

Universidade de Ribeirão Preto
Programa de Pós-Graduação em Tecnologia Ambiental
Mestrado Profissionalizante em Tecnologia Ambiental

ANTONIO ALVARES DA COSTA

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

RIBEIRÃO PRETO
2016

Antonio Alvares da Costa

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

Dissertação apresentada à Universidade
de Ribeirão Preto UNAERP, como
requisito parcial para a obtenção do título
de Mestre em Tecnologia Ambiental.

Orientador: Prof.^o Dr. Reinaldo Pisani
Júnior

Ribeirão Preto

2016

Ficha catalográfica preparada pelo Centro de Processamento
Técnico da Biblioteca Central da UNAERP

- Universidade de Ribeirão Preto -

C837d Costa, Antonio Alvares da, 1947-
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 / Antonio Alvares da Costa. - -
Ribeirão Preto, 2016.
100 f.: il. color.

Orientador: Prof. Dr. Reinaldo Pisani Júnior.

Dissertação (mestrado) - Universidade de Ribeirão Preto,
UNAERP, Tecnologia Ambiental. Ribeirão Preto, 2016.

1. Resíduos sólidos - Gerenciamento. 2. Resíduos sólidos
Urbanos. 3. Taxa de geração *per capita*. I. Título.

CDD 628

Antônio Alvares da Costa

“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”.

Dissertação apresentada como requisito parcial para a obtenção do título de Mestre pelo programa de Mestrado Profissionalizante em Tecnologia Ambiental do Centro de Ciências Exatas, Naturais e Tecnologias da Universidade de Ribeirão Preto.

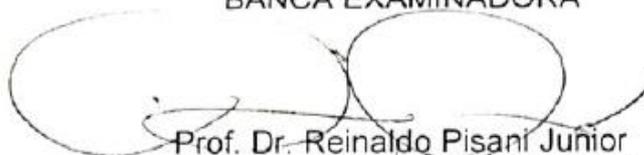
Orientador: Prof. Dr. Reinaldo Pisani Junior.

Área de concentração: Tecnologia Ambiental

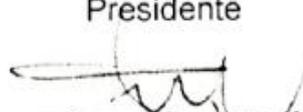
Data de defesa: 19 de dezembro de 2016

Resultado: aprovado

BANCA EXAMINADORA



Prof. Dr. Reinaldo Pisani Junior
Universidade de Ribeirão Preto - UNAERP
Presidente



Prof. Dr. Marcus Cesar Avezum Alves de Castro
Universidade Estadual Paulista Júlio de Mesquita Filho – UNESP



Profa. Dra. Cristina Filomena Pereira Rosa Paschoalato
Universidade de Ribeirão Preto - UNAERP

AGRADECIMENTOS

Primeiramente a DEUS por me permitir participar desse projeto e me conduzir pelos caminhos;

Ao meu orientador Prof. Dr. Reinaldo Pisani Júnior pelo incentivo, paciência e exigência que tornam possíveis a realização deste trabalho.

A todos os docentes do Programa de Pós-Graduação em Tecnologia Ambiental desta Universidade que contribuíram de forma direta ou indireta, incentivando e me dando força na elaboração e conclusão deste trabalho.

À Maria Inês minha namorada e a Rita minha irmã, pela paciência, respeito e consideração pelo período em que mais me dediquei ao trabalho em detrimento à nossa convivência.

À UNAERP, sua direção e administração pelo apoio, incentivo e oportunidade de realizar esse sonho de fazer o mestrado.

Ao Dr. Milton Faria Junior, pela ajuda nas discussões, interpretações e análises dos dados.

Ao Ms. Alexandre da Silva Mello, pelo apoio e incentivo na elaboração desse estudo.

A todos que diretamente ou indiretamente contribuíram para que eu concluísse mais uma etapa da minha vida.

A todos os amigos que torcendo pela minha vitória, me incentivaram e até se privaram do nosso convívio.

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 munícipe. 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 kg.hab⁻¹.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 kg.hab⁻¹.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%, com $p < 0,01$, fato que permitiu considerar as equações adequadas para prever as TGP nos municípios paulista.

Palavras-chave: Gerenciamento de resíduos sólidos. Resíduos sólidos urbanos.

Taxa de geração *per capita*. Análise de regressão. Cobrança. Previsão

ABSTRACT

Forecasting Municipal Solid Waste (MSW) generation is fundamental in choosing and scaling the operations and processes involved in municipal management. The challenge for the financial sustainability of this management is to create indicators that enable municipal solid waste fees to be charged in proportion to the amount of MSW generated by each resident. To this end, we sought to develop equations to estimate the *per capita* waste generation rate (TGP) in the municipalities of the state of São Paulo. It was assumed that the variables of population (P), daily *per capita* income (RPC) and daily *per capita* consumption of electric energy (Ce) in the municipalities were determining factors of the TGP. The dataset involved 238 municipalities that routinely weighed their solid wastes in the baseline year of 2013, and 252 municipalities in 2014, in relation to the total of 645 in the State of São Paulo. These samples represented the universe with a minimum confidence level of 94.9%. Several functions were tested in order to adjust the observed TGP to those calculated by the least squares method. The quality of the adjustments was evaluated by comparing the expected and observed values with the bisector of the first quadrant, as well as, by the Pearson (r) and determination (R^2) coefficients, root-mean-square error (RMSE), and mean percentage error (E_p) values. The equation that best represented the dataset in 2014 had an r of 0.51, R^2 of 0.26, RMSE of 0.227 kg.person⁻¹.d⁻¹ and E_p of -10.2%, while for 2013, r was 0.49, R^2 was 0.24, RMSE of 0.217 kg.person⁻¹.d⁻¹ and E_p of -14.1%. Despite the relatively low R^2 , it was demonstrated by Student's t-test that the proposed equations were able to represent mean values and result in the same variances with probability higher than 99%. This fact allow to consider the equations adequate for predicting the TGP in the municipalities of the state of São Paulo.

Keywords: Solid waste management. Municipal solid waste. *Per capita* generation rate. Regression analysis. Changing. Forecast.

LISTA DE FIGURAS

Figura 1 - Classificação de origem dos resíduos sólidos, segundo a Lei 12.305/2010	14
Figura 2 - Taxa de geração per capita de resíduos sólidos urbanos em função da população dos municípios paulistas que rotineiramente pesam seus resíduos	44
Figura 3 - Taxa de geração per capita de resíduos sólidos urbanos em função do consumo de energia elétrica nos municípios paulistas que rotineiramente pesam seus resíduos	44
Figura 4 - Taxa de geração per capita de resíduos sólidos urbanos em função da renda per capita média mensal nos municípios paulistas que rotineiramente pesam seus resíduos	45
Figura 5 - Representação superior de TGP observadas e previstas em função das variáveis consumo de energia elétrica ($\text{kW} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$) e renda per capita média diária ($\text{USD} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$), dados de 2013	47
Figura 6 - Vista lateral de TGP observadas e previstas em função das variáveis consumo de energia elétrica ($\text{kW} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$) e renda per capita média diária ($\text{USD} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$), dados de 2013	48
Figura 7 - Representação superior de TGP observadas e previstas em função das variáveis população (hab^{-1}) e renda per capita média diária ($\text{USD} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$), dados de 2013	48
Figura 8 - Vista lateral de TGP observadas e previstas em função das variáveis população (hab^{-1}) e renda per capita média diária ($\text{USD} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$), dados de 2013	49
Figura 9 - Representação superior de TGP observadas e previstas em função das variáveis população (P em hab.) e consumo per capita diário de energia elétrica ($\text{kWh} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$)	49
Figura 10 - Vista lateral do plano que representa as TGP observadas e previstas em função das variáveis população (P em hab.) e consumo per capita diário de energia elétrica ($\text{kWh} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$)	50
Figura 11 - Representação superior de TGP observadas e previstas em função das variáveis consumo de energia elétrica ($\text{kW} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$) e renda per capita média diária ($\text{USD} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$), dados de 2014	50

Figura 12- Vista lateral de TGP observadas e previstas em função das variáveis consumo de energia elétrica ($\text{kW.hab}^{-1}.\text{d}^{-1}$) e renda per capita média diária ($\text{USD.hab}^{-1}.\text{d}^{-1}$), dados de 2014.	51
Figura 13 - Representação superior de TGP observadas e previstas em função das variáveis população (hab^{-1}) e renda per capita média diária ($\text{USD.hab}^{-1}.\text{d}^{-1}$), dados de 2014.	51
Figura 14 - Vista lateral de TGP observadas e previstas em função das variáveis população (hab^{-1}) e renda per capita média diária ($\text{USD.hab}^{-1}.\text{d}^{-1}$), dados de 2014.	52
Figura 15 - Representação superior de TGP observadas e previstas em função das variáveis população (P em hab.) e consumo per capita diário de energia elétrica ($\text{kWh.hab}^{-1}.\text{d}^{-1}$).....	53
Figura 16 - Vista lateral do plano que representa as TGP observadas e previstas em função das variáveis população (P em hab.) e consumo per capita diário de energia elétrica ($\text{kWh.hab}^{-1}.\text{d}^{-1}$).....	53
Figura 17- 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.....	56
Figura 18 - 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.....	56
Figura 19 - 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.....	56
Figura 20 - Valores de TGP observados e previstos em relação a reta bissetriz do primeiro quadrante	57
Figura 21 - Desvios entre as TGP previstas e estimadas em função dos valores previstos em 2013 e 2014	57

LISTA DE TABELAS

Tabela 1 - Relação entre países de baixo, de médio e de alto desenvolvimento quanto ao tipo de resíduo sólido.	17
Tabela 2 - Investimento mundial por região, em milhões de dólares	18
Tabela 3 - Índices estimados de produção per capita de RSU adotados em função da população urbana.....	29
Tabela 4 - Municípios com Iniciativas de Coleta Seletiva.....	30
Tabela 5 - Comparação na coleta de RSU no Estado de São Paulo.	30
Tabela 6 - Geração de taxas de geração per capita de RSU em função da renda per capita mensal mundialmente.....	31
Tabela 7 - Índices estimados de produção per capita de RSU adotados em função da população urbana.....	31
Tabela 8 - Municípios para os quais as informações foram glosadas ou suprimidas.	46
Tabela 9 - 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.....	54
Tabela 10 - Parâmetros de avaliação da qualidade dos ajustes	55

LISTA DE ABREVIATURAS E SIGLAS

ABRELPE	Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais
ABNT	Associação Brasileira de Normas Técnicas
CE	Consumo de energia elétrica em cada município (MWh)
Ce	Consumo <i>per capita</i> de energia elétrica (kWh.hab ⁻¹ .d ⁻¹)
CEMPRE	Compromisso Empresarial para Reciclagem
CETESB	Companhia Ambiental do Estado de São Paulo
d	Dia
EUA	Estados Unidos da América
hab	Habitante
IBAM	Instituto Brasileiro de Administração Municipal
IBGE	Instituto Brasileiro de Geografia e Estatística
IQVU	Índice de Qualidade de Vida Urbana
NBR	Norma Brasileira Registrada
P	População
PDNAD	Pesquisa Nacional de Amostragem por Domicílio
PIB	Produto Interno Bruto
PNRS	Política Nacional de Resíduos Sólidos
PROSAB	Programas de Pesquisa em Saneamento Básico
RMSE	Raiz quadrada do erro médio ao quadrado
RD	Resíduos Domiciliares
RPC	Renda <i>per capita</i> média (USD.hab ⁻¹ .d ⁻¹ ou USD.hab ⁻¹ .mês ⁻¹)
RS	Resíduos Sólidos
RSB	Resíduos Urbanos Biodegradáveis
RSU	Resíduos Sólidos Urbanos
SEADE	Fundação Sistema Estadual de Análise de Dados

SECTAM	Secretária Executiva de Estado de Ciência, Tecnologia e Meio Ambiente
SIG	Sistema de Informação Geográfica
SISNAMA	Sistema Nacional do Meio Ambiente
SNIS	Sistema Nacional de Informações Sobre Saneamento
SNVS	Sistema Nacional de Vigilância Sanitária
TGP	Taxa de geração <i>per capita</i> de Resíduos Sólidos Urbanos (kg.hab ⁻¹ .d ⁻¹)

LISTA DE SÍMBOLOS

E_p	Erro percentual médio
Σ	Somatório
n	Número de elementos contidos no conjunto de dados de cada amostra
r	Coeficiente de correlação de Pearson
R^2	Coeficiente de determinação
RMSE	Raiz quadrada do erro médio ao quadrado
v_i	Número de variáveis independentes
x_i	Variável independente
\bar{x}	Valor médio da variável independente x_i
y_i	Variável dependente
\bar{y}_{medida}	Valor médio da variável dependente Y_i .
y_{medida_i}	Variável dependente observada para cada elemento do conjunto de dados
y_{calci}	Variável dependente calculada para cada elemento do conjunto de dados
\bar{y}_{calc}	Valor médio da variável dependente calculada para conjunto de dados

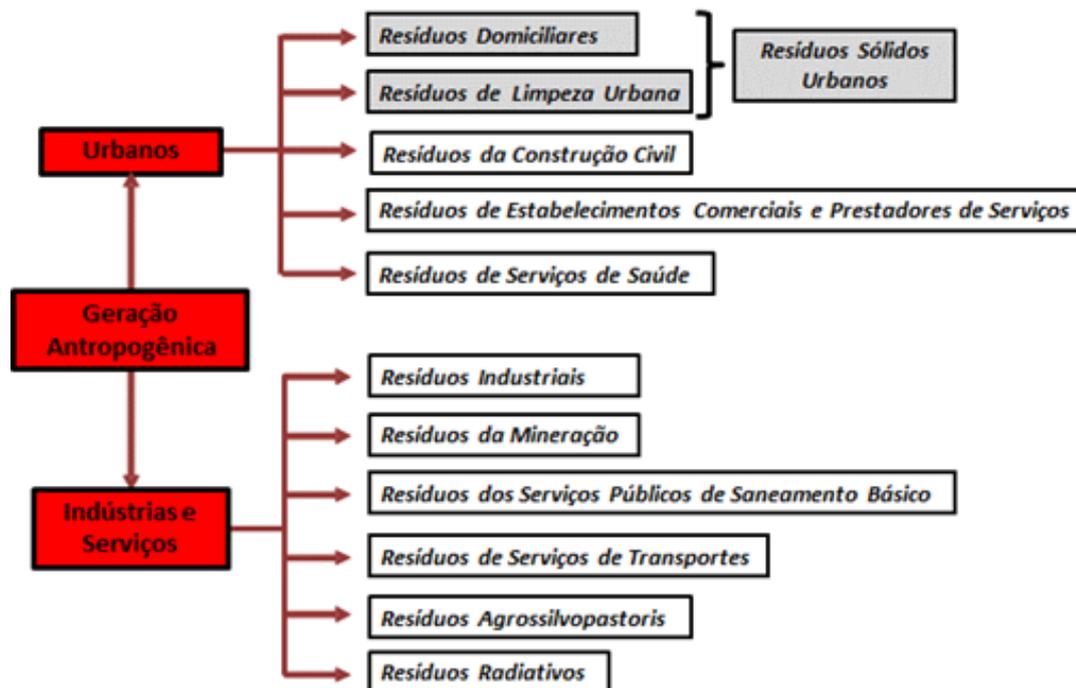
SUMÁRIO

1 INTRODUÇÃO	14
2 OBJETIVOS	16
2.1 OBJETIVO GERAL	16
2.2 OBJETIVOS ESPECÍFICOS	16
3 REVISÃO DE LITERATURA	17
3.1 RESÍDUOS SÓLIDOS.....	20
3.1.1 Classificação dos resíduos sólidos.....	21
3.1.2 Caracterização dos Resíduos Sólidos Urbanos	23
3.2 ASPECTOS AMBIENTAIS E DE SAÚDE COLETIVA RELACIONADOS AOS RSU.....	23
3.3 LEGISLAÇÃO E GERENCIAMENTO DOS RSU NO BRASIL	25
3.4 PANORAMAS ATUAIS SOBRE A GERAÇÃO DE RESÍDUOS SÓLIDOS E ESTIMATIVA DAS GERAÇÕES	27
4 MATERIAL E MÉTODOS	37
4.1 BASE DE DADOS	37
4.2 AVALIAÇÃO DO MODELO E REPRESENTATIVIDADE DA AMOSTRA	38
4.2.1 Coeficiente de Correlação de Pearson (r)	39
4.2.2 Qualidade de Ajuste	40
4.2.3 Teste <i>t-Student</i> para Correlação	43
5 RESULTADOS E DISCUSSÃO	44
5.1 REGRESSÃO LINEAR MÚLTIPLA DUAS VARIÁVEIS INDEPENDENTES	47
5.2 ESTUDO DE CORRELAÇÃO USANDO LN(P) E LN(Ce)	54
6 CONCLUSÕES	59
REFERÊNCIAS	61
APÊNDICE A – BIOESTAT V5.3	66
APÊNDICE B – DADOS LEVANTADOS MEDIANTE PESQUISAS DO SISTEMA NACIONAL DE INFORMAÇÕES SOBRE SANEAMENTO (MINISTÉRIO DAS CIDADES, 2013; FUNDAÇÃO SEADE, 2015)	70
APÊNDICE C – DADOS LEVANTADOS MEDIANTE PESQUISAS DO SISTEMA NACIONAL DE INFORMAÇÕES SOBRE SANEAMENTO (MINISTÉRIO DAS CIDADES, 2014; FUNDAÇÃO SEADE, 2016)	76
APÊNDICE D – ARTIGO SUBMETIDO EM 2016	82

1 INTRODUÇÃO

Os processos de produção e o consumo humano geram grande diversidade e quantidade de resíduos que requerem destinação ambientalmente adequada. A Lei Federal 12.305/2010 instituiu a política nacional de resíduos sólido e, no artigo 13º classificou os resíduos quanto à sua origem (Figura 1).

Figura 1 - Classificação de origem dos resíduos sólidos, segundo a Lei 12.305/2010



Fonte: Lei 12.305/2010

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 outros 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.

O Estado de São Paulo foi formado por 645 municípios no ano de 2013, dentre eles 533 participaram do Diagnóstico do Manejo de Resíduos Sólidos – 2013, dos quais 238 afirmaram pesar rotineiramente os resíduos coletados (SECRETARIA NACIONAL DE SANEAMENTO AMBIENTAL, 2015). Este conjunto de 238 municípios representou aproximadamente 82% da população total em 2013 (42.304.694 habitantes). É o Estado mais urbanizado do Brasil, com taxa de urbanização registrada em 2010 de 95,9% (FUNDAÇÃO SISTEMA ESTADUAL DE ANÁLISE DE DADOS, 2015).

O Estado de São Paulo abriga o maior parque industrial e, conseqüentemente, a maior produção econômica do país. Por ser o Estado mais rico, apresenta maior Índice de Desenvolvimento Humano (0,783 em uma escala de 0 a 1). Em 2012, gerou cerca de 56.626 t.d⁻¹ de RSU, deste montante cerca de 55.967 t.d⁻¹ foram coletados. Do total coletado, 76,3% tiveram como destino aterros sanitários e o restante, cerca de 23,7% foram enviados a aterros controlados ou lixões, não recebendo deste modo tratamento adequado (ABRELPE, 2012).

Sendo assim, este estudo teve como objetivo desenvolver uma correlação que permitisse estimar a taxa de geração *per capita* (TGP) de resíduos sólidos urbanos nos municípios do Estado de São Paulo, a partir da população, da renda *per capita* diária e do consumo diário *per capita* de energia elétrica de cada município.

2 OBJETIVOS

A seguir são mostrados os objetivos geral e específicos estabelecidos para a pesquisa.

2.1 OBJETIVO GERAL

O objetivo do trabalho foi o desenvolvimento de correlação para prever a taxa de geração *per capita* de resíduos sólidos urbanos nos municípios do Estado de São Paulo, a partir de variáveis demográficas e socioeconômicas.

2.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos propostos com intuito de atingir o objetivo geral foram:

- Verificar a dependência da taxa de geração *per capita* de resíduos sólidos urbanos (TGP) das variáveis independentes população (P), renda *per capita* média diária (RPC) e consumos de energia elétrica (Ce) nos municípios do Estado de São Paulo.
- Propor e testar diferentes funções matemáticas, com o intuito de ajustar os valores observados aos previstos para de TGP pela combinação das variáveis independentes (P, RPC e Ce).
- Avaliar a qualidade dos ajustes através do cálculo de parâmetros e aplicação de métodos estatísticos.

3 REVISÃO DE LITERATURA

A composição dos RSU é influenciada por fatores como a cultura, o desenvolvimento econômico, clima e fontes de energia; o que impacta na composição dos resíduos e na maneira em que são recolhidos e descartados, obedecendo normas e regulamentos dos países assim como suas regiões. Países de baixa renda têm a maior proporção de resíduos orgânicos enquanto papel, plásticos e outros materiais inorgânicos constituem a maior proporção de resíduos sólidos urbanos em países de alta renda.

A relação entre países de baixo, de médio e de alto desenvolvimento quanto ao tipo de resíduo sólido é apresentado na Tabela 1. Pode-se observar nesta tabela que quanto maior o desenvolvimento do país, menor é a geração de matéria orgânica, em países de alto desenvolvimento temos 30% de resíduo orgânico e biomassa, enquanto em países de baixo desenvolvimento chega a 65% deste resíduo. O uso de embalagens de papelão e plásticos cresce nos países com maior desenvolvimento. O descarte de metal também é mais acentuado nestes países com alto desenvolvimento (CHALMIN; GAILLOCHET, 2009).

Tabela 1 - Relação entre países de baixo, de médio e de alto desenvolvimento quanto ao tipo de resíduo sólido.

Tipo de resíduo	Países de baixo desenvolvimento	Países de médio desenvolvimento	Países de alto desenvolvimento
Orgânico/Biomassa	65%	43%	30%
Papel/Cartão	10%	10%	33%
Plástico	9%	11%	13%
Metal	3%	3%	7%
Vidro	3%	3%	7%
Outro	10%	12%	10%

Fonte: Chalmin, Gaillochet (2009)

O investimento mundial por região, em milhões de dólares é apresentado na Tabela 2. Os dados foram informados pelo banco mundial em 1999. Do montante investido a Ásia Oriental e do Pacífico foi a que maior recebeu investimentos predominando com 37% de todo investimento mundial e o sul da Ásia com a menor porcentagem apenas 5%.

Tabela 2 - Investimento mundial por região, em milhões de dólares

Região	Milhões de USD	Porcentagem
Sul da Ásia	428	5%
Europa e Ásia Central	1322	16%
América Latina e Caribe	1752	21%
Oriente médio e Norte da África	515	6%
Ásia Oriental e do Pacífico	3103	37%
África	1266	15%

Fonte: World Bank (1999)

O crescimento da população mundial é um fenômeno que ocorreu de maneira exponencial a partir do início da revolução industrial, em meados do século XVIII. A partir desta data, com o advento do êxodo rural, a urbanização intensificou-se de forma a ser considerada a transformação social mais importante da atualidade. Tal fenômeno exigiu com o passar dos anos, uma elevação significativa na extração de recursos naturais e conseqüentemente na geração de resíduos, uma vez que o aumento populacional demanda uma quantia maior de bens de consumo, seja eles duráveis ou não (ATHAYDE JUNIOR; BESERRA; FAGUNDES, 2008). Prova disso são estudos os quais alguns autores enfatizam que o homem a cada dia promove descobertas e produtos, criando novas necessidades de conforto e bem-estar ocasionando o aumento na exploração e transformação de recursos naturais e conseqüentemente na geração de resíduos (OLIVEIRA et al., 2004). Segundo Fialcoff (1998) o aumento crescente de resíduos gerados ocorre principalmente devido à valorização do uso de embalagens e pela preferência pelos descartáveis.

Hockett et al. (1995) correlacionaram a taxa de geração de RSU no Estado da Carolina do Norte (EUA) através de variáveis socioeconômicas, porém sem envolver a população de cada município, e obteve R^2 no intervalo de 0,37 a 0,50. Já Keser et al. (2012), em diferentes localidades na Turquia, levaram em consideração fatores socioeconômicos e climáticos na determinação da taxa de geração de RSU. Nesta pesquisa foram utilizados modelos de auto regressão espacial simultânea, regressão não espacial e regressão geograficamente ponderada para as análises de dados espaciais. Obtiveram coeficientes de Pearson (r) no intervalo de 0,47 a 0,59, porém com valores das raízes quadradas do erro médio ao quadrado (RMSE) da ordem de 50 % dos valores previstos. Xu et al. (2013) desenvolveram um modelo híbrido que combinava o modelo sazonal auto-regressivo de média móvel ao sistema de cinza para a previsão de geração de resíduos sólidos urbanos em uma

cidade específica (na China) por múltiplas escalas de tempo sem a necessidade de considerar outras variáveis, tais como dados demográficos e socioeconômicos. Os resultados alcançados demonstraram que o modelo bastante preciso, porém, restrito à cidade avaliada.

Ojeda-Benítez et al. (2008) propuseram para a cidade do México modelos capazes de relacionar a geração *per capita* de resíduos domiciliares (variável dependente) para diferentes variáveis (independentes), tais como educação, renda por domicílio e número de moradores. A fim de analisar o modelo que melhor explicava a previsão, o conjunto de dados foi analisado a partir dos testes de normalidade, Kolmogorov-Smirnov, multicolinearidade e heterocedasticidade. O valor máximo do coeficiente de determinação (R^2) foi de 0,51. Já no estudo de Navarro et al. (2002) foi demonstrados dois modelos, tendo como objeto 3 cidades gregas e 3 espanholas, propuseram técnicas distintas para prever a geração de resíduos sólidos urbanos. A primeira baseia-se em dinâmica não linear, na qual é proposto um modelo comparativo de desempenho, com uma média sazonal auto regressiva em movimento denominado SARIMA. A segunda técnica assumiu que a geração de resíduos sólidos urbanos era um sistema dinâmico discreto de uma única variável escalar. Apesar dos desvios resultantes de até 5%, não disponibilizaram equações que permitissem utilização.

A relação entre fatores demográficos e socioeconômicos foi alvo de estudo no Brasil em Pinto et al. (2012) e Dias et al. (2012), nos quais correlacionaram a taxa de geração de RSU em Belo Horizonte, com a população, o índice de qualidade de vida urbana (IQVU) e renda *per capita*. Demonstraram que o IQVU e a renda conjuntamente com o número de moradores eram variáveis que influenciam a geração de resíduos sólidos em bairros do município.

No entanto, as equações descritas são aplicáveis apenas ao município avaliado. Neste mesmo município foram empregados diferentes métodos que permitiram chegar à conclusão de que os fatores como socioeconômicos, como educação e renda, e demográficos, como estrutura etária e domiciliar, eram importantes na geração de RSU em sub-regiões do município (SILVA et al., 2012).

O Estado de São Paulo era formado por 655 municípios no ano de 2013, dentre eles 533 participaram do Diagnóstico do Manejo de Resíduos Sólidos – 2013, dos quais 238 afirmaram pesar rotineiramente os resíduos coletados (SECRETARIA NACIONAL DE SANEAMENTO AMBIENTAL, 2015). Este conjunto de 238

municípios representou aproximadamente 82 % da população total em 2013 (42.304.694 habitantes). É o Estado mais urbanizado do Brasil, com taxa de urbanização registrada em 2010 de 95,9% (FUNDAÇÃO SISTEMA ESTADUAL DE ANÁLISE DE DADOS, 2015). O Estado de São Paulo abriga o maior parque industrial e, conseqüentemente, a maior produção econômica do país. Por ser o Estado mais rico, apresenta maior Índice de Desenvolvimento Humano (0.783 em uma escala de 0 a 1). Em 2012, gerou cerca de 56626 t.d⁻¹ de RSU, deste montante cerca de 55967 t.d⁻¹ foram coletados. Do total coletado, 76,3% tiveram como destino aterros sanitários e o restante, cerca de 23,7% foram enviados a aterros controlados ou lixões, não recebendo deste modo tratamento adequado (ABRELPE, 2012). Sendo assim, este estudo teve como objetivo desenvolver uma correlação que permitisse estimar a taxa de geração *per capita* (TGP) de resíduos sólidos urbanos nos municípios do Estado de São Paulo, a partir da população, da renda *per capita* anual e do consumo total de energia elétrica de cada município, com base na geração de RSU de 2013.

Segundo a Lei nº 203, de 1991 e apensos, resíduo é definido como qualquer material resultante de processo de produção, transformação, utilização ou consumo, oriundos de atividades humanas ou animais, ou decorrentes de fenômenos naturais, cujo descarte se procede, se propõe proceder ou se está obrigado a proceder.

Dentre os diferentes tipos de resíduos gerados os denominados resíduos sólidos ocupam uma grande parcela e merece atenção no que diz respeito ao seu gerenciamento. Neste contexto, no Brasil foi instituída a lei nº 12305/2010 de Política Nacional de Resíduos Sólidos, a qual descreve os princípios, objetivos, instrumentos e diretrizes relacionadas a gestão integrada e ao gerenciamento de resíduos sólidos, incluídos os perigosos, às responsabilidades dos geradores e do poder público e aos instrumentos econômicos aplicáveis. Estando sujeitas a esta Lei, de acordo com o seu Art. 1º. § 1º, todas as empresas, administrações públicas (federais, estaduais e municipais) e população em geral.

3.1 RESÍDUOS SÓLIDOS

A definição estabelecida pela NBR 10004/2004 para resíduos sólidos consiste em:

Resíduos no estado sólido e semi-sólido, que resultam de atividades de origem industrial, doméstica, hospitalar, comercial, agrícola e de serviços de varrição. Ficam incluídos nessas definições os lodos provenientes de sistema de tratamento de água, aqueles gerados de equipamentos e instalações de controle de poluição, bem como determinados líquidos cujas particularidades tornem inviável o seu lançamento na rede pública de esgotos ou corpos de água, ou exijam para isso soluções técnicas e economicamente inviáveis em face à melhor tecnologia disponível (ABNT, 2004, p.1).

Uma segunda definição mais simples desta terminologia descreve que resíduo sólido é todo material sólido ou semi-sólido indesejável e que necessita ser removido por ter sido considerado inútil por quem o descarta em qualquer recipiente destinado a este ato (IBAM, 2001).

Calderoni (1998) afirma ainda que o conceito de resíduo possa variar conforme a época e o lugar e depende de fatores jurídicos, econômicos, ambientais, sociais e tecnológicos, pois a ideia de aproveitamento ou reinserção do resíduo na cadeia produtiva deve ser avaliada com suas particularidades.

3.1.1 Classificação dos resíduos sólidos

A classificação dos resíduos sólidos pode ocorrer de diversas maneiras, no entanto, as mais comuns estão relacionadas aos riscos potenciais de contaminação do meio ambiente e a origem e/ou natureza do mesmo.

Segundo a NBR – 10.004/2004 (ABNT, 2004) quanto ao potencial risco de contaminação os resíduos sólidos podem ser classificados em:

Classe I - Perigosos: são classificados como perigosos os resíduos sólidos que apresentam características tais como inflamabilidade, corrosividade, reatividade, toxicidade ou patogenicidade, pois podem acarretar danos à saúde pública e ao meio ambiente quando manuseados e/ou dispostos de forma inadequada;

Classe II – Não perigosos: esta classe se subdivide em:

Classe II A - Não-inertes: são resíduos que não apresentam periculosidade, não se enquadram na classe I ou Classe II B, porém não são inertes e apresentam como características: combustibilidade, biodegradabilidade ou solubilidade em água;

Classe II B - Resíduos inertes: são aqueles que, ao serem submetidos a teste de solubilização (NBR10.006/2004) não tiveram nenhum de seus constituintes solubilizados em concentrações superiores aos padrões de portabilidade da água.

No que diz respeito a sua origem, segundo a Lei de nº 12.305 de 2 de agosto de 2010, os resíduos sólidos podem ser classificados em:

- a) Resíduos domiciliares: são os resíduos gerados diariamente nas residências;
- b) Resíduos de limpeza urbana: são os resíduos provenientes do serviço de limpeza urbana;
- c) Resíduos sólidos urbanos: os englobados nos itens a e b;
- d) Resíduos de estabelecimentos comerciais e prestadores de serviços: os resíduos gerados nos estabelecimentos comerciais, como escritórios, lojas, hotéis, restaurantes, supermercados, bancos entre outros;
- e) Resíduos dos serviços públicos de saneamento básico: os gerados nessas atividades, excetuados os referidos no item c;
- f) Resíduos industriais: são compostos por vários tipos de materiais, dependendo do ramo de atividade industrial, do processamento e da matéria-prima empregada;
- g) Resíduos de serviços de saúde: os gerados nos serviços de saúde, conforme definido em regulamento ou em normas estabelecidas pelos órgãos do SISNAMA e do SNVS.
- h) Resíduos da construção civil: são resíduos provenientes de construções, reformas, reparos e demolição de obras da construção civil;
- i) Resíduos agrossilvopastoris: os gerados nas atividades agropecuárias e silviculturais, incluídos os relacionados a insumos utilizados nessas atividades;
- j) Resíduos de serviços de transportes: os originários de portos, aeroportos, terminais alfandegários, rodoviários e ferroviários e passagens de fronteira;
- k) Resíduos de mineração: os gerados na atividade de pesquisa, extração ou beneficiamento de minérios;

Os resíduos sólidos podem ainda ser classificados quanto a sua degradabilidade (facilmente degradáveis: como restos de alimentos; moderadamente degradáveis: como papéis, papelão e materiais celulósicos; dificilmente degradáveis: como trapos, pedaços de pano, serragens, aparas de couro, borracha e madeira; não-degradáveis: vidros, metais, plásticos, terra, pedras, e outros); quanto à sua natureza física (seco ou molhado), e, finalmente, quanto à sua composição (matéria orgânica ou inorgânica) (SILVA, 2005).

3.1.2 Caracterização dos Resíduos Sólidos Urbanos

A definição de RS torna clara a diversidade de materiais que podem ser enquadrados nesta definição, em particular os resíduos sólidos urbanos são aqueles produzidos em diferentes áreas do município pelas diferentes atividades desenvolvidas, abrangendo, por exemplo, os resíduos de origem residencial e comercial, industrial, de limpeza pública (varrição, capina, poda e outros), de estabelecimentos de saúde, construção civil e, finalmente agrícola (PROSAB, 2003).

O conhecimento da composição física destes resíduos é de grande importância para seu gerenciamento e varia de acordo com diversos aspectos; para tal caracterização a CETESB recomenda a análise da sua composição por meio de amostras coletadas pela técnica de quarteamento seguindo a NBR 10.007 da ABNT (PROSAB, 2003; SILVA, 2005).

Segundo IBAM (2001), entre os principais fatores que influenciam a composição dos resíduos sólidos urbanos estão os hábitos e a cultura da população, as variações sazonais e climáticas, a densidade demográfica, leis, regulamentações específicas, poder aquisitivo, nível educacional, entre outros. No entanto o fator econômico é o de maior influência, sendo assim composição e produção de resíduos está diretamente associada ao estágio de desenvolvimento da região (CONSONI; SILVA; GIMENEZ FILHO, 2000).

3.2 ASPECTOS AMBIENTAIS E DE SAÚDE COLETIVA RELACIONADOS AOS RSU

No que diz respeito ao aspecto ambiental, a disposição inadequada dos resíduos sólidos urbanos pode resultar ou não em contaminação e deterioração de recursos naturais como ar, solo e águas superficiais (BROLLO; SILVA, 2001). Quando o resíduo é lançado a céu aberto, sem nenhum critério, torna-se uma ameaça ao ambiente, pois pode ocasionar alterações nas características do solo e águas através do lixiviado, um líquido resultante do processo de decomposição da matéria orgânica presente, que apresenta como características a cor preta e o mau cheiro. Este chorume pode contaminar mananciais subterrâneos e superficiais de água, o que traria grande prejuízo à sociedade em geral. Se lançado diretamente em cursos de água, por exemplo, é possível que ocorra a redução da comunidade de

peixes e outros animais aquáticos presentes. Além disso, o resíduo diretamente lançado em córregos, igarapés, rios e praias provocam acúmulo de sedimentos nos leitos destes ecossistemas, onde além da contaminação provocada, ocorre o aumento da temperatura da água, provocando decréscimo na quantidade de oxigênio dissolvido, tornando o ambiente impróprio e difícil para a vida dos seres vivos que ali se encontram. Isso sem levar em consideração a possibilidade de lançamento de resíduo de origem hospitalar e industrial que podem apresentar características tóxicas e perigosas para o solo, água e ar onde foram despejados (SECTAM, 1997). De acordo com estudos realizados pelo Painel Intergovernamental sobre Mudanças Climáticas, o setor de resíduos contribui com pouco menos de 5% das emissões de gases de efeito globais, ressaltando que o gás metano gerado pela deposição final dos resíduos sólidos em aterros sanitários é o principal responsável pelo efeito estufa, uma vez que este gás é cerca de 21 vezes mais prejudicial que o dióxido de carbono. Além disto, as alterações ambientais causadas pela poluição ao longo do tempo têm o poder de comprometer ecossistemas causando danos muitas vezes irreversíveis (SEIDEL, 2010).

Em relação à saúde pública, os resíduos atuam como fator indireto na transmissão de doenças por meio de vetores que encontram nos resíduos sólidos urbanos restos de alimento e condições ideais para sua sobrevivência e proliferação, deixando claro desta forma a trajetória pela qual pode ocorrer a transmissão de doenças provenientes da falta de gerenciamento correto destes resíduos (BROLLO; SILVA, 2001, DEUS, LUCA; CLARKE, 2004).

De acordo com estudo realizado por Oliveira e Santos (2012), o qual avaliou a saúde ocupacional dos garis de Hidrôlandia em Goiás, e conforme relatado por Ferreira e Anjos (2001), dentre os agentes físicos, químicos e biológicos que se destacam pela capacidade de causar danos a saúde humana e o meio ambiente estão:

i) agentes físicos: o odor dos resíduos pode ocasionar mal estar, cefaléias e náuseas em pessoas que se encontrem próximas a eles; a poeira pode ser responsável pelo desconforto, perda momentânea da visão, e por problemas respiratórios e pulmonares; menos divulgada temos o fator estético dos resíduos o qual pode causar grande desconforto e náusea. Outro agente físico de risco apontado são os elementos perfurantes e cortantes, que trazem risco tanto aos

trabalhadores responsáveis pela limpeza quanto àqueles que por algum motivo tiveram acesso a estes resíduos.

ii) agentes químicos: a presença mais frequente é de pilhas e baterias; óleos e graxas; pesticidas/herbicidas; solventes; tintas; produtos de limpeza; cosméticos; remédios; aerossóis. Como já classificado previamente, a presença de muitos destes agentes pode apresentar periculosidade, podendo ser responsáveis por saturnismo e distúrbios no sistema nervoso (pela presença de chumbo, cádmio e mercúrio), dentre outras doenças.

iii) agentes biológicos: Microrganismos patogênicos presentes em itens como lenços de papel, curativos, fraldas descartáveis, papel higiênico, absorventes, agulhas e seringas descartáveis podem ser os responsáveis pela transmissão de doenças através do trato intestinal (*Ascaris lumbricoides*; *Entamoebacoli*; *Schistosoma mansoni*); o vírus causador da hepatite (principalmente do tipo B), dermatites, entre outras.

3.3 LEGISLAÇÃO E GERENCIAMENTO DOS RSU NO BRASIL

O gerenciamento integrado de resíduos sólidos envolve as etapas de geração, minimização, classificação, coleta, transporte, transbordo, reutilização, reciclagem, compostagem, recuperação e aproveitamento energético ou demais formas de tratamento de resíduos sólidos, seguidos da disposição final de rejeitos (BRASIL, 2010). A quantificação do montante de resíduos é fundamental para a escolha e dimensionamento das operações e processos envolvidos 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.

Inicialmente a legislação relacionada aos resíduos sólidos referia-se e preocupava-se com a coleta adequada e, principalmente com a disposição final do material descartado. Já na década de 80, a atenção estava voltada para as formas de pré-tratamento e eliminação total dos resíduos. Nos dias de hoje, principalmente nos países industrializados há uma inclinação bastante evidente relacionada a incentivos de ações de prevenção e redução de resíduos a partir da fonte geradora, além de propostas de recuperação dos recursos utilizados nestes resíduos (BROLLO, SILVA, 2001).

Os resíduos sólidos urbanos (RSU) são encaminhados para disposição final em aterros sob responsabilidade do poder municipal; no caso de resíduos comerciais estes são aceitos para coleta e disposição final em aterro desde que autorizado pelas instituições competentes, o que ocorre normalmente na maioria dos municípios. Já resíduos não domiciliares provenientes, por exemplo, da construção civil e de serviços ligados à saúde é de responsabilidade do gerador a disposição final, ficando o mesmo sujeito a legislação específica vigente (Lei de nº 12.305, 2010).

Dados de 2012 levantados pela ABRELPE em sua última publicação sobre o Panorama de Resíduos Sólidos no Brasil demonstram que 58% dos resíduos sólidos urbanos coletados tiveram como destino final os aterros sanitários (105.111 t/dia), enquanto os 42% restantes (cerca de 76 mil toneladas diárias) foram destinados a lixões ou aterros controlados, o que de fato não apresenta grandes diferenças, uma vez que estes aterros controlados assim como os lixões não apresentam medidas adequadas de proteção ao meio ambiente contra danos e prejuízos causados pelos resíduos. Este panorama quando comparado ao de 2011 demonstra que apesar dos incentivos e legislação restrita grande parte dos resíduos coletados no Brasil ainda tem destino impróprio, uma vez que os dados deste ano apontaram que 42% dos resíduos coletados foram destinados a locais impróprios.

A Constituição Federal prevê ao poder público municipal a responsabilidade de zelar pela limpeza, coleta e destinação final do resíduo urbano como mencionado anteriormente. Com a lei de nº 12.305/2010 instituída em 02 de agosto de 2010 que institui a Política Nacional de Resíduos Sólidos (PNRS), o papel das prefeituras ganha maior destaque com princípios e diretrizes, dentro de um conjunto de responsabilidades que tem o potencial de mudar o panorama dos resíduos no Brasil (CEMPRE, 2010).

A PNRS, *a priori* de responsabilidade do governo federal, também demanda uma participação intensa dos Estados, Distrito Federal e dos municípios, não apenas no que diz respeito a viabilidade, mas também a sua manutenção. O Art. 4º menciona que a Política Nacional de Resíduos Sólidos reúne o conjunto de princípios, objetivos, instrumentos, diretrizes, metas e ações adotadas pelo Governo Federal, isoladamente ou em regime de cooperação com estados, Distrito Federal, municípios ou particulares, com vistas à gestão integrada e ao gerenciamento

ambientalmente adequado dos resíduos sólidos. Os municípios deste modo teriam obrigação legal de erradicar áreas insalubres até agosto de 2014.

Um dos objetivos apresentadas no PNRS, abordado no art. 7º, parágrafo décimo, diz respeito à:

regularidade, continuidade, funcionalidade e universalização da prestação de serviços públicos de limpeza urbana e 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, observada a Lei nº 11.445, de 2007 (LEI FEDERAL nº 12305/2010).

As providências que devem ser tomadas pelos municípios incluem ações voltadas para a reciclagem e disposição em aterros legalizados, elaboração com prazo fixado de um plano de resíduos sólidos que aborde o diagnóstico atual da situação, metas a serem cumpridas com objetivo de mitigar a geração de resíduos, reciclagem, erradicação de lixões, soluções consorciadas com outros municípios, devendo ainda constar os principais geradores de resíduos, os custos envolvidos e indicadores de desempenho do serviço público neste campo (CEMPRE, 2010).

A Lei nº 12.300 de 16 de Março de 2006, denominada Política Estadual de Resíduos Sólidos regulamenta todo o processo de gestão integrada e compartilhada de resíduos sólidos. Em seu Capítulo I descreve que:

para alcançar os objetivos colimados, caberá ao poder público, em parceria com a iniciativa privada: - Incentivar a pesquisa, o desenvolvimento, a adoção e a divulgação de novas tecnologias, de reciclagem, tratamento e disposição final de resíduos sólidos, inclusive de prevenção à poluição e - Promover a implementação, em parcerias com os municípios, instituições de ensino e pesquisa e organizações não governamentais, de programa estadual de capacitação de recursos humanos com atuação na área de resíduos sólidos (LEI ESTADUAL nº 12300/2006)

3.4 PANORAMAS ATUAIS SOBRE A GERAÇÃO DE RESÍDUOS SÓLIDOS E ESTIMATIVA DAS GERAÇÕES

O conhecimento do cenário atual a respeito da quantidade de resíduos existentes e de métodos de projeção da geração dos mesmos ao longo dos anos é um processo de grande importância para se alcançar um gerenciamento focado em um planejamento eficaz e em instalações eficientes (CHUNG, 2010).

Baasch (1995) afirmou que o processo de geração de resíduos é o ponto de partida no sistema de gerenciamento de resíduos sólidos. A quantidade exata de gerada é de difícil determinação, uma vez que está susceptível a sofrer diferentes

interferências tanto no processo de armazenamento, reutilização e reciclagem quanto devido a descarte em locais clandestinos, o que acaba desviando o fluxo de materiais antes de sua deposição final em local de domínio público.

Atualmente os panoramas da geração de resíduos são estimados a partir da quantidade de resíduos de fato coletados por meio de pesquisa em base de dados pertencentes ao setor responsável das prefeituras municipais e através da utilização de métodos estimativos baseados, por exemplo, na expectativa de crescimento da população, na produção *per capita* de resíduos sólidos ou no crescimento da demanda dos serviços de limpeza urbana. Outra opção seria através de levantamentos de campo adotando diferentes procedimentos. Seja qual for o método escolhido deve-se sempre ter bem estabelecido o período de amostragem e a época do ano em que será realizado o estudo estatístico (ZANTA; FERREIRA, 2003, ONOFRE, 2011).

Para a projeção de geração de resíduos sólidos a ABRELPE coleta dados relativos às populações urbana, total dos municípios, estados brasileiros e índices de urbanização da Pesquisa Nacional de Amostragem por Domicílios – PNAD por meio de consulta à base de dados do Instituto Brasileiro de Geografia e Estatística (IBGE); para o levantamento da geração de resíduos a organização realiza pesquisas diretas realizadas junto aos municípios. Depois de coletados e tratados os dados são transformados em indicadores *per capita*. A assertividade das projeções é analisada através do coeficiente de determinação (R^2), e para as definições de equações que permitam realizar as projeções, as mesmas são submetidas a análise através dos métodos dos mínimos quadrados, eliminando pontos extremos, através da técnica de análise e regressão. A determinação dos mínimos quadrados é utilizada com o objetivo demonstrar a tendência das projeções e validar a fórmula encontrando assim uma equação que permita a realização de projeção para cada município. O teste de Fisher é empregado para analisar o quanto as variáveis contribuem para a explicação das variações apresentadas nas projeções. Os coeficientes das variáveis que compõem as equações obtidas são testados em sua significância. Os dados quantitativos relativos aos RSU estão diretamente relacionados à comunidade em que se encontra. A projeção da geração de RSU por região e estados, bem como para o total nacional, resulta da aplicação dos índices de coleta da pesquisa PNAD, obtendo-se por extrapolação os valores para os próximos anos.

No Brasil, a primeira pesquisa elaborada para análise da situação dos resíduos sólidos urbanos foi a Pesquisa Nacional de Saneamento Básico, realizada pelo governo brasileiro através do Instituto Brasileiro de Geografia e Estatística em 1989 e divulgada em 1992. O interesse de então conduzir estudos com objetivo de identificar fatores sociais, econômicos e demográficos associados à geração de resíduos sólidos no país levou não só o governo, mas entidades privadas a pesquisarem tais interações e aproximarem assim os dados do setor privado às estatísticas oficiais (FIGUEIREDO, 2011).

Dentre os indicadores adotados para mensurar a geração de resíduos sólidos de uma determinada população, a geração *per capita* é um dos mais utilizados e é calculado a partir da quantidade de resíduos sólidos produzido por determinado habitante em uma unidade de tempo estabelecida.

IBAM (2001) relatou que muitos técnicos consideram de 0,5 a 0,8 kg.hab⁻¹.d⁻¹ como a faixa de variação média de geração de resíduo sólido para o Brasil. No entanto, na ausência de dados mais precisos, a geração *per capita* pode ser estimada através da Tabela 3.

Tabela 3 - Índices estimados de produção *per capita* de RSU adotados em função da população urbana.

Tamanho da cidade	População urbana (habitantes)	Geração <i>per capita</i> (kg.hab⁻¹.d⁻¹)
Pequena	Até 30 mil	0,50
Média	De 30 mil a 500 mil	De 0,50 a 0,80
Grande	De 500 mil a 5 milhões	De 0,80 a 1,00
Megalópole	Acima de 5 milhões	Acima de 1,00

Fonte: IBAM, 2001

Na Tabela 4 está representado o número absoluto de municípios com iniciativa de coleta seletiva, nos anos de 2013 e 2014, em todas as regiões apresentou um aumento na coleta seletiva em torno de 10%.

Tabela 4 - Municípios com Iniciativas de Coleta Seletiva

Região	Norte		Nordeste		Centro-Oeste		Sudeste		Sul		BRASIL	
	2013	2014	2013	2014	2013	2014	2013	2014	2013	2014	2013	2014
Sim	223	239	725	767	158	175	1.378	1.418	975	1.009	3.459	3.608
Não	227	211	1.069	1.027	309	292	290	250	216	182	2.111	1.962
Total	450		1.794		467		1.668		1.191		5.570	

Fonte: ABRELPE, 2014

O panorama apresentado no estudo realizado pela Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais (ABRELPE, 2014) estipula valores de geração de resíduos no Estado de São Paulo nos anos de 2013 e 2014.

Tabela 5 - Comparação na coleta de RSU no Estado de São Paulo.

População Total		RSU Coletado				RSU Gerado (t/dia)	
		(kg.hab ⁻¹ .d ⁻¹)		(t/d)			
2013	2014	2013	2014	2013	2014	2013	2014
43.663.669	44.035.304	1,346	1,381	58.752	60.810	59.291	61.344

Fonte: ABRELPE e IBGE, 2014.

É importante salientar, é comum haver divergências entre as localidades estudadas uma vez que diversos fatores como cultura, renda, hábito, nível educacional como já mencionados podem influenciar não só a composição dos resíduos como também na quantidade gerada.

Para países da América Latina, especificamente, Acurio et al. (1998) relataram que a geração *per capita* tem uma variação de 0,5 a 1,3 kg.hab⁻¹.d⁻¹. Analisando uma relação entre o crescimento populacional, o crescimento econômico e a geração *per capita* de resíduos urbanos, Contador (2000) afirmou que pesquisas empíricas relataram que 1% de aumento no PIB *per capita* está associado com o aumento de 0,34% na geração de resíduos sólidos, enquanto o acréscimo de 1% da população expandiu a geração de resíduos em 1,04%. Ainda neste aspecto, Dangi et al. (2008) reportaram dados que apontam para uma relação direta entre a taxa de geração *per capita* e o nível de renda da população.

Segundo Contador (2000), uma variação de 0,5 kg em Moçambique a 1,9 kg na Austrália pode ser observada por meio dos dados obtidos a partir de 36 países. Entre a camada social menos favorecida, verificou-se que a geração não é inferior a

0,3 a 0,4 kg.hab⁻¹.d⁻¹. Na Tabela 6 são fornecidas a geração *per capita* em função da renda e, portanto, indiretamente de sua classe econômica.

No que diz respeito ao Brasil, segundo dados do IBGE (2002), se for levado em consideração somente os resíduos domiciliares (RD), em todos municípios foram coletados diariamente cerca de 125.281 t de RD do total de RSU coletados, e a estimativa da geração *per capita* de RD seria de 738 g.hab⁻¹.d⁻¹ (OLIVEIRA et al., 2004), o que mostra que esta classe representa uma parcela significativa dos resíduos sólidos urbanos, e 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.

Tabela 6 - Geração de taxas de geração *per capita* de RSU em função da renda *per capita* mensal mundialmente

Classe de renda <i>per capita</i> mensal (US\$)	Taxa de geração <i>per capita</i> (kg.hab ⁻¹ .d ⁻¹)
Até 600	0,53
600 – 2490	0,63
2490 – 7050	0,71
Mais de 7050	1,20

Fonte: adaptada de Beede, Bloom, apud Contador, 2000

No Estado de São Paulo, em seu inventário anual, a Companhia Ambiental do Estado de São Paulo (CETESB), no ano de 2014, apontou índices de produção por habitante apresentado na Tabela 7, usualmente empregados para estimar a quantidade de resíduos sólidos dispostos.

Tabela 7 - Índices estimados de produção *per capita* de RSU adotados em função da população urbana

População (hab)	Produção (kg.hab ⁻¹ .d ⁻¹)
Até 25.000	0,7
De 25.001 a 100.000	0,8
De 100.001 a 500.000	0,9
Maior que 500.000	1,1

Fonte: CETESB, 2014

A exceção a essa regra é feita ao município de São Paulo, para o qual são adotadas as quantidades diárias de resíduos divulgados oficialmente pelas concessionárias do serviço municipal. Para os municípios onde são efetuadas pesagens das quantidades de resíduos destinadas ao tratamento e/ou disposições

finais poderão ocorrer índices diferentes dos acima indicados, em decorrência de vários fatores, tais como: tipo da atividade produtiva predominante no município, nível socioeconômico, sazonalidade de ocupação, existência de programas de coletas seletivas e ações governamentais que objetivem a conscientização da população quanto à redução da geração de resíduos (CETESB, 2014).

Muitos são os trabalhos descritos na literatura que propõem métodos de estimativas da geração de resíduos, dentre eles, um estudo realizado por Purcell e Magette (2009) quantificou e identificou a distribuição da geração de resíduos urbanos biodegradáveis (RSB) em áreas residenciais e de estabelecimentos comerciais como restaurantes, hotéis e hospitais, em Dublin. Para realização desse trabalho, variáveis socioeconômicas, tipos de habitação, assim como os tamanhos e principais atividades dos estabelecimentos comerciais foram considerados como as principais determinantes que contribuem para a variabilidade espacial da geração de RSB e um modelo de sistema de informação geográfica (SIG) de geração de RSB foi criado. Dados estatísticos incluindo status socioeconômico e o tamanho da família foram coletados, assim como informações da literatura sobre taxas de geração de RSB para estabelecimentos residenciais e comerciais. Estas previsões foram combinadas para dar estimativas RSB globais para a região, estimativas estas que podem ajudar as decisões de planejamento e de políticas de resíduos. Como resultado observou-se que a técnica de previsão das residências apresentou uma estimativa global mais precisa da geração de resíduos domésticos do que a técnica de classe social. Ao alterar os dados de entrada, os autores afirmam que esta ferramenta de estimativa pode ser adaptada para o uso em outras localizações, trazendo assim grandes benefícios.

Outro trabalho, realizado por Vijayet et al. (2005), também apresentou uma metodologia baseada em um Sistema de Informações Geográficas (SIG), para estimar a geração de resíduos sólidos decorrentes de determinada sociedade, com disposição feita em coletores públicos, com base na densidade populacional e PIB *per capita* dessa sociedade. Apesar de diversos autores validarem essa metodologia, eles não apresentam nenhuma modelagem matemática que represente a mesma.

Navarro et al. (2002) propuseram dois modelos desenvolvidos, tendo como objeto de estudo cidades gregas e espanholas, onde os mesmos propuseram técnicas distintas para prever a geração de resíduos sólidos urbanos. A primeira

baseia-se em dinâmica não linear, na qual é proposto um modelo comparativo de desempenho, com uma média sazonal auto regressiva em movimento denominado SARIMA. A segunda técnica assume que a geração de resíduos sólidos urbanos é um sistema dinâmico discreto de uma única variável escalar. Apesar de desvios resultantes de até 5%, não disponibilizaram equações que permitissem utilização.

A possível relação entre fatores demográficos e socioeconômicos foi alvo de estudo no trabalho realizado por Pinto, Pereira e Freitas (2012), onde utilizando dados sobre a quantidade de resíduos sólidos gerada em Belo Horizonte, população o Índice de Qualidade de Vida Urbana (IQVU) do ano 2000, foi possível demonstrar através da utilização dos Modelos Lineares de Regressão Múltipla que o IQVU juntamente com o número de moradores são variáveis que influenciam a geração de resíduos sólidos no município em estudo, demonstrando ainda que exista influência de variáveis tais como sexo, raça/cor, idade e renda do responsável pelo domicílio e tipo de esgotamento sanitário. No entanto, as equações descritas são aplicáveis apenas ao município avaliado.

Um segundo trabalho nesse mesmo município, em 2002, foi realizado empregando-se diferentes métodos estatísticos os quais permitiram chegar à conclusão de que os fatores como socioeconômicos tais como educação e renda, e demográficos como estrutura etária e domiciliar, são importantes na definição volume de resíduos gerado em sub-regiões do município. Nesta conclusão o consumo foi visto como o elo entre as dimensões população e geração de resíduos (SILVA, BARBIERI e MONTE-MÓR, 2012). Ainda em Belo Horizonte, Dias et al. (2012) apresentaram um modelo matemático visando identificar a relação entre a geração *per capita* de resíduos e a renda *per capita* em alguns bairros, encontrando um coeficiente de determinação de 0,85.

Mello (2014) propôs em seu trabalho desenvolver uma equação que permitisse estimar a taxa de geração *per capita* (TGP) de resíduos sólidos urbanos nos municípios do Estado de São Paulo, a partir de variáveis demográficas e socioeconômicas. Como resultado observou-se que não houve correlação linear considerável entre o Produto Interno Bruto *per capita* e as TGP de RSU nos municípios do Estado de São Paulo, nos anos de 2008 e 2010, com base nos coeficientes de correlação de Pearson obtidos. No entanto, entre a variável população e as TGP de RSU. Diferentes equações foram testadas a fim verificar quais eram capazes de descrever adequadamente os dados estratificados ou em

conjunto referente aos anos de 2008, 2010 e 2012. As equações propostas foram qualificadas como adequadas para se prever as TGP de RSU, alcançando dessa forma o objetivo neste estudo.

Benítez et. al (2008) propuseram para uma cidade do México modelos capazes de relacionar a geração *per capita* de RS (variável dependente) para diferentes variáveis (independentes), tais como educação, renda por domicílio e número de moradores. Após coleta de dados da geração, quantificação e composição dos resíduos domiciliares, os modelos de previsão foram definidos e para cada fase de amostragem de resíduos foi desenvolvido um modelo matemático diferente, a fim de encontrar o que apresentasse a melhor relação linear para prever geração de resíduos sólidos residenciais. A fim de analisar o modelo que melhor explicasse a previsão cada conjunto de dados, foi analisado separadamente para determinar quão boa eram as medidas de ajuste, posteriormente foram empregados testes de normalidade, Kolmogorov-Smirnov, multicolinearidade e heterocedasticidade. Foram estabelecidos ainda modelos para explorar a combinação entre as variáveis a fim de selecionar aqueles que apresentaram um R^2 superior, neste modelo formulado com as quatro variáveis em análise o teste Durban - Watson foi aplicado. O valor máximo do coeficiente de determinação (R^2) foi de 0,51.

Em estudos na Europa e nos Estados Unidos, a geração de RSU tem sido correlacionada com valores correspondentes ao produto interno bruto (PIB) e população. Em um estudo realizado em algumas localidades destas duas regiões, em períodos específicos, foi desenvolvido um modelo que buscava associar as despesas relacionadas ao consumo total ao PIB; este modelo criado foi utilizado para estimar os valores das frações individuais de resíduos sólidos gerados. Para o desenvolvimento do modelo, as atividades foram divididas em duas partes, a primeira lida com a predição do total de resíduos sólidos municipais coletados por um país e a segunda atenta-se a estimar a composição destes resíduos. Para a primeira parte, dados estatísticos disponíveis da tonelagem anual de resíduos sólidos urbanos, PIB e população foram correlacionados. As correlações permitiram previsões satisfatórias da quantidade total de resíduos sólidos urbanos a serem obtidos tanto para os países europeus quanto para os EUA. Os desvios entre os valores previstos e medidos são, no entanto, inferiores no caso dos EUA, porque o modelo correspondente baseia-se em dados de um mesmo país. Boa combinação

entre os valores previstos e medidos para as frações individuais de resíduos sólidos municipal foram alcançadas, no entanto, o modelo de predição das frações individuais no resíduo sólido municipal para os países europeus, baseia-se exclusivamente em informações disponíveis para o Reino Unido (DASKALOPOULOS, PROBERT, 1998).

Em um estudo realizado por Keser; Duzgun; Aksoy (2012), em diferentes localidades na Turquia, foram levados em consideração fatores socioeconômicos e climáticos na determinação da taxa de geração de RSU. Nesta pesquisa foram utilizados modelos de auto regressão espacial simultânea e regressão geograficamente ponderada para as análises de dados espaciais. Semelhante a regressão dos mínimos quadrados ordinários, os coeficientes de regressão são globais em modelos de auto regressão espacial, o que significa que o efeito de uma dada variável independente sobre uma variável dependente é válido para todo o país. Já a regressão geograficamente ponderada e a auto regressão espacial simultânea revela o impacto local de um determinado fator (ou variável independente) sobre as taxas de geração de resíduos de diferentes províncias. Obtiveram neste estudo coeficientes de Pearson (r) no intervalo de 0,47 a 0,59, porém com valores das raízes quadradas de erro médio ao quadrado (RMSE) da ordem de 50% dos valores previstos.

Xu et al. (2013) desenvolveram um modelo híbrido que combinou o modelo sazonal auto regressivo de média móvel ao sistema de cinza para a previsão de geração de resíduos sólidos urbanos em uma cidade na China, por múltiplas escalas de tempo sem a necessidade de considerar outras variáveis, tais como dados demográficos e sócio econômicos. Os resultados alcançados demonstraram que o modelo foi bastante preciso, porém restrito à cidade avaliada.

Hockett; Lober e Pilgrim (1995) correlacionaram a taxa de geração de RSU no Estado da Carolina do Norte (EUA) através de variáveis socioeconômicas, porém sem envolver a população de cada município, e obteve R^2 no intervalo de 0,37 a 0,50.

Como demonstrando vários são os trabalhos que objetivaram estimar a geração de resíduos de determinada população, sendo este o princípio para uma gestão eficaz dos resíduos gerados. Neste sentido, Beigl; Lebersorger e Salhofer (2008) realizaram uma revisão dos modelos já publicados de geração de resíduos sólidos urbanos identificando as metodologias propostas e analisando-as no que diz

respeito a sua aplicação, que deve ser escolhida de acordo com o objetivo do trabalho. Entretanto, a pesquisa aponta em sua discussão três modelos com maior relevância, por poderem ser aplicados na maioria dos casos. São eles análises de correlação e regressão, e comparação de grupos.

4 MATERIAL E MÉTODOS

Como mencionado anteriormente, estimar e projetar as quantidades de resíduos gerados são estratégias fundamentais para o gerenciamento integrado de resíduos; neste contexto são descritos alguns parâmetros estatísticos utilizados para se avaliar a dependência entre variáveis e a qualidade do ajuste de modelos a conjuntos de dados.

No estudo de correlação procura-se verificar a magnitude e o sentido da associação que possa existir variáveis dependentes e independentes. No teste de regressão, ao contrário, a finalidade é determinar a dependência de uma variável em relação à chamada variável independente ou preditora.

4.1 BASE DE DADOS

Os dados iniciais de geração de resíduos sólidos urbanos para os municípios que rotineiramente pesaram 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 e 2014 (SECRETARIA NACIONAL DE SANEAMENTO AMBIENTAL, 2015, 2016). As taxas de geração *per capita* de resíduos sólido urbanos de seis municípios foram glosadas, por inconsistência nos valores observados e seus valores foram substituídos pelos resultados informados nos planos municipais de gestão integrada de resíduos sólidos.

Já as populações, as rendas *per capita* anuais e os consumos de eletricidade de cada município foram obtidos mediante consulta ao sítio Eletrônico da Fundação Estadual de Análise de Dados (FUNDAÇÃO SISTEMA ESTADUAL DE ANÁLISE DE DADOS, 2015, 2016). A fim de correlacionar os resultados foram utilizadas também as variáveis independentes renda *per capita* diária ($R\$.hab^{-1}.d^{-1}$) e consumo de eletricidade *per capita* em cada município ($kWh.hab^{-1}.d^{-1}$). Após a coleta dos dados secundários, determinou-se a taxa de geração *per capita* medida de todos os municípios do Estado de São Paulo admitindo a hipótese de que todo resíduo gerado no Estado foi coletado e encaminhado a aterros, pois a cobertura do serviço de coleta no Estado de São Paulo corresponde a 98 – 99,7 % (FUNDAÇÃO SISTEMA ESTADUAL DE ANÁLISE DE DADOS, 2015; ABRELPE, 2012).

4.2 AVALIAÇÃO DO MODELO E REPRESENTATIVIDADE DA AMOSTRA

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):

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

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.

Inicialmente 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 (C_e) e dependência linear para a renda *per capita* (RPC) (Equações 2 a 6). Para isto, foram utilizados os programas computacionais BIOESTAT 5.3, gratuito, 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.

$$TGP = a + b.(P) + c.(RPC) \quad (2)$$

$$TGP = a + b.(P) + c.(Ce) \quad (3)$$

$$TGP = a + b.(RPC) + c.(Ce) \quad (4)$$

$$TGP = a + b.(P) + c.(RPC) + d.(Ce) \quad (5)$$

$$TGP = a + b.Ln(P) + c.RPC + d.[Ln(Ce)]^e \quad (6)$$

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.

Os métodos estatísticos utilizados foram análise de correlação linear, regressão linear, teste t-Student e regressão multivariável. A regressão múltipla linear foi semelhante à regressão linear simples, mas a quantidade de variáveis independentes ou preditoras foi de duas ou mais.

4.2.1 Coeficiente de Correlação de Pearson (r)

O coeficiente de correlação de Pearson (r) também conhecido como coeficiente de correlação produto-momento ou o coeficiente r de Pearson (Equação 7) tem por objetivo medir o grau da correlação linear entre duas variáveis quantitativas. Tal avaliação apresenta-se como um índice adimensional com valores situados entre -1,0 e 1,0, normalmente representado pela letra r e reflete a intensidade de uma relação linear entre dois conjuntos de dados. Se r for igual a 1, há uma correlação perfeita positiva entre as duas variáveis e se r for igual a -1, obtém-se uma correlação negativa perfeita entre as duas variáveis, indicando que estas movem-se em direções opostas, isto é, se uma aumenta, a outra sempre diminui. Enquanto duas variáveis perfeitamente correlacionadas positivamente (r = 1) movem-se essencialmente em perfeita proporção na mesma direção, dois conjuntos que estão perfeitamente correlacionados negativamente movem-se em perfeita proporção, mas em direções opostas. Entretanto se o resultado final alcançado for igual a 0, as duas variáveis não dependem linearmente uma da outra, podendo existir uma outra dependência que seja não linear. Assim, o resultado r igual a 0 deve ser investigado por outros meios (LEGATES; MCCABE, 1999;

MORIASI et al., 2007). O coeficiente de correlação de Pearson (r) é definido pela Equação 7.

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y}_{medida})}{\sqrt{\left(\sum (x_i - \bar{x})^2\right)} \sqrt{\left(\sum (y_i - \bar{y}_{medida})^2\right)}} \quad (7)$$

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 .

Como valores extremos (-1 e 1) dificilmente são encontrados na prática, é importante discutir como os pesquisadores podem interpretar a magnitude dos coeficientes. Para Cohen (1988), valores entre 0,10 e 0,29 podem ser considerados pequenos; resultados entre 0,30 e 0,49 podem ser considerados como médios; e valores entre 0,50 e 1 podem ser interpretados como grandes. Dancey e Reidy (2005) apontaram para uma classificação ligeiramente diferente: $r = 0,10$ até $0,30$ (fraco); $r = 0,40$ até $0,6$ (moderado); $r = 0,70$ até 1 (forte). Seja como for, o certo é que quanto mais perto de 1 (independente do sinal) maior é o grau de dependência estatística linear entre as variáveis. No outro oposto, quanto mais próximo de zero, menor é a força dessa relação.

4.2.2 Qualidade de Ajuste

A avaliação da qualidade de ajuste dos dados obtidos foi feita a partir do cálculo de alguns parâmetros amplamente utilizados em estudos estatísticos: o coeficiente de correlação de Pearson (r), o coeficiente de determinação (R^2), raiz quadrada dos erros médios ao quadrado (RMSE) e erro percentual médio (Ep).

O coeficiente de determinação é o quadrado do coeficiente de correlação de Pearson (Equação 8), e apresenta-se como uma das formas de avaliar a qualidade do ajuste do modelo utilizado. É conhecido também como R^2 e 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 R^2 pode variar de 0 a 1, sendo pouco comum uma correlação

perfeita ($R^2= 1$) na prática, uma vez que existem muitos fatores que determinam as relações entre variáveis na vida real, deste modo valores mais elevados estão associados a menor variância de erro, em outras palavras, quanto mais próximo de 1 mais explicativo é o modelo, ou seja, melhor ele se ajusta a amostra (LEGATES; MCCABE, 1999; MORIASI et al., 2007).

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

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).

Conforme acima mencionado, como valores limite (0 ou 1) dificilmente são encontrados na prática, é importante verificar como os pesquisadores podem interpretar a magnitude dos coeficientes, R^2 variando de 0 a 1 com maior valor encontrado indica menor variância do erro e, geralmente valores maiores do que 0,5 são considerados aceitáveis (MORIASI et al., 2007).

Diversos são os índices de erros comumente utilizados na avaliação de modelos estatísticos. Tais índices de erros são importantes uma vez que indicam erros nas unidades (ou unidades quadradas) dos elementos de interesse, o que auxilia na análise e interpretação dos resultados. Entre estes um dos mais utilizados

é denominada de raízes quadradas do erro médio ao quadrado, ou simplesmente RMSE (Equação 9).

O RMSE quantifica os erros em termos de unidades da variável, é a estatística não-negativa que não têm limite superior, onde valores de 0 indicam um ajuste perfeito, é dada através da fórmula (ABDULLAH, 2009; MORIASI et al., 2007; YAFEE; McGEE, 2000).

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

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 e n é o número de elementos contidos no conjunto de dados de cada amostra e vi é o número de variáveis independentes.

O erro percentual médio é dado pela Equação 10, quanto menor for seu valor indica o quão eficiente é a previsão comparada com o valor encontrado no período de avaliação; melhor será a previsão pelo modelo quanto mais próximo E_p for de 0%:

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

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.

4.2.3 Teste *t-Student* para Correlação

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 dessas médias seguiria uma distribuição *t* de Student. O formato da distribuição *t* de Student é dependente do número de graus de liberdade, ou seja, quanto maior este número, mais concentrada é a distribuição. Quanto maiores os graus de liberdade mais a distribuição *t* de Student se aproxima da distribuição normal.

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 desse resultado ter ocorrido for pequena, pode-se concluir que o resultado observado é estatisticamente relevante. Essa probabilidade também é chamada de p -valor ou p . Conseqüentemente, 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 um $p < 0,05$, tem-se um r momento de Pearson próximo de 1, o que significa uma forte correlação (TIBONI, 2010).

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

5 RESULTADOS E DISCUSSÃO

Nas Figuras 2 a 4 são mostradas as taxas de geração de *per capita* de resíduos sólidos urbanos para os municípios do Estado de São Paulo que informaram pesar rotineiramente seus resíduos (MINISTÉRIO DAS CIDADES, 2015, 2016), referente aos anos de 2013 e 2014. Nos apêndices A e B são os conjuntos de dados utilizados.

Figura 2 - Taxa de geração *per capita* de resíduos sólidos urbanos em função da população dos municípios paulistas que rotineiramente pesam seus resíduos

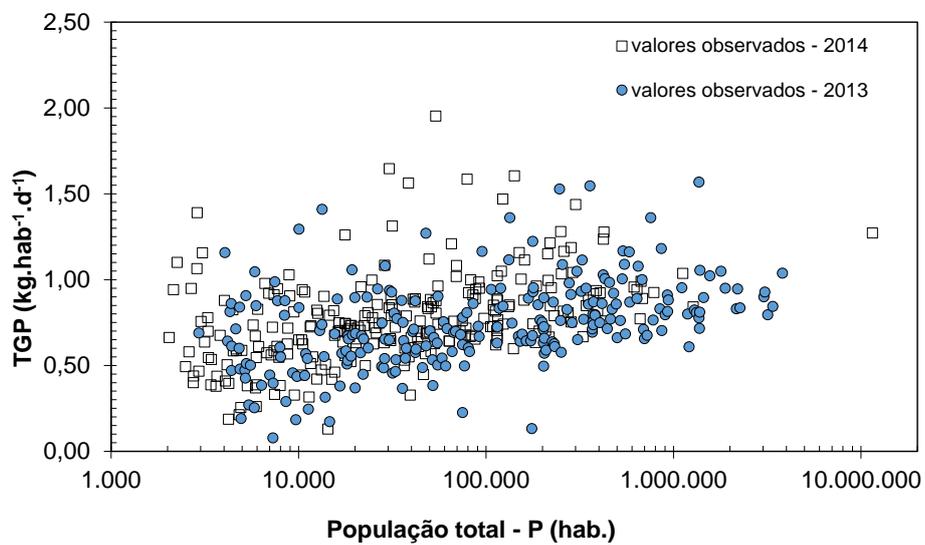


Figura 3 - Taxa de geração *per capita* de resíduos sólidos urbanos em função do consumo de energia elétrica nos municípios paulistas que rotineiramente pesam seus resíduos

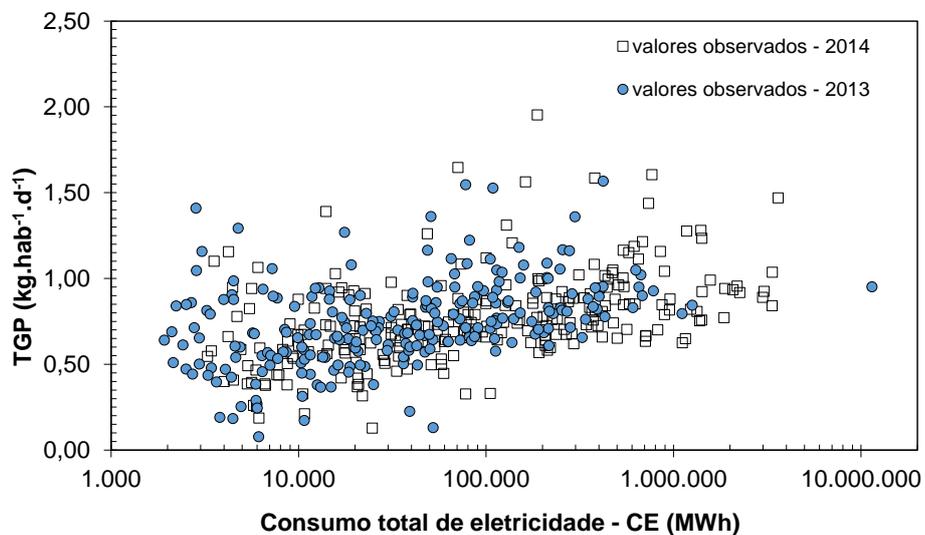
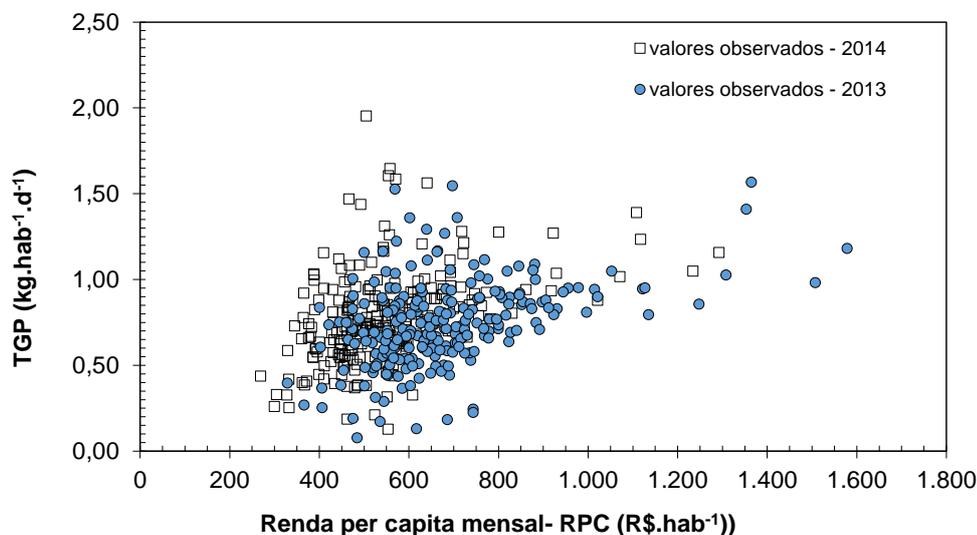


Figura 4 - Taxa de geração *per capita* de resíduos sólidos urbanos em função da renda *per capita* média mensal nos municípios paulistas que rotineiramente pesam seus resíduos



Nota-se pelas Figuras 2 a 4 dispersão acentuada da taxa de geração *per capita* de RSU em relação às variáveis independentes, há municípios com geração superior a $1,0 \text{ kg.hab}^{-1}.\text{d}^{-1}$ para populações na faixa de 3 mil a 400 mil habitantes, por outro lado cidades com TGP inesperadamente baixas, inferiores a $0,5 \text{ kg.hab}^{-1}.\text{d}^{-1}$ para populações no intervalo de no intervalo de 3 mil a 40 mil habitantes. Além disto, percebe-se pelas Figuras 2 e 3 o mesmo comportamento de TGP em relação a P e CE, cuja tendência foi de crescimento em relação ao logaritmo neperiano destas variáveis e linear a partir da renda *per capita*. No entanto, existe interdependência entre P e CE, uma vez que o consumo total de eletricidade nos municípios ao longo do ano é bastante influenciado pelo número de habitantes, logo optou-se por utilizar a consumo diário *per capita* de energia elétrica (Ce) na análise dos resultados.

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. Na Tabela 8 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 %.

Tabela 8 - Municípios para os quais as informações foram glosadas ou suprimidas

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

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 %.

Portanto, comprovou-se 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.

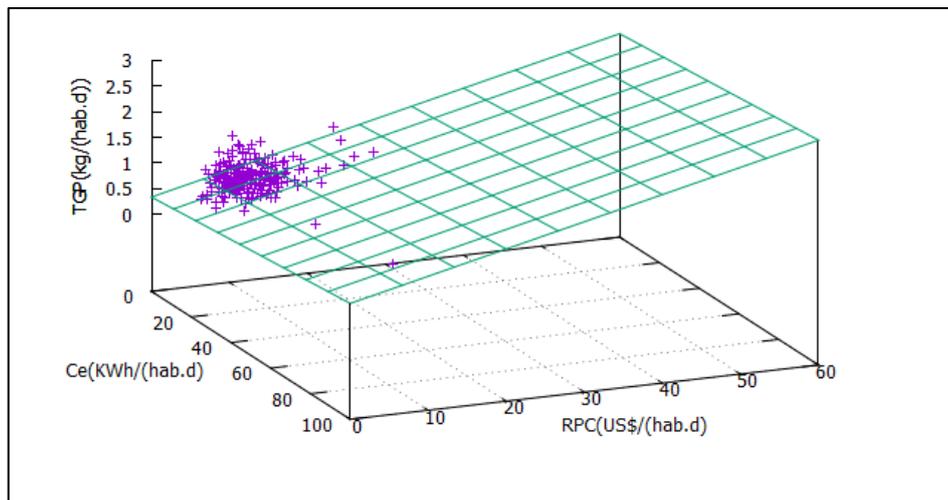
5.1 REGRESSÃO LINEAR MÚLTIPLA DUAS VARIÁVEIS INDEPENDENTES

As regressões lineares múltiplas foram feitas com a combinação de duas variáveis independentes nos anos de 2013 e 2014. Os resultados foram representados comparando as funções de regressão de $TGP_{(Ce, RPC)}$, $TGP_{(P, RPC)}$ e $TGP_{(P, Ce)}$ nos diferentes anos. As análises de correlação e da regressão linear múltipla foram realizadas com o uso do software Bioestat versão 5.3.

A correlação múltipla entre a variável dependente TGP e as variáveis independentes, dados de 2013, consumo de energia elétrica *per capita* diário (Ce em $kWh.hab^{-1}.d^{-1}$) e renda *per capita* diária (RPC em $USD.hab^{-1}.d^{-1}$) (Equação 12) resultou em coeficiente de correlação de Pearson r de 0,45, R^2 de 0,20, RMSE de 0,223 $kg.hab^{-1}.d^{-1}$ e Ep de -15,0%, indicando moderado grau de correlação. Os resultados da equação no plano de regressão $TGP_{(Ce, RPC)}$ foram apresentados nas Figuras 5 e 6, com vistas superior e lateral. Pode-se observar relativa correlação entre a função e os pontos observados das diferentes cidades

$$TGP = 0,335 + 0,0042.Ce_{(kW.hab^{-1}.d^{-1})} + 0,0164.RPC_{(USD.hab^{-1}.d^{-1})} \quad (12)$$

Figura 5 - Representação superior de TGP observadas e previstas em função das variáveis consumo de energia elétrica ($kW.hab^{-1}.d^{-1}$) e renda *per capita* média diária ($USD.hab^{-1}.d^{-1}$), dados de 2013.



A correlação múltipla entre a variável dependente TGP e as variáveis independentes, renda *per capita* (RPC) e população (P em hab.) (Equação 13) forneceu coeficiente de correlação de Pearson r igual a 0,43, coeficiente de determinação (R^2) de 0,18, erro percentual médio (Ep) de -15,2 % e com RMSE de $0,225 \text{ kg.hab}^{-1}.\text{d}^{-1}$, indicando média ou intermediária correlação múltipla. A equação ajustada foi:

$$\text{TGP} = 0,348 + 4,19 \cdot 10^{-9} \cdot P_{(\text{hab})} + 0,0375 \cdot \text{RPC}_{(\text{USD.hab}^{-1}.\text{d}^{-1})} \quad (13)$$

O ajuste do plano (Figuras 7 e 8) referente a essa combinação de variáveis não trouxe melhoria em relação à qualidade de ajuste quando comparada com RPC e P.

Figura 6 - Vista lateral de TGP observadas e previstas em função das variáveis consumo de energia elétrica ($\text{kW.hab}^{-1}.\text{d}^{-1}$) e renda *per capita* média diária ($\text{USD.hab}^{-1}.\text{d}^{-1}$), dados de 2013.

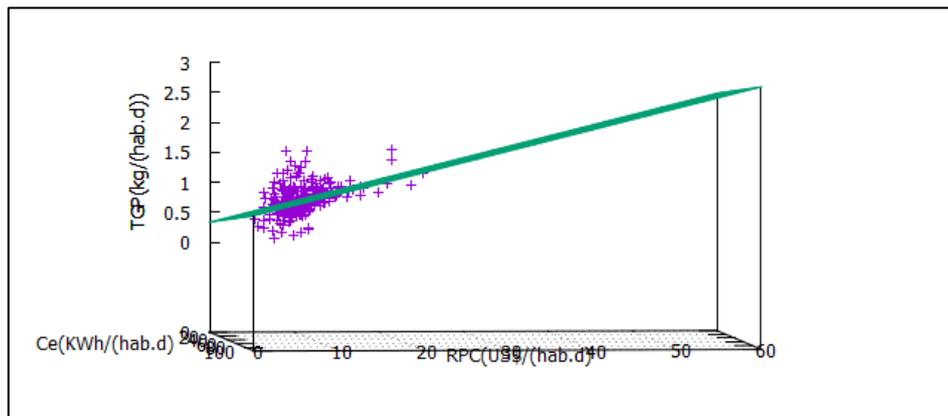


Figura 7 - Representação superior de TGP observadas e previstas em função das variáveis população (hab^{-1}) e renda *per capita* média diária ($\text{USD.hab}^{-1}.\text{d}^{-1}$), dados de 2013

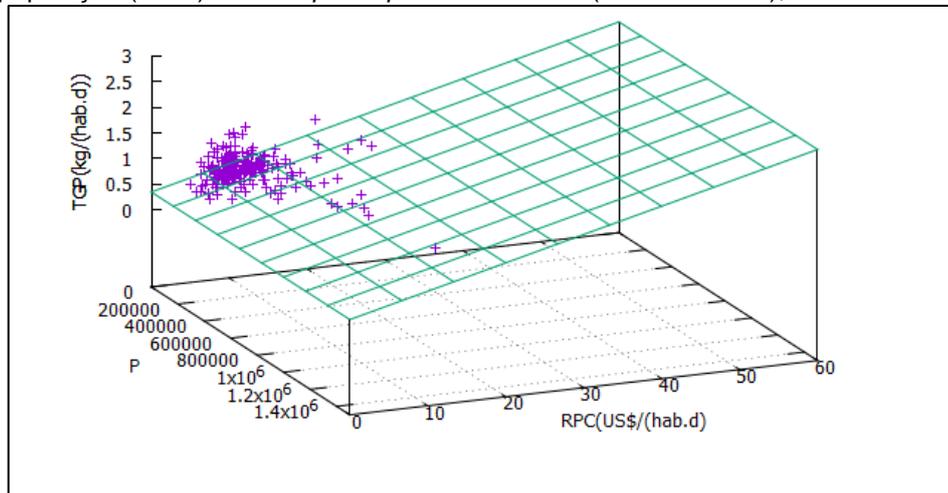
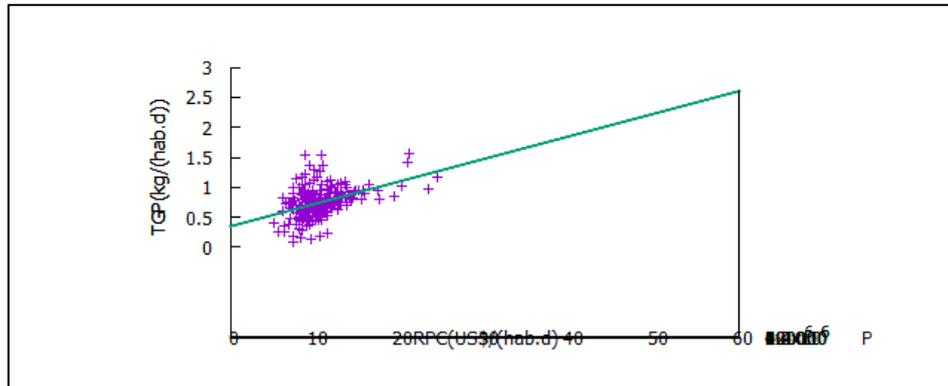


Figura 8 - Vista lateral de TGP observadas e previstas em função das variáveis população (hab^{-1}) e renda *per capita* média diária ($\text{USD} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$), dados de 2013.



A correlação múltipla entre a variável dependente TGP e as variáveis independentes população (P) e consumo diário de energia elétrica *per capita* (Ce) (Equação 14) resultaram em coeficiente de correlação de Pearson (r) de apenas 0,24, R^2 de 0,06, Ep de -17,2 % e RMSE igual $0,241 \text{ kg} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$, valores que representam a pior correlação até o momento. A equação do plano ajustado TGP em função das variáveis população (P em hab.) e consumo *per capita* diário de energia elétrica Ce ($\text{kWh} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$) foi representada nas Figuras 9 e 10.

$$\text{TGP} = 0,675 + 3,81 \cdot 10^{-8} \cdot P_{(\text{hab})} + 0,00745 \cdot \text{Ce}_{(\text{kWh} \cdot \text{hab}^{-1} \cdot \text{d}^{-1})} \quad (14)$$

Figura 9 - Representação superior de TGP observadas e previstas em função das variáveis população (P em hab.) e consumo *per capita* diário de energia elétrica ($\text{kWh} \cdot \text{hab}^{-1} \cdot \text{d}^{-1}$)

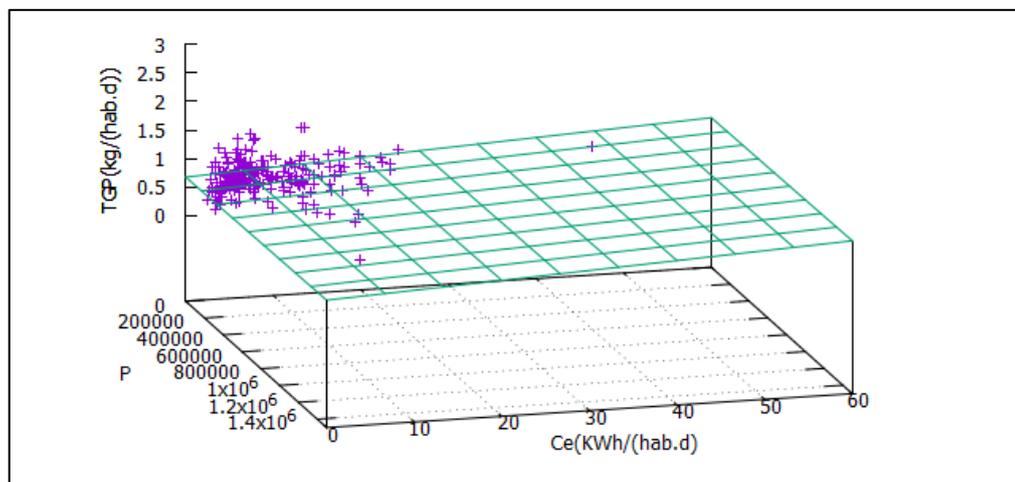
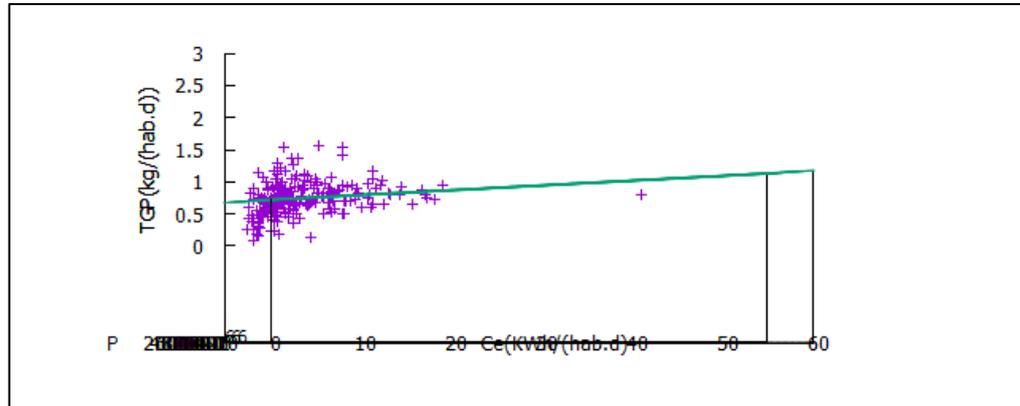


Figura 10 - Vista lateral do plano que representa as TGP observadas e previstas em função das variáveis população (P em hab.) e consumo *per capita* diário de energia elétrica (kWh.hab⁻¹.d⁻¹)



Nos dados de 2014, a correlação múltipla entre a variável dependente TGP e as variáveis independentes, consumo de energia elétrica *per capita* diário (Ce em kWh.hab⁻¹.d⁻¹) e renda *per capita* diária (RPC em USD.hab⁻¹.d⁻¹) resultou na Equação 15, atrelada a r de 0,44, R² de 0,20, RMSE de 0,238 kg.hab⁻¹.d⁻¹ e Ep de -16,1%, indicando moderada correlação múltipla. Os planos representados nas Figuras 11 e 12 são indicativos dessa dependência, TGP_(Ce, RPC).

$$TGP = 0,357 + 0,0075.Ce_{(kW.hab^{-1}.d^{-1})} + 0,0338.RPC_{(USD.hab^{-1}.d^{-1})} \quad (15)$$

Figura 11 - Representação superior de TGP observadas e previstas em função das variáveis consumo de energia elétrica (kW.hab⁻¹.d⁻¹) e renda *per capita* média diária (USD.hab⁻¹.d⁻¹), dados de 2014.

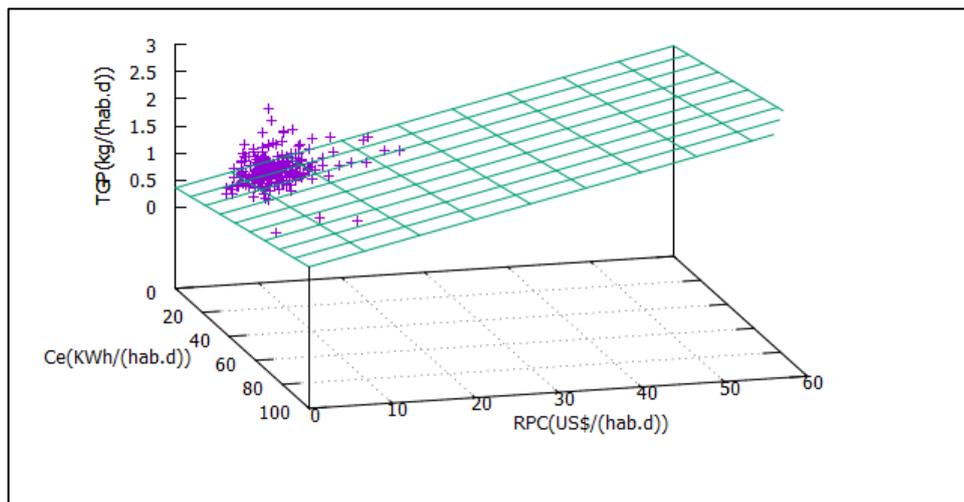
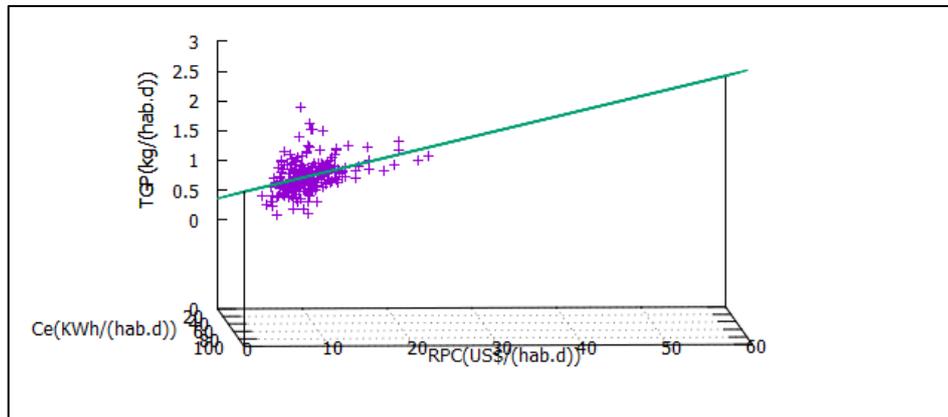


Figura 12- Vista lateral de TGP observadas e previstas em função das variáveis consumo de energia elétrica (kW.hab⁻¹.d⁻¹) e renda *per capita* média diária (USD.hab⁻¹.d⁻¹), dados de 2014.



A correlação múltipla $TGP_{(P,RPC)}$ para 2014 (Equação 16) forneceu coeficiente de correlação de Pearson igual a 0,40, coeficiente de determinação (R^2) de 0,17, erro percentual médio (E_p) de -16,4 % e RMSE de 0,243 kg.hab⁻¹.d⁻¹, indicando também média ou intermediária correlação múltipla, cuja representação foi feita através das Figuras 13 e 14).

$$TGP = 0,4012 + 3,09 \cdot 10^{-8} \cdot P_{(hab)} + 0,0353 \cdot RPC_{(USD.hab^{-1}.d^{-1})} \quad (16)$$

Figura 13 - Representação superior de TGP observadas e previstas em função das variáveis população (hab⁻¹) e renda *per capita* média diária (USD.hab⁻¹.d⁻¹), dados de 2014.

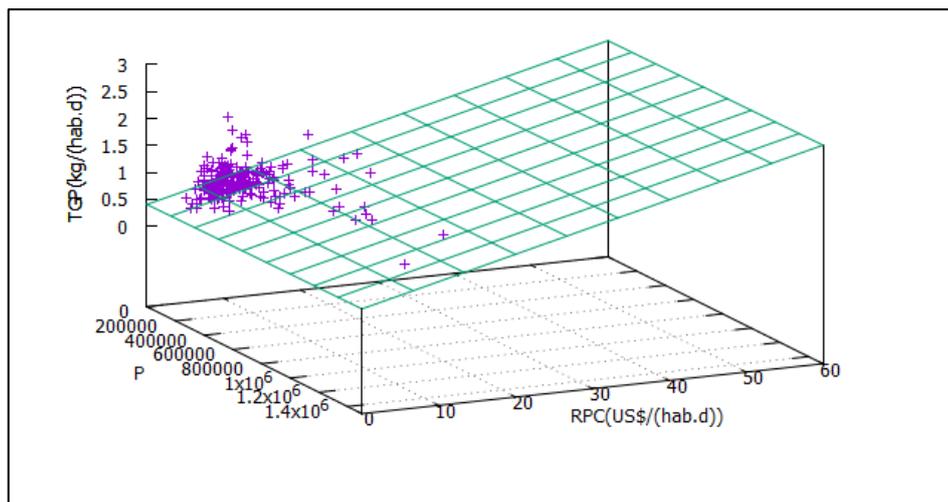
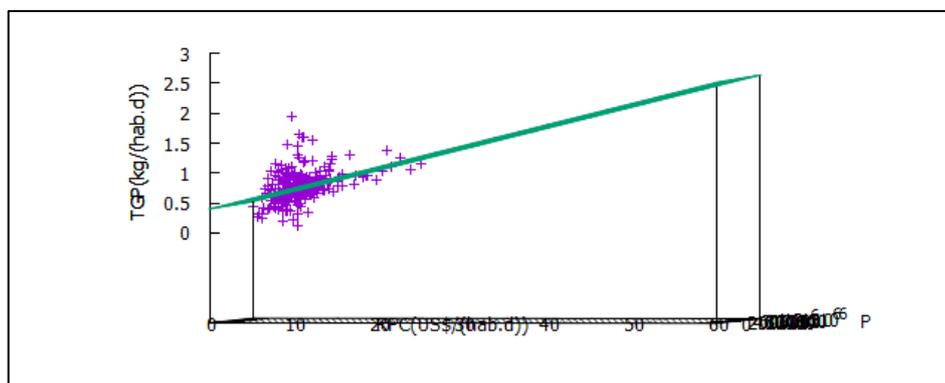


Figura 14 - Vista lateral de TGP observadas e previstas em função das variáveis população (hab^{-1}) e renda *per capita* média diária ($\text{USD}.\text{hab}^{-1}.\text{d}^{-1}$), dados de 2014.



A correlação múltipla entre a variável dependente TGP e as variáveis independentes população (P) e consumo diário de energia elétrica *per capita* (Ce) resultaram em coeficiente de correlação de Pearson (r) de apenas 0,32, R^2 de 0,10, Ep de -17,7 % e RMSE igual $0,252 \text{ kg}.\text{hab}^{-1}.\text{d}^{-1}$, valores que representam a pior correlação até o momento. A equação do plano ajustado TGP em função das variáveis população (P em hab.) e consumo *per capita* diário de energia elétrica Ce ($\text{kWh}.\text{hab}^{-1}.\text{d}^{-1}$) (Equação 17) foi representado superiormente na Figura 15 e lateralmente na Figura 16.

$$\text{TGP} = 0,678 + 6,317 \cdot 10^{-8} \cdot P_{(\text{hab})} + 0,0101 \cdot \text{Ce}_{(\text{kWh}.\text{hab}^{-1}.\text{d}^{-1})} \quad (17)$$

Em síntese, nota-se pelas Figuras 5 e 7 que os pontos observados estão dispersos ao redor dos planos de previsão, o que indica que não houve desvio sistemático na previsão pelas Equações 11 e 12. Porém, a qualidade do ajuste ao se utilizar a Equação 6 foi melhor, em decorrência de maiores valores de r e R^2 e menores RMSE e Ep ($r = 0,32$, $R^2 = 0,10$, $\text{RMSE} = 0,344 \text{ kg}.\text{hab}^{-1}.\text{d}^{-1}$ e $\text{Ep} = -26,3\%$), quando comparados com os obtidos na Equação 12 ($r = 0,30$, $R^2 = 0,08$, $\text{Ep} = -25,8\%$, $\text{RMSE} = 0,347 \text{ kg}.\text{hab}^{-1}.\text{d}^{-1}$).

Já nas Figuras 9 e 10, foi observada a tendência de desvio sistemático, sobretudo para municípios com população ao redor de 200 mil habitantes. Fato que comprometeu a qualidade das estimativas ao se utilizar a Equação 8. Sendo assim, fez-se o teste de previsão para equações envolvendo as três variáveis independentes.

A regressão linear múltipla para as três variáveis simultaneamente (P, Ce e RPC) (Equação 18), referente aos anos de 2013 e 2014, forneceu a mesma equação de regressão e o melhor ajuste até o momento, pois r foi de 0,32, R^2 de 0,10, Ep de -5,8 % e RMSE de 0,345 $\text{kg.hab}^{-1}.\text{d}^{-1}$ para 2013, e para 2014 r foi de 0,45, R^2 de 0,21, Ep de -16,1 % e RMSE de 0,237 $\text{kg.hab}^{-1}.\text{d}^{-1}$.

$$\text{TGP} = 0,339 + 6,19 \cdot 10^{-9} \cdot P_{(\text{hab})} + 0,00422 \cdot \text{Ce}_{(\text{kWh.hab}^{-1}.\text{d}^{-1})} + 0,0348 \cdot \text{RPC}_{(\text{USD.hab}^{-1}.\text{d}^{-1})} \quad (18)$$

Figura 15 - Representação superior de TGP observadas e previstas em função das variáveis população (P em hab.) e consumo *per capita* diário de energia elétrica ($\text{kWh.hab}^{-1}.\text{d}^{-1}$)

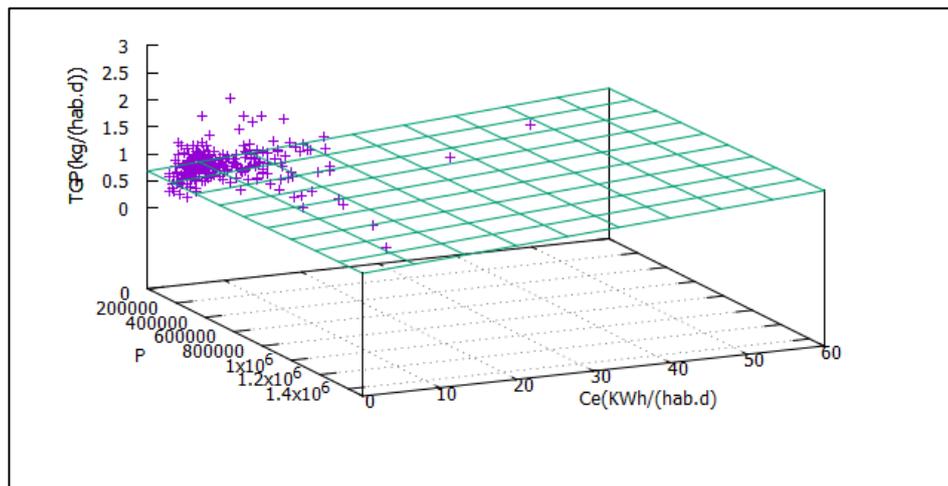
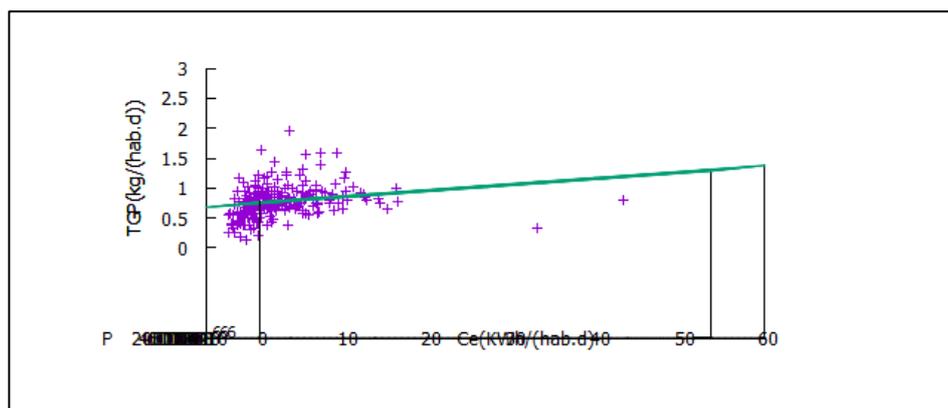


Figura 16 - Vista lateral do plano que representa as TGP observadas e previstas em função das variáveis população (P em hab.) e consumo *per capita* diário de energia elétrica ($\text{kWh.hab}^{-1}.\text{d}^{-1}$)



No entanto, foi mostrada na Figura 2 a dependência de TGP em função do logaritmo neperiano da população. Sendo assim, é possível que função deste tipo tenha melhor ajuste. No próximo item serão mostrados estes resultados.

5.2 ESTUDO DE CORRELAÇÃO USANDO LN(P) E LN(Ce)

Na Tabela 9 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 9 - 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 (R\$.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 9, que correlações envolvendo Ln(P), RPC e Ln(Ce) potencialmente ajustariam melhor as TGP de RSU. Sendo assim, o emprego destas três variáveis resultou na Equação 19, tomando-se por base o ano de 2013:

$$TGP = -11,280 + 0,0356.Ln(P) + 0,0179.RPC + 11,347.[Ln(Ce)]^{0,0103} \quad (19)$$

válida para $1.923 \text{ hab} \leq P \leq 11.446.275 \text{ hab}$; $6,23 \text{ USD.hab}^{-1}.d^{-1} \leq RPC \leq 29,89 \text{ USD.hab}^{-1}.d^{-1}$; e $2,51 \text{ kWh.hab}^{-1}.d^{-1} \leq Ce \leq 87,04 \text{ kWh.hab}^{-1}.d^{-1}$.

Já para 2014, a regressão resultou em (Equação 20):

$$TGP = -14,162 + 0,0441.Ln(P) + 0,0160.RPC + 14,164.[Ln(Ce)]^{0,0154} \quad (20)$$

válida para os seguintes intervalos de $2.044 \text{ hab} \leq P \leq 11.513.836 \text{ hab}$, $5,10 \text{ USD.hab}^{-1}.d^{-1} \leq RPC \leq 24,48 \text{ USD.hab}^{-1}.d^{-1}$ e $2,69 \text{ kWh.hab}^{-1}.d^{-1} \leq Ce \leq 81,67 \text{ kWh.hab}^{-1}.d^{-1}$.

Os parâmetros de avaliação da qualidade do ajuste são mostrados na Tabela 10. 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 $0,217 \text{ kg.hab}^{-1}.\text{d}^{-1}$ e $0,227 \text{ kg.hab}^{-1}.\text{d}^{-1}$, que representam 29 % da média de todos os valores observados em 2013 e 2014 respectivamente.

Tabela 10 - Parâmetros de avaliação da qualidade dos ajustes

Parâmetros de avaliação da qualidade do ajuste				
	r (-)	R ² (-)	RMSE ($\text{kg.hab}^{-1}.\text{d}^{-1}$)	Ep (%)
Equação (19) - 2013	0,49	0,24	0,217	-14,1
Equação (20) - 2014	0,51	0,26	0,227	-10,2

Nas Figuras 17 a 19 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 10). 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 $1,00 \text{ kg.hab}^{-1}.\text{d}^{-1}$, 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 $0,20 \text{ kg.hab}^{-1}.\text{d}^{-1}$, 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 17- 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

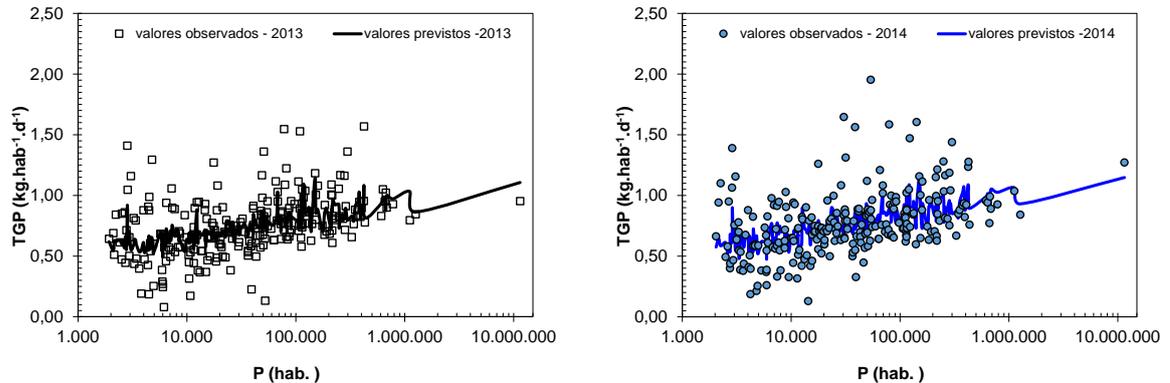


Figura 18 - Taxas de geração *per capita* de RSU em função da renda *per capita* nos municípios do Estado de São Paulo que alegaram pesar rotineiramente seus resíduos em 2013 e 2014

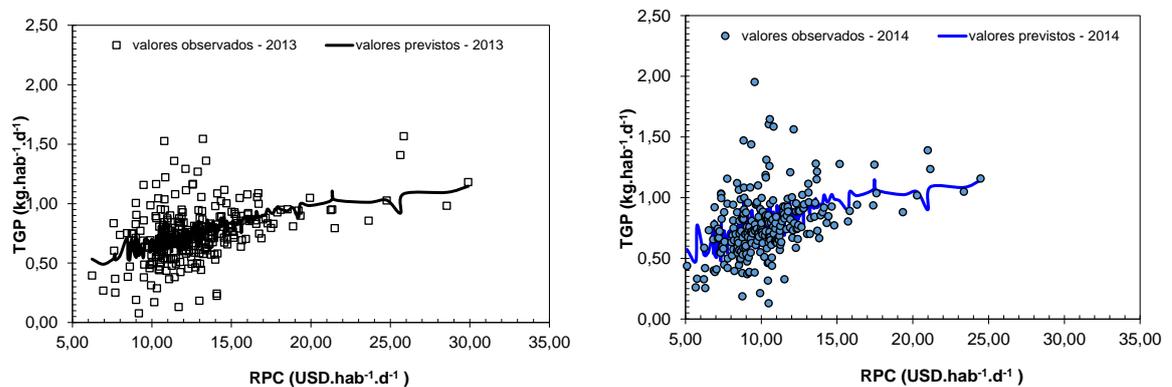
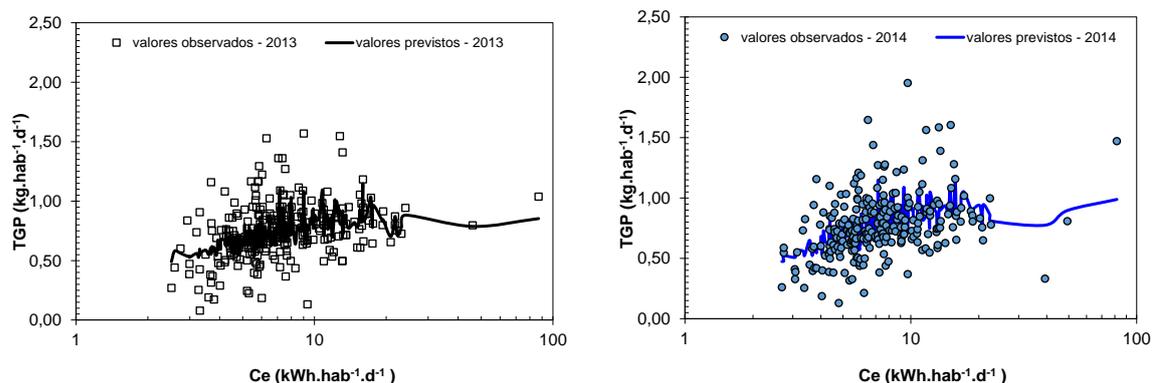
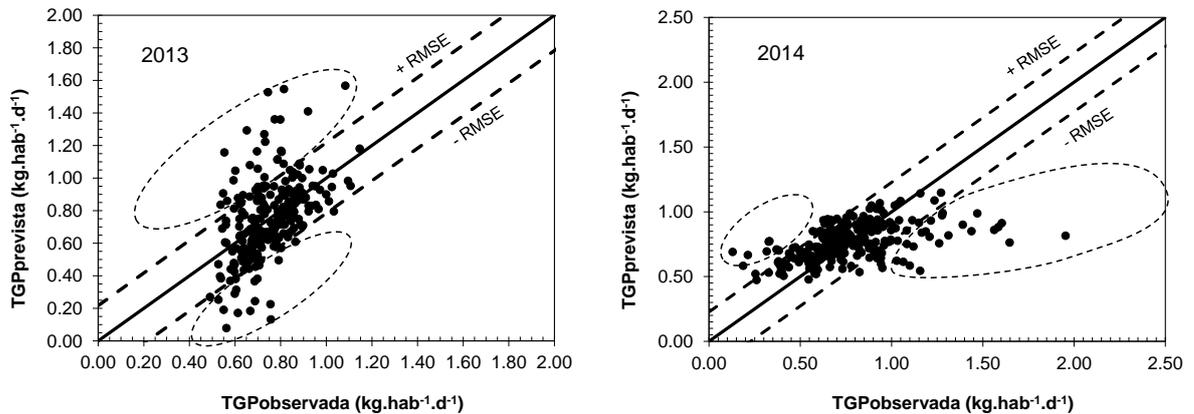


Figura 19 - Taxas de geração *per capita* de RSU em função do consumo de energia elétrica total nos municípios do Estado de São Paulo que alegaram pesar seus resíduos em 2013 e 2014



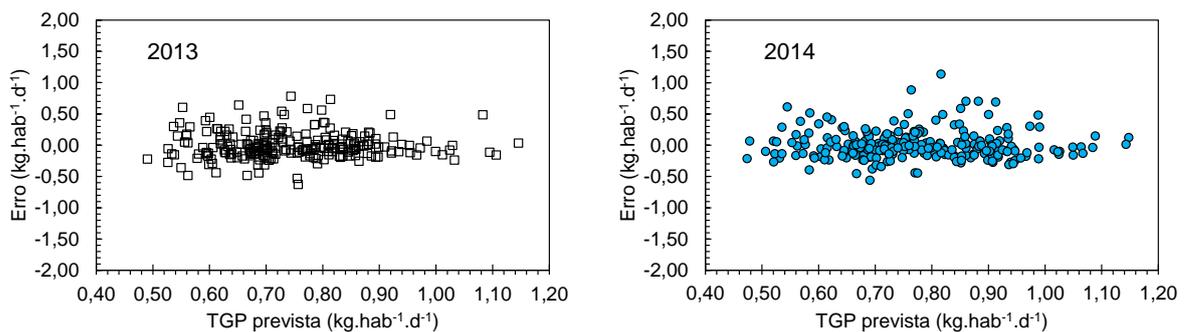
Nas Figuras 20 e 21 foram plotadas as TGP observadas e previstas pelas equações 19 e 20 para se avaliar a qualidade do ajuste, quanto mais próximos os pontos forem da reta diagonal, melhor é a previsão.

Figura 20 - Valores de TGP observados e previstos em relação à reta bissetriz do primeiro quadrante



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 na Figura. 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). Percebe-se pela aleatoriedade da distribuição dos erros frente as TGP previstas pelas equações 19 e 20, que não ocorreu erro sistemático na previsão (Figura 21). Apesar de R^2 iguais a 0,24 e 0,26 (Tabela 10).

Figura 21 - Desvios entre as TGP previstas e estimadas em função dos valores previstos em 2013 e 2014



O teste de t-Student mostrou que as equações 19 e 20 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.

6 CONCLUSÕES

A partir da realização do presente estudo foi possível concluir que:

- As amostras utilizadas (238 municípios em 2013 e 252 em 2014) representaram o total de 645 com uma margem de erro máxima de 5,1 % e intervalo de confiança de 94,9 %. Já, com base na população do estado abrangida, a margem de erro máxima passou a ser de apenas 0,015% e intervalo de confiança de 99,985 %. Portanto, comprovou-se 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.

- As variáveis independentes, população (P), renda *per capita* média diária (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.

- A dependência de TGP em função das variáveis independentes (P, Ce e RPC) mostrou ter apenas um domínio de validade, não sendo necessário subdividir as equações testadas em diferentes intervalos de validade.

- 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 kg.hab⁻¹.d⁻¹ para 2013 e de 1,95 kg.hab⁻¹.d⁻¹ para 2014, já os valores mínimos foram de 0,080 kg.hab⁻¹.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 (R² 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 19 e 20) com intervalos de confiança acima de 99%.

REFERÊNCIAS

ABDULLAH, W. S. Exponential Model for Predicting the Sorption Isotherms-Evaluation, Statistical Appraisal and Comparison with Existing Models. **Jordan Journal of Civil Engineering**, v. 3, n. 4, p. 344 – 355, 2009.

ACURIO, G., ROSSIM, A., TEIXEIRA, P. F., ZEPEDA, F. **Diagnosis of Municipal Solid Waste Management in Latin América and the Caribben**. Série Ambients n° 148, 2º ed, p. 148, 1998.

ASSOCIAÇÃO BRASILEIRA DE EMPRESAS DE LIMPEZA PÚBLICA E RESÍDUOS ESPECIAIS - ABRELP. **Panorama dos resíduos sólidos no Brasil**. São Paulo, 9ºed, p. 82, 2012.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. NBR 10004: Resíduos Sólidos – Classificação. Rio de Janeiro, 2004.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. NBR 10006: Procedimentos para obtenção de extratos solubilizados de Resíduos Sólidos. Rio de Janeiro, 2004.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. NBR 10007: Amostragem de Resíduos Sólidos. Rio de Janeiro, 2004.

ATHAYDE JR, G. B., BESERRA, L. B., FAGUNDES, G. S. Estimando a geração de resíduos sólidos domiciliares a partir do consumo de água em edifícios multifamiliares. **Revista Tecnol. Fortaleza**, v.29, n. 2, p.125-133, 2008.

BAASCH, S. S. N. **Um sistema de suporte multicritério aplicada na gestão de resíduos sólidos nos municípios catarinenses**. Tese de Doutorado. Universidade Federal de Santa Catarina, Florianópolis/SC, 1995.

BEIGL, P., LEBERSORGER, S., SALHOFER, S. Modelling municipal solid waste generation: a review. **Waste Management**, v. 28, n. 1, p. 200-214, 2008.

BIOESTAT version 5.3: Instituto Mamirauá. Disponível em <www.mamiraua.org.br/pt-br/downloads/programas/>

BRASIL. Política Nacional de Resíduos Sólidos (PNRS): Lei de nº 12.305 de 2010.

BRASIL. Projeto de lei nº 203, de 1991. Brasília, DF, Senado, 1991.

BRASIL. Lei nº 12.300, de 16 de março de 2006

BROLLO, M. J., SILVA, M. M. Política e Gestão Ambiental em Resíduos Sólidos. Revisão e análise sobre a atual situação no Brasil. In: Congresso Brasileiro de Engenharia Sanitária e Ambiental, 21, 2001, João Pessoa/PB. **ABES – Trabalhos Técnicos**, p. 1 – 27, 2001.

CALDERONI, S. **Os bilhões perdidos no lixo**. 2ª ed. São Paulo: Humanitas, 1998.

CEMPRE COMPROMISSO EMPRESARIAL PARA A RECICLAGEM. **Política Nacional de Resíduos Sólidos - Agora é lei.** Disponível em: <http://www.cempre.org.br/ciclosoft_2010.php>. Acesso em: 05 abr. 2016.

CHALMIN, P., GAILLOCHET, C. **From waste to resource, An abstract of world waste survey Cyclope.** Veolia Environmental Services, Edition Economica, France, 2009.

CHUNG, S. S. Projecting municipal solid waste: The case of Hong Kong SAR. **Resources, Conservation and Recycling**, v.54, p. 759-768, 2010.

COHEN, J. **Statistical power analysis for the behavioral sciences.** 2 ed., Hillsdale, N. J.: Lawrence Earlbaum Associates, 1988.

COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO – CETESB (2014) Inventário Estadual de Resíduos Sólidos Domiciliares 2013. 126p.

COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO – CETESB (2015) Inventário Estadual de Resíduos Sólidos Domiciliares 2014. 126p.

CONSONI, A. J., SILVA, I. C., GIMENEZ FILHO, A. **Disposição final do lixo.** In: D'ALMEIDA, M. L. O.; VILHENA, A. (Coord.). Lixo municipal: manual de gerenciamento integrado. 2. ed. São Paulo: Instituto de Pesquisas Tecnológicas – IPT/ Compromisso Empresarial para Reciclagem – CEMPRE, 2000. cap. 5, p. 251-291.

CONTADOR, C. **Projetos Sociais, Avaliação e Prática.** São Paulo, Atlas, 4º ed., p. 375, 2000.

D'ALMEIDA, M. L. O., VILHENA, A. (Coord.). Lixo municipal: manual de gerenciamento integrado. 2. ed. São Paulo: Instituto de Pesquisas Tecnológicas – IPT/Compromisso Empresarial para Reciclagem – CEMPRE, 2000. cap. 5, p. 251-291.

DANCEY, C.; REIDY, J. Estatística **sem matemática para psicologia: usando SPSS para Windows.** 3. ed. Porto Alegre: Artmed, 2006.

DANGI, M. B.; URYMOWICZ, M. A.; GEROW, K. G. ;THAPA, R. B. Use of stratified cluster sampling for efficient estimation of solid waste generation at household level. **Waste Management & Research**, v. 26, p 493-499. 2008.

DASKALOPOULOS, E., BADR, O., PROBERT, S.D. Municipal solid waste: a prediction methodology for the generation rate and composition in the European Union and the United States of America. **Resources, Conservation and Recycling**, v. 24, n. 1, p. 155-166, 1998.

DEUS, A. B. S., LUCA, S. J., CLARKE, R. T. Índice de impacto dos resíduos sólidos urbanos na Saúde Pública (IIRSP): metodologia e aplicação. **Engenharia Sanitária e Ambiental**, v. 9, n. 4, p. 329-334, 2004.

DIAS, D. M., MARTINEZ, C. B., BARROS, P. T. V., LIBÂNIO, M. 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, 2012.

FERREIRA, J. A., ANJOS, L. A. Aspectos de saúde coletiva e ocupacional associados à gestão dos resíduos sólidos municipais. **Cadernos de Saúde Pública**, v. 17, n. 3, p. 689-696, 2001.

FIALCOFF, D. **É lixo demais**. Porto Alegre, Agosto de 1998. Online. Disponível em <<http://simpro-rg.org.br/extra/ago98>>. Acesso em 25 jul. 2016.

FIGUEIREDO, F. F. Panorama dos Resíduos Sólidos Brasileiros: Análises de suas Estatísticas. **Revista Bibliográfica de Geografía y Ciencias Sociales**, V. XVI, n. 928, 2011.

FUNDAÇÃO SISTEMA ESTADUAL DE ANÁLISE DE DADOS – SEADE (2015) <<http://www.seade.gov.br/>> Acesso em 20.01.2016.

HOCKETT, D., LOBER, D. J., PILGRIM, K. Determinants of *Per capita* Municipal Solid Waste Generation in the Southeastern United States. **Journal of Environmental Management**, v. 45, p. 205-217, 1995.

ISRAEL, G. D. **Determining sample size**. Gainesville: University of Florida Cooperative Extension Service, Institute of Food and Agriculture Sciences, EDIS, 1992.

INSTITUTO BRASILEIRO DE ADMINISTRAÇÃO MUNICIPAL – IBAM (Brasil) (Org.). **Manual Gerenciamento Integrado de Resíduos Sólidos**. Rio de Janeiro, 2001. 2004 p.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. (2002) Censo Demográfico 2001.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. (2014) Censo Demográfico 2013.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. (2015) Censo Demográfico, 2014.

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, p. 359-371, 2012.

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, p. 233–241, 1999.

MELLO, A. S. Desenvolvimento de equação para previsão da taxa de geração *per capita* de resíduos sólidos urbanos no estado de São Paulo. 2014. 121 f. Dissertação (Mestrado) - Universidade de Ribeirão Preto, Ribeirão Preto, 2014.

MINISTÉRIO DAS CIDADES – Disponível em <http://www.cidades.gov.br/>. Acesso em 18 de abril de 2016.

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, p.885-890, 2007.

NAVARRO, E. J.; DIAMADOPOULOS, E.; GINESTAR, D. Time series analysis and forecasting techniques for municipal solid waste management. **Resources, Conservation and Recycling**, v. 35, p. 201–214, 2002.

OJEDA-BENÍTEZ, S. C. VEGA, A. D., MARQUEZ--MONTENEGRO, M. Y. Household solid waste characterization by family socioeconomic profile as unit of analysis **Resources, Conservation and Recycling**, v. 52, p. 992-999, 2008.

OLIVEIRA, G. A.; SANTOS, H. I. **Avaliação da saúde ocupacional dos garis de Hidrolândia, Goiás**. 2012. 19f. Trabalho de Conclusão de Curso (Graduação) – Pontifícia, 2012.

OLIVEIRA, S. A., LEITE, V. D., PRASAD, S., RIBEIRO, M. D. Estudo da produção *per capita* de resíduos sólidos domiciliares da cidade de Campina Grande/PB. **Revista saúde e ambiente**, v. 5, n. 2, 37-44, 2004.

ONOFRE, F. L. Estimativa da geração de resíduos sólidos domiciliares. 2011. 235 f. Dissertação Mestrado em Engenharia Urbana e Ambiental – Universidade Federal da Paraíba, João Pessoa, 2011

PINTO M. R., PEREIRA D. R. M., FREITAS, R. C. Fatores sociais, econômicos e demográficos associados à geração de lixo domiciliar na cidade de Belo Horizonte. **Reuna Belo Horizonte**, v. 17, v. 2, p. 27-44, 2012.

PROSAB - PROGRAMAS DE PESQUISA EM SANEAMENTO BÁSICO (Brasil) (Org.). **Resíduos sólidos urbanos: Aterros sustentáveis para municípios de pequeno porte**. Florianópolis - SC, 2003. 288 p.

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, p. 1237-1250, 2009.

SECRETARIA NACIONAL DE SANEAMENTO AMBIENTAL. Sistema Nacional de Informações sobre Saneamento: diagnóstico do manejo de resíduos sólidos urbanos – 2016

SECTAM - SECRETARIA EXECUTIVA DE CIÊNCIA E TECNOLOGIA E MEIO AMBIENTE. MANUAL. **Lixo – este problema tem solução**. Série Saneamento Ambiental, Belém, n. 1,1997.

SEIDEL J. M. Um Problema Urbano - Gerenciamento de Resíduos Sólidos e as Mudanças Ambientais Globais. In: **Encontro Nacional da Anppas**, V, Florianópolis – SC, p. 1-8, 2010.

SILVA, H., BARBIERI A. F., MÓR, R. L. M. Fatores Demográficos e Geração de Resíduos Sólidos Domiciliares no Município de Belo Horizonte. **Revista Brasileira de Estudos de População**, v. 29, n. 2, p. 421-449, 2012.

SILVA, J. M. S. **Uma revisão bibliográfica sobre resíduos sólidos domésticos e algumas considerações sobre Uberlândia/MG e condomínio Miranda V – município de Uberlândia-MG**. 2005. 118 f. Monografia (Graduação) - Universidade Federal de Uberlândia, Uberlândia, 2005.

TIBONI, C. G. R. Estatística Básica para cursos de administração, ciências contábeis, tecnológicos e de gestão. 1 ed., São Paulo: Atlas, 2010.

VIJAY R.; GUPTA, A.; KALAMDHAD, A. S.; DEVOTTA, S. Estimation and allocation of solid waste to bin through geographical information systems. **Waste Management & Research**, v. 23, n. 5, p. 479–484, 2005.

WORLD BANK. **What a Waste: Solid Waste Management in Asia**. Urban Development Sector Unit, East Asia and Pacific Region. Disponível em www.worldbank.org/urban/solid_wm/erm/CWG%20folder.uwp1.pdf. 1999. Acesso em 11 de março de 2016.

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, p. 1324-1331, 2013.

YAFEE, R.; MCGEE, M. **Introduction to Time Series Analysis and Forecasting with Applications of SAS and SPSS**. Orlando, Academic Press, 2000. 509p.
Applications of SAS and SPSS. Orlando, Academic Press, 2000. 509p

ZANTA, V. M.; FERREIRA, C. F. A.. Gerenciamento integrado de resíduos sólidos urbanos. **Resíduos sólidos urbanos: aterro sustentável para municípios de pequeno porte**. Rio de Janeiro: ABES, 294p. 2003.

APÊNDICE A – BIOESTAT V5.3

Fontes de variação	GL	SQ	QM			
Regressão	2	2,8883	1,4442			
Erro	229	11,6197	0,0507			
Total	231	14,5081	---			
	---	---	---			
F Regressão (2, 229) =		28,4616	---	---		
(p) = < 0,0001		---	---			
Coef. de determinação múltipla (R^2_{yy}) =				0,1991	---	---
F R^2_{yy} (2, 229) =		57,1718	---	---		
(p) = < 0,0001		---	---			
R^2_{yy} ajustado =		0,1921	---	---		
Coef. de correlação múltipla (R^2_{yy}) =				0,4462	---	---
Intercepto (a) =		0,3356		t = 5,8965		p < 0,0001
Coef. parcial de regressão (b1) =		0,0042		t = 1,9809		p = 0,0498
Coef. parcial de regressão (b2) =		0,0164		t = 6,6105		p < 0,0001
Comparação: Coef. (b1) e Coef. (b2) =		---		t = -3,3562		p = 0,0010
Variável dependente =		Coluna 1		---		---
$Y' = a + b_1X_1 + b_2X_2 + \dots + b_iX_i$						

TGP(RPC,P)

Fontes de variação	GL	SQ	QM			
Regressão	2	9,2973	4,6487			
Erro	228	4,4840	0,0197			
Total	230	13,7813	---			
	---	---	---			
F Regressão (2, 228) =		236,3747	---	---		
(p) = < 0,0001		---	---			
Coef. de determinação múltipla (R^2_{yy}) =				0,3821	---	---
F R^2_{yy} (2, 228) =		474,8229	---	---		
(p) = < 0,0001		---	---			
R^2_{yy} ajustado =		0,6718	---	---		
Coef. de correlação múltipla (R_{yy}) =				0,6182	---	---
Intercepto (a) =		0,4549		t = 12,4806		p < 0,0001
Coef. parcial de regressão (b1) =		0,0134		t = 4,5067		p < 0,0001
Coef. parcial de regressão (b2) =		$8,58 \times 10^{-7}$		t = 19,0015		p < 0,0001
Comparação: Coef. (b1) e Coef. (b2) =		---		t = 3,6141		p = 0,0004
Variável dependente =		Coluna 1		---		---
$Y' = a + b_1X_1 + b_2X_2 + \dots + b_iX_i$						

TGP(Ce,P)

Fontes de variação	GL	SQ	QM			
Regressão	2	9,1673	4,5837			
Erro	228	4,6140	0,0202			
Total	230	13,7813	---			
	---	---	---			
F Regressão (2, 228) =		226,5024	---	---		
(p) =	< 0,0001	---	---			
Coef. de determinação múltipla (R^2_{yy}) =				0,4635	---	---
F R^2_{yy} (2, 228) =		454,9917	---	---		
(p) =	< 0,0001	---	---			
R ² _{yy} ajustado =		0,6623	---	---		
Coef. de correlação múltipla (R^2_{yy}) =				0,6808	---	---
Intercepto (a) =	0,5728		t = 37,1631		p < 0,0001	
Coef. parcial de regressão (b1) =	0,0042			t = 3,6488		p = 0,0004
Coef. parcial de regressão (b2) =	$8,58 \times 10^{-7}$			t = 20,5026		p < 0,0001
Comparação: Coef. (b1) e Coef. (b2) =	---			t = 2,5402		p = 0,0123
Variável dependente =	Coluna 1	---	---			
Y' = a + b1X1 + b2X2 + ... + biXi						

Tabela de Frequências:

Classes	População	TGP (kg/(hab.d))	Cons de Eg El. (KWh/(hab.d))	Renda (R\$/(hab.d))
0-10000	4980	0,636905649	5,987513463	19,57777358
10001-30000	17433	0,646600042	7,617228328	20,0240679
30001-100000	56975	0,769140386	9,134236645	23,26541111
100001-500000	212014	0,887176089	11,2411429	26,37417262
ACIMA 500001	2073031	0,927993589	8,843056974	32,78841667

Analise descritiva dos dados

<i>População 0-10000</i>	<i>Pop.</i>	<i>TGP (kg/(hab.d))</i>	<i>Energ (KWh/h.d)</i>	<i>R. per capita(R\$/d)</i>
Média	4980,34	0,64	5,99	19,58
Erro padrão	278,4158	0,04	0,45	0,67
Mediana	4588	0,60	5,35	19,30
Desvio padrão	2026,897	0,28	3,25	4,91
Variância da amostra	4108313	0,08	10,58	24,11
Curtose	-0,88308	0,34	7,89	13,41
Assimetria	0,390422	0,51	2,38	2,62
Intervalo	7613	1,33	18,37	34,15
Mínimo	1923	0,08	2,51	10,97
Máximo	9536	1,41	20,88	45,12
Soma	263958	33,76	317,34	1037,62
Contagem	53	53,00	53,00	53,00
Nível de confiança (95,0%)	558,6821	0,08	0,90	1,35
10001-30000	<i>Pop.</i>	<i>TGP (kg/(hab.d))</i>	<i>Energ (KWh/h.d)</i>	<i>R. per capita(R\$/d)</i>
Média	17432,94	0,65	7,62	20,02
Erro padrão	720,4546	0,03	0,96	0,47
Mediana	16780	0,65	5,74	20,13
Desvio padrão	5294,238	0,20	7,05	3,43
Variância da amostra	28028958	0,04	49,72	11,77
Curtose	-0,82646	0,88	17,16	3,82
Assimetria	0,449216	0,46	3,82	1,16
Intervalo	19376	1,10	43,49	20,29
Mínimo	10341	0,17	2,59	13,53
Máximo	29717	1,27	46,08	33,82
Soma	941379	34,92	411,33	1081,30
Contagem	54	54,00	54,00	54,00
Nível de confiança (95,0%)	1445,049	0,06	1,92	0,94
30001-100000	<i>Pop.</i>	<i>TGP (kg/(hab.d))</i>	<i>Energ (KWh/h.d)</i>	<i>R. per capita(R\$/d)</i>
Média	56975,18	0,77	9,13	23,27
Erro padrão	2407,89	0,03	0,57	0,52
Mediana	50980	0,73	7,29	23,35
Desvio padrão	18651,44	0,23	4,43	4,02
Variância da amostra	3,48E+08	0,05	19,63	16,20
Curtose	-1,01995	2,33	0,17	9,82
Assimetria	0,500096	0,59	1,00	2,09
Intervalo	66984	1,41	17,85	26,79
Mínimo	30081	0,13	3,93	16,82
Máximo	97065	1,55	21,79	43,61
Soma	3418511	46,15	548,05	1395,92

Contagem	60	60,00	60,00	60,00
Nível de confiança (95,0%)	4818,178	0,06	1,14	1,04
100001-500000	<i>Pop.</i>	<i>TGP</i> (kg/(hab.d))	<i>Energ</i> (KWh/h.d)	<i>R. per</i> <i>capita(R\$/d)</i>
Média	212014	0,89	11,24	26,37
Erro padrão	13266,35	0,03	1,47	1,03
Mediana	197283	0,83	9,05	25,43
Desvio padrão	99276,25	0,21	11,01	7,72
Variância da amostra	9,86E+09	0,04	121,20	59,53
Curtose	-0,50896	2,20	42,45	3,04
Assimetria	0,76993	1,33	6,14	1,48
Intervalo	325138	0,99	82,78	37,27
Mínimo	105310	0,58	4,26	15,35
Máximo	430448	1,57	87,04	52,62
Soma	11872782	49,68	629,50	1476,95
Contagem	56	56,00	56,00	56,00
Nível de confiança (95,0%)	26586,35	0,06	2,95	2,07
ACIMA 500001	<i>Pop.</i>	<i>TGP</i> (kg/(hab.d))	<i>Cons de Energ</i> (KWh/h.d)	<i>R. per</i> <i>capita(R\$/d)</i>
Média	2073031	0,93	8,84	32,79
Erro padrão	1340267	0,03	0,72	1,51
Mediana	676117,5	0,94	7,99	32,95
Modo	#N/D	#N/D	#N/D	#N/D
Desvio padrão	3790846	0,09	2,03	4,27
Variância da amostra	1,44E+13	0,01	4,11	18,26
Curtose	7,955537	-0,65	-0,45	-0,16
Assimetria	2,818216	-0,20	0,80	-0,55
Intervalo	10838006	0,25	5,90	12,59
Mínimo	608269	0,80	6,49	25,25
Máximo	11446275	1,05	12,39	37,84
Soma	16584246	7,42	70,74	262,31
Contagem	8	8,00	8,00	8,00
Nível de confiança (95,0%)	3169227	0,07	1,69	3,57

APÊNDICE B – DADOS LEVANTADOS MEDIANTE PESQUISAS DO SISTEMA NACIONAL DE INFORMAÇÕES SOBRE SANEAMENTO (MINISTÉRIO DAS CIDADES, 2013; FUNDAÇÃO SEADE, 2015)

Tabela B1 - Dados levantados mediante pesquisas do Sistema Nacional de Informações sobre Saneamento (MINISTÉRIO DAS CIDADES, 2014; SEADE, 2015)

Município	Massa anual coletada (t)	População	Consumo de Energia Elétrica Total (Em MWh)	Renda per capita em 2014
Turmalina	450	1.923	4.177	633,98
Marinópolis	530	2.106	2.943	498,79
Monções	400	2.148	5.271	622,13
Embaúba	540	2.414	4.403	683,03
Pedranópolis	432	2.510	5.171	554,39
Pontes Gestal	780	2.519	5.931	613,95
Marapoama	440	2.719	7.016	691,07
Florínia	723,5	2.782	4.624	474,05
Águas de São Pedro	1.458,00	2.834	13.382	1.353,66
Mira Estrela	1.090,00	2.856	5.841	549,29
Floreal	541	2.958	5.550	677,82
Jumirim	706	2.959	22.245	645,57
Alvinlândia	1.291,00	3.055	4.052	500,44
Elisiário	961	3.238	4.312	618,39
Mombuca	523	3.287	9.833	576,39
Quadra	977,7	3.379	8.428	581,6
Pongaí	599,4	3.429	4.878	594,12
Bom Sucesso de Itararé	528	3.648	7.331	329,1
Anhumas	265	3.808	4.933	475,43
Onda Verde	1.277,00	3.987	8.454	542,38
São José do Barreiro	700	4.072	4.386	454,64
Gastão Vidigal	680	4.380	5.205	623,15
Espírito Santo do Turvo	1.456,70	4.405	5.240	476,15
Analândia	300	4.468	9.672	685,94
Nipoã	1.440,00	4.497	7.722	579,12
Ubirajara	1.620,00	4.498	7.477	522,85
Canas	1.014,00	4.588	7.962	402,53
Glicério	912	4.624	11.154	607,26
Mendonça	2.252,00	4.770	10.056	639,82
Novais	1.070,00	4.881	4.816	568,17
Coronel Macedo	456	4.939	5.808	406,58
Águas de Santa Bárbara	1.421,00	5.700	15.588	703,8
Pardinho	1.440,00	5.817	19.426	585,38
Silveiras	830	5.913	6.356	448,24

Taiacu	626,4	5.937	8.576	544,6
Riversul	590	6.003	5.428	366,24
Paraíso	537	6.019	11.298	743,63
Arandu	175	6.132	7.300	484,52
Iacri	1.280,00	6.380	8.030	542,91
Santo Antônio da Alegria	1.068,00	6.405	9.319	520,37
Ipeúna	2.210,00	6.457	30.580	694,92
Gália	1.420,00	6.843	10.939	526,55
Lindóia	1.270,90	7.045	27.774	660,23
Guatapar	1.431,00	7.106	13.679	541,49
Vista Alegre do Alto	2.792,00	7.236	19.320	692,71
Saltinho	2.400,00	7.326	23.193	824,83
Macaubal	2.493,00	7.704	16.117	626,9
Pereiras	1.508,20	7.752	33.121	600,17
Blsamo	1.732,00	8.281	21.397	735,55
Guaraa	2.167,00	8.439	12.955	551,94
Dumont	2.160,00	8.617	20.143	600,51
Porangaba	1.797,40	8.629	17.030	550,88
Euclides da Cunha Paulista	2.912,10	9.536	10.063	400,5
Roseira	2.369,30	9.917	18.469	544,65
Bananal	1.920,00	10.341	18.140	528,97
Rinco	1.709,00	10.433	22.086	550,16
So Bento do Sapuca	1.200,00	10.476	13.892	525,47
General Salgado	2.280,00	10.680	17.898	685,51
Parapu	674	10.735	14.639	535,59
Nhandeara	2.080,00	10.765	18.298	738,49
Palestina	2.800,00	11.411	18.376	619,45
Serra Azul	3.106,00	11.540	13.310	421,83
Tabapu	2.335,00	11.543	19.082	658,52
Palmares Paulista	1.860,00	11.560	10.785	552,22
Cardoso	3.848,40	11.782	20.010	540,04
Holambra	4.235,00	12.307	106.560	1.014,47
Piratinga	3.050,00	12.413	21.707	768,8
Florida Paulista	1.749,00	12.599	16.616	501,49
Urups	4.440,00	12.856	26.437	682,87
Quat	1.755,00	13.140	35.799	585,28
Tarum	2.661,10	13.463	37.144	572,15
Santa Branca	2.740,00	13.890	28.806	591,21
Itajobi	4.680,00	14.593	35.531	686,66
Ipu	4.967,50	14.666	31.352	630,03
Guare	2.003,00	14.903	20.070	405,79
Bady Bassitt	4.463,20	15.187	32.279	693,08
Pindorama	2.620,00	15.451	32.898	672,47
Altinpolis	3.709,30	15.580	28.866	635,36

Cesário Lange	3.897,90	16.108	52.652	536,8
Elias Fausto	2.946,20	16.265	76.735	527,37
Conchas	3.888,00	16.539	36.405	633,57
Nazaré Paulista	4.800,00	17.021	33.496	489,58
Águas de Lindóia	8.160,00	17.610	47.799	680,22
Viradouro	4.807,30	17.624	27.868	626,55
Cerqueira César	4.682,00	18.034	41.181	586,82
Capela do Alto	4.353,60	18.390	30.471	464,89
Pradópolis	3.068,00	18.486	31.739	648,98
Itatinga	3.329,00	18.770	28.429	520,74
Guapiaçu	6.017,00	18.809	42.008	618,66
Junqueirópolis	7.540,70	19.124	28.949	605,36
Nova Granada	4.320,00	19.707	37.598	630,89
Guará	4.368,00	20.132	42.312	544,41
Bastos	4.680,00	20.334	54.861	518,35
Miguelópolis	4.353,40	20.757	41.942	559,99
Palmital	3.862,00	21.317	60.991	608,27
Santo Antônio de Posse	7.018,50	21.323	55.386	588,32
Brodowski	5.609,90	22.021	40.574	647,89
Taquarituba	4.020,00	22.584	45.862	502,48
Santa Gertrudes	6.679,00	22.968	380.991	604,6
Santa Rosa de Viterbo	6.451,80	24.390	203.405	646,64
Apiáí	6.840,00	24.903	199.480	445,21
Pereira Barreto	3.500,00	25.105	52.058	603,58
Piracaia	6.523,50	25.455	50.233	604,33
Conchal	6.531,30	25.850	67.248	522,73
Laranjal Paulista	6.111,30	26.032	164.071	665,4
Serra Negra	6.965,00	26.733	62.121	799,57
Pilar do Sul	7.380,00	26.957	36.078	465,21
Santa Fé do Sul	6.300,00	29.717	81.617	745,67
Morro Agudo	6.744,00	30.081	47.972	567,18
Guararapes	8.844,70	31.097	75.144	645,78
Bariri	9.528,00	32.342	79.190	677,08
Adamantina	8.637,00	33.845	68.771	778,44
Américo Brasiliense	7.183,00	36.235	58.299	565,83
Pitangueiras	6.660,00	36.286	55.260	557,25
Guariba	7.112,30	36.578	51.784	579,21
Promissão	9.148,00	36.866	73.151	601,82
Novo Horizonte	8.456,30	37.320	75.024	705,62
Tietê	9.490,20	38.118	155.819	641,13
São Manuel	8.200,00	38.704	66.070	641,13
Ituverava	3.220,00	39.197	74.875	743,57
Jardinópolis	8.640,00	39.309	80.594	600,65
Orlândia	13.200,00	40.561	168.407	758,9

Serrana	11.180,00	40.569	59.255	571,8
Louveira	13.559,40	40.668	284.092	803
Tremembé	11.320,00	42.588	91.047	715,72
Pederneiras	9.500,00	42.733	232.478	629,78
Pedreira	7.800,00	43.135	202.805	687,97
Mairinque	10.800,00	44.186	148.952	594,45
Artur Nogueira	11.431,20	46.907	91.862	661,52
Monte Alto	9.846,00	47.242	204.587	724,58
São Joaquim da Barra	14.500,00	47.695	117.709	722,9
Jaguariúna	15.194,00	47.798	374.900	854,67
Campos do Jordão	14.964,00	48.497	123.192	568,87
Mongaguá	20.743,00	48.787	95.225	542,11
Itupeva	17.556,00	49.061	277.834	738,7
Porto Feliz	12.246,00	49.743	177.157	650,62
Capivari	10.800,00	50.252	209.335	669,18
Olímpia	25.241,80	50.813	134.127	708,25
Boituva	15.405,20	51.147	270.599	742,19
Monte Mor	12.217,00	52.039	173.611	548,32
Bertioga	2.504,50	52.223	175.586	617,07
Nova Odessa	15.547,10	53.378	371.178	733,41
Ibitinga	19.025,30	54.855	119.695	626,92
Mirassol	15.001,10	55.051	137.562	752,16
Penápolis	15.661,60	59.237	114.959	705,28
Cosmópolis	14.400,00	62.587	114.422	703,59
Lençóis Paulista	14.520,00	62.941	202.381	708,66
Fernandópolis	26.553,00	65.198	132.269	768,74
Amparo	19.383,00	67.056	381.632	816,69
Vinhedo	25.453,90	67.899	422.070	1.308,22
Cajamar	23.607,10	68.115	341.538	571,55
Jaboticabal	22.599,00	72.501	189.415	851,98
Lins	20.257,50	72.636	194.322	796,51
Ibiúna	17.000,00	72.764	152.331	504,51
Bebedouro	23.733,00	74.835	228.739	695,75
Matão	20.274,60	77.858	369.844	679,92
São Sebastião	43.993,60	77.956	358.417	697,24
Arujá	31.459,00	79.275	255.392	745,4
São Roque	19.600,00	81.557	204.920	778,3
Ubatuba	36.500,00	81.771	177.438	572,41
Lorena	19.507,60	83.784	226.097	823,48
São João da Boa Vista	26.535,90	84.844	352.626	823,48
Caçapava	20.976,00	86.859	501.773	719,83
Votuporanga	28.371,90	86.910	203.564	808
Mogi Mirim	22.200,50	87.796	369.389	827,06
Itanhaém	31.470,90	90.492	179.341	557,63
Caieiras	23.623,60	90.669	443.602	683,16

Assis	32.904,00	97.065	178.166	802,57
Ourinhos	27.236,70	105.310	202.257	724,4
Caraguatatuba	42.913,50	105.571	326.313	641,55
Itatiba	29.149,40	106.638	404.551	884
Salto	35.242,00	108.459	639.630	753,69
Poá	60.753,00	108.968	246.894	569,23
Tatuí	30.570,00	111.122	371.780	673,96
Várzea Paulista	26.400,00	111.336	308.149	574,7
Birigui	23.725,00	112.685	252.321	698,14
Valinhos	35.360,00	113.022	495.100	1.247,87
Sertãozinho	31.990,70	114.023	332.030	779,98
Barretos	38.798,40	114.027	321.885	792,94
Guaratinguetá	30.638,00	114.057	373.197	800,48
Catanduva	43.741,60	114.270	305.595	819,66
Ribeirão Pires	31.970,80	115.000	249.760	726,35
Santana de Parnaíba	42.165,30	117.568	456.234	1.507,66
Cubatão	46.121,50	121.848	3.818.109	569,82
Araras	34.420,00	122.554	461.047	796,15
Botucatu	41.784,00	131.723	584.449	897,9
Franco da Rocha	31.510,00	137.782	231.052	479,44
Mogi Guaçu	39.236,00	140.664	780.254	677,48
São Caetano do Sul	64.697,00	150.035	861.827	1.578,74
Pindamonhangaba	44.409,20	152.230	1.191.609	683,99
Bragança Paulista	55.779,40	152.290	532.773	776,01
Itu	62.566,00	158.925	647.796	845,24
Ferraz de Vasconcelos	48.000,00	175.583	287.707	460,59
Santa Bárbara D Oeste	45.065,00	182.764	724.372	730,23
Araçatuba	62.000,00	184.491	479.288	847,76
Rio Claro	48.994,00	190.849	866.405	840,39
Hortolândia	50.851,10	203.717	553.662	552,57
Itapevi	77.568,00	211.282	430.314	474,89
Presidente Prudente	84.214,00	211.832	547.088	881,16
Cotia	78.443,00	214.911	680.459	882,64
Araraquara	55.712,90	215.080	691.593	891,74
Indaiatuba	65.365,70	215.670	846.635	931,09
Jacareí	48.068,50	216.432	1.213.333	712,14
Americana	64.422,40	217.960	1.380.582	996,71
São Carlos	66.378,00	228.556	904.039	923,62
Barueri	95.431,80	247.935	1.383.509	877,46
Embu ou Embu das Artes	75.433,00	249.469	471.029	474,17
Sumaré	75.583,30	254.205	931.422	668,49
Taboão da Serra	109.140,00	256.183	537.506	664,47
Suzano	79.856,00	270.887	1.323.385	552,44

Praia Grande	118.161,50	278.727	580.846	663,09
Limeira	73.710,60	282.391	1.377.879	767,62
Taubaté	95.568,00	287.521	927.982	846,33
Guarujá	148.033,70	298.169	757.711	602,13
Franca	78.043,00	326.042	701.332	716,39
São Vicente	94.557,50	339.955	521.479	661,48
Bauru	112.645,30	350.392	939.226	905,65
Piracicaba	113.571,80	372.553	2.261.885	912,22
Jundiaí	132.000,00	382.363	2.197.553	1.121,82
Diadema	117.703,00	392.042	1.292.326	564,99
Mogi das Cruzes	131.147,10	401.201	1.449.005	757,93
São José do Rio Preto	146.506,00	421.169	1.109.239	978,49
Santos	241.430,90	421.896	1.368.995	1.364,92
Mauá	122.059,00	430.448	1.370.431	583,61
Sorocaba	184.306,00	608.269	2.164.682	874,7
Ribeirão Preto	241.177,70	629.855	1.793.938	1.052,76
São José dos Campos	226.958,80	654.827	1.889.773	955,77
Osasco	249.991,50	670.416	1.565.249	757,55
Santo André	223.877,50	681.819	3.040.254	1.021,51
São Bernardo do Campo	264.221,20	780.735	3.074.299	944,67
Campinas	322.698,00	1.112.050	3.188.955	1.135,29
São Paulo	3.976.258,00	11.446.275	29.486.140	1.126,97

APÊNDICE C – DADOS LEVANTADOS MEDIANTE PESQUISAS DO SISTEMA NACIONAL DE INFORMAÇÕES SOBRE SANEAMENTO (MINISTÉRIO DAS CIDADES, 2014; FUNDAÇÃO SEADE, 2016)

Tabela C1 - Dados levantados mediante pesquisas do Sistema Nacional de Informações sobre Saneamento (MINISTÉRIO DAS CIDADES, 2014; SEADE, 2016)

Localidades	P	RPC (US\$/((hab.d))	Ce(kWh/((h.d))	TGP(kg/((h.d))
Águas da Prata	7676	11,26	5,23	0,61
Águas de Lindóia	17731	10,55	7,62	1,26
Águas de São Pedro	2880	20,99	13,52	1,39
Altinópolis	15571	9,85	5,56	0,68
Alvinlândia	3074	7,76	3,82	1,16
Américo Brasiliense	36861	8,77	4,35	0,53
Américo de Campos	5726	9,17	4,37	0,73
Amparo	67486	12,66	15,36	0,76
Apiaí	24803	6,90	22,65	0,78
Araçatuba	185509	13,14	7,65	0,96
Araraquara	217343	13,83	9,07	0,67
Araras	123863	12,34	10,71	0,74
Arealva	7988	9,57	7,26	0,38
Artur Nogueira	47893	10,26	5,55	0,69
Arujá	80841	11,56	8,75	0,92
Assis	97738	12,44	5,30	0,77
Atibaia	132017	13,51	9,11	0,84
Auriflama	14331	10,48	4,80	0,13
Bady Bassitt	15396	10,75	6,12	0,82
Bananal	10382	8,20	5,67	0,65
Bariri	32606	10,50	7,46	0,79
Barretos	114701	12,29	8,09	0,89
Barueri	250477	13,60	15,54	1,28
Bastos	20296	8,04	8,21	0,63
Bauru	352654	14,04	7,55	0,88
Bebedouro	74769	10,79	8,39	0,76
Bertioga	53915	9,57	9,69	1,95
Birigui	114081	10,82	6,36	0,70
Boituva	52177	11,51	14,65	0,86
Bom Sucesso de Itararé	3676	5,10	5,93	0,44
Botucatu	133281	13,92	12,16	0,85
Bragança Paulista	154253	12,03	9,69	1,00
Brodowski	22349	10,04	5,24	0,73
Buritizal	4160	10,70	5,82	0,50
Caçapava	87599	11,16	15,91	0,65
Cachoeira Paulista	30989	9,74	5,44	0,64
Caieiras	92142	10,59	13,33	0,95

Cajamar	69549	8,86	15,11	1,08
Campinas	1123241	17,60	8,33	1,04
Campo Limpo Paulista	77669	10,50	10,27	0,68
Campos do Jordão	48746	8,82	7,22	0,84
Campos Novos Paulista	4648	7,42	3,72	0,60
Canas	4660	6,24	4,92	0,59
Capela do Alto	18696	7,21	4,89	0,67
Capivari	50847	10,37	11,64	0,58
Catanduva	114778	12,71	7,57	1,02
Cerqueira César	18212	9,10	6,47	0,70
Cesário Lange	16311	8,32	9,35	0,70
Conchal	26069	8,10	7,15	0,69
Conchas	16628	9,82	6,35	0,70
Coronel Macedo	4917	6,30	3,37	0,25
Cosmópolis	63942	10,91	5,00	0,64
Cotia	219888	13,68	8,64	1,21
Cravinhos	32818	10,29	8,56	0,72
Cubatão	122940	8,83	81,67	1,47
Descalvado	31643	10,34	11,29	1,31
Diadema	394131	8,76	8,69	0,82
Dumont	8786	9,31	6,72	0,72
Elias Fausto	16438	8,18	13,23	0,75
Elisiário	3282	9,59	3,97	0,78
Embú das Artes	252729	7,35	5,17	1,03
Engenheiro Coelho	17772	9,55	13,02	0,74
Espírito Santo do Turvo	4462	7,38	3,41	0,82
Euclides da Cunha Paulista	9517	6,21	3,08	0,33
Fernandópolis	65375	11,92	5,86	1,21
Ferraz de Vasconcelos	178160	7,14	4,37	0,74
Floreal	2942	10,51	5,61	0,47
Flórida Paulista	12522	7,78	3,75	0,42
Franca	328640	11,11	6,03	0,67
Franco da Rocha	139981	7,43	4,38	0,60
Gália	6787	8,16	4,63	0,57
Gavião Peixoto	4496	8,95	13,14	0,58
Guapiaçu	19146	9,59	8,05	0,73
Guará	20226	8,44	4,75	0,60
Guararapes	31270	10,01	7,14	0,79
Guaratinguetá	114750	12,41	10,09	0,66
Guareí	15033	6,29	3,83	0,42
Guariba	36962	8,98	4,00	0,60
Guarujá	300761	9,34	6,81	1,44
Guarulhos	1274528	9,82	7,33	0,84
Guataporá	7155	8,40	5,50	0,56
Holambra	12678	15,73	16,64	0,80
Hortolândia	207665	8,57	7,54	0,70

Iacanga	10557	10,10	6,38	0,62
Ibirá	11390	10,45	5,35	0,32
Ibitinga	55453	9,72	6,40	0,96
Igarapava	28594	10,49	4,44	0,63
Ilhabela	30431	10,57	6,46	1,65
Indaiatuba	220762	14,44	10,96	0,85
Iperó	30835	6,83	7,16	0,66
Ipeúna	6617	10,77	13,08	0,98
Itajobi	14607	10,65	7,55	0,79
Itanhaém	91716	8,65	5,82	0,99
Itapecerica da Serra	159457	7,55	4,10	0,88
Itapevi	215034	7,36	5,79	1,00
Itatiba	108484	13,71	10,11	0,73
Itatinga	19024	8,07	4,18	0,52
Itu	160608	13,10	11,23	1,11
Itupeva	50622	11,45	15,97	0,88
Ituverava	39373	11,53	5,50	0,33
Jaboticabal	72796	13,21	7,46	0,70
Jacareí	218260	11,04	14,21	0,63
Jaguariúna	49074	13,25	20,26	0,83
Jandira	114431	10,60	6,50	0,67
Jardinópolis	39896	9,31	6,17	0,66
João Ramalho	4243	8,23	3,68	0,39
Jumirim	3017	10,01	20,70	0,76
Jundiaí	386677	17,39	14,92	0,94
Laranjal Paulista	26307	10,32	18,75	0,86
Lençóis Paulista	63474	10,99	9,09	0,64
Limeira	284627	11,90	13,48	0,75
Lorena	84217	10,55	7,80	0,67
Louveira	41974	12,45	18,44	0,89
Lucianópolis	2249	9,79	4,38	1,10
Lutécia	2671	7,77	4,62	0,95
Macaubal	7718	9,72	6,11	0,95
Macedônia	3626	8,75	5,10	0,38
Mairinque	44522	9,22	9,41	0,76
Marapoama	2750	10,71	7,75	0,44
Marília	223002	12,31	6,78	0,95
Matão	78233	10,54	12,99	0,72
Mauá	435171	9,05	9,03	0,76
Mendonça	4817	9,92	6,21	0,21
Meridiano	3810	9,13	7,55	0,67
Miguelópolis	20864	8,68	6,27	0,72
Mira Estrela	2869	8,52	5,88	1,06
Mirassol	55493	11,66	7,35	0,74
Mogi das Cruzes	405959	11,75	9,73	0,92
Mogi Guaçu	141862	10,50	15,02	1,60

Mogi Mirim	88244	12,82	12,66	0,94
Mombuca	3294	8,94	9,05	0,70
Monções	2154	9,65	7,26	0,94
Mongaguá	49687	8,40	5,60	1,12
Monte Alegre do Sul	7415	12,29	6,57	0,59
Monte Alto	47453	11,23	11,23	0,57
Monte Aprazível	22557	12,17	4,83	0,79
Monte Mor	53151	8,50	9,06	0,63
Morro Agudo	30422	8,79	4,48	0,83
Murutinga do Sul	4228	8,76	4,04	0,19
Nazaré Paulista	17236	7,59	5,60	0,64
Neves Paulista	8727	11,04	5,68	0,63
Nhandeara	10780	11,45	5,08	0,93
Nova Aliança	6122	9,63	4,55	0,61
Nova Granada	19892	9,78	5,38	0,70
Nova Odessa	54139	11,37	18,82	0,81
Novais	4986	8,81	2,74	0,59
Novo Horizonte	37578	10,94	4,98	0,79
Olímpia	51092	10,98	7,86	0,84
Onda Verde	4023	8,41	6,87	0,88
Orlândia	40837	11,77	12,11	0,89
Osasco	671686	11,74	6,52	0,99
Oswaldo Cruz	31088	10,10	6,33	0,88
Ourinhos	106106	11,23	5,50	0,73
Ouroeste	8979	9,93	5,73	0,90
Palestina	11540	9,60	4,73	0,72
Palmital	21362	9,43	10,65	0,71
Paraguaçu Paulista	43061	8,96	4,96	0,70
Paraibuna	17724	8,66	4,42	0,56
Paraíso	6060	11,53	5,56	0,83
Pardinho	5901	9,08	9,69	0,37
Parisi	2044	7,13	5,72	0,66
Pedranópolis	2494	8,60	5,98	0,49
Pedreira	43693	10,67	13,16	0,61
Penápolis	59492	10,93	5,80	0,74
Pereira Barreto	25151	9,36	5,42	0,63
Pereiras	7858	9,30	12,10	0,55
Pindamonhangaba	154082	10,60	20,89	0,65
Pindorama	15596	10,43	5,94	0,46
Piracaia	25573	9,37	5,36	0,72
Piracicaba	375358	14,14	16,72	0,92
Piratininga	12533	11,92	5,09	0,82
Pitangueiras	36632	8,64	4,39	0,50
Platina	3314	7,32	2,74	0,55
Poá	110001	8,83	6,33	0,82
Pongaí	3411	9,21	4,34	0,39

Porangaba	8738	8,54	5,64	0,57
Porto Feliz	50041	10,09	9,25	0,69
Pradópolis	18887	10,06	4,60	0,72
Praia Grande	284757	10,28	6,02	1,19
Presidente Epitácio	41727	8,83	6,68	0,87
Presidente Prudente	213313	13,66	7,52	1,15
Quadra	3430	9,02	7,60	0,53
Quatá	13259	9,07	7,97	0,47
Queluz	11894	7,31	3,14	0,55
Rancharia	28800	9,28	7,10	1,08
Regente Feijó	18906	9,96	5,21	0,73
Registro	54058	8,99	4,59	0,88
Restinga	6946	6,93	6,57	0,92
Ribeirão Grande	7457	5,77	39,29	0,33
Ribeirão Pires	115677	11,26	5,77	0,77
Ribeirão Preto	638796	16,32	8,17	0,94
Rincão	10440	8,53	6,16	0,44
Rio Claro	192460	13,03	11,91	0,70
Rio das Pedras	31593	10,46	8,78	0,85
Rio Grande da Serra	46326	7,55	3,57	0,45
Riversul	5947	5,68	2,69	0,26
Roseira	10029	8,44	5,53	0,65
Sabino	5326	9,19	4,54	0,38
Saltinho	7420	12,79	8,48	0,91
Salto	109496	11,69	15,84	0,85
Salto Grande	8900	7,35	4,91	1,03
Santa Bárbara D Oeste	183720	11,32	10,71	0,63
Santa Branca	13934	9,17	5,76	0,51
Santa Gertrudes	23450	9,37	49,38	0,81
Santa Rosa de Viterbo	24577	10,03	22,42	1,00
Santana de Parnaíba	120765	23,37	10,92	1,05
Santo André	683709	15,84	12,17	0,89
Santo Antônio de Posse	21561	9,12	7,42	0,96
Santo Antônio do Jardim	5882	8,77	4,70	0,67
Santos	422737	21,16	9,32	1,23
São Bento do Sapucaí	10478	8,15	3,72	0,94
São Bernardo do Campo	786078	14,65	10,77	0,93
São Caetano do Sul	150319	24,48	15,74	1,16
São Carlos	230890	14,32	10,77	0,79
São Francisco	2746	6,87	4,06	0,40
São João da Boa Vista	85269	12,77	11,76	0,91
São Joaquim da Barra	48110	11,21	6,97	0,68
São José do Barreiro	4070	7,05	3,07	0,41
São José do Rio Preto	425716	15,17	7,68	1,28
São José dos Campos	663632	14,82	7,79	0,77
São Manuel	38830	9,94	4,81	0,55

São Paulo	11513836	17,47	7,16	1,27
São Pedro do Turvo	7253	7,25	5,66	0,72
São Roque	82528	12,07	6,94	0,67
São Sebastião	79395	10,81	13,32	1,59
São Vicente	342583	10,26	4,39	0,85
Sarapuí	9455	8,15	5,85	0,81
Sebastianópolis do Sul	3154	10,95	7,70	0,64
Serra Azul	11650	6,54	3,33	0,73
Serra Negra	26856	12,40	6,54	0,75
Sertãozinho	115419	12,09	8,25	0,73
Silveiras	5955	6,95	3,08	0,39
Sorocaba	615955	13,56	9,86	0,96
Sumaré	258801	10,36	10,24	0,82
Suzano	273854	8,56	13,57	0,81
Tabapuã	11606	10,21	4,86	0,51
Taboão da Serra	260345	10,30	5,75	1,16
Taiaçu	5953	8,44	4,33	0,55
Taquarituba	22684	7,79	6,25	0,50
Tarumã	13669	8,87	7,71	0,90
Tatuí	112459	10,45	9,45	0,82
Taubaté	290634	13,12	8,57	1,04
Tietê	38571	12,14	11,70	1,56
Timburi	2605	7,50	3,66	0,58
Tremembé	43157	11,10	6,39	0,66
Ubatuba	82823	8,87	6,37	1,00
Valinhos	115258	19,35	11,75	0,88
Várzea Paulista	112833	8,91	7,25	0,62
Vinhedo	69449	20,28	17,23	1,02
Viradouro	17739	9,71	4,59	0,74
Votuporanga	87690	12,53	6,69	0,89

APÊNDICE D – ARTIGO SUBMETIDO EM 2016

DESENVOLVIMENTO DE CORRELAÇÃO PARA ESTIMATIVA DA TAXA DE GERAÇÃO *PER CAPITA* DE RSU NO ESTADO DE SÃO PAULO: INFLUÊNCIAS DA POPULAÇÃO, RENDA E CONSUMO DE ENERGIA ELÉTRICA

DEVELOPMENT OF A CORRELATION TO ESTIMATE *PER CAPITA* MUNICIPAL SOLID WASTE GENERATION RATES IN THE STATE OF SÃO PAULO: INFLUENCE OF POPULATION, INCOME AND ELECTRICITY CONSUMPTION

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. 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: dos coeficientes de correlação de Pearson (r) e de determinação (R^2), das raízes quadradas dos erros médios ao quadrado (RMSE), dos erros percentuais médios (E_p) e da comparação dos valores previstos e observados com a reta bissetriz do primeiro quadrante. A equação que melhor representou o conjunto de dados forneceu r de 0,49, R^2 de 0,24, RMSE de 0,217 kg.hab⁻¹.d⁻¹ e E_p de -14,1%. Apesar de R^2 relativamente baixo, foi demonstrado, através do teste de *t-Student*, que a equação proposta foi capaz de representar valores médios e resultar em mesma variância com probabilidade acima de 99 %, fato que permitiu considerar a equação adequada para prever as TGP nos municípios paulista.

Abstract

Forecasting Municipal Solid Waste (MSW) generation is fundamental in choosing and scaling the operations and processes involved in municipal management. The challenge for the financial sustainability of this management is to create indicators that enable municipal solid waste fees to be charged in proportion to the amount of MSW generated by each resident. To this end, we sought to develop equations to estimate the *per capita* waste generation rate (TGP) in the municipalities of the state of São Paulo. It was assumed that the variables of population (P), daily *per capita* income (RPC) and daily *per capita* consumption of electric energy (Ce) in the municipalities were determining factors of the TGP. The dataset involved 238 municipalities that routinely weighed their solid wastes in the baseline year of 2013. Several functions were tested in order to adjust the observed TGP to those calculated by the least squares method. The quality of the adjustments was

evaluated by comparing the expected and observed values with the bisector of the first quadrant, as well as, by the Pearson (r) and determination (R^2) coefficients, root-mean-square error (RMSE), and mean percentage error (E_p) values. The equation that best represented the dataset had an r of 0.49, R^2 of 0.24, RMSE of 0.217 $\text{kg.person}^{-1}.\text{d}^{-1}$ and E_p of -14.1%. Despite the relatively low R^2 , it was demonstrated by Student's t-test that the proposed equation was able to represent mean values and result in the same variance with probability higher than 99%. This fact allow to consider the equation adequate for predicting the TGP in the municipalities of the state of São Paulo.

Palavras-chave: gerenciamento de resíduos sólidos, resíduos sólidos urbanos, taxa de geração *per capita*, análise de regressão.

Key Words: waste management, municipal solid waste, *per capita* generation rate, regression analysis.

CORRELAÇÃO PARA ESTIMATIVA DA GERAÇÃO *PER CAPITA* DE RSU EM SP

INTRODUÇÃO

Os processos de produção e o consumo humano geram grande diversidade e quantidade de resíduos que requerem destinação ambientalmente adequada. Os resíduos sólidos urbanos (RSU) representam parcela significativa dos resíduos sólidos que, devido aos riscos potenciais 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” (grifo dos autores). 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.

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 outros serviços de limpeza urbana (Figura 1).

O Estado de São Paulo foi formado por 655 municípios no ano de 2013, dentre eles 533 participaram do Diagnóstico do Manejo de Resíduos Sólidos – 2013, dos quais 238 afirmaram pesar rotineiramente os resíduos coletados (SECRETARIA NACIONAL DE SANEAMENTO AMBIENTAL, 2015). Este conjunto de 238 municípios representou aproximadamente 82 % da população total em 2013 (42.304.694 habitantes). É o Estado mais urbanizado do Brasil, com taxa de urbanização registrada em 2010 de 95,9% (SEADE, 2013).

O Estado de São Paulo abriga o maior parque industrial e, conseqüentemente, a maior produção econômica do país. Apresenta maior Índice de Desenvolvimento Humano (0,783 em uma escala de 0 a 1). Em 2013, gerou cerca de 59.291 t.d⁻¹ de RSU, dos quais, 74,6 % foram dispostos em aterros sanitários, 15,1% em aterros controlados e 8,5% em lixões (ABRELPE, 2014). Panorama diferente foi descrito em Cetesb (2015), pois relatou que 97,8 % (39.009 t.d⁻¹) do montante total (39.865 t.d⁻¹) dos RSU foram adequadamente dispostos e apenas 2,2% (856 t.d⁻¹) em locais inadequados em 2013.

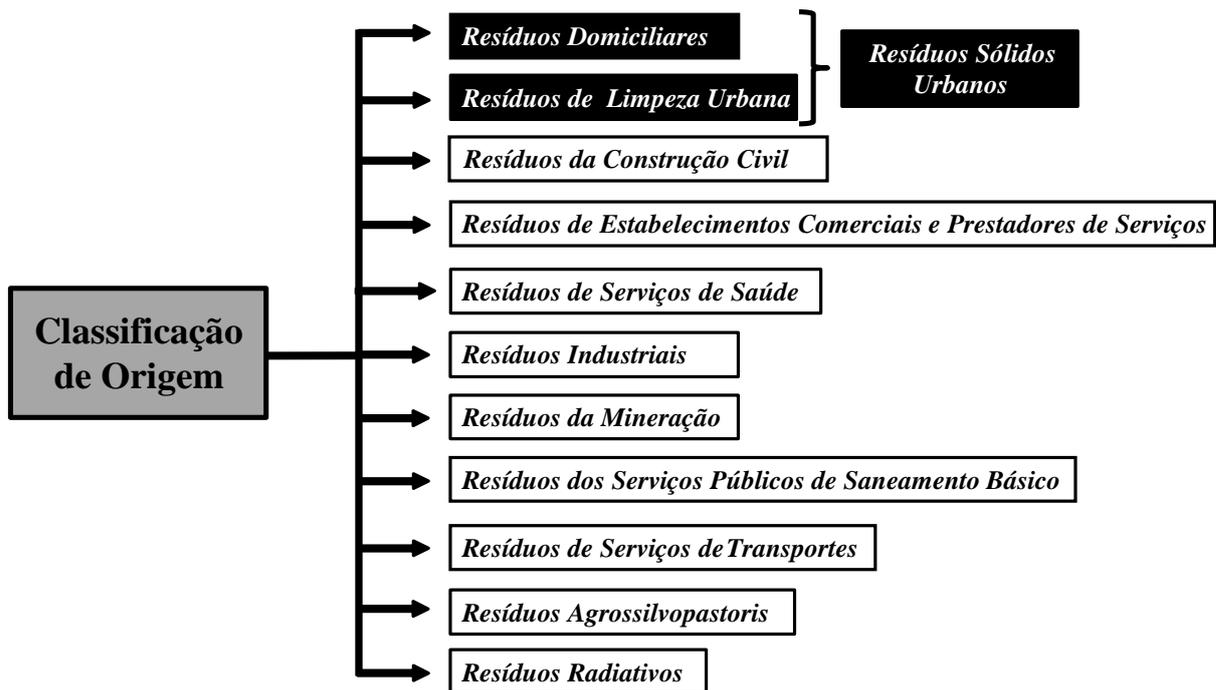


Figura 1 - Classificação de origem dos resíduos sólidos, segundo a Lei 12.305/2010

Fonte: Lei 12.305/2010 e Decreto 7.404/2010

Hockett et al. (1995) correlacionaram a taxa de geração de RSU no Estado da Carolina do Norte (EUA) através de variáveis socioeconômicas, porém sem envolver a população de cada município, e obtiveram R^2 no intervalo de 0,37 a 0,50.

Já Keser et al. (2012), em diferentes localidades da Turquia, levaram em consideração fatores socioeconômicos e climáticos na determinação da taxa de geração de RSU. Nesta pesquisa foram utilizados modelos de auto-regressão espacial simultânea, regressão não-espacial e regressão geograficamente ponderada para as análises de dados espaciais. Obtiveram coeficientes de Pearson (r) no intervalo de 0,47 a 0,59, porém com valores das raízes quadradas dos erros médios ao quadrado (RMSE) da ordem de 50 % dos valores previstos.

Xu et al. (2013) desenvolveram um modelo híbrido que combinava o modelo sazonal auto-regressivo de média móvel para a previsão da geração de resíduos sólidos urbanos em uma cidade específica (na China) para múltiplas escalas de tempo, sem a necessidade de considerar outras variáveis. Os resultados alcançados demonstraram que o modelo foi bastante preciso, porém, restrito à cidade avaliada.

Benítez et al. (2008) propuseram para a cidade do México modelos capazes de relacionar a geração *per capita* de resíduos domiciliares (variável dependente)

para diferentes variáveis (independentes), tais como educação, renda por domicílio e número de moradores. A fim de analisar o modelo que melhor explicava a previsão, o conjunto de dados foi analisado a partir dos testes de normalidade, Kolmogorov-Smirnov, multicolinearidade e heterocedasticidade. O valor máximo do coeficiente de determinação (R^2) foi de 0,51.

Já no estudo de Navarro et al. (2002) foram demonstrados dois modelos, tendo como objeto 3 cidades gregas e espanholas, propuseram técnicas distintas para prever a geração de resíduos sólidos urbanos. A primeira era baseada em dinâmica não-linear, na qual foi proposto um modelo comparativo de desempenho, com uma média sazonal auto-regressiva em movimento denominado (sARIMA). A segunda técnica assumiu que a geração de resíduos sólidos urbanos era um sistema dinâmico discreto de uma única variável escalar. Apesar dos desvios resultantes de até 5%, não disponibilizaram equações que permitissem utilização.

A relação entre fatores demográficos e socioeconômicos foi alvo de estudo no Brasil em Pinto et al. (2012) e Dias et al. (2012), que correlacionaram a taxa de geração de RSU em Belo Horizonte, com a população, o índice de qualidade de vida urbana (IQVU) e renda *per capita*. Demonstraram que o IQVU e a renda conjuntamente com o número de moradores eram variáveis que influenciam a geração de resíduos sólidos em bairros do município. No entanto, as equações descritas são aplicáveis apenas ao município avaliado. Neste mesmo município foram empregados diferentes métodos que permitiram chegar à conclusão de que os fatores como socioeconômicos, como educação e renda, e demográficos, como estrutura etária e domiciliar, eram importantes na geração de RSU em sub-regiões do município (Silva et al., 2012). Sendo assim, este estudo teve como objetivo desenvolver equações que permitissem estimar a taxa de geração *per capita* (TGP) de resíduos sólidos urbanos (RSU) nos municípios do Estado de São Paulo, a partir das variáveis população total (P), renda *per capita* e consumo de energia elétrica.

MATERIAL E MÉTODOS

Estimar e projetar as quantidades de resíduos gerados são fundamentais para o gerenciamento integrado de resíduos sólidos; neste contexto, são descritos métodos e parâmetros estatísticos utilizados para se verificar o nível de confiança da

amostra disponível, avaliar a dependência entre as variáveis e investigar a qualidade do ajuste do modelo ao conjunto de dados.

No estudo de correlação procura-se verificar a dependência da TGP de RSU em função da população total, renda *per capita* e consumo *per capita* diário de energia elétrica nos municípios do Estado de São Paulo. As populações totais e rendas *per capita* foram utilizadas como variáveis independentes pois suas influências foram evidenciadas na literatura, já a variável consumo *per capita* de energia elétrica foi escolhida por estar associada indiretamente ao padrão de consumo, infraestrutura disponível e à utilização de bens e serviços.

BASE DE DADOS

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, Diagnóstico do Manejo de Resíduos Sólidos Urbanos – 2013-2015 (SECRETARIA NACIONAL DE SANEAMENTO AMBIENTAL, 2015). Neste documento são explicitadas, dentre muitas informações, separadamente as quantidades dos resíduos domiciliares, dos resíduos de limpeza urbana e dos 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 admite 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 totais (P), rendas *per capita* anual e consumos anuais de eletricidade (CE) de cada município foram obtidos mediante consulta ao sítio Eletrônico da Fundação Estadual de Análise de Dados (SEADE, 2016). As rendas *per capita* dos municípios paulistas estavam atualizadas com referência ao ano base de 2010, sendo assim, os seus valores foram convertidos em dólares americanos para a cotação média neste ano de R\$ 1,76 por USD. Além disso, a fim de correlacionar os resultados foram utilizadas na forma de rendas *per capita* diárias

(RPC) ($\text{USD.hab}^{-1}.\text{d}^{-1}$) e consumos *per capita* diários de eletricidade (C_e) em cada município ($\text{kWh.hab}^{-1}.\text{d}^{-1}$).

REPRESENTATIVIDADE DA AMOSTRA

O espaço amostral, uma vez que nem todos os municípios paulistas participaram do Diagnóstico do Manejo de Resíduos Sólidos Urbanos – 2013-2015 e informaram pesar rotineiramente seus RSU, pôde ser estabelecido na forma de dois critérios principais, com base no número de municípios ou na população abrangida, em relação ao total do Estado de São Paulo.

A representatividade da amostra 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):

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

na qual n é o tamanho da amostra, N é o tamanho do universo amostral (646 municípios ou 42.304.694 habitantes em 2013), 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 do número total de municípios ou da população do Estado, resultassem no número de municípios ou de população que participaram da amostra.

AValiação DO MODELO

Inicialmente 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 2 a 6). Para isto, foram utilizados os programas computacionais BIOESTAT 5.3, gratuito, 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.

$$TGP = a + b.(P) + c.(RPC) \quad (2)$$

$$TGP = a + b.(P) + c.(Ce) \quad (3)$$

$$TGP = a + b.(RPC) + c.(Ce) \quad (4)$$

$$TGP = a + b.(P) + c.(RPC) + d.(Ce) \quad (5)$$

$$TGP = a + b.Ln(P) + c.RPC + d.[Ln(Ce)]^e \quad (6)$$

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 estatística das qualidades dos ajustes envolveu a análise de correlação linear, de regressão linear, teste t-Student e regressão multivariável.

Dependência entre Variáveis

O coeficiente de correlação de Pearson (r) também conhecido como coeficiente de correlação produto-momento ou o coeficiente r de Pearson (Equação 7) tem por objetivo medir o grau da correlação linear entre duas variáveis quantitativas. Tal avaliação apresenta-se como um índice adimensional com valores situados entre -1,0 e 1,0, normalmente representado pela letra r e reflete a intensidade de uma relação linear entre dois conjuntos de dados. Se r for igual a 1, há uma correlação perfeita positiva entre as duas variáveis e se r for igual a -1, obtém-se uma correlação negativa perfeita entre as duas variáveis, indicando que estas movem-se em direções opostas. Isto é, se uma aumenta, a outra sempre diminui. Enquanto para duas variáveis perfeitamente correlacionadas positivamente (r = 1), elas estariam em perfeita proporção na mesma direção. Entretanto se o

resultado final alcançado for igual a 0, as duas variáveis não dependem linearmente uma da outra, podendo existir uma outra dependência que seja não linear. Assim, o resultado r igual a 0 deve ser investigado por outros meios (Legates; McCabe, 1999; Moriasi et al., 2007). O coeficiente de correlação de Pearson (r) é definido por (Equação 7).

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y}_{medida})}{\sqrt{\left(\sum (x_i - \bar{x})^2\right)} \cdot \sqrt{\left(\sum (y_i - \bar{y}_{medida})^2\right)}} \quad (7)$$

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

Como valores extremos (-1 e 1) dificilmente são encontrados na prática, é importante qualificar intervalos para o coeficiente r . Para Cohen (1988), valores entre 0,10 e 0,29 podem ser considerados pequenos; resultados entre 0,30 e 0,49 podem ser avaliados como médios e de 0,50 a 1,00, como grandes. Dancey e Reidy (2006) apontaram para uma classificação ligeiramente diferente: r de 0,10 até 0,30 para fraca dependência entre as variáveis; 0,40 a 0,60 como moderada, e de 0,70 a 1,00 como forte correlação. Seja como for, o certo é que quanto mais próximo a 1 (independente do sinal) maior é o grau de dependência estatística linear entre as variáveis. No outro oposto, quanto mais próximo de zero, menor é a força desta relação.

Qualidade de Ajuste

A avaliação da qualidade dos ajustes foi feita a partir do cálculo de alguns parâmetros amplamente utilizados em avaliações estatísticas: o coeficiente de determinação (R^2), 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 é o quadrado do coeficiente de correlação de Pearson (Equação 8), e apresenta-se como uma das formas de avaliar a qualidade

do ajuste do modelo utilizado. É conhecido também como R^2 e 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 R^2 pode variar de 0 a 1, sendo pouco comum uma correlação perfeita ($R^2 = 1$) 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 R^2 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).

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

na qual y_{medidq} é a variável dependente observada para cada elemento do conjunto de dados, \bar{y}_{medida} é o valor médio da variável dependente observada do conjunto de dados, y_{calci} 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 (Abdullah, 2009; Moriasi et al., 2007; Yafee, McGee, 2000).

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

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 :

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

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.

Teste *t-Student* para Correlação

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*. O formato da distribuição t de *Student* é dependente do número de graus de liberdade, ou seja,

quanto maior este número, mais concentrada é a distribuição. Quanto maiores os graus de liberdade mais a distribuição *t* de *Student* se aproxima da distribuição normal.

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*. Conseqüentemente, 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).

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

RESULTADOS E DISCUSSÃO

Nas figuras 2 a 4 são mostradas as taxas de geração de *per capita* de resíduos sólidos urbanos para os municípios do Estado de São Paulo que informaram pesar rotineiramente seus resíduos (Secretaria Nacional de Saneamento Ambiental, 2015), referente ao ano base de 2013.

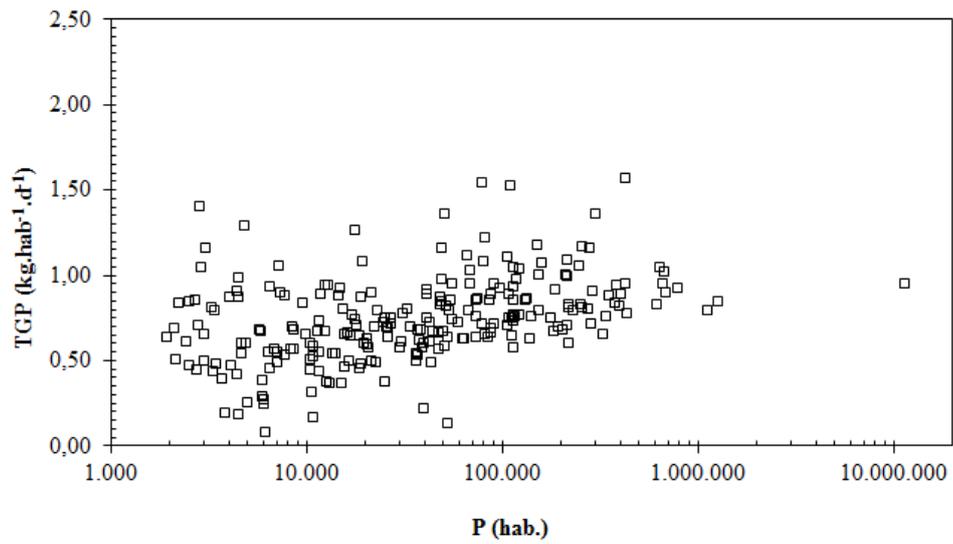


Figura 2 - Taxa de geração *per capita* de resíduos sólidos urbanos em função da população total dos municípios paulistas que rotineiramente pesaram seus resíduos

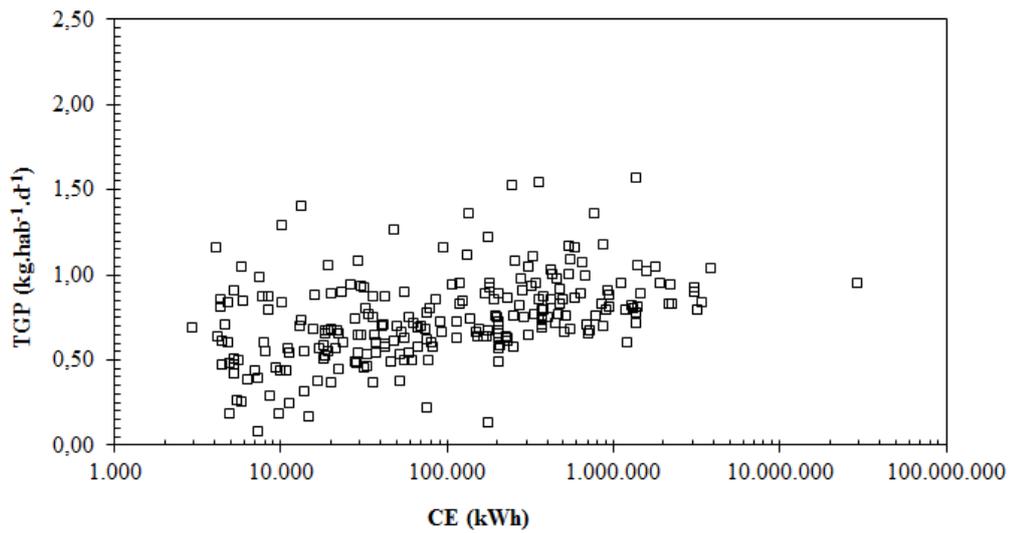


Figura 3 - Taxa de geração per capita de resíduos sólidos urbanos em função do consumo anual de energia elétrica nos municípios paulistas que rotineiramente pesaram seus resíduos

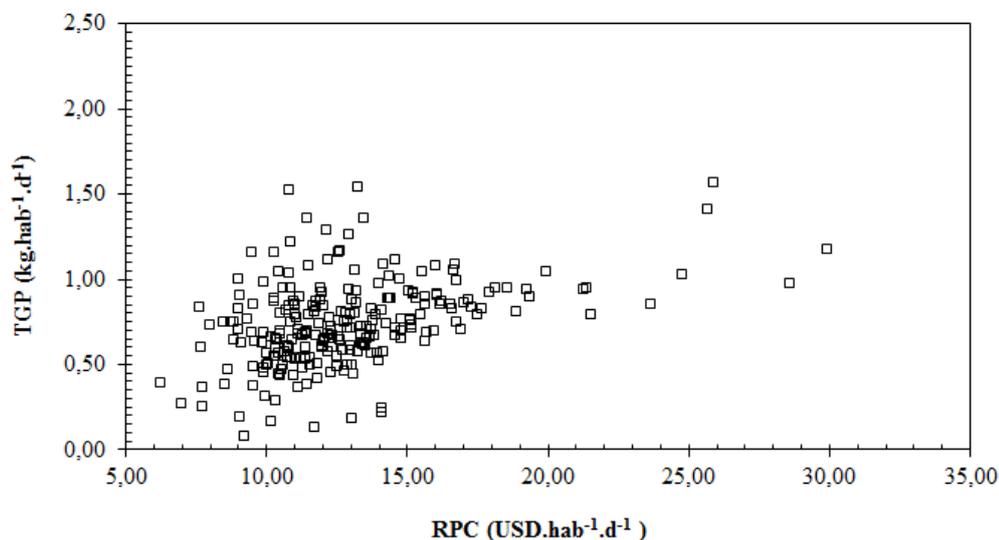


Figura 4 - Taxa de geração *per capita* de resíduos sólidos urbanos em função da renda *per capita* média diária nos municípios paulistas que rotineiramente pesaram seus resíduos

Nota-se pelas figuras 2 a 4 dispersão acentuada da taxa de geração *per capita* de RSU em relação às variáveis independentes, há municípios com geração superior a $1,0 \text{ kg.hab}^{-1}.\text{d}^{-1}$ para populações na faixa de 3 mil a 400 mil habitantes, por outro lado, cidades com TGP inesperadamente baixas, inferiores a $0,5 \text{ kg.hab}^{-1}.\text{d}^{-1}$, para populações no intervalo de 3 mil a 40 mil habitantes. Percebe-se pelas figuras 2 e 3 o mesmo comportamento entre TGP frente a P e CE, cuja tendência foi de crescimento em relação ao logaritmo destas variáveis. Porém, o consumo total de energia elétrica é bastante dependente da população de cada município, portanto, optou-se por utilizar o consumo diário *per capita* de eletricidade para tornar as variáveis independentes entre si. Já, na Figura 4, apesar da grande dispersão dos pontos, o comportamento foi decréscimo linear de TGP a partir da renda *per capita* diária de cada município.

As taxas de gerações *per capita* de RSU de 9 municípios foram glosadas, 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. 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.

Tabela 1 - Municípios para os quais as informações foram glosadas ou suprimidas

Município	População (hab)	TGP_{SNIS} (kg.hab⁻¹.d⁻¹)	TGP_{PMGIRS} (kg.hab⁻¹.d⁻¹)
Cruzália	2.222	1,24	0,84
Lutécia	2.682	1,56	0,86
Lavínia	8.666	1,99	não informado
Iacanga	10.414	1,57	0,60
Ilhabela	29.837	2,86	não informado
Paraguaçu Paulista	42.858	3,20	não informado
Registro	54.107	1,53	0,86
Atibaia	130.606	1,58	0,86
Guarulhos	1.260.840	1,53	0,84

O universo amostral 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 compõe o Estado de São Paulo de 645 municípios (42.304.694 habitantes) em 2013. Pelo critério de número de cidades, pôde-se afirmar que 238 municípios representam 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 representam a população total de 42.304.694 habitantes com margem de erro de apenas 0,015% e intervalo de confiança de 99,985 %. Portanto, concluiu-se que a amostra foi representativa do Estado de São Paulo e que os resultados obtidos são passíveis de extrapolação para os demais municípios, incluindo aqueles que não participaram do Diagnóstico do Manejo de Resíduos Sólidos Urbanos – 2013-2015.

Regressão Linear Múltipla

A regressão linear múltipla de TGP em função de P e RPC (Equação 1) resultou em (Equação 12):

$$TGP=0,348+4,19.10^{-9}.P_{(hab)}+0,0306.RPC_{(USD.hab^{-1}.d^{-1})} \quad (12)$$

Esta correlação múltipla apresentou coeficiente de correlação de Pearson r de 0,43, R^2 de 0,18, RMSE de $0,225 \text{ kg.hab}^{-1}.\text{d}^{-1}$ e E_p de -15,2%, indicando média ou intermediária correlação múltipla.

A correlação múltipla entre a variável dependente TGP e as variáveis independentes, população total (P em hab.) e consumo *per capita* diário de energia elétrica (C_e) (Equação 13), resultaram em coeficiente de correlação de Pearson (r) de apenas 0,24, R^2 de 0,06, E_p de -17,2 % e RMSE igual $0,241 \text{ kg.hab}^{-1}.\text{d}^{-1}$:

$$\text{TGP} = 0,675 + 3,80 \cdot 10^{-8} \cdot P_{(\text{hab})} + 0,00745 \cdot C_{e(\text{kW.hab}^{-1}.\text{d}^{-1})} \quad (13)$$

Essa combinação de variáveis piorou a qualidade de ajuste quando comparada com a regressão que empregou as variáveis P e RPC , em razão de valores de r , R^2 e módulo de E_p menor e RMSE mais elevado.

O ajuste de TGP em função linear de RPC e C_e (Equação 14) forneceu o melhor ajuste de duas variáveis até o momento, pois o coeficiente de correlação de Pearson (r) foi de 0,44, R^2 de 0,19, E_p de -15,3 % e RMSE igual a $0,223 \text{ kg.hab}^{-1}.\text{d}^{-1}$:

$$\text{TGP} = 0,345 + 0,0284 \cdot RPC_{(\text{USD.hab}^{-1}.\text{d}^{-1})} + 0,00408 \cdot C_{e(\text{kW.hab}^{-1}.\text{d}^{-1})} \quad (14)$$

Já a correlação multilinear empregando as três variáveis independentes simultaneamente (P , C_e e RPC) resultou em r de 0,44, R^2 de 0,19, E_p de +9,1 % e RMSE de $0,279 \text{ kg.hab}^{-1}.\text{d}^{-1}$ (Equação 15):

$$\text{TGP} = 0,339 + 6,19 \cdot 10^{-9} \cdot P_{(\text{hab})} + 0,00422 \cdot C_{e(\text{kW.hab}^{-1}.\text{d}^{-1})} + 0,0162 \cdot RPC_{(\text{USD.hab}^{-1}.\text{d}^{-1})} \quad (15)$$

que não melhorou sensivelmente a qualidade do ajuste, uma vez que o valor de RMSE ($0,279 \text{ kg.hab}^{-1}.\text{d}^{-1}$) foi maior que os obtidos com as equações 12 a 14 para R^2 próximos a 0,19, exceção feita 0,06 fornecido pela Equação 13. No entanto, foram mostradas nas figuras 2 e 3 as dependências de TGP em função do logaritmo neperiano da população e do consumo de energia elétrica. Sendo assim, é possível que função expressa no logaritmo natural de P e C_e resulte em melhor ajuste.

Correlação para $\ln(P)$ E $\ln(C_e)$

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 diário *per capita* de energia elétrica (C_e).

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)	0,12	0,41	0,41	0,42	0,21	0,32

Nota-se pela Tabela 2, que correlações envolvendo Ln(P), RPC e Ln(Ce) potencialmente ajustariam melhor as TGP de RSU. Sendo assim, o método dos mínimos quadrados permitiu determinar os coeficientes presentes na Equação 6, que resultou em (Equação 16):

$$TGP = -11,280 + 0,0356.Ln(P) + 0,0179.RPC + 11,347.[Ln(Ce)]^{0,0103} \quad (16)$$

válida para os seguintes intervalos: $1.923 \text{ hab} \leq P \leq 11.446.275 \text{ hab}$; $6,23 \text{ USD.hab}^{-1} \cdot \text{d}^{-1} \leq RPC \leq 29,89 \text{ USD.hab}^{-1} \cdot \text{d}^{-1}$; e $2,51 \text{ kWh.hab}^{-1} \cdot \text{d}^{-1} \leq Ce \leq 87,04 \text{ kWh.hab}^{-1} \cdot \text{d}^{-1}$.

Os parâmetros de avaliação da qualidade do ajuste são mostrados na Tabela 3. Apesar do baixo coeficiente de determinação (0,24), o desvio percentual associado à previsão foi aceitável, em torno de -14%, o sinal negativo indicou uma tendência de estimar valores acima dos observados. O valor de RMSE foi da ordem de 29% (0,217 kg.hab⁻¹.d⁻¹) do valor médio observado (0,746 kg.hab⁻¹.d⁻¹). Portanto, a Equação 16 forneceu o melhor ajuste dentre as equações testadas. Nas figuras 5 a 7 são mostradas as taxas de geração *per capita* de RSU observada e previstas pela Equação 16 em função das variáveis independentes.

Tabela 3 - Parâmetros de avaliação da qualidade dos ajustes para Equação 16

	Parâmetros de avaliação da qualidade do ajuste			
	r (-)	R ² (-)	RMSE (kg.hab ⁻¹ .d ⁻¹)	E _p (%)
Equação (16)	0,49	0,24	0,217	-14,1

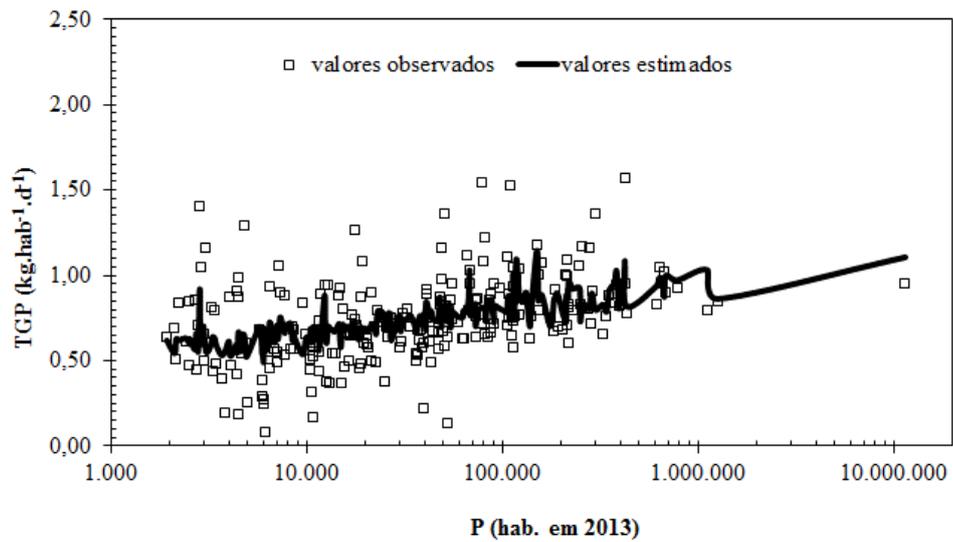


Figura 5 - Taxas de geração *per capita* de RSU em função da população total dos municípios do Estado de São Paulo que alegaram pesar rotineiramente seus resíduos

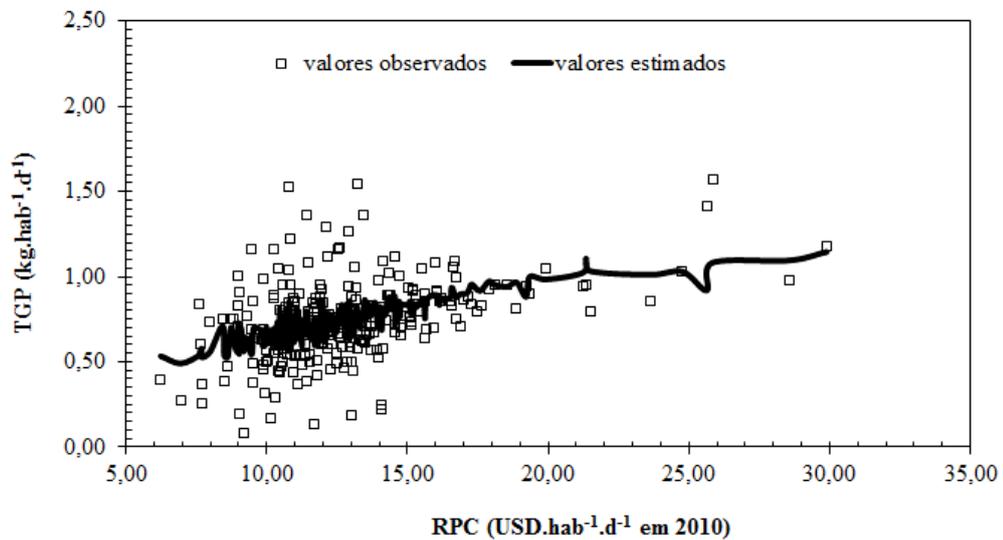


Figura 6 - Taxas de geração *per capita* de RSU em função da renda *per capita* diária nos municípios do Estado de São Paulo que alegaram pesar rotineiramente seus resíduos