

## ESTIMATIVA DO IMPACTO DAS VARIAÇÕES DE TEMPERATURA SOBRE O CONSUMO RESIDENCIAL DE ENERGIA ELÉTRICA NO RIO DE JANEIRO

**Gustavo Naciff de Andrade**

Universidade Federal Fluminense

gnandrade@id.uff.br

**Annibal Parracho Sant'Anna**

Universidade Federal Fluminense

annibal.parracho@gmail.com

### RESUMO

No momento atual, em que cresce a preocupação com as mudanças climáticas, aumenta a importância de mensurar os impactos que a elevação das temperaturas pelo planeta pode ocasionar na necessidade de energia elétrica pelas residências. O presente estudo objetiva evidenciar a relação entre a temperatura e o consumo residencial de energia elétrica na cidade do Rio de Janeiro. Para tanto, utiliza-se o método de decomposição sazonal X11 nas duas séries e posteriormente ajusta-se um modelo de regressão para explicar o efeito que variações na temperatura podem causar sobre o consumo residencial. A análise de regressão emprega uma abordagem *fuzzy*, que permite levar em conta a incerteza inerente tanto nas medidas quanto na própria relação estudada. Os resultados obtidos permitem demonstrar uma influência da temperatura no consumo e estabelecer previsões de valores extremos para o consumo.

**PALAVRAS CHAVE:** Energia Elétrica, Análise de Regressão, Conjuntos Nebulosos.

**Área Principal:** EN - P. O. na Área de Energia

### MODELLING THE IMPACT OF TEMPERATURE CHANGE ON RESIDENTIAL CONSUMPTION OF ELECTRICITY IN RIO DE JANEIRO

The actual worry about climate change increases the importance of measuring the impact that rising temperatures in the planet may cause in the need of electricity by households. The present study aims to identify the relationship between temperature and residential consumption of electricity in the city of Rio de Janeiro. To do so, it applies the method X11 of seasonal decomposition in these two series and then fits a regression model to explain the effect that variations in temperature may cause on the consumption levels. The regression analysis employs a fuzzy approach, which allows for taking into account the uncertainty inherent not only in both measures studied but also in the relationship itself. The results obtained show an influence of temperature on consumption and provide forecasts of extreme values for consumption.

**KEYWORDS:** Electric energy, Regression analysis, Fuzzy sets.

**Main area:** EN - Energy

## 1. Introdução

De acordo com a Agência Internacional de Energia (IEA, 2011), o consumo residencial de eletricidade no mundo em 2009 totalizou 4.734 TWh, o equivalente a aproximadamente 28% do total. O consumo de eletricidade nos lares brasileiros em 2011 foi de 112 TWh, representando cerca de 26% do total do país (EPE, 2012).

O consumo residencial sofre influência de distintas variáveis, a depender do horizonte temporal analisado. No longo prazo, variáveis estruturais relacionadas a questões demográficas e econômicas determinam o montante de energia consumido. São exemplos de variáveis capazes de influenciar a demanda residencial por energia, neste horizonte de tempo, o número de habitantes por residência, renda disponível, posse de equipamentos por residência, entre outros.

Já no curto prazo variações significativas no consumo médio residencial são muitas vezes derivadas de aspectos relacionados a mudanças na temperatura. Em situações ambientais extremas o aumento ou diminuição acentuada da temperatura geram a necessidade da utilização de energia para condicionar o ambiente residencial.

A influência da temperatura sobre o consumo de energia elétrica varia de acordo com características climatológicas da área avaliada. Assim, em regiões com clima temperado (estações bem definidas e com inverno rigoroso) a relação é tipicamente não linear. Nesta situação há uma temperatura limiar (usualmente entre 18 °C e 21°C) a partir da qual tanto aumento como diminuição da temperatura acarreta crescimento do consumo para fins de refrigeração (no caso do aumento da temperatura) ou aquecimento (no caso de diminuição). Moral-Carcedo *et al.* (2005) demonstram a não linearidade da variação de temperatura sobre a carga diária de energia na Espanha. Já Henley e Peirson (1997) registram a relação não linear entre a temperatura e a demanda residencial no Reino Unido utilizando métodos paramétricos e não paramétricos.

No entanto para regiões caracterizadas pelo clima tropical (temperaturas anuais menos variáveis e mais elevadas), a relação entre temperatura e consumo de energia apresenta comportamento linear. Esta característica está em grande parte associada ao fato de o inverno nessas regiões apresentar temperaturas médias que não caracterizam a necessidade de calefação de ambientes, o que em última instância não aumenta a demanda de energia para tal fim. A Figura 1, ainda que de maneira hipotética, ilustra essa diferença no comportamento do consumo de energia e temperatura média para regiões de climas distintos. O eixo y representa as variações no consumo de eletricidade dadas as variações na temperatura no eixo x.

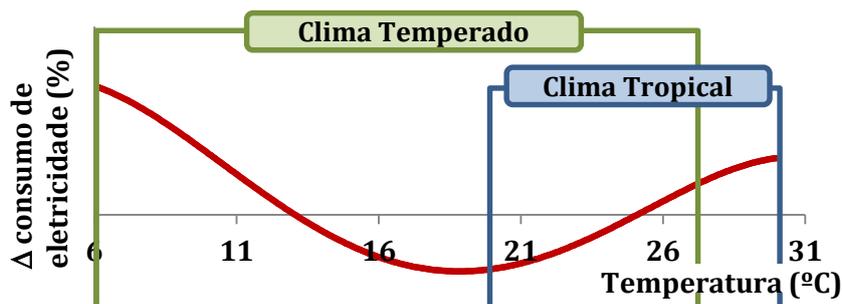


Figura 1: Relação entre variações no consumo de energia e temperatura

Fonte: Elaboração própria.

Assim, diversos estudos quantificaram e demonstraram a influência da temperatura sobre a carga ou o consumo de energia elétrica. Fung (2006) estima a partir de regressão estatística que o aumento da temperatura urbana em 1°C elevaria o consumo residencial em Hong Kong em aproximadamente 9%.

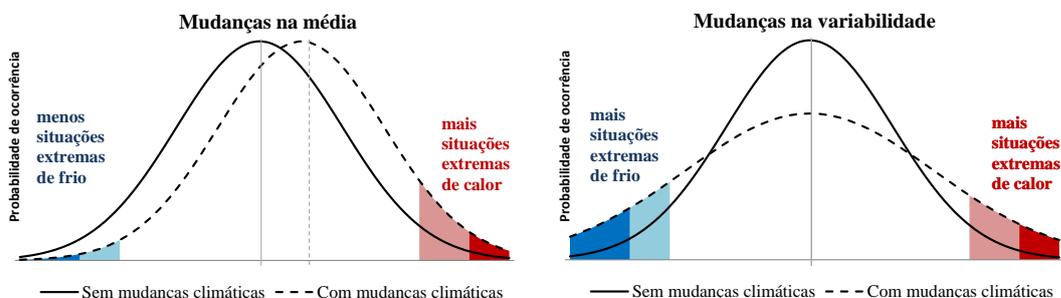
Le Conte e Warren (1981), Al-Zayer e Al-Ibrahim (1996) e Valor *et al.* (2001) empregaram o conceito de *degree days* para analisar o impacto da temperatura e conforto térmico sobre o consumo de eletricidade. *Degree days* é um conceito que leva em consideração quanto

(em graus de temperatura) e por quanto tempo (em dias) a temperatura do ambiente está acima (*cooling degree day*) ou abaixo (*heating degree day*) de um determinado valor.

A relação entre consumo de energia elétrica e temperatura tende a ganhar ainda mais relevância na literatura dado o crescente envolvimento da sociedade com discussões acerca das mudanças climáticas. O conceito de mudança climática refere-se a alterações do clima através do tempo, que podem estar associados tanto à variabilidade natural como também pode ser consequência das atividades do homem sobre o meio ambiente, como emissões de CO<sub>2</sub> intensificando o efeito estufa no planeta terra.

Atualmente o Painel Intergovernamental de Mudança Climática (IPCC), principal entidade avaliadora do conhecimento sobre alterações climáticas, realiza estudos sistemáticos com o intuito de mensurar a magnitude e os impactos que alterações originárias de uma possível mudança climática podem acarretar para a vida no planeta Terra.

Segundo IPCC (2012), mudanças no clima podem acarretar alterações na frequência, intensidade, extensão espacial e duração de eventos climáticos. Ainda segundo esse estudo, mudanças nos extremos de temperatura podem estar relacionadas a mudanças na média, na variância ou em outros parâmetros da distribuição de probabilidade, isolados ou conjuntamente. A Figura 2 ilustra duas das diferentes alterações climáticas que podem ocorrer.



**Figura 2- Exemplificação de tipos de mudanças climáticas.**

Fonte: Elaboração própria a partir de IPCC (2012).

IPCC(2012) registra ainda que os modelos preveem substancial aumento de temperaturas extremas até o fim do século 21. É esperado o crescimento da frequência e magnitude de dias e noites mais quentes e menor ocorrência de frio ao longo do século, em escala global. Como resultado final é esperado aumento na temperatura média do planeta.

Já em IPCC (2007) era projetado um aumento médio global das temperaturas entre 1,8°C e 4,0°C até o ano de 2100. Segundo este estudo, tal aumento pode ser ainda maior (atingindo 6,4°C) caso se configure um cenário mais extremo com maior crescimento econômico e intensificação do consumo de combustíveis fósseis.

Assim, diante da relevância do tema, o objetivo deste artigo é medir o impacto que variações na temperatura média podem exercer sobre o consumo de energia nos lares cariocas. Para tanto, a partir da dessazonalização dos dados da temperatura média mensal e do consumo residencial na cidade do Rio de Janeiro, será ajustada uma regressão entre as séries históricas dessazonalizadas dessas variáveis que permite estimar a relação entre elas.

## 2. Técnicas de Dessazonalização

Morettin e Toloi (2006) mostram como uma série temporal  $\{Z_t, t=1, \dots, N\}$  pode ser decomposta como uma soma de três componentes não observáveis:

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

Em (1),  $T_t$  e  $S_t$  representam a tendência e a sazonalidade da série, enquanto  $a_t$  representa a componente aleatória. O principal interesse em decompor a série temporal desta maneira é que, ao destacar a componente sazonal, se consegue constituir uma série sazonalmente ajustada. Feita

a decomposição, determinam-se as componentes  $Tt$  e  $St$  e a diferença entre os dados observados e o somatório dessas parcelas constitui a componente aleatória ( $at$ ).

Um método bastante usual na decomposição de séries temporais é o X-11 (Shiskin *et al.*, 1967), derivado do método Census II desenvolvido pelo U.S Bureau of the Census. O método utiliza-se do artifício de médias móveis inicialmente desenvolvido por Henderson (1916) para estimar as componentes sazonal e tendencial de uma série de dados. De acordo com Pezzulli *et al.* (2005), o método pode ser definido como um algoritmo de três passos: estimativa inicial das componentes tendencial e sazonal, revisão iterativa das componentes estimadas e estimativa final da tendência e componente aleatória.

Um maior detalhamento do método pode ser encontrado em Shiskin *et al.* (1967). No presente estudo foi utilizado o software E-views para decomposição multiplicativa X-11.

### 3. Conjuntos Nebulosos

O conceito de conjuntos nebulosos (*fuzzy sets*, em inglês) foi desenvolvido por Zadeh (1965) e pode ser interpretado como uma generalização da teoria clássica de conjuntos. Tem grande campo de aplicação em classificação de dados e processamento de informações. Nos modelos de regressão, a abordagem *fuzzy* permite lidar com problemas nos quais a fonte de imprecisão está relacionada tanto à associação entre as variáveis quanto a cada variável aleatória.

A diferença entre a teoria de conjuntos tradicional e a teoria de conjuntos nebulosos pode ser esclarecida com o uso da função de pertinência. Os conjuntos da teoria tradicional podem ser pensados como conjuntos nebulosos cuja função de pertinência ( $\mu_A(x)$ ) assume apenas os valores 0 ou 1. Assim a relação é binária, o que significa que um elemento pertence ao conjunto ou não pertence, não havendo situações intermediárias. Algebricamente esta relação é descrita por:

$$\mu_A(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases} \quad (2)$$

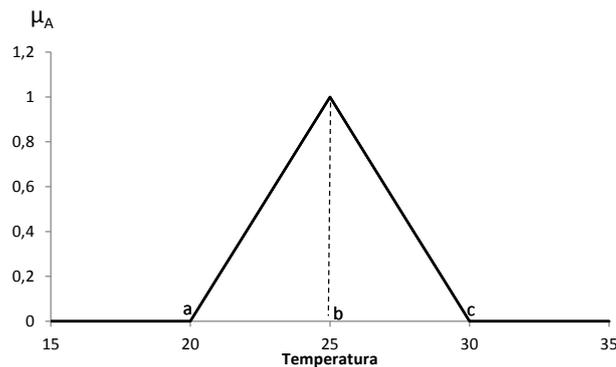
A teoria dos conjuntos nebulosos propõe caracterização mais ampla admitindo que uns elementos são mais membros do conjunto que outros. Assim, a função de pertinência pode assumir qualquer valor entre 0 e 1, sendo que o valor 0 indica uma completa exclusão e o valor 1 representa completa pertinência. Desta forma a utilização da função característica torna-se mais poderosa. Funções com valores maiores que 1 também podem ser usadas, mas, nada se perde com a normalização.

Assim, a classe dos conjuntos nebulosos com base em um conjunto  $C$  é representada pela função de pertinência  $\mu_A(x)$  que associa a cada ponto de  $C$  um número real pertencente ao intervalo  $[0,1]$ . O valor de  $\mu_A(x)$  representa o grau de adesão de  $x$  a  $A$ .

Para identificar um conjunto nebuloso podem ser usadas diversas formas de funções de pertinência como a linear, sigmoide, triangular e trapezoidal. Para indicar que a função de pertinência é convexa, em vez de conjunto nebuloso fala-se em número nebuloso. No caso da triangular, a função de pertinência pode ser algebricamente definida, para  $C = [a, c]$  e  $b$  um ponto de  $C$ , por

$$\mu_A(x, a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (3)$$

Em (3) quando  $x$  assume valores menores ou maiores do que o limite inferior ( $a$ ) e superior ( $c$ ), respectivamente, a função de pertinência apresenta valor igual a zero, que representa a exclusão deste valor do conjunto nebuloso. Já no intervalo entre  $a$  e  $c$  a função de pertinência assume valores de 0 a 1, sendo que a máxima pertinência é atingida em  $b$  (abscissa de um dos vértices do triângulo e moda da distribuição triangular). A Figura 3 representa graficamente o conceito.



**Figura 3: Exemplo de conjunto nebuloso com função de pertinência triangular**

Fonte: Elaboração própria.

São diversas as aplicações de conjuntos nebulosos na literatura envolvendo tanto questões climáticas como consumo de energia elétrica. Cao e Chen (1981) aplicaram conjuntos nebulosos na previsão meteorológica. Já Kucukali e Baris (2010) com o auxílio de conjuntos nebulosos estimam o crescimento de curto prazo da demanda de energia elétrica na Turquia. Mamlook *et al.* (2009) utilizam abordagem *fuzzy* para prever o efeito de diferentes fatores condicionantes, como o clima, na carga de energia.

#### 4. Análise de Regressão Fuzzy

A análise de regressão é uma ferramenta estatística para estabelecer uma relação entre variáveis. Uma vez ajustado, o modelo de regressão pode ser usado para prever o valor de uma variável, dita dependente, a partir do valor observado para outras, ditas variáveis independentes.

A regressão é dita linear quando a relação é de proporcionalidade e é dita simples quando a previsão da variável dependente é feita a partir de apenas uma variável independente. Usualmente utiliza-se a letra  $Y$  para identificar a variável dependente e a letra  $X$  para a variável independente. A forma mais geral para um modelo de regressão linear simples, em que  $Y$  é a variável dependente e  $X$  a variável independente ou regressor é:

$$Y = \beta_0 + \beta_1 X + \mu. \quad (4)$$

O parâmetro  $\beta_0$  é chamado intercepto e representa a predição para  $Y$  quando  $X$  é igual à zero. O parâmetro  $\beta_1$  representa a declividade da reta e representa a variação em  $Y$  associada a uma variação unitária em  $X$ .

Muitas vezes, é preciso levar em conta que, além dos valores das variáveis dependentes e independentes que servirão de base para estimar os parâmetros da reta de regressão, os próprios coeficientes da reta não são valores precisos, mas estão contidos em um intervalo possível de valores. Nestes casos torna-se desejável para lidar com esses parâmetros aplicar a teoria dos conjuntos nebulosos.

Seguindo a abordagem de Diamond (1988) adotada por Bargiela *et al.* (2007), pode-se determinar um número nebuloso  $A$  com função de pertinência  $\mu_A: R \rightarrow [0,1]$  por uma família de conjuntos  $A_\alpha$  chamados  $\alpha$ -cuts. Para cada valor  $\alpha \in (0, 1]$ ,

$$A_\alpha = [A^L(\alpha), A^U(\alpha)], \quad (5)$$

$$\text{onde } A^L(\alpha) = \inf\{z \in R : \mu_A(z) \geq \alpha\} \quad (6)$$

e

$$A^U(\alpha) = \sup\{z \in R : \mu_A(z) \geq \alpha\} \quad (7)$$

Uma distância entre dois números nebulosos  $A$  e  $B$  pode ser definida empregando os respectivos  $\alpha$ -cuts como:

$$d(A, B) = \sqrt{\int_0^1 (A^L(\alpha) - B^L(\alpha))^2 d\alpha + \int_0^1 (A^U(\alpha) - B^U(\alpha))^2 d\alpha} \quad (8)$$

Desta forma é possível definir o ajustamento de um modelo de regressão simples fuzzy como um problema de identificação dos parâmetros  $\beta_0$  e  $\beta_1 \in R$  na Equação 4. Isto é realizado generalizando o processo de ajustamento de um modelo linear, minimizando o erro, que é a distância entre os valores observados e preditos para  $Y$ .

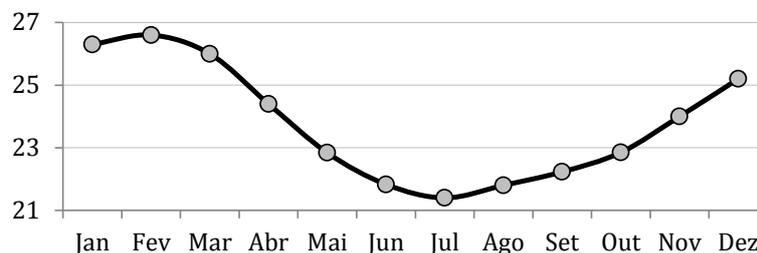
No procedimento para o ajuste de uma regra de regressão desenvolvido por Bargiela *et al.* (2007), o cálculo da função erro  $H(\cdot)$  depende do sinal de  $\beta_1$ . No caso presente, o interesse em analisar as séries temporais da temperatura e consumo residencial parte de que, por estarmos analisando uma região de clima tropical, a variação positiva na temperatura média deve acarretar aumento da energia consumida. Assim, elimina-se a priori a hipótese de  $\beta_1 < 0$ . Desta forma, os parâmetros  $\beta_0$  e  $\beta_1$  foram estimados minimizando a função  $H^+$  definida por

$$H^+(\beta_0, \beta_1) = \sum_{i=1}^k \int_0^1 (Y_i^L(\alpha) - \beta_0 - \beta_1 X_i^L(\alpha))^2 d\alpha + \sum_{i=1}^k \int_0^1 (Y_i^U(\alpha) - \beta_0 - \beta_1 X_i^U(\alpha))^2 d\alpha \quad (9)$$

onde  $Y_i^L(\alpha)$ ,  $Y_i^U(\alpha)$ ,  $X_i^L(\alpha)$  e  $X_i^U(\alpha)$  são as representações por  $\alpha$ -cuts dos conjuntos nebulosos representando a  $i$ -ésima observação das variáveis dependente e independente.

## 5. Caracterização dos Dados

A cidade do Rio de Janeiro está localizada na região Sudeste do Brasil, mais precisamente nas coordenadas 22,9° de latitude sul e 43,2° de longitude oeste. O clima da cidade é tropical quente e úmido e a temperatura média anual está entre 23°C e 24°C. Segundo o Instituto Nacional de Meteorologia (INMET) as normais climatológicas para o período entre 1961 e 1990, apresentam o comportamento descrito na Figura 4, com média mensal mais elevada no mês de fevereiro e menos elevada no mês de julho.



**Figura 4: Gráfico das Normais Climatológicas**

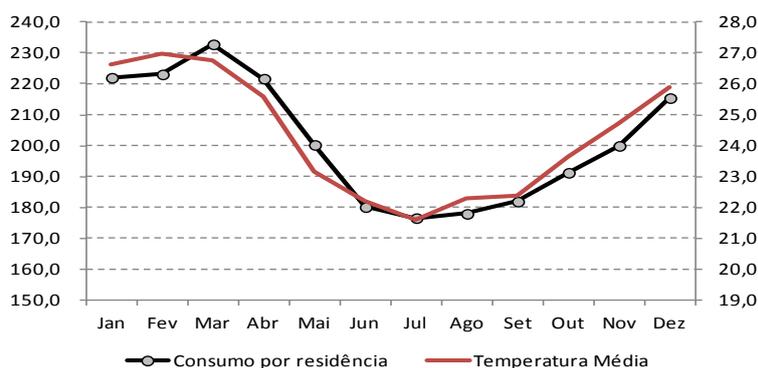
Fonte: Elaboração própria a partir de INMET (2012).

Notadamente, mesmo nos meses de inverno (de junho a agosto), as temperaturas médias não são típicas de uso de energia para aquecimento de ambientes (embora, seja possível supor um aumento do uso de chuveiro elétrico). Sobre este aspecto é razoável supor que aumentos de temperatura tendam a aumentar o consumo de eletricidade para fins de refrigeração dos ambientes residenciais, ao passo que as temperaturas mais baixas não têm o efeito de aumento do consumo verificado em regiões de inverno mais intenso.

Os dados de temperatura que serão utilizados de agora em diante foram extraídos de WUNDERGROUND (2012) e são relativos a medições para o período compreendido entre 2002 e 2010 no Aeroporto Santos Dummont, localizado na área central da cidade.

Para relacionar os efeitos da temperatura sobre o consumo residencial de energia elétrica, o presente estudo adotará a medida de consumo residencial por unidade consumidora definida como o total consumido pelas residências (em KWh) dividido pelo número total de consumidores residenciais no mesmo período.

É importante aqui notar que a medida utilizada não é o consumo residencial, mas, sim, o consumo total das residências dividido pelo número de consumidores. Esta medida se torna mais adequada, pois expurga o efeito de aumento do número de consumidores sobre o crescimento do consumo.



**Figura 5: Consumo de energia elétrica por residência e temperatura média**

Fonte: Elaboração própria a partir de LIGHT (2011) e WUNDERGROUND (2012).

Assim, de acordo com dados da concessionária de energia elétrica LIGHT (2011), publicados pela prefeitura do município do Rio de Janeiro, foi calculado o consumo médio por residência por mês para o período compreendido entre 2002 e 2010. O consumo médio por residência no Rio de Janeiro foi de 202 KWh/mês, variando entre 177 KWh/mês em julho e 233 KWh/mês em março.

Como é possível visualizar na Figura 5, a temperatura e o consumo por consumidor residencial na cidade do Rio de Janeiro apresentam, de fato, comportamento semelhante, o que sugere uma relação de causalidade entre elas.

## 6. Análise de Dados

A partir do levantamento de dados de temperatura média e consumo residencial de energia na cidade do Rio de Janeiro, o objetivo do presente artigo é estimar a relação entre essas duas variáveis. Para melhor compreensão da relação entre as duas variáveis, resumem-se na Tabela 1 os valores médios mensais para a amostra observada que compreende o período entre os anos de 2002 e 2010 na cidade do Rio de Janeiro. Notadamente a temperatura é mais elevada nos meses de verão e no início de outono (mês de abril), período no qual se observa também um maior consumo de energia elétrica nas residências.

**Tabela 1: Valores médios de temperatura e consumo residencial de energia elétrica no Rio de Janeiro (2002-2010)**

Mês	Valores médios observados	
	Temp. (°C)	CCR (KWh/mês)
Janeiro	26,6	222,0
Fevereiro	27,0	223,1
Março	26,8	232,8
Abril	25,6	221,7
Mai	23,1	200,2
Junho	22,2	180,1
Julho	21,6	176,6
Agosto	22,3	177,9
Setembro	22,4	181,9
Outubro	23,6	191,2
Novembro	24,7	199,9
Dezembro	25,9	215,4

Fonte: Elaboração própria a partir de LIGHT (2011) e WUNDERGROUND (2012).

O primeiro passo do estudo foi dessazonalizar os dados utilizando o método X11, tanto para as séries de temperatura quanto para o consumo médio por residência. A identificação do componente sazonal é importante, pois possibilita a linearização do modelo. Assim, é possível estimar a relação linear entre as variáveis através de uma regressão linear simples relacionando as diferenças entre os dados observados e os mesmos dessazonalizados.

Além disso, dada a imprecisão do modelo, cuja inclinação pode variar em uma cidade que possui diferentes regiões, optou-se pela utilização da regressão *fuzzy*.

Outra vantagem da utilização dessa técnica é que muitas vezes o interesse maior está, não na simples determinação da relação entre variáveis, mas sim na obtenção de predições sobre picos ou baixos consumos. A regressão *fuzzy* ao substituir valores exatos para os parâmetros por uma distribuição de probabilidades, permite realizar essas predições empregando os limites superiores e inferiores para as estimativas dos coeficientes da relação entre variáveis.

No que segue, denotam-se, para cada mês ( $m$ ) de cada ano ( $a$ ) do horizonte analisado, por  $X_m^a$  e  $Y_m^a$  as variáveis independente e dependente, respectivamente, a serem consideradas no modelo de regressão linear:

$$X_m^a = \mu_{(TEMP)_m}^a - \mu_{(TEMP\ des)_m}^a \quad (10)$$

$$Y_m^a = \mu_{(CCR)_m}^a - \mu_{(CCR\ des)_m}^a \quad (11)$$

onde  $\mu_{(TEMP)_m}^a$  é a média das temperaturas diárias do período em questão e  $\mu_{(TEMP\ des)_m}^a$  o equivalente dessazonalizado, enquanto  $\mu_{(CCR)_m}^a$  é a média mensal do consumo residencial no Rio de Janeiro e  $\mu_{(CCR\ des)_m}^a$  o seu equivalente dessazonalizado. Considerando que o período analisado é o compreendido entre janeiro de 2002 e dezembro de 2010, para cada mês têm-se nove observações.

O próximo passo foi separar e agrupar essas variáveis por mês, para definir os limites inferiores e superiores a serem utilizados para a caracterização dos números *fuzzy* a serem usados na regressão. Definiu-se a seguinte formulação para definição dos limites superiores e inferiores a serem utilizados:

$$LS(X)_m^a = X_m^a + [Max(X_m) - Md(X_m)] \quad (12)$$

$$LI(X)_m^a = X_m^a - [Md(X_m) - Min(X_m)] \quad (13)$$

onde, para cada mês fixo  $m$ ,  $LS(X)_m^a$  representa o limite superior do ano  $a$  para o mês  $m$ ,  $LI(X)_m^a$  representa o limite inferior para o ano  $a$  no mês  $m$ ,  $Max(X_m)$  é o valor máximo da variável  $X$  no mês  $m$  em toda a amostra analisada,  $Md(X_m)$  é a mediana dos valores de  $X$  no mês  $m$  na amostra e  $Min(X_m)$ , o valor mínimo da variável  $X$  no mês  $m$  em toda a amostra analisada. Analogamente, para as variáveis dependentes  $Y$  temos:

$$LS(Y)_m^a = Y_m^a + [Max(Y_m) - Md(Y_m)] \quad (14)$$

$$LI(Y)_m^a = Y_m^a - [Md(Y_m) - Min(Y_m)] \quad (15)$$

Assim, tem-se para cada observação uma distribuição triangular com moda nos valores dados, respectivamente, pelas equações 10 e 11, limite superior nos valores dados pelas equações 12 e 14 e limite inferior nos valores dados pelas equações 13 e 15. A partir dessas distribuições se estimam os coeficientes da regressão *fuzzy*. O resultado do ajustamento do modelo pela minimização do erro definido na Equação 9 é a seguinte reta de regressão:

$$\widehat{Y}_m^a = -0,11 + 9,85.X_m^a \quad (16)$$

Para simples comparação, cabe registrar que o ajustamento por mínimos quadrados ordinários conduziria a um coeficiente angular de 9,94 com um  $R^2$  de 89%.

Combinando o resultado do ajustamento do modelo de regressão *fuzzy* com as predições para as variações nas temperaturas em relação à média anual, é possível estabelecer as predições

para os extremos no consumo das residências. A Tabela 2 apresenta um sumário dos resultados deste desenvolvimento.

A análise da Tabela 2 permite algumas observações importantes sobre a relação entre temperatura e consumo por residência. Por exemplo, pode-se depreender que os meses de janeiro apresentam temperaturas entre 1,99 e 2,72 °C superiores à média anual o que acarreta aumento entre 19,50 KWh/mês e 26,64 KWh/mês do consumo por lar carioca.

**Tabela 2: Influência da variação da temperatura sobre o consumo residencial**

Mês	Limite inferior		Valores Médios		Limite Superior	
	Temp. (°C)	CCR (KWh/mês)	Temp. (°C)	CCR (KWh/mês)	Temp. (°C)	CCR (KWh/mês)
Janeiro	1,99	19,50	2,34	22,95	2,72	26,64
Fevereiro	1,73	16,94	2,51	24,60	3,12	30,57
Março	2,35	23,01	2,47	24,19	2,58	25,29
Abril	0,65	6,27	1,28	12,46	1,64	16,09
Maio	-1,40	-13,92	-1,19	-11,85	-1,05	-10,44
Junho	-2,57	-25,38	-2,04	-20,20	-1,78	-17,69
Julho	-3,00	-29,66	-2,65	-26,18	-2,25	-22,31
Agosto	-2,06	-20,40	-1,85	-18,28	-1,68	-16,69
Setembro	-2,35	-23,30	-2,00	-19,82	-1,54	-15,28
Outubro	-1,12	-11,17	-0,77	-7,65	-0,43	-4,36
Novembro	-0,09	-1,04	0,10	0,91	0,70	6,79
Dezembro	1,66	16,23	1,69	16,55	1,93	18,91

Fonte: Elaboração própria.

Interessante é notar que a variação de 1°C na temperatura para mais aumenta o consumo de uma residência em aproximadamente 10 kWh/mês por ano. Para compreender melhor o que isto representaria em termos de necessidade incremental de energia na cidade do Rio de Janeiro, tomou-se 2010 como o ano base, ou seja, utilizou-se o número de consumidores ( $NCR_{2010}$ ) e o consumo residencial deste ano ( $CR_{2010}$ ).

A partir desses dados estabeleceu-se um valor para o consumo médio por consumidor residencial inicial ( $CCR_{ini}$ ) que quando adicionado aos incrementos de consumo para cada mês por consumidor residencial ( $\Delta CCR_m$ ) e multiplicado pelo número total de consumidores residenciais totaliza o total consumido em 2010 pelas residências cariocas. Algebricamente tem-se:

$$CCR_m = CCR_{ini} + \Delta CCR_m \quad (17)$$

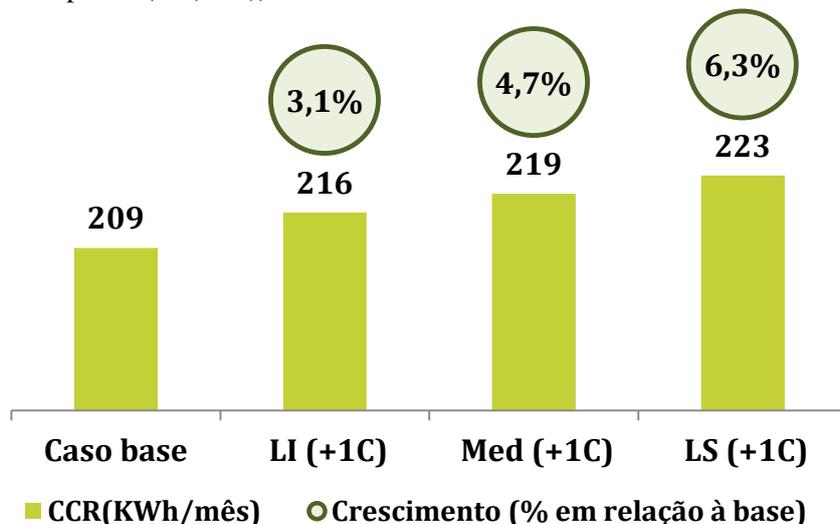
onde  $\Delta CCR_m$  é a média para o mês  $m$  da variação de CCR esperada dada a variação na temperatura esperada, em outras palavras é o resultado da predição pela regressão *fuzzy*. Assim tem-se o consumo residencial total:

$$CR_{2010} = \sum_{m=1}^{12} CCR_m \times NCR_m \quad (18)$$

A seguir simula-se o efeito que uma variação do aumento de um grau Celsius na temperatura em todos os meses do ano traria para o consumo total naquele ano.

Em 2010, o consumo residencial no município do Rio de Janeiro totalizou 5.988.844 MWh e a partir do modelo encontrado estima-se que o aumento de 1°C poderia aumentar o consumo residencial da cidade em valores entre 3,1% e 6,3%, com um valor médio de 4,7%. Assim, o consumo médio mensal ao longo do ano pode chegar a ser 14 kWh/mês maior do que o cenário base, totalizando 223 kWh/mês. A Figura 6 ilustra o consumo médio mensal por

residência e para o cenário base, o limite inferior (LI (+1C)) de impacto, o impacto médio (Med (+1C)) e o limite superior (LS(+1C)).



**Figura 6: Impacto do aumento de 1°C sobre o consumo residencial**

Fonte: Elaboração própria.

Observa-se que o crescimento médio desta magnitude aumentaria o consumo da cidade em 281.807 Mwh/ano. Isso equivaleria ao acréscimo de 112 mil residências com perfil de consumo equivalente ao dos cariocas (consumo médio anual de 209 kWh/mês). Destaca-se ainda que o aumento de 4,7% é maior que o crescimento médio anual do consumo residencial entre 2002 e 2010, que foi de 3,4%.

Em IPCC(2007) estimou-se que até 2100 as temperaturas médias sejam entre 1,8°C e 4°C maiores do que as atuais, o que acarretaria impacto de crescimento do consumo entre 6,8% e impressionantes 20,4% por residência carioca de acordo com o aqui estimado. No entanto, em se tratando de tão longo prazo a relação passa a ser muito menos precisa, pois é provável que ações visando ao aumento da eficiência energética de edificações e aparelhos possam vir a reduzir a necessidade de energia por residência.

Verifica-se, assim, que a relação entre temperatura e consumo residencial de energia é de significativa importância para o mercado de energia elétrica. Caso se concretizem os cenários mais pessimistas de elevação da temperatura média nos próximos anos, o consumo residencial de energia em mercados localizados em regiões como o Rio de Janeiro deverão aumentar consideravelmente seu consumo de energia para fins de conforto térmico e as empresas do setor deverão estar preparadas para tal situação.

## 7. Conclusão

A relação entre temperatura e consumo de energia elétrica é largamente estudada na literatura. A temática tende a aumentar de importância dadas as crescentes preocupações acerca do impacto das ações antropogênicas sobre a natureza que pode resultar em aumento das temperaturas médias pelo globo terrestre.

Caso realmente se comprove tal cenário, é razoável supor que o consumo de energia elétrica nas residências para fim de refrigeração e ventilação aumente. Partindo desta premissa o presente estudo calculou a relação entre consumo residencial de energia elétrica e variações de temperatura na cidade do Rio de Janeiro.

Além disso, estimou-se o impacto que a elevação de temperatura pode exercer sobre o consumo médio das residências cariocas. A expansão calculada com o emprego da regressão *fuzzy* é que o consumo pode ser majorado em 4,7% no ano em resposta ao aumento de 1 °C na

temperatura. A magnitude de tal número é significativa, pois representa valor superior ao crescimento médio anual entre 2002 e 2010 do mercado residencial da cidade.

Assim, é razoável supor que as distribuidoras de energia elétrica passem de alguma forma a incorporar esse tipo de informação em seu planejamento de mercado, pois, em última instância, a concretização de tal cenário pode exigir maiores compras de energia e investimentos na rede para suportar picos de consumo devidos a variações na temperatura.

Por outro lado, esta constatação pode ainda funcionar como um estímulo à eficiência energética. Reduções de consumo devem ser buscadas, seja pelo uso de aparelhos associados ao condicionamento de ambientes mais eficientes, seja pelo desenvolvimento de novos padrões de residências mais adaptadas à nova realidade.

## Referências

- Al-Zayer, J. e Al-Ibrahim, A.** (1997), Modelling the impact of temperature on electricity consumption in the eastern province of Saudi Arabia, *Journal of Forecasting*, 15, 97-106.
- Bargiela, A., Pedrycz, W. e Nakashima, T.** (2007), Multiple regression with fuzzy data, *Fuzzy Sets and Systems*, 158, 2169 – 2188.
- Cao, H. e Chen, G.** (1983), Some applications of fuzzy sets to meteorological forecasting, *Fuzzy Sets and Systems*, 9, 1-12.
- Diamond, P.** (1988), Fuzzy least squares, *Information Sciences*, 46, 141–157.
- EPE.** (2012) *Resenha Mensal do Mercado de Energia Elétrica*, disponível em: <[http://www.epe.gov.br/ResenhaMensal/20120127\\_1.pdf](http://www.epe.gov.br/ResenhaMensal/20120127_1.pdf)>. Acesso em: agosto de 2012.
- Fung, W. Y., Lam, K. S., Hung, W. T., Pang, S. W. e Lee, Y. L.** (2006), Impact of urban temperature on energy consumption of Hong Kong, *Energy*, 31, 14, 2623–2637.
- Henley, A. e Peirson, J.** (1997), Non-linearities in electricity demand and temperature: parametric versus non-parametric methods, *Oxford Bulletin of Economics & Statistics*, 59, 149-162.
- Henderson, R.** (1916), Note on Graduation by Adjusted Average, *Transactions of the American Society of Actuaries*, 17, 43-48.
- INMET (2012)**, Gráficos das Normais Climatológicas, in: *Gráficos Climatológicos*, disponível em: <<http://www.inmet.gov.br/html/clima/graficos/>>. Acesso em: agosto de 2012.
- IPCC (2007)**, Climate Change 2007 Synthesis Report. *Contribution of Working Groups I, II and III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, 104 p.
- IPCC.** (2012), Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation. Cambridge University Press, 582 p.
- IEA (2011)**, Electricity/Heat in World in 2009, in: *Statistics & Balances*, 2011. Disponível em: <[http://www.iea.org/stats/electricitydata.asp?COUNTRY\\_CODE=29](http://www.iea.org/stats/electricitydata.asp?COUNTRY_CODE=29)>. Acesso em: agosto de 2012.
- Kucukali, S. e Baris, K.** (2010), Turkey's short-term gross annual electricity demand forecast by fuzzy logic approach, *Energy Policy*, 38, 2438–2445.
- Le Conte, D. e Warren, H.** (1981), Modeling the impact of summer temperatures on National Electricity Consumption, *Journal of Applied Meteorology*, 20, 1415-1419.
- LIGHT (2011)**, *Armazém dos dados*, Prefeitura do Rio de Janeiro, Rio de Janeiro, disponível em <<http://portalgeo.rio.rj.gov.br/indice/flanali.asp?codpal=884&pal=ENERGIA%20EL%C9TRICA>> Acesso em agosto de 2012.
- Mamlook, R., Badran, O. e Abdulhadi, E.** (2009), A fuzzy inference model for short-term load forecasting, *Energy Policy*, 37, 1239–1248.
- Moral-Carcedo e J. Vicéns-Otero, J.** (2005), Modelling the non-linear response of Spanish electricity demand to temperature variations, *Energy Economics*, 27, 477– 494.
- Morettin, P. A. e Tolói, C. M. C.** *Análise de séries temporais*. E. Blücher, São Paulo, (2006).
- Pezzulli, S., Stephenson, D. B. e Hannachi, A.** (2005), The Variability of Seasonality. *Journal of Climate*, 18, 71–88.

**Shiskin, J., Young, A. H. e Musgrave, J. C.** *The X-11 variant of the Census Method II seasonal adjustment program*. Technical Paper 15, U.S. Bureau of the Census, 1967. Disponível em :<<https://www.census.gov/ts/papers/ShiskinYoungMusgrave1967.pdf> >

**Valor, E., Meneu, V. e Caselles, V.** (2001), Daily Air Temperature and Electricity Load in Spain. *Journal of Applied Meteorology*. 40, 1413-1421.

**WUNDERGROUND** (2012). *Weather History*. Michigan (United States) disponível em: <<http://www.wunderground.com/history/airport/SBRJ/> >. Acesso em agosto de 2012.

**Zadeh, L. A.** (1965), Fuzzy sets. *Information and control*, 8, 338-353.