



PROGRAMA DE PÓS-GRADUAÇÃO EM SISTEMAS E PROCESSOS INDUSTRIAL MESTRADO
ÁREA DE CONCENTRAÇÃO EM CONTROLE E OTIMIZAÇÃO DE PROCESSOS
INDUSTRIAIS

JANAINA LOPES DIAS

ESTUDO DO USO DE MINERAÇÃO DE DADOS NO PROCESSO DE
ROTEAMENTO DA COLETA DE RESÍDUOS SÓLIDOS URBANOS EM
CIDADES DA REGIÃO SUL DO BRASIL

Santa Cruz do Sul

2021

Janaina Lopes Dias

**ESTUDO DO USO DE MINERAÇÃO DE DADOS NO PROCESSO DE
ROTEAMENTO DA COLETA DE RESÍDUOS SÓLIDOS URBANOS EM
CIDADES DA REGIÃO SUL DO BRASIL**

Dissertação de Mestrado apresentado
ao Programa de Pós-Graduação em
Sistemas e Processos
Industriais –
Mestrado, Universidade de Santa
Cruz do Sul – UNISC, como requisito
parcial para obtenção do título
de Mestre em Sistemas e Processos
Industriais.

Orientador: Dr. João Carlos Furtado

SUMÁRIO

INTRODUÇÃO	10
TEMA E PROBLEMA	12
OBJETIVOS	13
JUSTIFICATIVA	14
FUNDAMENTAÇÃO TEÓRICA	16
EXTRAÇÃO DE CONHECIMENTO EM BASE DE DADOS	17
Seleção	19
Pré-processamento	19
Transformação	20
Mineração de Dados	21
Análise/Assimilação	24
COLETA DE RESÍDUOS SÓLIDOS	24
METODOLOGIA	26
Classificação da Pesquisa	26
Procedimentos Metodológicos	27
ARTIGO I: Mineração de dados para gerenciamento de resíduos sólidos: uma revisão sistemática da literatura	30

Resumo

O gerenciamento adequado dos resíduos produzidos pelos municípios é um dos grandes desafios para os gestores públicos e para a sociedade, ainda que os processos relacionados às etapas de coleta, transporte e destinação dos resíduos sólidos vêm sendo revistos à medida que surgem e são aplicadas novas tecnologias na área, com a finalidade de alcançar a maior sustentabilidade ambiental, social e econômica para a sociedade. Este trabalho, através do apoio de técnicas e algoritmos de Mineração de Dados e Descoberta de Conhecimento em Bases de Dados (KDD), avalia padrões na coleta de resíduos sólidos urbanos em três municípios do estado do Rio Grande do Sul. Utilizando dados históricos acerca do peso de descarga de caminhões de coleta em unidades de transbordo, dados da rota de recolhimento e dados sociodemográficos e de clima, com o objetivo de predizer a quantidade de resíduos sólidos coletados em cada ponto. A partir do modelo predição, foram utilizadas métricas de avaliação, como Médio Absoluto (Mean Absolute Error - MAE), Erro Quadrático Médio (Root Mean Squared Error - RMSE) e Coeficiente de Determinação (R^2) para avaliar a qualidade da base de dados e do modelo proposto. Os resultados mostram que o modelo do algoritmo Gradient Boosting apresentou melhor desempenho MAE (25,244), RMSE (87,667) e R^2 (0,642) na fase de treinamento e evidenciam o potencial de técnicas de mineração de dados para auxiliar na análise do gerenciamento de resíduos sólidos urbanos.

Palavras-chave: Mineração de dados; Gerenciamento de Resíduos Sólidos Urbanos; Coleta de Resíduos; Transformação digital; Sustentabilidade.

1INTRODUÇÃO

O ritmo gradativo de crescimento da população, do processo de urbanização e de uso da tecnologia, amplia significativamente a produção industrial e a aquisição de bens de consumo. Em virtude disso, dois fatos podem ser observados: a quantidade de Resíduos Sólidos gerada aumenta (Gouveia, 2012; Ripa *et al.*, 2017; Rong *et al.*, 2017) e, o dia a dia do trânsito municipal, é prejudicado (CNT, 2018b). Enquanto empresas crescem e são favorecidas com este comportamento consumista, o modelo deixa problemas ambientais, sociais e de saúde pública no mundo inteiro (Gouveia, 2012). Por isso, torna-se fundamental que esses fatores citados sejam levados em conta pela gestão governamental, com o intuito de agregar qualidade de vida para a população, reduzindo os congestionamentos e a poluição ambiental (CNT, 2018b).

Entre os países de maior extensão territorial do mundo (IBGE, 2018), o Brasil possui dentro de suas fronteiras 8,5 milhões de km² em área total. Distribuí seu espaço geográfico em 5 regiões, 27 estados e 5.570 municípios (IBGE, 2019). Dispõe em todo o território 1,7 milhões de km em rodovias (CNT, 2018a) e têm registrados no Departamento Nacional de Trânsito 99,6 milhões de veículos aptos para o tráfego (DENATRAN, 2019). De acordo com o censo realizado em 2010, essa infraestrutura está distribuída entre 190,8 milhões de pessoas. E, estima-se que no ano de 2019 esse quantitativo tenha crescido 10% (IBGE, 2019).

No ano de 2019 a geração de resíduos no Brasil foi de 79,06 milhões de toneladas, representando um crescimento de 18,65% com relação ao ano de 2010, ano em que a Política Nacional de Resíduos Sólidos (PNRS) foi lançada (ABRELPE, 2020). Os rejeitos gerados pela sociedade precisam da atenção das gestões municipais através da implementação de estratégias a curto, médio e longo prazo (MMA, 2011), uma vez que, a parcela de recursos públicos ou privados destinados a gestão de resíduos é insuficiente para proporcionar uma infraestrutura que minimize deficiências (ONU, 2017). Por esse motivo, soluções que proporcionem melhoria no custo, na qualidade da coleta, na destinação final do lixo (ONU, 2015), na gestão de serviços de transporte e disposição final dos resíduos (MMA, 2011) são vitais para melhoria do ciclo (ONU, 2015).

Considerando todos os fatos citados, torna-se fundamental o gerenciamento dos recursos naturais, bens e produtos em busca da sustentabilidade em todos os âmbitos citados. Arantes, Vieira Neto e Cardoso (2014) concluem que sustentabilidade “busca a garantia dos aspectos econômicos, sociais, culturais, educacionais, permitindo o preenchimento das necessidades humanas e preservando os ecossistemas para as futuras gerações por meio do planejamento de ações eficientes a longo prazo”.

Nesse contexto, o uso de técnicas computacionais pode se tornar uma ferramenta eficaz para otimizar o gerenciamento da Coleta de Resíduos Sólidos Urbanos tornando o processo mais produtivo e sustentável com capacidade de diminuir as distâncias excedentes no trajeto, possibilitar o transporte máximo de resíduos, reduzir desperdícios aumentando a eficiência no uso de energia e minimizar as emissões geradas.

Referências

- Abbasi, M., & El Hanandeh, A. (2016). Forecasting municipal solid waste generation using artificial intelligence modelling approaches. *Waste Management*, 56, 13-22. doi:10.1016/j.wasman.2016.05.018
- Abbasi, M., Rastgoo, M. N., & Nakisa, B. (2019). Monthly and seasonal modeling of municipal waste generation using radial basis function neural network. *Environmental Progress & Sustainable Energy*, 38(3), 10. doi:10.1002/ep.13033
- Abdallah, M., Abu Talib, M., Feroz, S., Nasir, Q., Abdalla, H., & Mahfood, B. (2020). Artificial intelligence applications in solid waste management: A systematic research review. *Waste Management*, 109, 231-246. doi:10.1016/j.wasman.2020.04.057
- Adamovic, V. M., Antanasijevic, D. Z., Ristic, M. A., Peric-Grujic, A. A., & Pocajt, V. V. (2017). Prediction of municipal solid waste generation using artificial neural network approach enhanced by structural break analysis. *Environmental Science and Pollution Research*, 24(1), 299-311. doi:10.1007/s11356-016-7767-x
- Adamovic, V. M., Antanasijevic, D. Z., Ristic, M. D., Peric-Grujic, A. A., & Pocajt, V. V. (2018). An optimized artificial neural network model for the prediction of rate of hazardous chemical and healthcare waste generation at the national level. *Journal of Material Cycles and Waste Management*, 20(3), 1736-1750. doi:10.1007/s10163-018-0741-6
- Ahmmmed, M. S., Arif, M. F., & Hossain, M. M. (2020). Prediction of solid waste generation and finding the sustainable pathways in the city of Dhaka. *Management of Environmental Quality*, 31(6), 1587-1601. doi:10.1108/meq-10-2019-0214
- Ali, S. A., & Ahmad, A. (2019). Forecasting MSW generation using artificial neural network time series model: a study from metropolitan city. *Sn Applied Sciences*, 1(11), 16. doi:10.1007/s42452-019-1382-7
- Araiza-Aguilar, J. A., Rojas-Valencia, M. N., & Aguilar-Vera, R. A. (2020). Forecast generation model of municipal solid waste using multiple linear regression. *Global Journal of Environmental Science and Management-Gjesm*, 6(1), 1-14. doi:10.22034/gjesm.2020.01.01
- Azadi, S., & Karimi-Jashni, A. (2016). Verifying the performance of artificial neural network and multiple linear regression in predicting the mean seasonal municipal solid waste generation rate: A case study of Fars province, Iran. *Waste Management*, 48, 14-23. doi:10.1016/j.wasman.2015.09.034
- Azarmi, S. L., Oladipo, A. A., Vaziri, R., & Alipour, H. (2018). Comparative Modelling and Artificial Neural Network Inspired Prediction of Waste Generation Rates of Hospitality Industry: The Case of North Cyprus. *Sustainability*, 10(9), 18. doi:10.3390/su10092965
- Babaee Tirkolaee, E., Abbasian, P., Soltani, M., & Ghaffarian, S. A. (2019). Developing an applied algorithm for multi-trip vehicle routing problem with time windows in urban waste collection: A case study. *Waste Management and Research*, 37(1_suppl), 4-13.

doi:10.1177/0734242X18807001

- Baghban, A., & Shamshirband, S. (2019). On the estimation of higher heating value of municipal wastes using soft computing approaches. *Energy Sources Part a-Recovery Utilization and Environmental Effects*, 9. doi:10.1080/15567036.2019.1645764
- Bagheri, M., Esfilar, R., Golchi, M. S., & Kennedy, C. A. (2019). A comparative data mining approach for the prediction of energy recovery potential from various municipal solid waste. *Renewable & Sustainable Energy Reviews*, 116, 12. doi:10.1016/j.rser.2019.109423
- Boumanchar, I., Chhiti, Y., Ataoui, F. E. M., Sahibed-dine, A., Bentiss, F., Jama, C., & Bensitel, M. (2019). Municipal solid waste higher heating value prediction from ultimate analysis using multiple regression and genetic programming techniques. *Waste Management & Research*, 37(6), 578-589. doi:10.1177/0734242x18816797
- Buenrostro-Delgado, O., Ortega-Rodriguez, J. M., Clemitschaw, K. C., González-Razo, C., & Hernández-Paniagua, I. Y. (2015). Use of genetic algorithms to improve the solid waste collection service in an urban area. *Waste management*, 41, 20-27.
- Cavallin, A., Rossit, D. G., Symonds, V. H., Rossit, D. A., & Frutos, M. (2020). Application of a methodology to design a municipal waste pre-collection network in real scenarios. *Waste Management & Research*, 38(1_SUPPL), 117-128. doi:10.1177/0734242x19894630
- Ceylan, Z. (2020). Estimation of municipal waste generation of Turkey using socio-economic indicators by Bayesian optimization tuned Gaussian process regression. *Waste Management & Research*, 38(8), 840-850. doi:10.1177/0734242x20906877
- Ceylan, Z., Bulkan, S., & Elevli, S. (2020). Prediction of medical waste generation using SVR, GM (1,1) and ARIMA models: a case study for megacity Istanbul. *Journal of Environmental Health Science and Engineering*, 11. doi:10.1007/s40201-020-00495-8
- Chhay, L., Reyad, M. A. H., Suy, R., Islam, M. R., & Mian, M. M. (2018). Municipal solid waste generation in China: influencing factor analysis and multi-model forecasting. *Journal of Material Cycles and Waste Management*, 20(3), 1761-1770. doi:10.1007/s10163-018-0743-4
- Cobo, M. J., López-Herrera, A. G., Herrera-Viedma, E., & Herrera, F. (2011). An approach for detecting, quantifying, and visualizing the evolution of a research field: A practical application to the fuzzy sets theory field. *Journal of informetrics*, 5(1), 146-166.
- Colvero, D. A., Feitosa, A. K., Ramalho, J. C., Gomes, A. P. D., Tarelho, L. A. D., & de Matos, M. A. A. (2019). Per capita municipal solid waste generation and its relationship with socioeconomic and demographic factors in Goias State, Brazil. *Revista Tecnologia E Sociedade*, 15(36), 254-+. doi:10.3895/rts.v15n36.8757
- Coskuner, G., Jassim, M. S., Zontul, M., & Karateke, S. (2020). Application of artificial intelligence neural network modeling to predict the generation of domestic, commercial and construction wastes. *Waste Management & Research*, 9. doi:10.1177/0734242x20935181

- Dai, F., Nie, G. H., & Chen, Y. (2020). The municipal solid waste generation distribution prediction system based on FIG-GA-SVR model. *Journal of Material Cycles and Waste Management*, 22(5), 1352-1369. doi:10.1007/s10163-020-01022-5
- Das, S., & Bhattacharyya, B. K. (2015). Optimization of municipal solid waste collection and transportation routes. *Waste Management*, 43, 9-18. doi:10.1016/j.wasman.2015.06.033
- Drudi, K. C. R., Drudi, R., Martins, G., Antonio, G. C., & Leite, J. T. C. (2019). Statistical model for heating value of municipal solid waste in Brazil based on gravimetric composition. *Waste Management*, 87, 782-790. doi:10.1016/j.wasman.2019.03.012
- Faccio, M., Persona, A., & Zanin, G. (2011). Waste collection multi objective model with real time traceability data. *Waste Management*, 31(12), 2391-2405. doi:10.1016/j.wasman.2011.07.005
- Fayyad, U. M., Piatetsky-Shapiro, G., & Smyth, P. (1996, August). Knowledge Discovery and Data Mining: Towards a Unifying Framework. In *KDD* (Vol. 96, pp. 82-88).
- Fernandez-Brana, A., Sousa, V., & Dias-Ferreira, C. (2020). A structured methodology to understand municipal waste generation at local level with minimized effort: development and case study. *Environmental Science and Pollution Research*, 16. doi:10.1007/s11356-020-11108-0
- Hannan, M., Akhtar, M., Begum, R., Basri, H., Hussain, A., & Scavino, E. (2018). Capacitated vehicle-routing problem model for scheduled solid waste collection and route optimization using PSO algorithm. *Waste management*, 71, 31-41.
- Hartnett, T. Q., Ayyasamy, M. V., & Balachandran, P. V. (2019). Prediction of new iodine-containing apatites using machine learning and density functional theory. *Mrs Communications*, 9(3), 882-890. doi:10.1557/mrc.2019.103
- Hoornweg, D., & Bhada-Tata, P. (2012). What a waste: a global review of solid waste management.
- Hoque, M. M., & Rahman, M. T. U. (2020). Landfill area estimation based on solid waste collection prediction using ANN model and final waste disposal options. *Journal of Cleaner Production*, 256, 12. doi:10.1016/j.jclepro.2020.120387
- Imran, Ahmad, S., & Kim, D. H. (2020). Quantum GIS Based Descriptive and Predictive Data Analysis for Effective Planning of Waste Management. *IeeeAccess*, 8, 46193-46205. doi:10.1109/access.2020.2979015
- IPEA, Antenor, S. & Szigethy, L. (2020). Resíduos sólidos urbanos no Brasil: desafios tecnológicos, políticos e econômicos. Publicado em: 09 de julho de 2020. Última modificação em: 23 de dezembro de 2020. Disponível em:
<<https://www.ipea.gov.br/cts/pt/central-de-conteudo/artigos/artigos/217-residuos-solidos-urbanos-no-brasil-desafios-tecnologicos-politicos-e-economicos>> Acessado em: 08 de março de 2021

Kang, L., Du, H. L., Zhang, H., & Ma, W. L. (2018). Systematic Research on the Application of Steel Slag Resources under the Background of Big Data. *Complexity*, 12. doi:10.1155/2018/6703908

Kannangara, M., Dua, R., Ahmadi, L., & Bensebaa, F. (2018). Modeling and prediction of regional municipal solid waste generation and diversion in Canada using machine learning approaches. *Waste Management*, 74, 3-15. doi:10.1016/j.wasman.2017.11.057
Kolekar, K. A., Hazra, T., & Chakrabarty, S. N. (2017). Prediction of municipal solid waste generation for developing countries in temporal scale: A fuzzy inference system approach. *Global Nest Journal*, 19(3), 511-520.

Kontokosta, C. E., Hong, B., Johnson, N. E., & Starobin, D. (2018). Using machine learning and small area estimation to predict building-level municipal solid waste generation in cities. *Computers Environment and Urban Systems*, 70, 151-162. doi:10.1016/j.compenvurbsys.2018.03.004

Korhonen, P., & Kaila, J. (2015). Waste container weighing data processing to create reliable information of household waste generation. *Waste Management*, 39, 15-25. doi:10.1016/j.wasman.2015.02.021

Kumar, A., & Samadder, S. R. (2017). An empirical model for prediction of household solid waste generation rate - A case study of Dhanbad, India. *Waste Management*, 68, 3-15. doi:10.1016/j.wasman.2017.07.034

Kumar, A., Samadder, S. R., Kumar, N., & Singh, C. (2018). Estimation of the generation rate of different types of plastic wastes and possible revenue recovery from informal recycling. *Waste Management*, 79, 781-790. doi:10.1016/j.wasman.2018.08.045

Kumar, S., Nimchuk, N., Kumar, R., Zietsman, J., Ramani, T., Spiegelman, C., & Kenney, M. (2016). Specific model for the estimation of methane emission from municipal solid waste landfills in India. *Bioresource Technology*, 216, 981-987. doi:10.1016/j.biortech.2016.06.050

Kupusamy, K., Nagapan, S., Abdullah, A., Kaliannan, S., Sohu, S., Subramaniam, S., & Maniam, H. (2019). Construction Waste Estimation Analysis in Residential Projects of Malaysia. *Engineering Technology & Applied Science Research*, 9(5), 4842-4845.

Kvasničková-Stanislavská, L., Pilař, L., Margarisovalová, K., & Kvasnička, R. (2020). Corporate Social Responsibility and social media: Comparison between developing and developed countries. *Sustainability*, 12(13), 5255.

Leary, A., Cook, R., Jones, S., Radford, M., Smith, J., Gough, M., & Punshon, G. (2020). Using knowledge discovery through data mining to gain intelligence from routinely collected incident reporting in an acute English hospital. *International journal of health care quality assurance*.

Li, J., Pan, L. J., Suvarna, M., Tong, Y. W., & Wang, X. N. (2020). Fuel properties of hydrochar and pyrochar: Prediction and exploration with machine learning. *Applied Energy*, 269, 10. doi:10.1016/j.apenergy.2020.115166

- Li, Y., Zhou, L. W., & Wang, R. Z. (2017). Urban biomass and methods of estimating municipal biomass resources. *Renewable & Sustainable Energy Reviews*, 80, 1017-1030. doi:10.1016/j.rser.2017.05.214
- Li, Y. S., Zhang, X. Q., Ding, G. Y., & Feng, Z. Q. (2016). Developing a quantitative construction waste estimation model for building construction projects. *Resources Conservation and Recycling*, 106, 9-20. doi:10.1016/j.resconrec.2015.11.001
- Ma, S. J., Zhou, C. B., Chi, C., Liu, Y. J., & Yang, G. (2020). Estimating Physical Composition of Municipal Solid Waste in China by Applying Artificial Neural Network Method. *Environmental Science & Technology*, 54(15), 9609-9617. doi:10.1021/acs.est.0c01802
- McInnes, M. D., Moher, D., Thombs, B. D., McGrath, T. A., Bossuyt, P. M., Clifford, T., ... & Hunt, H. A. (2018). Preferred reporting items for a systematic review and meta-analysis of diagnostic test accuracy studies: the PRISMA-DTA statement. *Jama*, 319(4), 388-396.
- Nair, V. V., Dhar, H., Kumar, S., Thalla, A. K., Mukherjee, S., & Wong, J. W. C. (2016). Artificial neural network based modeling to evaluate methane yield from biogas in a laboratory-scale anaerobic bioreactor. *Bioresource Technology*, 217, 90-99. doi:10.1016/j.biortech.2016.03.046
- Niu, R. X., Wu, C. F., Yue, B., Song, N., & Wang, Q. H. (2020). Estimation and prediction of the generation of waste organic solvents in China. *Journal of Material Cycles and Waste Management*, 22(4), 1094-1102. doi:10.1007/s10163-020-01002-9
- Nowakowski, T. J., Bhaduri, A., Pollen, A. A., Alvarado, B., Mostajo-Radji, M. A., Di Lullo, E., ... Velmeshev, D. (2017). Spatiotemporal gene expression trajectories reveal developmental hierarchies of the human cortex. *Science*, 358(6368), 1318-1323.
- Oliveira, V., Sousa, V., & Dias-Ferreira, C. (2019). Artificial neural network modelling of the amount of separately-collected household packaging waste. *Journal of Cleaner Production*, 210, 401-409. doi:10.1016/j.jclepro.2018.11.063
- ONU, Organizaçāo das Naçōes Unidas A ONU e o meio ambiente Disponível em:
<<https://brasil.un.org/pt-br/91223-onu-e-o-meio-ambiente>> Acessado em: 07 de março de 2021
- Perez-Alonso, D., Pena-Tejedor, S., Navarro, M., Rad, C., Arnaiz-Gonzalez, A., & Diez-Pastor, J. F. (2017). Decision Trees for the prediction of environmental and agronomic effects of the use of Compost of Sewage Sludge (CSS). *Sustainable Production and Consumption*, 12, 119-133. doi:10.1016/j.spc.2017.07.001
- Perez-Lopez, G., Prior, D., Zafra-Gomez, J. L., & Plata-Diaz, A. M. (2016). Cost efficiency in municipal solid waste service delivery. Alternative management forms in relation to local population size. *European Journal of Operational Research*, 255(2), 583-592. doi:10.1016/j.ejor.2016.05.034
- Pollock, A., & Berge, E. (2018). How to do a systematic review. *International Journal of Stroke*, 13(2), 138-156.

- Rostami, A., & Baghban, A. (2018). Application of a supervised learning machine for accurate prognostication of higher heating values of solid wastes. *Energy Sources Part a-Recovery Utilization and Environmental Effects*, 40(5), 558-564. doi:10.1080/15567036.2017.1360967
- Severo, P. P., Furstenau, L. B., Sott, M. K., Cossul, D., Bender, M. S., & Bragazzi, N. L. (2021). Thirty Years of Human Rights Study in the Web of Science Database (1990–2020). *International Journal of Environmental Research and Public Health*, 18(4), 2131.
- Singh, D., & Satija, A. (2018). Prediction of municipal solid waste generation for optimum planning and management with artificial neural network-case study: Faridabad City in Haryana State (India). *International Journal of System Assurance Engineering and Management*, 9(1), 91-97. doi:10.1007/s13198-016-0484-5
- Sott, M. K., Furstenau, L. B., Kipper, L. M., Giraldo, F. D., Lopez-Robles, J. R., Cobo, M. J., ... & Imran, M. A. (2020). Precision Techniques and Agriculture 4.0 Technologies to Promote Sustainability in the Coffee Sector: State of the Art, Challenges and Future Trends. *IEEE Access*, 8, 149854-149867.
- Sott, M. K., Bender, M. S., Furstenau, L. B., Machado, L. M., Cobo, M. J., & Bragazzi, N. L. (2020b). 100 years of scientific evolution of work and organizational psychology: a bibliometric network analysis from 1919 to 2019. *Frontiers in Psychology*, 11.
- Sott, M. K., Furstenau, L. B., Kipper, L. M., Rodrigues, Y. P. R., López-Robles, J. R., Giraldo, F. D., & Cobo, M. J. (2021). Process modeling for smart factories: using science mapping to understand the strategic themes, main challenges and future trends. *Business Process Management Journal*.
- Stewart, L. A., Clarke, M., Rovers, M., Riley, R. D., Simmonds, M., Stewart, G., & Tierney, J. F. (2015). Preferred reporting items for a systematic review and meta-analysis of individual participant data: the PRISMA-IPD statement. *Jama*, 313(16), 1657-1665.
- Van Eck, N. J., & Waltman, L. (2010). Software survey: VOSviewer, a computer program for bibliometric mapping. *Scientometrics*, 84(2), 523-538.
- van Turnhout, A. G., Kleerebezem, R., & Heimovaara, T. J. (2016). A toolbox to find the best mechanistic model to predict the behavior of environmental systems. *Environmental Modelling & Software*, 83, 344-355. doi:10.1016/j.envsoft.2016.05.002
- Vu, H. L., Bolingbroke, D., Ng, K. T. W., & Fallah, B. (2019). Assessment of waste characteristics and their impact on GIS vehicle collection route optimization using ANN waste forecasts. *Waste Management*, 88, 118-130. doi:10.1016/j.wasman.2019.03.037
- Vu, H. L., Ng, K. T. W., & Bolingbroke, D. (2019). Time-lagged effects of weekly climatic and socio-economic factors on ANN municipal yard waste prediction models. *Waste Management*, 84, 129-140. doi:10.1016/j.wasman.2018.11.038
- Wang, Y., Shao, Y. X., Matovic, M. D., & Whalen, J. K. (2016). Recycling combustion ash for sustainable cement production: A critical review with data-mining and time-series predictive models. *Construction and Building Materials*, 123, 673-689. doi:10.1016/j.conbuildmat.2016.07.031

Yang, Q., Zhu, Y. X., Liu, X. X., Fu, L. M., & Guo, Q. Q. (2019). Bayesian-Based NIMBY Crisis Transformation Path Discovery for Municipal Solid Waste Incineration in China. *Sustainability*, 11(8), 21. doi:10.3390/su11082364

Yang, W. T., Fan, B., & Desouza, K. C. (2019). Spatial-temporal effect of household solid waste on illegal dumping. *Journal of Cleaner Production*, 227, 313-324. doi:10.1016/j.jclepro.2019.04.173

Çetinkaya, A. Y., Kuzu, S. L., & Demir, A. (2020). Medical waste management in a mid-populated Turkish city and development of medical waste prediction model. *Environment Development and Sustainability*, 22(7), 6233-6244. doi:10.1007/s10668-019-00474-6