

III-148 - DESENVOLVIMENTO DE CORRELAÇÃO PARA ESTIMATIVA DA TAXA DE GERAÇÃO PER CAPITA DE RESÍDUOS SÓLIDOS URBANOS A PARTIR DAS VARIÁVEIS POPULAÇÃO, RENDA E CONSUMO DE ENERGIA ELÉTRICA EM MUNICÍPIOS DO ESTADO DE SÃO PAULO

Reinaldo Pisani Junior⁽¹⁾

Engenheiro. Professor do Curso de Engenharia Química e Programa de Pós-Graduação em Tecnologia Ambiental, Universidade de Ribeirão Preto.

Marcus Cesar Avezum A. de Castro⁽²⁾

Engenheiro. Livre docente. Professor do Curso de Engenharia Ambiental-IGCE-UNESP

Antônio Álvares da Costa⁽³⁾

Matemático e Mestre em Tecnologia Ambiental da Universidade de Ribeirão Preto

Endereço⁽¹⁾: Avenida Costabile Romano, 2201 – Ribeirânia - Ribeirão Preto - São Paulo - CEP: 14096-900 - Brasil - Tel: +55 (16) 3603-6784 - Fax: +55 (16) 3603-6718 - e-mail: pisanijr@terra.com.br.

RESUMO

A previsão da geração dos Resíduos Sólidos Urbanos é fundamental para escolha e dimensionamento das operações e processos envolvidos na cadeia de gerenciamento em âmbito municipal. O desafio da sustentabilidade financeira desse gerenciamento passa pela criação de indicadores que permitam a cobrança individualizada e proporcional da geração per capita de cada município. Buscou-se, então, desenvolver equações para estimar a taxa de geração per capita de RSU (TGP) nos municípios do Estado de São Paulo. Adotou-se a premissa de que as variáveis população (P), renda per capita diária (RPC) e consumo per capita diário de energia elétrica (Ce) nos municípios eram intervenientes na TGP. A série de dados envolveu 238 municípios que rotineiramente pesaram seus resíduos no ano base de 2013 e 252 municípios em 2014, para o total de 645 no Estado de São Paulo. Amostras que representaram o universo com nível de confiança mínimo de 94,9%. Diversas funções foram testadas com o intuito de ajustar as TGP observadas às calculadas pelo método dos mínimos quadrados. A qualidade dos ajustes foi avaliada através da comparação dos valores previstos e observados com a reta bissetriz do primeiro quadrante, dos coeficientes de correlação de Pearson (r) e de determinação (R^2), das raízes quadradas dos erros médios ao quadrado (RMSE) e dos erros percentuais médios (E_p). A equação que melhor representou o conjunto de dados forneceu r de 0,51, R^2 de 0,26, RMSE de 0,227 $\text{kg.hab}^{-1}.\text{d}^{-1}$ e E_p de -10,2% em 2014, enquanto que para 2013, r foi de 0,49, R^2 de 0,24, RMSE de 0,217 $\text{kg.hab}^{-1}.\text{d}^{-1}$ e E_p de -14,1%. Apesar de R^2 relativamente baixos, foi demonstrado, através do teste de t-Student, que as equações propostas foram capazes de representar valores médios e resultar em mesmas variâncias com probabilidade acima de 99%, que permitiram considerar as equações adequadas para prever as TGP nos municípios paulista.

PALAVRAS-CHAVE: Resíduos sólidos urbanos, geração per capita, análise de regressão, cobrança, previsão

INTRODUÇÃO

Os resíduos sólidos urbanos (RSU) são formados pelos resíduos domiciliares, aqueles gerados nas moradias, e pelos resíduos de limpeza urbana, decorrentes da varrição, limpeza de logradouros e vias públicas e demais serviços de limpeza urbana. Representam parcela significativa dos resíduos sólidos que, devido ao seu risco potencial ao meio ambiente e à saúde, necessitam de gestão e gerenciamento integrados em concordância com a manutenção da qualidade ambiental.

A quantificação do montante de resíduos é fundamental para a escolha e dimensionamento das operações envolvidas na cadeia de gerenciamento. Além disso, a estimativa das quantidades geradas é necessária para totalização das massas ou volumes, uma vez definida a vida útil dos sistemas utilizados no gerenciamento. A taxa de geração per capita é um indicador bastante utilizado para representar a geração de RSU, pois relaciona a massa diária de resíduo produzido por habitante em uma dada localidade. Segundo o art. 7º da Política Nacional de Resíduo Sólidos (Lei 12.305/2010), um de seus objetivos é a “regularidade, continuidade, funcionalidade e universalização da prestação

dos serviços públicos de limpeza urbana e de manejo de resíduos sólidos, com adoção de mecanismos gerenciais e econômicos que assegurem a recuperação dos custos dos serviços prestados, como forma de garantir sua sustentabilidade operacional e financeira”. Nesta linha, o estabelecimento de correlações entre a taxa de geração per capita de resíduos com o consumo de energia e renda dos municípios, variáveis com mensuração temporal já estabelecida, permite a cobrança dos serviços individualizada e proporcional a geração de cada município.

A taxa de geração per capita de resíduos sólidos urbanos foi demonstrada ser dependente das condições demográficas, socioeconômicas e de vida, tais como renda, produto interno bruto, população urbana, proporção da população urbana, consumo per capita das famílias, consumo total de energia, mas a influência de cada parâmetro não está totalmente esclarecida (Daskalopoulos et al., 1998, Chowdhury et al., 2009, Purcell et al., 2009, Liu et al., 2010, Keser et al., 2012, Ghinea et al., 2016, Kawai et al., 2016).

Hockett et al. (1995) correlacionaram a taxa de geração per capita de RSU no Estado da Carolina do Norte em função de dez variáveis, envolvendo aspectos socioeconômicos e de população urbana de cada município. O coeficiente de determinação (R^2) foi encontrado na faixa de 0,37 a 0,50.

Keser et al. (2012), em diferentes locais da Turquia, levaram em conta fatores socioeconômicos e climáticos na previsão da taxa de geração per capita de RSU. Nesta pesquisa, foram aplicados modelos de auto-regressão espacial simultânea e ponderados geograficamente para análise de dados espaciais, onde o coeficiente de Pearson (r) estava na faixa de 0,47 a 0,59, mas o erro quadrático-médio foi encontrado na magnitude de 50% em relação aos valores previstos.

Xu et al. (2013) desenvolveram um modelo híbrido que combinou a auto-regressão sazonal e média móvel para prever a geração de resíduos sólidos urbanos em uma cidade específica (da China) para escalas de tempo múltiplas, sem a necessidade de considerar outras variáveis. Os resultados mostraram que o modelo era muito preciso, mas restrito à cidade estudada.

Benítez et al. (2008) propuseram, para a Cidade do México, modelos para relacionar a taxa per capita de geração de resíduos domiciliares (variável dependente) com diferentes variáveis (independentes), como educação, renda por domicílio e número de habitantes. Para analisar o modelo que melhor explicou a predição, o conjunto de dados foi analisado pelos testes de normalidade, Kolmogorov-Smirnov, multicolinearidade e heterocedasticidade. O valor máximo do coeficiente de determinação (R^2) foi de 0,51.

Em Navarro-Esbrí et al. (2002), foram aplicados modelos para prever as quantidades de resíduos sólidos urbanos gerados em três cidades gregas e espanholas. Os autores compararam modelos compatíveis com influência sazonal, com auto-regressão e ajuste de média móvel. Apesar de desvios de até 5%, não foram mostradas equações que pudessem ser utilizadas para prever.

A relação entre fatores demográficos e socioeconômicos foi estudada no Brasil, principalmente no nível municipal (Campos, 2012, Dias et al. 2014, Melo et al., 2009). Por exemplo, na cidade de Belo Horizonte (MG), foi demonstrado que a população, o índice de qualidade de vida urbana e a renda per capita foram os principais parâmetros para correlacionar a geração de RSU (Dias, et al., 2012, Pinto et al., 2012, Silva et al., 2012). No entanto, as equações, quando descritas, são diretamente aplicáveis apenas ao município avaliado.

Assim, o objetivo deste estudo foi desenvolver equações que permitissem prever as taxas de geração de MSW per capita (PCWG) em municípios do Estado de São Paulo, com base na população total, renda per capita e consumo de eletricidade, como variáveis independentes.

MATERIAIS E MÉTODOS

Os dados iniciais de geração de resíduos sólidos, para os municípios que rotineiramente pesam seus resíduos, foram obtidos junto ao Sistema Nacional de Informações sobre Saneamento – SNIS, que disponibilizou, em 2015 e 2016, os documentos Diagnóstico do Manejo de Resíduos Sólidos Urbanos – 2013-2015 e 2014-2016 (SECRETARIA NACIONAL DE SANEAMENTO AMBIENTAL, 2015, 2016). Nestes documentos foram explicitadas, dentre muitas informações, separadamente as quantidades dos resíduos domiciliares, e de resíduos de limpeza urbana e de resíduos de serviços de saúde, assim como, a utilização de balança para a totalização

dos montantes e a cobertura dos serviços de coleta. Portanto, não se admitiu por hipótese que haja parcelas de outros tipos de resíduos naqueles tipificados na pesquisa. Taxas de geração *per capita* de resíduos sólidos urbanos que apresentaram inconsistências claras, através da comparação dos valores informados ao SNIS com os constantes nos Planos Municipais de Gestão Integrada de Resíduos Sólidos, foram substituídos pelos valores informados nos PMGIRS.

Já as populações, as rendas per capita anuais e os consumos de eletricidade dos municípios paulistas foram obtidos mediante consulta ao sítio Eletrônico da Fundação Estadual de Análise de Dados (SEADE, 2015, 2016). A fim de correlacionar os resultados foram utilizadas também as variáveis independentes renda per capita diária (USD.hab⁻¹.d⁻¹) e consumo de eletricidade per capita em cada município (kWh.hab⁻¹.d⁻¹).

A representatividade das amostras foi avaliada através do nível de confiança, associado a uma margem de erro. A margem de erro corresponde a um intervalo no qual deve estar compreendido o valor estimado no universo da pesquisa. O nível de confiança expressa o grau de certeza de que o valor encontrado esteja realmente dentro da margem de erro estipulada. A relação entre essas variáveis foi expressa através de (Equação 1) (ISRAEL, 1992):

$$n = \frac{N \cdot Z^2 \cdot p \cdot (1-p)}{(N-1) \cdot e^2 + Z^2 \cdot p \cdot (1-p)} \quad \text{equação (1)}$$

na qual n é o tamanho da amostra, N é o tamanho do universo amostral (número de municípios ou população em 2013 e 2014, ano base da pesquisa), Z é o desvio do valor médio aceitável para o intervalo de confiança adotado (determinado na curva de distribuição normal), e é a margem de erro estipulada, p é a proporção esperada ou heterogeneidade do espaço amostral, normalmente 50% quando não estão disponíveis informações a respeito da variabilidade da amostra (ISRAEL, 1992). Sendo assim, foram adotados valores de margem de erro e intervalo de confiança que, a partir dos números totais de municípios ou das populações do Estado, resultassem nos números de municípios ou populações que participaram das amostras.

O coeficiente de correlação de Pearson (r) ou coeficiente de correlação (Equação 2) foi utilizado para analisar o grau da correlação linear a variável quantitativa dependente (TGP) e as independentes (P, RPC e Ce).

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y}_{medida})}{\sqrt{\left(\sum (x_i - \bar{x})^2\right) \cdot \left(\sum (y_i - \bar{y}_{medida})^2\right)}} \quad \text{equação (2)}$$

sendo x_i a variável independente observada, \bar{x} é o valor médio da variável independente x_i ; y_i a variável dependente observado e \bar{y}_{medida} valor médio da variável dependente y_i .

Posteriormente, foram ajustadas funções lineares, com o intuito de representar as TGP de RSU, em função das variáveis população total, renda *per capita* diária média e consumo médio de energia elétrica *per capita* de cada município do espaço amostral, combinadas duas a duas independentemente ou as três variáveis simultaneamente. Posteriormente, foi feita a combinação de três variáveis independentes, porém utilizando funções logarítmicas para a população total (P) e consumo *per capita* de energia elétrica (Ce) e dependência linear para a renda *per capita* (RPC) (equações 3 a 7). Para isto, foram utilizados os programas computacionais BIOESTAT 5.3, voltado para aplicações em Ecologia e desenvolvido pelo Instituto MAMIRAUÁ (Ayres, 2007), e Microsoft Excel, através do aplicativo solver para aplicação do método dos mínimos quadrados.

$$TGP = a + b \cdot (P) + c \cdot (RPC) \quad \text{equação (3)}$$

$$TGP = a + b \cdot (P) + c \cdot (Ce) \quad \text{equação (4)}$$

$$TGP = a + b \cdot (RPC) + c \cdot (Ce) \quad \text{equação (5)}$$

$$TGP = a + b \cdot (P) + c \cdot (RPC) + d \cdot (Ce) \quad \text{equação (6)}$$

$$TGP = a + b \cdot \ln(P) + c \cdot RPC + d \cdot [\ln(Ce)]^e \quad \text{equação (7)}$$

nas quais a, b, c, d e e são constantes de ajuste, P é a população total (hab.), Ce é o consumo per capita diário de energia elétrica (kWh.hab⁻¹.d⁻¹) e RPC é a renda per capita média diária (USD.hab⁻¹.d⁻¹) em cada município do Estado de São Paulo.

A avaliação da qualidade dos ajustes foi feita a partir do cálculo de alguns parâmetros amplamente utilizados em avaliações estatísticas: o coeficiente de determinação (R²), raiz quadrada dos erros médios ao quadrado (RMSE) e erro percentual médio (E_p), além da comparação dos valores previstos e observados para TGP com a reta bissetriz no primeiro quadrante, incluindo o intervalo compreendido a RMSE para cima e para baixo.

O coeficiente de determinação (R²) é das formas de avaliar a qualidade do ajuste do modelo utilizado. Descreve a proporção da variabilidade em uma variável que é explicada pela variabilidade da outra. Basicamente, este coeficiente indica quanto o modelo foi capaz de explicar os dados coletados. O valor de R² pode variar de 0 a 1, sendo pouco comum uma correlação perfeita (R² = 1) na prática, uma vez que existem muitos fatores interferentes no fenômeno analisado podem não estar presentes nos modelos testados, deste modo, valores mais elevados de R² estão associados a menores variâncias de erros, ou seja, quanto mais próximo de 1, mais explicativo é o modelo e melhor é a qualidade do ajuste (Legates; McCabe, 1999; Moriasi et al., 2007).

$$R^2 = \frac{\left[\sum_{i=1}^n [y_{medida_i} - \bar{y}_{medida}] [y_{calc_i} - \bar{y}_{calc}] \right]^2}{\left[\sum_{i=1}^n (y_{medida_i} - \bar{y}_{medida})^2 \right]^{0,5} \cdot \left[\sum_{i=1}^n (y_{calc_i} - \bar{y}_{calc})^2 \right]^{0,5}} \quad \text{equação (8)}$$

na qual y_{medida_i} é a variável dependente observada para cada elemento do conjunto de dados, \bar{y}_{medida_i} é o valor médio da variável dependente observada do conjunto de dados, y_{calc_i} é a variável dependente calculada para cada elemento do conjunto de dados, e \bar{y}_{calc} é o valor médio da variável dependente calculada para conjunto de da dose n é o número de elementos contidos no conjunto de dados de cada amostra. A barra superior indica a média de todo o período de avaliação, observando-se que o coeficiente de determinação é limitado na medida em que uniformiza as diferenças entre as médias e variâncias observadas e previstas, uma vez que avalia apenas as relações lineares entre as variáveis (Legates; McCabe, 1999).

Diversos são os desvios comumente utilizados na avaliação de modelos, com o intuito de avaliar as imprecisões dos elementos de interesse, o que auxilia na análise e interpretação dos resultados. Dentre eles, as raízes quadradas dos erros médios ao quadrado, ou simplesmente RMSE (Equação 9), quantificam os erros em termos de unidades da variável, é a estatística não-negativa que não têm limite superior, porém, no extremo oposto, valores iguais a 0 indicam um ajuste perfeito (Moriasi et al., 2007).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{medida_i} - \bar{y}_{calc_i})^2}{n - v}} \quad \text{equação (9)}$$

sendo que: y_{medida_i} é a variável dependente observada para cada elemento do conjunto de dados, \bar{y}_{calc} é o valor médio da variável dependente calculada para conjunto de dados, n é o número de elementos contidos no conjunto de dados da amostra e v é o número de variáveis independentes envolvidas no modelo. O erro percentual médio (Equação 10) expressa a proporção do desvio encontrado entre os valores observados e previstos, que se traduz em melhor previsão quanto menor for E_p:

$$E_p = \frac{100}{n} \sum_{i=0}^n \left[\frac{y_{medida_i} - y_{calc_i}}{y_{medida_i}} \right] \quad \text{equação (10)}$$

na qual y_{medida_i} é a variável dependente observada para cada elemento do conjunto de dados, y_{calc_i} é a variável dependente calculada para cada elemento do conjunto de dados, e n é o número de elementos contidos no conjunto de dados de cada amostra.

O teste *t-Student* utiliza conceitos estatísticos para rejeitar ou não uma hipótese nula (H_0), quando a estatística de teste (t) segue uma distribuição normal. Essa premissa é normalmente usada quando a estatística de teste segue uma distribuição normal, mas a variância da população é desconhecida. Assim, utiliza-se uma variância amostral, e com esse ajuste, a estatística de teste passa a seguir uma distribuição t de *Student*. Isso significa que, se forem realizadas amostras de determinado tamanho a partir de uma única população e se forem calculadas as médias de uma variável desta população que apresenta uma distribuição normal, a distribuição destas médias seguiria uma distribuição t de *Student*.

Ao calcular o valor de t pela Equação 11 e aplicá-lo na função densidade de probabilidade da distribuição t de *Student*, avalia-se a integral desta função para valores maiores ou iguais a t . Esta área representa a probabilidade da média das amostras em estudo terem apresentados valores observados ou valores mais extremos. Se a probabilidade deste resultado ocorrer for pequena, pode-se concluir que o resultado observado é estatisticamente relevante. Essa probabilidade também é chamada de p -valor ou p . Consequentemente, o nível de confiança é igual a $1-p$. Normalmente, utiliza-se um ponto de corte, $p < 0,05$ (nível de confiança 95%) para o valor de p ou para o nível de confiança para definir se a hipótese nula deve ser rejeitada ou não. Se o valor de p for menor que este ponto de corte, a hipótese nula é rejeitada. Caso contrário a hipótese nula não é rejeitada (Tiboni, 2010).

$$t = \frac{r}{\sqrt{\frac{1-r^2}{n-2}}} \quad \text{equação (11)}$$

RESULTADOS E DISCUSSÃO

Os dados originais de 9 municípios em 2013 e de 4 em 2014 foram glosados, por apresentarem TGP exageradamente grandes, assim os valores informados ao Sistema Nacional de Informações sobre Saneamento foram substituídos pelas gerações encontradas nos planos municipais de gestão integrada de resíduos sólidos (PMGIRS). Na Tabela 1 são mostradas as informações referentes a estes municípios. Logo, apenas três municípios foram excluídos do conjunto de dados, pois seus planos não foram localizados.

O universo amostral de 2013 foi formado por 238 municípios, cuja população somada foi de 34.551.664 habitantes (82%), frente ao número de municípios que responderam à coleta de informações junto ao SNIS (533 cidades) e ao total que compôs o Estado de São Paulo que era de 645 municípios (42.304.694 habitantes). Pelo critério de número de cidades, pôde-se afirmar que 238 municípios representaram o total de 645 com uma margem de erro de 5,1 % e intervalo de confiança de 94,9 %. Já, com base na população, 34.551.664 habitantes retrataram a população total de 42.304.694 habitantes com margem de erro de apenas 0,015% e intervalo de confiança de 99,985 %. No conjunto de dados referentes a 2014 ($n = 251$), o erro amostral para número de municípios participantes (e) e o intervalo de confiança correspondente foram respectivamente de 4,9% e 95,1 %. Já, com base na população abrangida, 35.229.824 habitantes representaram a população total de 42.673.386 habitantes com margem de erro de apenas 0,000026 % e intervalo de confiança de 99,999974 %. Comprovou-se, portanto, que as amostras utilizadas foram representativas do Estado de São Paulo e que os resultados obtidos foram passíveis de extrapolação para os demais municípios, incluindo aqueles que não participaram do Diagnóstico do Manejo de Resíduos Sólidos Urbanos – 2013 e 2014.

Tabela 1: Municípios para os quais as informações foram glosadas.

Ano base	Município	População (hab.)	TGP _{observada} (kg.hab. ⁻¹ .d ⁻¹)	TGP _{PMGIRS} (kg.hab. ⁻¹ .d ⁻¹)
2013	Cruzália	2.222	1,24	084
	Lutécia	2.682	1,56	0,86
	Lavínia	8.666	1,99	não disponível
	Iacanga	10.414	1,57	0,60
	Ilhabela	29.837	2,86	não disponível
	Paraguaçu Paulista	42.858	3,20	não disponível
	Registro	54.107	1,53	0,86
	Atibaia	130.606	1,58	0,86
2014	Guarulhos	1.260.840	1,53	0,84
	Paraíso	6.060	3,09	0,83
	Nhandeara	10.780	2,98	0,93
	Pedregulho	15.940	2,43	não disponível
	Palmital	21.362	2,07	0,71

Na Tabela 2 são mostrados os valores dos coeficientes de Pearson para as taxas de geração per capita de RSU em relação às variáveis independentes população (P), renda per capita média diária (RPC) e consumo de energia médio diário (Ce) para os anos de 2013 e 2014.

Tabela 2: Coeficientes de Pearson (r) entre as taxas de geração per capita de RSU observadas para os municípios do Estado de São Paulo em relação às variáveis independentes.

	Variáveis independentes					
	P (hab)	Ln(P)	RPC (USD.hab. ⁻¹ .d ⁻¹)	Ln(RPC)	Ce (kWh.hab. ⁻¹ .d ⁻¹)	Ln(Ce)
Coeficiente de Pearson (r) 2013	0,12	0,41	0,43	0,42	0,21	0,32
Coeficiente de Pearson (r) 2014	0,18	0,43	0,40	0,41	0,27	0,37

Nota-se pela Tabela 2, que correlações envolvendo Ln(P), RPC e Ln(Ce) potencialmente ajustariam melhor as TGP de RSU. Sendo assim, tomando-se por base os anos de 2013 e 2014, os empregos destas três variáveis resultaram nas equações (12) e (13):

$$TGP = -11,280 + 0,0356.Ln(P) + 0,0179.RPC + 11,347.[Ln(Ce)]^{0,0103} \quad \text{equação (12)}$$

válida para $1.923 \text{ hab} \leq P \leq 11.446.275 \text{ hab}$; $6,23 \text{ USD.hab}^{-1}.\text{d}^{-1} \leq RPC \leq 29,89 \text{ USD.hab}^{-1}.\text{d}^{-1}$; e $2,51 \text{ kWh.hab}^{-1}.\text{d}^{-1} \leq Ce \leq 87,04 \text{ kWh.hab}^{-1}.\text{d}^{-1}$. Já para 2014, a regressão resultou em (Equação 12):

$$TGP = -14,162 + 0,0441.Ln(P) + 0,0160.RPC + 14,164.[Ln(Ce)]^{0,0154} \quad \text{equação (13)}$$

válida para os seguintes intervalos de $2.044 \text{ hab} \leq P \leq 11.513.836 \text{ hab}$, $5,10 \text{ USD.hab}^{-1}.\text{d}^{-1} \leq RPC \leq 24,48 \text{ USD.hab}^{-1}.\text{d}^{-1}$ e $2,69 \text{ kWh.hab}^{-1}.\text{d}^{-1} \leq Ce \leq 81,67 \text{ kWh.hab}^{-1}.\text{d}^{-1}$. Os parâmetros de avaliação da qualidade do ajuste são mostrados na Tabela 3. Apesar dos baixos coeficientes de determinação (0,23 e 0,24), os desvios percentuais associados às previsões foram aceitáveis, em torno de -14% a -10%, o sinal negativo indicou uma tendência de estimar valores acima dos observados. Os valores de RMSE foram de 0,217 kg.hab.⁻¹.d⁻¹ e 0,227 kg.hab.⁻¹.d⁻¹, que representaram 29 % da média de todos os valores observados em 2013 e 2014 respectivamente. Optou-se também por efetuar a regressão envolvendo as amostras dos anos de 2013 e 2014 simultaneamente, ou seja, 489 dados, uma vez que foram obtidas tendências e qualidades de ajuste bastante semelhantes (Equação 14).

$$TGP = -13,476 + 0,0436.Ln(P) + 0,0114.RPC + 13,521.[Ln(Ce)]^{0,0143} \quad \text{equação (14)}$$

indicada para $1.923 \text{ hab} \leq P \leq 11.513.836 \text{ hab}$, $5,10 \text{ USD.hab}^{-1}.\text{d}^{-1} \leq RPC \leq 29,89 \text{ USD.hab}^{-1}.\text{d}^{-1}$ e $2,51 \text{ kWh.hab}^{-1}.\text{d}^{-1} \leq Ce \leq 87,04 \text{ kWh.hab}^{-1}.\text{d}^{-1}$.

Tabela 3: Parâmetros de avaliação da qualidade dos ajustes.

	Parâmetros de avaliação da qualidade do ajuste			
	r (-)	R ² (-)	RMSE (kg.hab ⁻¹ .d ⁻¹)	Ep (%)
Equação (12) - 2013	0,49	0,24	0,217	-14,1
Equação (13) - 2014	0,51	0,26	0,227	-10,2
Equação (14) 2013 e 2014	0,49	0,24	0,224	-12,3

Nas figuras 1 a 3 são mostradas as taxas de geração per capita de RSU em função das variáveis: população, renda per capita e consumo de energia elétrica dos municípios. Foi possível perceber que melhor tendência de comportamento dos resultados era obtida ao se utilizar escala logarítmica nos eixos das variáveis P e Ce. Fato corroborado com maiores coeficientes de Pearson calculados para LnP, Ln(Ce) e RPC, quando comparados com os obtidos para P e Ce (Tabela 2). Além disso, percebe-se grande dispersão das TGP, em relação aos valores observados e previstos, que implicou em coeficiente de determinação relativamente baixo (R²). Há municípios com TGP excessivamente baixas e inesperadamente elevadas. Por exemplo, existem municípios com populações inferiores a 10 mil habitantes com TGP acima de 1,00 kg.hab⁻¹.d⁻¹, que podem ser decorrentes da disposição final inadequada de resíduos da construção civil em conjunto com resíduos sólidos urbanos. Ao mesmo tempo em que foram encontradas cidades com população no intervalo de 6 mil a 60 mil com TGP da ordem de 0,20 kg.hab⁻¹.d⁻¹, talvez sejam decorrentes de inconsistência nos dados informados pelos municípios ao Sistema Nacional de Informações sobre Saneamento. Comprovou-se também que as TGP foram crescentes em relação às variáveis independentes, população, renda per capita e consumo diário de energia elétrica per capita nos municípios.

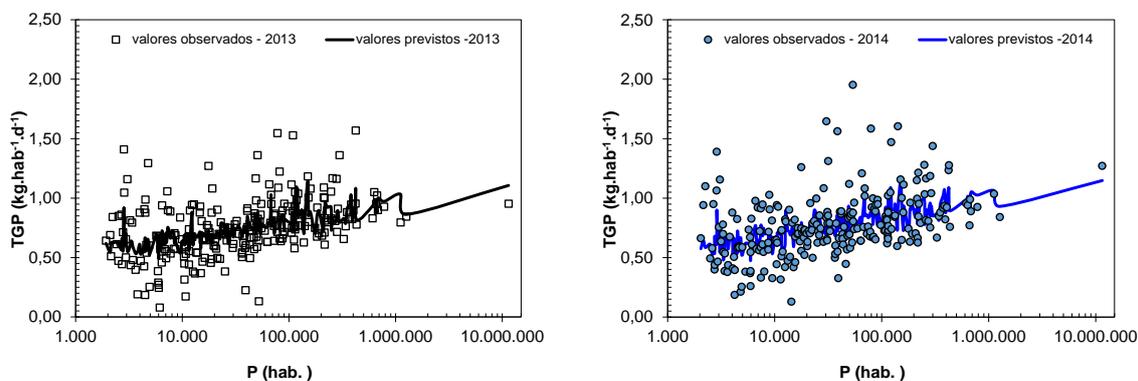


Figura 1: Taxas de geração per capita de RSU em função da população dos municípios do Estado de São Paulo que alegaram pesar rotineiramente seus resíduos em 2013 e 2014.

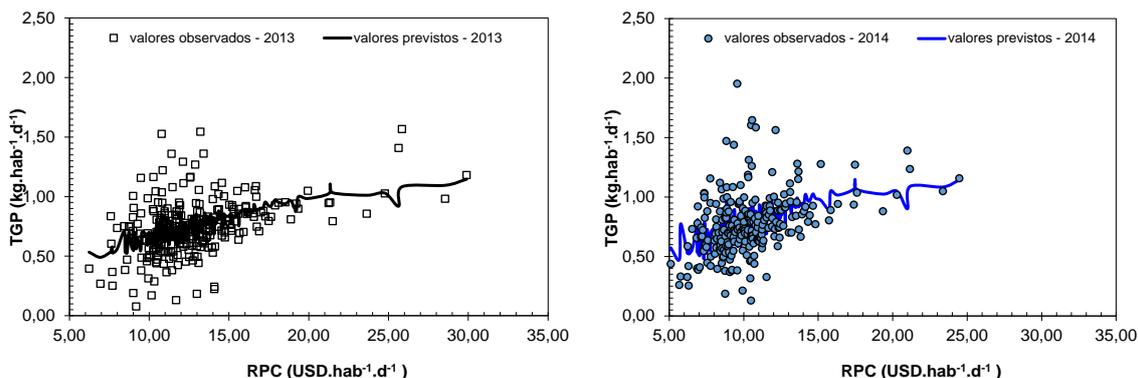


Figura 2: Taxas de geração per capita de RSU em função da renda per capita nos municípios do Estado de São Paulo que alegaram pesar rotineiramente seus resíduos em 2013 e 2014.

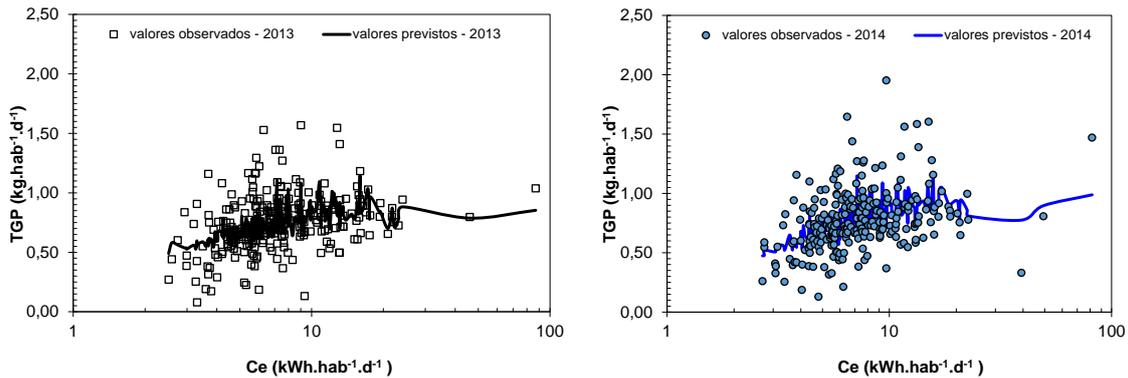


Figura 3: Taxas de geração per capita de RSU em função do consumo de energia elétrica total nos municípios do Estado de São Paulo que alegaram pesar seus resíduos em 2013 e 2014.

Nas figuras 4 e 5 foram plotadas as TGP observadas e previstas pelas equações 12 e 13 para se avaliar a qualidade do ajuste, quanto mais próximos os pontos forem da reta diagonal, melhor é a previsão. Nota-se, portanto, que grande parte dos pontos obedecem esta condição. Porém, percebe-se que há condições para as quais claramente as TGP foram subestimadas e superestimadas, mostradas pelas regiões tracejadas nas figuras. No entanto, a grande maioria dos pontos encontra-se dentro do intervalo de boa previsão, ou seja, entre o valor médio e uma raiz quadrada dos erros médios ao quadrado para mais e para menos ($0,217 \text{ kg.hab}^{-1}.\text{d}^{-1}$ para 2013 e $0,227 \text{ kg.hab}^{-1}.\text{d}^{-1}$ para 2014).

O teste de *t-Student* mostrou que as equações 8 e 9 foram capazes de representar valores médios de TGP com probabilidade acima de 99 %. O valor de *t* crítico bicaudal foi de 2,60 para 2013 e 15,60 para 2014, enquanto que o valor de *t* dos dois conjuntos de dados foi de 1,00, fato que comprovou que as médias e as variâncias foram praticamente iguais para 2013 e 2014. Portanto, estas equações puderam ser consideradas adequadas para prever as TGP nos municípios do Estado de São Paulo.

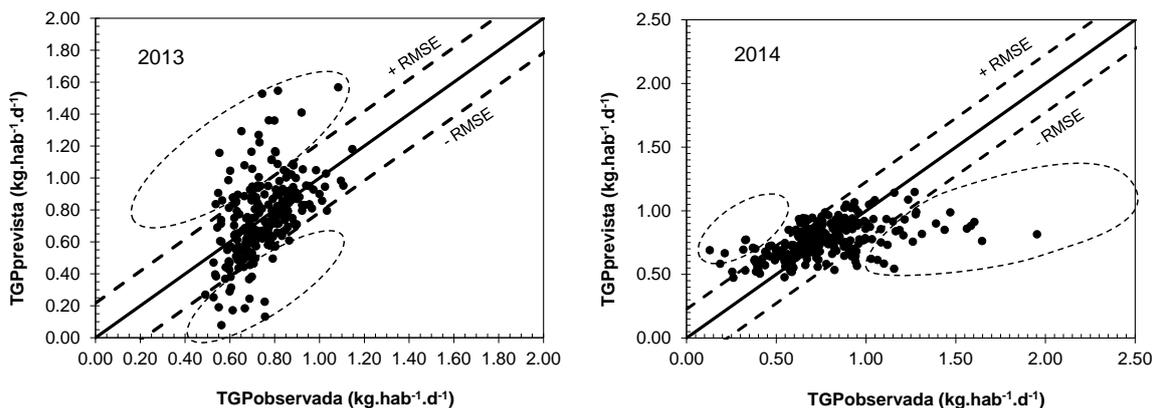


Figura 4: Valores de TGP observados e previstos em relação a reta bissetriz do primeiro quadrante.

CONCLUSÕES

As variáveis independentes, população (*P*), renda per capita média (*RPC*) e consumo per capita de energia elétrica (*Ce*) se mostraram interferentes na taxa de geração per capita de resíduos sólidos urbanos, sobretudo ao se considerar $\ln(P)$, *RPC* e $\ln(Ce)$, coeficientes que foram compatíveis com moderada correlação entre as variáveis dependentes e independentes.

Foi constatada grande dispersão dos resultados observados para as TGP para os municípios de informaram pesar rotineiramente os seus resíduos no Estado de São Paulo, cujos valores máximos foram de $1,57 \text{ kg.hab}^{-1}.\text{d}^{-1}$ para 2013 e de $1,95 \text{ kg.hab}^{-1}.\text{d}^{-1}$ para 2014, já os valores mínimos foram de $0,080 \text{ kg.hab}^{-1}.\text{d}^{-1}$ para 2013 e

0,13 kg.hab⁻¹.d⁻¹, que se refletiram em relativamente baixos coeficientes de determinação para as equações testadas (R^2 no intervalo de 0,24 a 0,26).

Correlações lineares envolvendo as variáveis população, renda per capita e consumo per capita de energia não foram satisfatórias para prever as TGP observadas. Porém, ao se considerar a função envolvendo variáveis na forma de Ln (P), Ln (Ce) e RPC, os erros percentuais médios foram de -14,1% para 2013 e -10,2% para 2014. Além disto, foi demonstrado que a maior parte dos valores observados de TGP estiveram no intervalo compreendido entre os valores médios e as raízes quadradas dos erros médios ao quadrado (RMSE) para mais e para menos, o que conferiu segurança à previsão realizada para a maioria dos casos.

Os testes de *Student* realizados para testar as hipóteses de médias iguais pareadas e mesmas variâncias para os dois conjuntos de dados (referentes a 2013 e 2014) comprovaram as validades das equações propostas (equações 8 e 9) com intervalos de confiança acima de 99%.

REFERÊNCIAS BIBLIOGRÁFICAS

1. AYRES, M. BioEstat Aplicações estatísticas nas áreas das ciências biomédicas. 5 ed., Universidade Federal do Pará, 2007, 364p.
2. BENÍTEZ, S. O., LOZANO-OLVERA, G.; MORELOS, R.A.; VEJA, C. A. Mathematical modeling to predict residential solid waste generation. *Waste management*, v. 28, 2008, p. S7 – S13.
3. BRASIL. Política Nacional de Resíduos Sólidos (PNRS): Lei de nº 12.305 de 2010.
4. CAMPOS, H. K. T. Evolution of income and per capita generation of solid wastes in Brazil. *Engenharia Sanitária e Ambiental*, v. 17, n. 2, 2012, p. 171-180.
5. CHOWDHURY, M. Searching quality data for municipal solid waste planning. *Waste Management*, v. 29, n. 8, 2009, p. 2240–2247.
6. DASKALOPOULOS, E., BADR, O., PROBERT, S. D. Municipal solid waste: a prediction methodology for the generation rate and composition in the European Union countries and the United States of America. *Resources, Conservation and Recycling*, v. 24, n. 1, 1998, p. 155–166.
7. DIAS, D. M., MARTINEZ, C. B., BARROS, R. T. V. Generation estimate of municipal solid waste as subsidy actions aimed to environmental sustainability. *Revista Brasileira de Ciências Ambientais*, n. 33, 2014, p. 13-20.
8. DIAS, D. M.; MARTINEZ, C. B.; BARROS, P. T. V.; LIBÂNIO, M. Model to domestic solid waste generation estimative in urban areas based on socioeconomic conjuncture variables. *Engenharia Sanitária Ambiental*, v. 17, n. 3, 2012, p. 325-332.
9. FUNDAÇÃO SISTEMA ESTADUAL DE ANÁLISE DE DADOS – SEADE (2015, 2016) <<http://www.seade.gov.br/>> Acesso em 20.05.2016.
10. GHINEA, C., DRAGOI, E. N., COMANITA, E. D., GAVRILESCU, M., CÂMPEAN, T., CURTEANU, S., GAVRILESCU, M. Forecasting municipal solid waste generation using prognostic tools and regression analysis. *Journal of Environmental Management*, v. 182, 2016, p. 80–93.
11. ISRAEL, G. D. Determining sample size. Florida Cooperative Extension Service, University of Florida, Fact sheet PEOD-6, November, 1992, p. 1-5.
12. KAWAI, K., TASAKI, T. Revisiting estimates of municipal solid waste generation per capita and their reliability. *Journal of Material Cycles and Waste Management*, v. 18, n. 1, 2016, p. 1-13.
13. KESER, S.; DUZGUNB, S.; AKSOY, A. Application of spatial and non-spatial data analysis indetermination of the factors that impact municipal solid waste generation rates in turkey. *Waste Management*, v. 32, n. 3, 2012, p. 359-371.
14. LEGATES, D. R.; MCCABE Jr, G. J. Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, v. 35, n. 1, 1999, p. 233–241.
15. LIU, C., WU, X. Factors influencing municipal solid waste generation in China: A multiple statistical analysis study. *Waste Management & Research*, v. 29, n. 4, 2010, p. 371-378.
16. MELO, L. A., SAUTTER, K. D., JANISSEK, P. R. Scenario studies for the management of urban solid waste in Curitiba. *Engenharia Sanitária e Ambiental*, v. 14, n. 4, 2009, p. 551-558.
17. MORIASI, D. N.; ARNOLD, J. G.; LIEW, M. W. V.; BINGNER, R. L.; HARMEL, R. D.; VEITH, T. L. Model evaluation guidelines for systematic Quantification of accuracy in watershed simulations. *American Society of Agricultural and Biological Engineers*, v. 50, n. 3, 2007, p.885-890.

18. NAVARRO-ESBRÍ, J.; DIAMADOPOULOS, E.; GINESTAR, D. Time series analysis and forecasting techniques for municipal solid waste management. *Resources, Conservation and Recycling*, v. 35, n. 3, 2002, p. 201–214.
19. PINTO, M. R.; PEREIRA, D. R. M.; FREITAS, R. C. Factors social, economic and demographic associated with household waste generation in the city of Belo Horizonte. *Reuna*, v. 17, n. 2, 2012, p. 27-44.
20. PURCELL, M., MAGETTE, W. L. Prediction of household and commercial BMW generation according to socio-economic and other factors for the Dublin region, *Waste Management*, v. 29, n. 4, 2009, p. 1237–1250.
21. SECRETARIA NACIONAL DE SANEAMENTO AMBIENTAL. Sistema Nacional de Informações sobre Saneamento: diagnóstico do manejo de resíduos sólidos urbanos – 2013. Ministério das Cidades, 2015, 154p.
22. SECRETARIA NACIONAL DE SANEAMENTO AMBIENTAL. Sistema Nacional de Informações sobre Saneamento: diagnóstico do manejo de resíduos sólidos urbanos – 2014. Ministério das Cidades. 2016, 146p.
23. SILVA, H.; BARBIERI, A. F.; MÓR, R. L. M Demography of urban consumption: a study on the generation of solid waste in the city of Belo Horizonte. *Revista Brasileira de Estudos de População*, v. 29, n. 2, 2012, p. 421-449.
24. TIBONI, C. G. R. Basic Statistics for administration, accounting, technology and management courses. 1 ed., São Paulo: Atlas, 2010. 344p. (in Portuguese).
25. XU, L.; GAO, P.; CUI, S.; LIU, C. A hybrid procedure for MSW generation forecasting at multiple time scales in Xiamen City China. *Waste Management*, v. 33, 2013, p. 1324-1331.