

Previsão de geração de resíduos sólidos para o aterro de Aparecida de Goiânia (GO) por séries temporais

Forecasting of solid waste generation for the Aparecida de Goiânia (GO), Brazil, landfill by time series

Leonardo Rodrigues de Oliveira Merelles^{1*} , Cláudio de Oliveira e Silva¹,
Marta Pereira da Luz¹, José Elmo de Menezes¹, Viviane de Souza Dias¹

RESUMO

Um sistema eficaz e robusto de tratamento de resíduos sólidos urbanos requer um modelo de previsão adequado para auxiliar seu gerenciamento. Neste trabalho foi realizada, utilizando séries temporais, a análise da projeção de geração dos resíduos sólidos no aterro do município de Aparecida de Goiânia, localizado no estado de Goiás. Para a compreensão da geração de resíduos foram analisadas as influências exercidas por variáveis climáticas e incentivos governamentais. O modelo que melhor se ajustou ao fenômeno estudado foi o autorregressivo integrado de média móvel sazonal (SARIMA), em decorrência da existência de sazonalidade na série temporal analisada. Como principal resultado, a previsão para a geração de resíduos sólidos urbanos em Aparecida de Goiânia projetou redução do volume produzido até 2018. A sazonalidade na geração de resíduos sólidos urbanos não ocorre por causa da influência de variáveis climáticas. A modelagem dos resíduos sólidos urbanos pode auxiliar na tomada de decisões e no gerenciamento da coleta, além de contribuir para o controle dos impactos ambientais.

Palavras-chave: resíduos sólidos; previsão; séries temporais.

ABSTRACT

An effective and robust municipal solid-waste-treatment system requires a suitable forecast model to assist in its management. This work was carried out, using time series, an analysis of the projection of solid waste generation in the landfill of Aparecida de Goiânia, located in the State of Goiás. In order to understand the generation of residues, we analyzed the influences exerted by climatic variables and governmental incentives. The model that best fit the studied phenomenon was SARIMA, due to the presence of seasonality in the analyzed time series. As a main result, the forecast for the generation of solid urban waste in Aparecida de Goiânia projected a reduction of the volume produced until 2018. Seasonality in the generation of municipal solid waste does not occur due to the influence of climatic variables. The modeling of municipal solid waste can aid in decision-making and collection management, as well as in contributing to the environmental impacts control.

Keywords: solid waste; forecast; time series.

INTRODUÇÃO

A geração de resíduos sólidos urbanos (RSU) nos países em desenvolvimento tem acelerado por causa do aumento populacional, da expansão da economia, da rápida urbanização e da melhoria no padrão de vida da sociedade (XU *et al.*, 2013). Após a década de 1990, o aumento no volume gerado de RSU próximos aos centros urbanos tornou-se um problema ambiental, com elevado impacto negativo. A má gestão dos RSU pode gerar problemas, tais como o odor desagradável, a contaminação de água subterrânea e o risco de explosão (ANTANASIJEVIĆ *et al.*, 2013; MOR *et al.*, 2006).

A previsão da geração de RSU é fundamental para o processo de planejamento do volume de resíduos produzidos. A estimativa serve como base para adequação de infraestrutura, desenvolvimento sustentável, otimização de recursos utilizados no tratamento dos RSU (ABBASI; EL HANANDEH, 2016) e tomada de decisão (DENAFAS *et al.*, 2014). Entretanto, alcançar a previsão desejada é desafiador, pois envolve elementos importantes, como escala espacial, identificação temporal, fatores influentes e métodos de previsão (BEIGL; LEBERSORGER; SALHOFER, 2008), além de falta de dados históricos em países em desenvolvimento (RIMAITYTĖ *et al.*, 2012).

¹Pontifícia Universidade Católica de Goiás - Goiânia (GO), Brasil.

*Autor correspondente: leonardotringo@gmail.com

Recebido: 27/07/2017 - Aceito: 26/04/2018 - Reg. ABES: 183284

As principais abordagens de previsão de geração de RSU utilizadas em pesquisas realizadas sobre o tema a partir de 2010 foram: análise de regressão (DENAFAS *et al.*, 2014; RIMAITYTË *et al.*, 2012), modelo de fluxo de materiais (TONJES & GREENE, 2012; ZHANG *et al.*, 2012), sistema de modelos dinâmicos (KOLLIKATHARA, FENG & YU, 2010), análise de séries temporais (RIMAITYTË *et al.*, 2012; XU *et al.*, 2013) e modelos de inteligência artificial (ABBASI; EL HANANDEH, 2016; KUMAR; SUBBAIAH; PRASADA-RAO, 2011).

Entre os modelos apresentados, a análise de regressão com dados econômicos e geográficos (DENAFAS *et al.*, 2014) é o mais frequente. Para Xu *et al.* (2013), isso está associado à simples aplicação do método. O modelo de fluxo de materiais consiste na análise de subgrupos e da influência de fatores que impactam a geração de RSU (ABDOLI *et al.*, 2012). A análise de séries temporais consiste em capturar a influência do tempo na série analisada, possibilitando a sua projeção (RIMAITYTË *et al.*, 2012). O modelo de inteligência artificial consiste em uma técnica de aprendizagem, na qual o desafio é determinar os pesos e o índice de aprendizagem (ABBASI; EL HANANDEH, 2016).

No Brasil, de 2010 a 2014, a produção de RSU cresceu 29% (ABRELPE, 2014), demandando mais serviços de logística (COUTO & LANGE, 2017), tratamento para redução dos impactos (GOMES *et al.*, 2017), infraestrutura, postos de trabalho diretos e recursos financeiros. No contexto da discussão apresentada anteriormente, os objetivos deste trabalho foram modelar e realizar a previsão de geração de RSU na cidade de Aparecida de Goiânia, em Goiás, aplicando séries temporais considerando o horizonte de médio prazo; e verificar a influência da variabilidade de geração de resíduos sólidos em função de variáveis climáticas (temperatura e precipitação) e incentivos governamentais.

ANÁLISE DE SÉRIES TEMPORAIS

Na aplicação dos modelos de Box e Jenkins, não é necessário que a série temporal estudada seja estacionária, podendo apresentar tendência ou sazonalidade (MORETTIN & TOLOI, 2011). A série temporal pode ser decomposta como apresentado na Equação 1.

$$Y_t = T_t + S_t + a_t \quad (1)$$

Em que:

Y_t = série temporal, podendo assumir valores de $t = 1, \dots, n$ com n representando a observação no tempo;

T_t = tendência ao longo do período;

S_t = sazonalidade ocorrida nos períodos;

a_t = componente aleatória ou erro, que mostra as oscilações aleatórias irregulares com média zero e variância constante $N(0, \sigma^2)$. Para um bom ajuste do modelo, faz-se necessário que a_t seja um ruído branco.

Para analisar a estacionariedade de uma série temporal, são calculados os coeficientes da função de autocorrelação amostral (FAC) e a função de autocorrelação amostral parcial (FACP) com as suas defasagens. Os coeficientes devem variar entre o intervalo de confiança (IC) da estatística FAC e FACP, exceto para as primeiras defasagens. O IC pode ser definido pela Equação 2.

$$IC = \frac{t_y}{\sqrt{N}} \quad (2)$$

Em que:

IC = intervalo de confiança;

t_y = valor da estatística t de Student com $N-1$ graus de liberdade (na prática, t_y é igual a 2 — MORETTIN & TOLOI, 2011);

N = tamanho da amostra.

Pode ser aplicado também o teste de Dickey e Fuller (1979) para hipótese nula de existência de raiz unitária, confirmando, assim, o comportamento da série. Se uma série temporal Y_t converge para $t = \infty$, ela será: estacionária para $|\rho| < 1$; não estacionária para $|\rho| > 1$; e passeio aleatório quando $\rho = 1$. No entanto, o teste Dickey-Fuller aumentado (ADF) é recomendado para evitar autocorrelação dos resíduos, pois engloba a defasagem para eliminar os resíduos (DICKEY; FULLER, 1981).

Quando a série temporal não apresenta sazonalidade e o seu comportamento é não estacionário, pode ser aplicado o modelo autorregressivo integrado de média móvel (ARIMA) (p, d, q) (MONTGOMERY; JENNINGS; KULAHCI, 2015). Essas especificações representam os parâmetros:

- (p) número de modelos autorregressivos;
- (d) quantidade de diferenciações;
- (q) número de média móvel aplicada.

O modelo pode ser representado pela Equação 3.

$$\phi(B)(1 - B)^d Y_t = \delta + \theta(B)a_t \quad (3)$$

Em que:

$\phi(B)$ = polinômio autorregressivo de ordem (p) $(1 - \phi_1 B^1 - \dots - \phi_p B^p)$;

B = operador de retardo ($B^j Y_t = Y_{t-j}$);

d = quantidade de diferenciações necessárias para tornar a série estacionária;

δ = média $\mu(1 - \phi_1 - \phi_p)$;

$\Theta(B)$ = polinômio de média móvel de ordem (q) $(1 - \phi_1 B^1 - \dots - \phi_q B^q)$.

A identificação do grau de diferenciação d ocorre através da FAC. Os valores da FAC precisam cair exponencialmente e estabilizar entre os limites, caracterizando, assim, a série estacionária. O teste de raiz unitária deve ser aplicado para identificar o número ideal de diferenciações.

As principais ferramentas para identificação do modelo ARIMA (p, 0, q) são a FACP e FAC, em que se esperam o decaimento exponencial da FAC e o truncamento da FACP, o que dificulta a análise. Porém, podem ser adotados os critérios de seleção *Akaike's Information Criterion* (AIC) e o *Bayesian Information Criterion* (BIC), definidos pelas Equações 4 e 5.

$$AIC = \delta_k^2 + \frac{n + 2k}{n} \quad (4)$$

$$BIC = \log(\delta_k^2) + \frac{(k + \log(n))}{n} \quad (5)$$

Em que:

$$\delta_k^2 = SSE/N$$

$$SSE = \sum_{t=1}^N (Y_t - \bar{Y})^2$$

SSE = soma do quadrado dos resíduos;

δ_k^2 = estimador da máxima verossimilhança;

n = tamanho da amostra;

k = número de parâmetros do modelo.

Entre os vários modelos gerados, escolhe-se aquele que apresenta os menores valores de AIC e BIC. Vale salientar também, que a escolha deverá levar em consideração os modelos que apresentam o menor número de parâmetros. Por fim, é recomendável que os critérios AIC e BIC sejam avaliados conjuntamente, pois são complementares e não excludentes.

Quando a série temporal apresenta um comportamento sazonal em determinado período, faz-se necessário acrescentar essa componente ao modelo. A distância entre os intervalos sazonais ao longo do tempo pode ser determinada pela Equação 6.

$$\nabla_s Y_s = (1 - B^s)Y_T = Y_T - Y_{T-s} \quad (6)$$

Em que:

∇_s = diferença sazonal;

Y_T = série temporal;

Y_s = componente determinística com periodicidade s;

B = operador de retardo.

Determinado o intervalo sazonal, o modelo SARIMA (p, d, q) (P, D, Q)s pode ser obtido pela equação multiplicativa (Equação 7).

$$\phi_p(B)\phi_p(B^s)(1 - B)^d(1 - B^s)^d Y_t = \theta_q(B)\Theta_q(B^s)a_t \quad (7)$$

Em que:

$\Phi_p(B^s)$ e $\Theta_q(B^s)$ = polinômios sazonais autorregressivos e média móvel de ordem (P) e (Q), respectivamente;

p = número de modelos autorregressivos;

d = quantidade de diferenciações;

q = número de média-móvel aplicada;

P = ordem sazonal autorregressiva;

D = diferença sazonal;

Q = ordem sazonal de média-móvel;

S = período sazonal.

Para ajuste do modelo SARIMA são necessárias quatro etapas: análise dos valores da FAC e FACP; estimativa dos parâmetros desconhecidos; teste do ajuste de qualidade dos resíduos; e avaliação da previsão (TSENG & TZENG, 2002).

Para realizar a análise da série temporal, a adoção de um *software* é fundamental para auxiliar na elaboração e interpretação dos resultados (R DEVELOPMENT CORE TEAM, 2016). Em alguns casos, essa aquisição pode ser elevada, levando à busca de *softwares* livres como Octave ou R.

METODOLOGIA

Nesta seção serão apresentados os dados aplicados, a área de estudo, o método utilizado para determinar o modelo de previsão, o *software* aplicado para realizar as análises das projeções e as medidas de desempenho utilizadas.

Dados e área de estudo

Aparecida de Goiânia é uma das principais cidades do estado de Goiás, com área de 290 km². Está localizada na região metropolitana de Goiânia, a 222 km de Brasília, Distrito Federal (capital do Brasil), e é a segunda cidade mais populosa do estado, com mais de 532 mil habitantes em 2016 e geração de 217 kg de RSU *per capita* (Companhia de Urbanização de Goiânia — COMURG), anualmente. A cidade possui o terceiro maior polo industrial de Goiás, atrás de Goiânia e Anápolis. A sua arrecadação com os setores de serviços e indústria é de R\$ 5.834.788 e 2.793.469, respectivamente (IBGE, 2017).

Para desenvolver o modelo de previsão, um total de 151 registros mensais de dados de RSU foram coletados do município de Aparecida de Goiânia por um período superior a 12 anos, a partir de 2004.

Os dados climáticos da cidade foram obtidos na base de dados do Instituto Nacional de Meteorologia (INMET, 2017) e *National Oceanic and Atmospheric Administration* (NOAA) (2017) para avaliar a hipótese de influência na geração de RSU. As falhas existentes nos dados foram corrigidas aplicando o método de Vicente-Serrano *et al.* (2010) e Ferrari e Ozaki (2014). Para testar a significância da variação na geração de RSU pela temperatura e precipitação acumulada mensal, foi aplicada a medida de associação entre duas variáveis.

Método aplicado

O algoritmo aplicado consiste em analisar a série temporal e identificar se ela é estacionária ou não estacionária, e sazonal ou não

sazonal. Caso ela seja não sazonal e não estacionária, aplica-se o modelo ARIMA (MONTGOMERY; JENNINGS; KULAHCI, 2015). Se for sazonal e não estacionária, é aplicado o modelo SARIMA (TSENG; TZENG, 2002).

Para melhor compreender a geração de RSU, inicialmente foram determinadas suas medidas de dispersão. A análise corresponde ao RSU gerado mensalmente na cidade de Aparecida de Goiânia; o intervalo de tempo de modelagem foi compreendido entre 2004 e 2014 (com periodicidade mensal, contendo 120 períodos); e a calibração do modelo ocorreu nos 31 meses seguintes.

Neste artigo foi aplicado o *software* R, por permitir modificar e implementar suas rotinas, além de possuir diversos pacotes destinados a analisar séries temporais. Para ajustar os parâmetros da série, foi aplicado o algoritmo de Hyndman e Khandakar (2008). O algoritmo determina a quantidade de defasagens e os parâmetros autorregressivo e média móvel.

Medidas de ajuste

Existem alguns critérios que podem ser aplicados para avaliar a qualidade do modelo de previsão (ABBASI; EL HANANDEH, 2016). Neste trabalho, a avaliação da *performance* do modelo de previsão proposta foi realizada aplicando as seguintes estatísticas: raiz do erro quadrático médio (RMSE; Equação 8); coeficiente de determinação (R^2 ; Equação 9); erro absoluto médio (MAE; Equação 10); e média absoluta percentual dos erros (MAPE; Equação 11).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |w_i - w_i^*|^2} \quad (8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (w_i - w_i^*)^2}{\sum_{i=1}^n (w_i - \bar{w})^2} \quad (9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |w_i - w_i^*| \quad (10)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{w_i - w_i^*}{w_i} \right| \quad (11)$$

Em que:

W = valor previsto;

W* = valor observado;

n = tamanho da amostra.

RESULTADOS OBTIDOS

Análise descritiva dos dados

As medidas de dispersão estão apresentadas na Tabela 1. O autovalor para o desvio padrão e o coeficiente de variação indicam que a média é pouco representativa, o que pode caracterizar a sazonalidade. A geração mensal máxima de resíduos sólidos ocorreu em janeiro de 2003 e a mínima, em julho de 2005.

Após realizar os cálculos das medidas de dispersão, foi plotada a série temporal e o *boxplot* mensal dos RSU gerados. Na Figura 1A é possível sugerir que a série temporal possui tendência, porém, torna-se necessário realizar testes estatísticos para confirmar essa hipótese. A geração de RSU apresenta maior concentração e variabilidade nos meses de dezembro e janeiro e se prolonga no início do ano, como representado na Figura 1B.

Para identificar as componentes da geração de RSU, foram retirados a sazonalidade, a tendência e os resíduos da série (MORETTIN & TOLOI, 2011). A decomposição de série temporal está apresentada na Figura 2. Nota-se que, na decomposição, o comportamento sazonal é idêntico ao longo do tempo. A tendência é de aumento até 2009 e recuo no fim de 2010. Após isso, ocorre o retorno do crescimento até 2015, que, posteriormente, é reduzido em 2016.

De acordo com Dias *et al.* (2012), o comportamento sazonal idêntico é justificado por causa do 13º salário e dos picos de tendência pelas medidas tomadas pelo governo para evitar crises financeiras. Esses elementos injetaram bilhões de reais na economia, aumentando o poder de compra e favorecendo a geração de RSU destinados aos aterros sanitários. O comportamento sazonal também ocorre devido às influências meteorológicas (ABDOLI *et al.*, 2012) e climáticas. Em períodos de baixa temperatura acontecem reduções nas gerações de RSU, mas em períodos de temperaturas mais elevadas ocorre o inverso (XU *et al.*, 2013).

Pelo coeficiente de contingência, as variáveis climáticas apresentaram associação moderada ($p = 0,45$) e baixa ($p = 0,25$) para precipitação e temperatura, nessa ordem. O pico de tendência de 2009 foi analisado pelo teste de Tukey; com 95% de certeza o comportamento da série não foi igual aos anos de 2008 e 2010 com valor p de 0,0004 e 0,0047, nessa ordem. Essa análise corrobora a hipótese de que a geração de RSU acompanha as medidas de incentivo governamental, porém, difere da hipótese de que os dados climáticos interferem na geração de RSU.

Tabela 1 - Medidas descritivas dos resíduos sólidos urbanos gerados em Aparecida de Goiânia, Goiás.

Medidas descritivas	Valor	Medidas descritivas	Valor
Média (tonelada)	8.038,57	Valor máximo (tonelada)	13.223,81
Mediana (tonelada)	8.003,94	Valor mínimo (tonelada)	5.081,54
Desvio padrão (tonelada)	1.877,89	Assimetria	0,40
Coeficiente de variação (%)	23,36	Curtose	-0,16

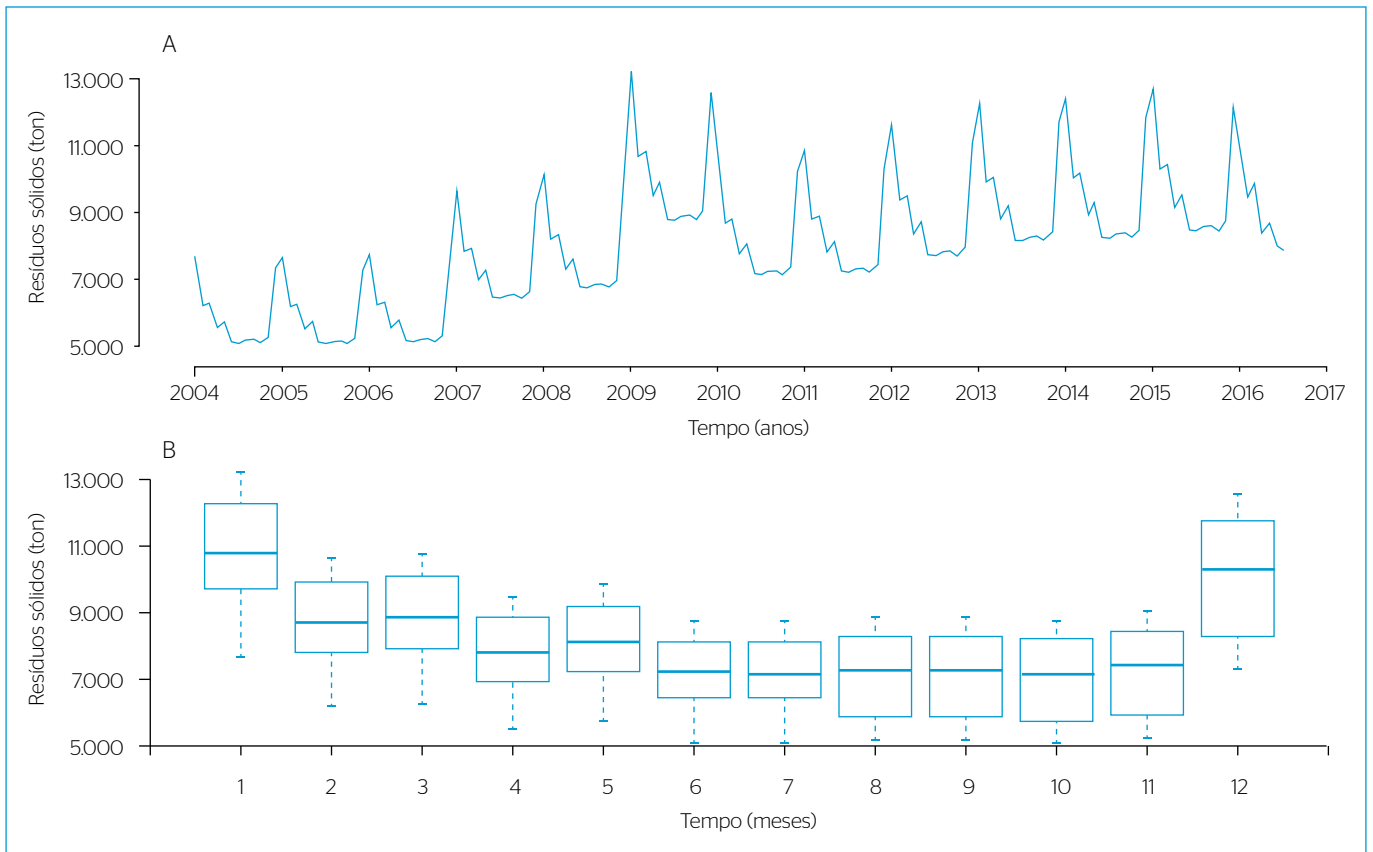


Figura 1 - Aterro sanitário de Aparecida de Goiânia, Goiás, 2004 a 2016. (A) Resíduo sólido urbano do aterro ao longo do tempo; (B) variabilidade dos resíduos sólidos.




Figura 2 - Decomposição da série temporal da geração de resíduos sólidos urbanos no aterro de Aparecida de Goiânia, Goiás.

Modelagem e previsão

A FAC e a FACP foram estimadas para dar início à modelagem. Na FAC é apresentado um decaimento na correlação e também é observado comportamento sazonal (Figura 3A). Vê-se na, Figura 3B, que os lags 1 e 2 estão fora dos limites. Esses lags aconteceram nos meses de janeiro e dezembro. Tal comportamento é considerado normal para as primeiras defasagens.

O número de defasagens foi determinado através da análise de dispersão. A análise de dispersão de uma a quatro defasagens está apresentada na Figura 4. Na análise de dependência entre as defasagens, verifica-se que a menor dispersão ocorre na primeira defasagem.

O modelo ajustado pelo algoritmo foi o SARIMA (1,0,0)(2,1,1) [12]. Os parâmetros estimados, erro padrão e IC estão apresentados




Figura 3 - Análise de correlação. (A) Análise da função de autocorrelação; (B) análise da função de autocorrelação parcial.

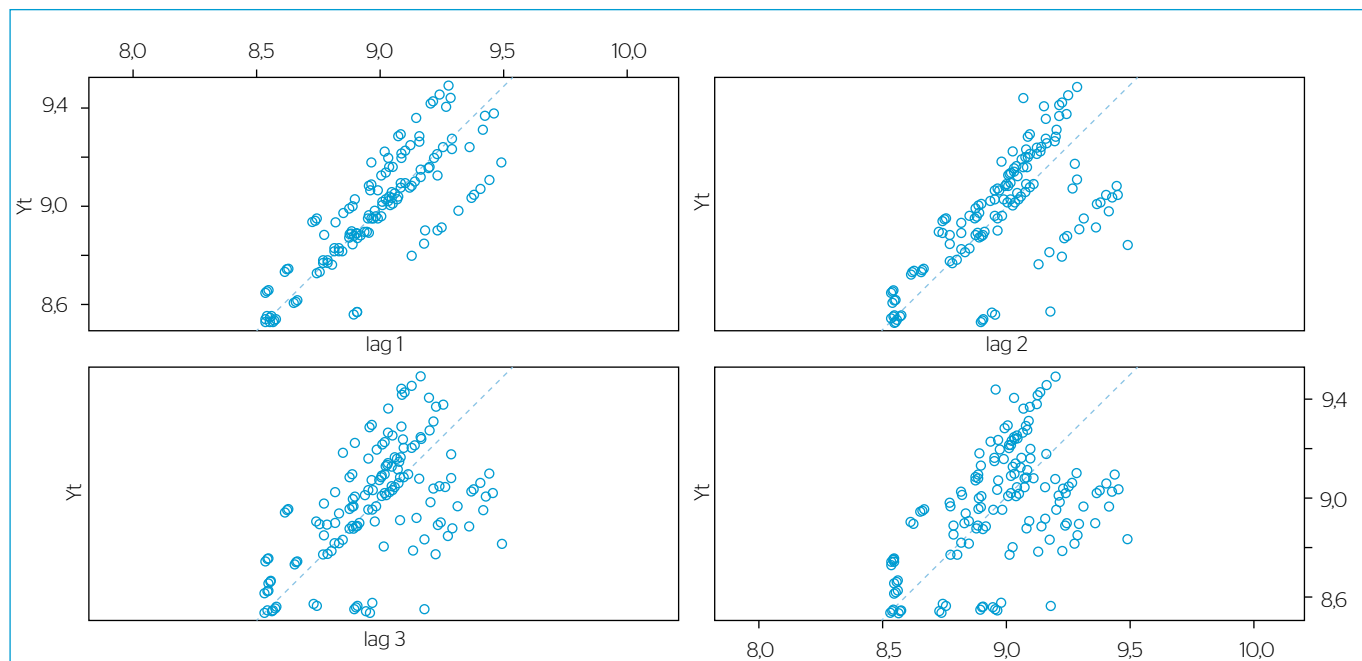


Figura 4 - Dependência entre as defasagens.

na Tabela 2. Os valores dos critérios de informações AIC e BIC foram -471,52 e -456,84, nessa ordem.

Os resíduos do modelo estimado se acumulam próximo a zero, demonstrando bom ajuste aos dados. A análise dos resíduos está apresentada na Figura 5. Os resíduos podem ser vistos no histograma (ver Figura 5A). O gráfico QQ-plot está apresentado na Figura 5B. Nela, a maioria dos resíduos se encontra em cima da reta, demonstrando que apresentam comportamento normal e apenas alguns desvios nas caudas.

As estatísticas observadas foram RMSE, R^2 , MAE e MAPE, com os valores 0,0385; 0,9742; 0,0134; e 0,1462, nessa ordem. O modelo SARIMA explicou 97,42% do ocorrido na série, demonstrando ser adequado.

Após a validação, o modelo SARIMA (1,0,0)(2,1,1)[12] pode ser aplicado para realizar previsões. A previsão realizada até junho de 2018 está apresentada na Figura 6. É observado que haverá redução na geração de RSU no aterro. A previsão para dezembro e janeiro de 2018 é de 11.372 toneladas. Essa quantidade é 2 mil toneladas abaixo da máxima

Tabela 2 - Modelo autorregressivo integrado de média móvel sazonal (SARIMA) ajustado.

Descrição	Parâmetro estimado	Erro padrão	Intervalo de confiança	
			2,5%	97,5%
ϕ_1	0,9858	0,0191	0,9482	1,0232
Φ_1	-0,1382	0,1472	-0,4267	0,1503
Φ_2	0,1587	0,1328	-0,1015	0,4190
Θ_1	-0,8678	0,1572	-1,1759	-0,5596

observada na série histórica considerada. Nos últimos 12 meses, a média de geração de RSU foi de 18,083 kg.mês⁻¹.per capita⁻¹; na projeção, a média passa para 17,265 kg.mês⁻¹.per capita⁻¹. A previsão para o aterro de Aparecida de Goiânia, Goiás, está no Apêndice 1.

Ao observar outros modelos, destacam-se Abdoli *et al.* (2012), que analisaram o modelo de regressão e redes neurais e concluíram que as redes neurais artificiais são melhores. Adamović *et al.* (2017) e Antanasijević *et al.* (2013) também defendem a aplicação dos modelos de redes artificiais para previsão dos RSU, entretanto Xu *et al.* (2013) e Denafas *et al.* (2014) demonstram que a aplicação de séries temporais possui ótima performance ao modelar e realizar as previsões de RSU. Já Dias *et al.* (2012) mostram que é possível modelar a geração de RSU por meio de índices socioeconômicos.

Assim, Abbasi e El Hanandeh (2016) testaram quatro modelos de inteligência artificial: *artificial neural network*; *adaptive neuro-fuzzy inference systems*; *support vector machine*; e *k-nearest neighbours*, que apresentaram coeficientes de determinação R^2 de 0,46; 0,98; 0,71; e 0,51, nessa ordem. Também, Adamović *et al.* (2017) avaliaram as redes neurais em vários países e chegaram ao melhor coeficiente de determinação (R^2) de 0,981, no entanto não é fácil parametrizar as redes neurais. O modelo de série temporal abordado neste trabalho resultou em um R^2 de 0,974, o que é próximo aos melhores modelos analisados aplicando redes neurais artificiais.

Quando existe característica sazonal na geração de RSU, de acordo com Xu *et al.* (2013), não é rentável dividir os recursos de gestão igualmente em cada mês. Então, o modelo proposto pode captar essa dinâmica com base nas informações de geração de resíduos mensais e

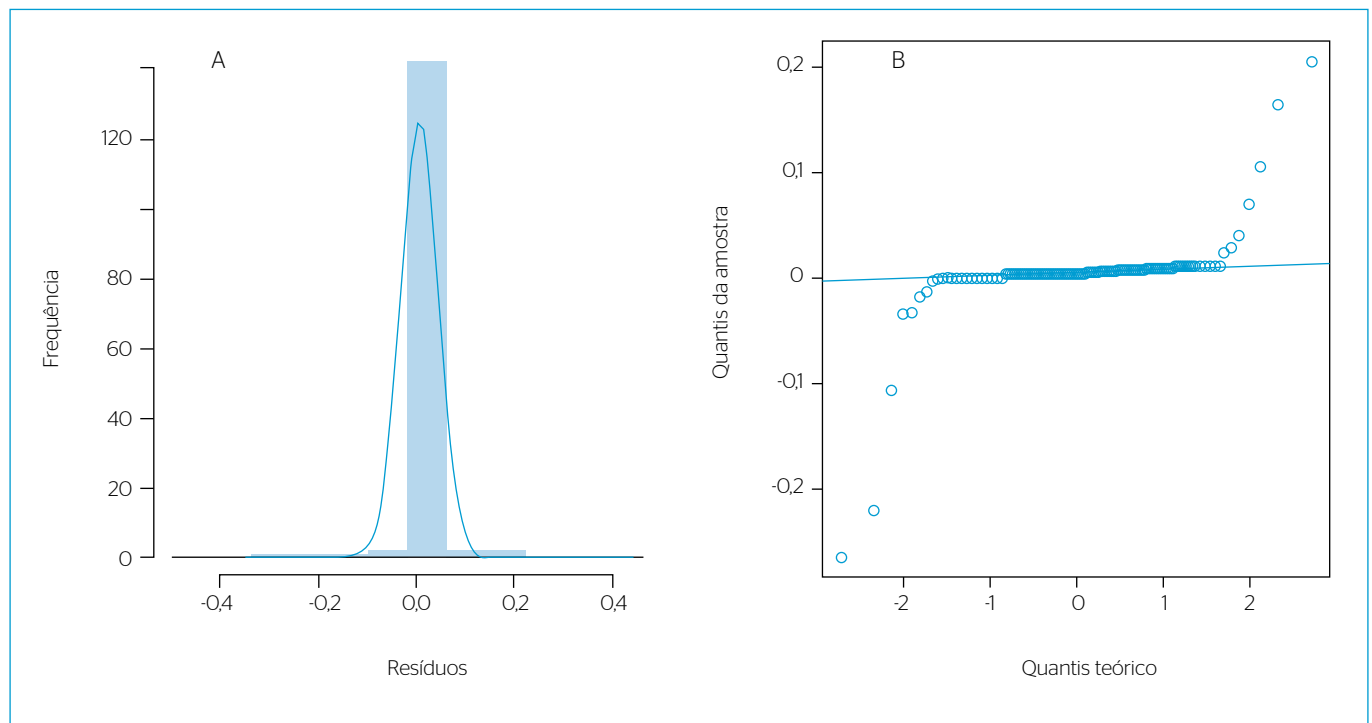


Figura 5 - Análise dos resíduos. (A) Histograma dos resíduos; (B) quartil-quartil plot dos resíduos.




Figura 6 - Previsão de geração de resíduos sólidos urbanos para o aterro de Aparecida de Goiânia, Goiás.

auxiliar o tomador de decisão a planejar, organizar e gerenciar a coleta dos resíduos e controlar os impactos ambientais.

CONCLUSÕES

Existem vários métodos para realizar a previsão de geração de RSU. A partir de 2010, essa análise tem se concentrado em análise de regressão, modelo de fluxo de materiais, sistemas de modelos dinâmicos, análise de séries temporais e modelos de inteligência artificial. Em Aparecida de Goiânia, Goiás, o modelo SARIMA foi proposto devido à sazonalidade ocorrida na série, que pode estar correlacionada a incentivos governamentais. Os fatores climáticos não estão associados à alteração na geração de RSU, mas acredita-se que exista uma variável em comum, nesse caso, o tempo. Em outras regiões onde o clima é mais definido pode ocorrer sua influência.

O modelo SARIMA ajustou-se bem às previsões, forneceu valores próximos à série observada, reproduzindo a periodicidade e a tendência detectadas na série. O modelo SARIMA aplicado apresentou *performance* próxima a outros modelos presentes na literatura internacional, confirmando seu poder de predição.

A previsão para a geração de RSU no aterro de Aparecida de Goiânia, em Goiás, não é mais de crescimento em 2018, predominando a redução de RSU. Essa tendência provavelmente vai continuar até ocorrer interferência governamental na economia.

FONTE DE FINANCIAMENTO

Fundação de Amparo à Pesquisa do Estado de Goiás (FAPEG).

REFERÊNCIAS

- ABBASI, M.; EL HANANDEH, A. (2016) Forecasting municipal solid waste generation using artificial intelligence modelling approaches. *Waste Management*, v. 56, p. 13-22. <https://doi.org/10.1016/j.wasman.2016.05.018>
- ABDOLI, A.M.; NEZHAD, M.F.; SEDE, R.S.; BEHBOUDIAN, S. (2012) Longterm forecasting of solid waste generation by the artificial neural networks. *Environmental Progress & Sustainable Energy*, v. 31, n. 4, p. 628-636. <http://dx.doi.org/10.1002/ep.10591>
- ADAMOVIĆ, V.M.; ANTANASIJEVIĆ, D.Z.; RISTIĆ, M.D.; PERIĆ-GRUJIĆ 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*, v. 24, n. 1, p. 299-311.
- ANTANASIJEVIĆ, D.; POCAJT, V.; POPOVIĆ, I.; REDZIC, N.; RISTIĆ, M. (2013) The forecasting of municipal waste generation using artificial neural networks and sustainability indicators. *Sustainability Science*, v. 8, n. 1, p. 37-46. <http://dx.doi.org/10.1007/s11625-012-0161-9>
- ASSOCIAÇÃO BRASILEIRA DE EMPRESAS DE LIMPEZA PÚBLICA E RESÍDUOS ESPECIAIS (ABRELPE). (2014) *Panorama*. Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais. Disponível em: <<http://www.abrelpe.org.br/Panorama/panorama2014.pdf>>. Acesso em: 12 mar. 2017.
- BEIGL, P.; LEBERSORGER, S.; SALHOFER, S. (2008) Modelling municipal solid waste generation: a review. *Waste Management*, v. 28, n. 1, p. 200-214. <https://doi.org/10.1016/j.wasman.2006.12.011>

- COUTO, M.C.L.; LANGE, L.C. (2017) Análise dos sistemas de logística reversa no Brasil. *Engenharia Sanitária & Ambiental*, v. 22, n. 5, p. 889-898. <http://dx.doi.org/10.1590/s1413-41522017149403>
- DENAFAS, G.; RUZGAS, T.; MARTUZEVICIUS, D.; SHMARIN, S.; HOFFMANN, M.; MYKHAYLENKO, V.; OGORODNIK, S.; ROMANOV, M.; NEGULIAEVA, E.; CHUSOV, A.; TURKADZE, T.; BOCHOIDZE, I.; LUDWIG, I. (2014) Seasonal variation of municipal solid waste generation and composition in four East European cities. *Resources Conservation and Recycling*, v. 89, p. 22-30. <http://dx.doi.org/10.1016/j.resconrec.2014.06.001>
- DIAS, D.M.; MARTINEZ, C.B.; BARROS, R.T.V.; LIBÂNIO, M. (2012) Modelo para estimativa da geração de resíduos sólidos domiciliares em centros urbanos a partir de variáveis socioeconômicas conjunturais. *Engenharia Sanitária & Ambiental*, v. 17, n. 3, p. 325-332. <http://dx.doi.org/10.1590/S1413-41522012000300009>
- DICKEY, D.A.; FULLER, W.A. (1979) Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, v. 74, n. 366, p. 427-431. <http://dx.doi.org/10.2307/2286348>
- DICKEY, D.A.; FULLER, W.A. (1981) Likelihood ratio statistics for autoregressive time series a unit root. *Econometrica*, v. 49, n. 4, p. 1052-1072. <http://dx.doi.org/10.2307/1912517>
- FERRARI, G.T.; OZAKI, V. (2014) Missing data imputation of climate datasets: Implications to modeling extreme drought events. *Revista Brasileira de Meteorologia*, v. 29, n. 1, p. 21-28. <http://dx.doi.org/10.1590/S0102-77862014000100003>
- GOMES, S.; WEIRICH NETO, P.H.; da SILVA, D.A.; ANTUNES, S.R.M.; ROCHA, C.H. (2017) Potencial energético dos resíduos sólidos domiciliares do município de ponta grossa, PR, Brasil. *Engenharia Sanitária & Ambiental*, v. 22, n. 6, p. 1197-1202. <http://dx.doi.org/10.1590/s1413-41522017143432>
- HYNDMAN, R.J.; KHANDAKAR, Y. (2008) Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, v. 27, n. 3, p. 1-22. <http://dx.doi.org/10.18637/jss.v027.i03>
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). *Cidades@*. Instituto Brasileiro de Geografia e Estatística. Disponível em: <<http://cidades.ibge.gov.br/xtras/perfil.php?codmun=520140>>. Acesso em: mar. 2017.
- INSTITUTO NACIONAL DE METEOROLOGIA (INMET). (2017) *Banco de dados meteorológicos para ensino e pesquisa*. Instituto Nacional de Meteorologia. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>. Acesso em: 12 mar. 2017.
- KOLLIKKATHARA, N.; FENG, H.; YU, D. (2010) A system dynamic modeling approach for evaluating municipal solid waste generation, landfill capacity and related cost management issues. *Waste Management*, v. 30, n. 11, p. 2194-2203. <https://doi.org/10.1016/j.wasman.2010.05.012>
- KUMAR, J.S.; SUBBAIAH, K.V.; PRASADA-RAO, P.V. (2011) Prediction of Municipal Solid Waste with RBF Net Work-A Case Study of Eluru, AP, India. *International Journal of Innovation, Management and Technology*, v. 2, n. 3, p. 238-243. <https://doi.org/10.7763/IJIMT.2011.V2I38>
- MONTGOMERY, D.C.; JENNINGS, C.L.; KULAHCI, M. (2015) *Introduction to time series analysis and forecasting*. 2. ed. New Jersey: John Wiley & Sons.
- MORETTIN, P.A.; TOLOI, C.M. (2011) *Análise de series temporais*. 2. ed. São Paulo: Edgard Blücher. 538p.
- MOR, S.; RAVINDRA, K.; VISSCHER, A.; DAHIYA, R.P.; CHANDRA, A. (2006) Municipal solid waste characterization and its assessment for potential methane generation: a case study. *Science of the Total Environment*, v. 371, n. 1-3, p. 1-10. <https://doi.org/10.1016/j.scitotenv.2006.04.014>
- NATIONAL OCEANIC AND ATMOSPHERIC ADMINISTRATION (NOAA). *Data access - NOAA*. National Oceanic and Atmospheric Administration. Disponível em: <<https://www.ncdc.noaa.gov/>>. Acesso em: 12 mar. 2017.
- R DEVELOPMENT CORE TEAM. (2016) *R: A language and environment for statistical computing*. Viena: R Foundation for Statistical Computing. Disponível em: <<https://www.r-project.org/>>. Acesso em: 12 mar. 2017.
- RIMAITYTĖ, I.; RUZGAS, T.; DENAFAS, G.; RACYS, V.; MARTUZEVICIUS, C. (2012) Application and evaluation of forecasting methods for municipal solid waste generation in an eastern-European city. *Waste Management Research*, v. 30, n. 1, p. 89-98. <https://doi.org/10.1177/0734242X10396754>
- TONJES, D.J.; GREENE, K.L. (2012) A review of national municipal solid waste generation assessments in the USA. *Waste Management Research*, v. 30, n. 8, p. 758-771. <https://doi.org/10.1177%2F0734242X12451305>
- TSENG, F.M.; TZENG, G.H. (2002) A fuzzy seasonal ARIMA model for forecasting. *Fuzzy Sets and Systems*, v. 126, n. 3, p. 367-376. [https://doi.org/10.1016/S0165-0114\(01\)00047-1](https://doi.org/10.1016/S0165-0114(01)00047-1)
- VICENTE-SERRANO, S.M.; BEGUERÍA, S.; LÓPEZ-MORENO, J.I.; GARCÍA-VERA, M.A.; STEPANEK, P. (2010) A complete daily precipitation database for northeast Spain: reconstruction, quality control, and homogeneity. *International Journal of Climatology*, v. 30, n. 8, p. 1146-1163. <https://doi.org/10.1002/joc.1850>
- XU, L.; GAO, P.; CUI, S.; LIU, C. (2013) A hybrid procedure for MSW generation forecasting at multiple time scales in Xiamen City, China. *Waste Management*, v. 33, n. 6, p. 1324-1331. <https://doi.org/10.1016/j.wasman.2013.02.012>
- ZHANG, L.; YUAN, Z.; BI, J.; HUANG, L. (2012) Estimating future generation of obsolete household appliances in China. *Waste Management Research*, v. 30, n. 11 p. 1160-1168. <https://doi.org/10.1177%2F0734242X12441238>

Apêndice 1 - Previsão para geração de resíduos sólidos urbanos no aterro de Aparecida de Goiânia, Goiás.

Tempo	Média	Lo 80%	Lo 95%	Hi 80%	Hi 95%
Ago-16	7982,2	7376,3	7055,6	8588,1	8908,8
Set-16	7998,6	7265,9	6878,0	8731,4	9119,3
Out-16	7866,0	7030,9	6588,8	8701,0	9143,1
Nov-16	8106,1	7184,8	6697,1	9027,5	9515,2
Dez-16	11.243,4	10.247,4	9.720,1	12.239,4	12.766,6
Jan-17	11.805,7	10.744,0	10.182,0	12.867,4	13.429,4
Fev-17	9674,4	8.554,2	7.961,2	10.794,6	11.387,7
Mar-17	9834,8	8.662,0	8.041,2	11.007,7	11.628,5
Abr-17	8.610,4	7.390,0	6.743,9	9.830,9	10.476,9
Mai-17	8.947,4	7.683,6	7.014,6	10.211,2	10.880,2
Jun-17	7.993,6	6.690,2	6.000,3	9.297,0	9.987,0
Jul-17	7.962,6	6.622,9	5.913,7	9.302,3	10.011,5
Ago-17	8.067,5	6.673,9	5.936,2	9.461,0	10.198,7
Set-17	8.084,8	6.648,3	5.887,9	9.521,3	10.281,7
Out-17	7.951,2	6.475,3	5.693,9	9.427,1	10.208,4
Nov-17	8.195,1	6.682,9	5.882,4	9.707,4	10.507,9
Dez-17	11.372,9	9.827,1	9.008,8	12.918,6	13.736,9
Jan-18	11.337,7	9.761,0	8.926,3	12.914,5	13.749,1
Fev-18	9.520,0	7.914,6	7.064,7	11.125,5	11.975,4
Mar-18	9.740,4	8.108,3	7.244,2	11.372,6	12.236,6
Abr-18	8.454,5	6.797,6	5.920,5	10.111,5	10.988,6
Mai-18	8.779,2	7.099,2	6.209,8	10.459,3	11.348,6
Jun-18	7.914,6	6.213,0	5.312,3	9.616,2	10.516,9
Jul-18	7.855,1	6.133,5	5.222,1	9.576,8	10.488,2

Lo: limite inferior; Hi: limite superior.