Energy and Combustion Science*, 70, 22-42.
<https://doi.org/10.1016/j.pecs.2018.08.002>

Vapnik, V. (1998). The Support Vector Method of Function Estimation. En J. A. K. Suykens & J. Vandewalle (Eds.), *Nonlinear Modeling: Advanced Black-Box Techniques* (pp. 55-85). Springer US. https://doi.org/10.1007/978-1-4615-5703-6_3

Wallace, T., Gibbons, D., O'Dwyer, M., & Curran, T. P. (2017). International evolution of fat, oil and grease (FOG) waste management – A review. *Journal of Environmental Management*, 187, 424-435. <https://doi.org/10.1016/j.jenvman.2016.11.003>

Walski, T., Falco, J., McAloon, M., & Whitman, B. (2011). Transport of large solids in unsteady flow in sewers. *Urban Water Journal*, 8(3), 179-187. <https://doi.org/10.1080/1573062X.2011.581298>

Yel, E., & Yalpir, S. (2011). Prediction of primary treatment effluent parameters by Fuzzy Inference System (FIS) approach. *Procedia Computer Science*, 3, 659-665. <https://doi.org/10.1016/j.procs.2010.12.110>

Comunicación alineada con los Objetivos de Desarrollo Sostenible

