



UMA COMPARAÇÃO DE TÉCNICAS DE REGRESSÃO PARA A PREVISÃO DE CONSUMO DE ENERGIA RESIDENCIAL NO CENÁRIO NACIONAL

Leonardo Pio Vasconcelos, José Viterbo Filho

Instituto de Computação – Universidade Federal Fluminense
Campus Praia Vermelha, Niterói, RJ - Brasil
{lvasconcelos,viterbo}@ic.uff.br

Igor Machado Coelho

Instituto de Matemática e Estatística – Universidade do Estado do Rio de Janeiro
Campus Maracanã, Rio de Janeiro, RJ - Brasil
igor.machado@ime.uerj.br

João Marcos Meirelles da Silva

Escola de Engenharia – Universidade Federal Fluminense
Campus Praia Vermelha, Niterói, RJ - Brasil
jmarcos@vm.uff.br

RESUMO

O aumento do consumo de energia vem despertando a atenção de governos e da comunidade acadêmica. É de suma importância para uma nação ter a possibilidade de saber se terá ou não a capacidade de fornecer continuamente energia com qualidade. Na literatura, várias técnicas de regressão vêm sendo abordadas com o objetivo de prever o consumo de energia com qualidade. Dentre estas, destacam-se o SVR, as redes neurais perceptron multicamadas e a regressão linear. Esse trabalho tem o objetivo de avaliar essas técnicas na previsão do consumo de energia residencial no Brasil. Foi realizado um estudo de caso utilizando três abordagens: uma somente com dados de consumo, outra com dados de consumo e o PIB e a última com dados de consumo juntamente com o PIB e a população. Os resultados de nossas abordagens foram superiores à um dos modelos mais recentes na literatura.

**PALAVRAS CHAVE. Previsão de Consumo de Energia; Regressão; Cenário Nacional.
Tópicos (SS1 - Sessão Especial 1 - Pesquisa Operacional & Cidades Inteligentes)**

ABSTRACT

The increase in energy consumption has been attractin the attention of governments and the academic community. It is of utmost importance for a nation to have the possibility of knowing whether or not it will have the capacity to continuously provide energy with quality. In literature, several regression techniques are being approached in order to predict energy consumption with quality. Among these, we call the attention to the SVR, the multilayer perceptron neural networks and the linear regression stand out. This work has the objective of evaluating these techniques in the prediction of consumption of residential energy in Brazil. A case study was carried out using three approaches: one only with consumption data, another with consumption data and GDP and the last with consumption data together with GDP and population. The results of our approaches were superior to one of the most recent models in literature.

**KEYWORDS. Energy Consumption Forecast; Regression; National Scenario.
Paper topics (SS1 - Special Session 1 - Operational Research & Smart Cities)**



1. Introdução

A população mundial vem se elevando em grande escala. Houve um salto de 3 bilhões de pessoas em 1960 para 7 bilhões em 2015 [CIA, 2016]. Esse resultado reflete diretamente no consumo de energia elétrica. Nos setores públicos, residenciais e agrícola de 1971 a 2012 o consumo se elevou de 4,65 a 18,6 bilhões de GWh [IEA, 2015], o que mostra claramente que o consumo de energia mundial aumentou muito mais que a população [Pérez-Lombard et al., 2008]. No Brasil, esse crescimento seguiu a mesma proporção. Segundo o IBGE, a população se elevou de aproximadamente 157 a 206 milhões no período de 1996 a 2016 [IBGE, 2017]. E o consumo de energia elétrica, conforme dados da Eletrobras - Centrais Elétricas Brasileiras S.A. aumentou de 20 mil GWh a 38 mil GWh no período de 1996 à 2016 [Eletrobras, 2017]. Como no mundo inteiro, tanto no campo econômico, quanto no campo político o setor elétrico está se modificando. Esse fator, dá-se à desregulamentação do setor elétrico e à privatização. No Brasil por exemplo, essa reforma teve início em 1995 com a publicação da Lei de concessão em 1995 [Campos, 2008].

As usinas hidrelétricas são as que mais produzem energia no Brasil, ainda assim o país têm enfrentado grandes problemas relacionados à energia. Para se construir uma hidrelétrica, gera-se um impacto sócio-ambiental muito grande como: destruição da fauna e flora ao criar as represas com grandes áreas de alagamento e desapropriação de zonas rurais ou urbanas [Tidre et al., 2013]. Diante deste cenário, técnicas para a previsão do consumo de energia de forma acurada se apresenta com grande utilidade, pois estes dados podem ser aplicados para tomadas de decisões e um bom planejamento direcionados ao provimento ininterrupto e confiável de energia [Bianco et al., 2010]. Em países desenvolvidos e em desenvolvimento, a previsão de consumo de energia tem grande relevância para os seus governos, pois uma previsão abaixo do consumo real acarretaria eventuais interrupções de energia e a elevação dos custos de operação dos fornecedores de energia e esses custos seriam repassados ao consumidor. Em contrapartida, uma previsão acima do consumo real poderia resultar em uma capacidade ociosa possibilitando desperdícios de recursos financeiros desnecessariamente [Kaytez et al., 2015].

A previsão do consumo de eletricidade a longo prazo desempenha um papel importante para os governos nos países em desenvolvimento, pois ela é a base para o planejamento do investimento no setor energético [Kaytez et al., 2015]. Além de serem muito importantes para sustentar a industrialização, a demanda crescente de energia elétrica e políticas de energia estáveis a longo prazo. Uma previsão de qualidade é importante para planejar ferramentas que irão abastecer os consumidores quando necessário, tendo em vista que é impossível armazenar a corrente alternada [Hamzacebi e Es, 2014]. De acordo com [Todesco et al., 2004], uma das principais metas de uma concessionária de energia é oferecer um serviço de qualidade, com um preço justo através de um gerenciamento eficiente de distribuição de energia. Na Turquia por exemplo, as estimativas de consumo oficiais são superiores aos valores de consumo e por causa disso os resultados são revisados a cada 6 meses pelos órgãos oficiais do governo [Kaytez et al., 2015]. Com o objetivo de melhorar casos como esses, as redes de distribuição devem fazer o máximo possível para alocar de forma otimizada seus investimentos e recursos operacionais. Logo, as concessionárias buscam constantemente o aperfeiçoamento e otimização da distribuição de energia. Ainda vale destacar que em alguns países como o Brasil, por exemplo, parte dos consumidores não tem um consumo de energia consciente, desperdiçando energia com a utilização de aparelhos elétricos sem se preocupar com as consequências. Por isso é interessante orientar a população com o objetivo de aumentar a conservação de energia elétrica [Tidre et al., 2013].

No futuro, as usinas hidrelétricas e vários fornecedores de energia alternativa estarão conectados entre si e com os consumidores de energia nos modernos núcleos urbanos e, por meio de medidores inteligentes, será possível que estas partes interajam em tempo real, o que permitirá a compra e venda de energia de acordo com a demanda de consumo individual [Karnouskos e De Holanda, 2009]. Por isso a extração e análise de dados de consumo elétrico é um passo inevitável para tornar uma cidade inteligente [Pan et al., 2013]. Por definição, uma cidade pode ser consi-



derada inteligente quando há investimentos em pessoas, capital social, uma infraestrutura moderna com sistemas embarcados, medidores inteligentes, sensores, atuadores, gerenciamento de dados em tempo real, crescimento econômico sustentável, alta qualidade de vida com uma administração sábia de recursos naturais, por meio de um governo participativo [Schaffers et al., 2011].

Existem diversas técnicas que são usualmente empregadas para a previsão do consumo de energia, dentre estas, as técnicas de regressão vem se apresentando como uma das mais utilizadas na previsão do consumo de eletricidade [Kaytez et al., 2015]. Regressão é uma metodologia que possibilita obter uma relação funcional entre variáveis dependentes e variáveis independentes [Fumo e Biswas, 2015]. Em outras palavras, a regressão de uma forma geral é calcular valores por meio de uma função obtendo uma resposta (no nosso caso uma predição) através de variáveis predictoras. As técnicas de regressão mais conhecidas são: regressão linear [Bianco et al., 2009], redes neurais [Günay, 2016] e máquina de vetores de regressão [Kaytez et al., 2015], do inglês *Support Vector Regression* – SVR.

Nos trabalhos apresentados na literatura, diversas metodologias são encontradas, com o objetivo de resolver problemas específicos de determinados países ou regiões [Hamzacebi e Es, 2014], [Kaytez et al., 2015], [Torrini et al., 2016]. São usualmente empregadas técnicas clássicas como máquina de vetores de suporte para regressão, redes neurais e regressão linear, mas também técnicas emergentes de otimização e lógica nebulosa, como *particle swarm optimization* [Askarzadeh, 2014], *gray model* [Hamzacebi e Es, 2014], *lógica fuzzy* [Torrini et al., 2016], estratégias evolutivas com modelo fuzzy [Coelho et al., 2016], [Coelho et al., 2017] entre outras. Entretanto, para se obter um modelo com uma boa acurácia, alguns pontos devem ser analisados [Kaytez et al., 2015]. Em primeiro lugar, devem ser bem definidos os parâmetros que afetam o consumo de eletricidade. Em segundo lugar, deve ser escolhida uma metodologia adequada para gerar o modelo. E, em terceiro lugar, o modelo gerado deve propiciar extensões para futuras melhorias em seu desempenho.

Esse artigo tem o objetivo avaliar técnicas de previsão do consumo de energia para o cenário nacional. São utilizados dados de consumo residencial, do PIB e da População do Brasil. Foram consideradas técnicas de SVR, redes neurais perceptron multicamadas (do inglês *multilayer perceptron* – MLP) e regressão linear - R.L, que são os algoritmos amplamente aplicados em problemas de previsão e regressão [Dong et al., 2005], [Kaytez et al., 2015]. Comparamos os resultados da previsão com os dados apresentados em [Torrini, 2014] que é um dos trabalhos mais recentes na literatura à realizar previsão de consumo de energia residencial. Este trabalho é organizado em seis seções, incluindo esta introdução. Na próxima seção, apresentamos os métodos de regressão adotados no estudo de caso. Na Seção 3 discutimos os parâmetros envolvidos nos modelos de previsão e regressão. Na Seção 4, descrevemos a previsão do consumo de energia no mundo e depois apresentamos o que vem sendo desenvolvido no Brasil. Na Seção 5 abordamos o estudo de caso e faremos uma discussão dos resultados. Finalmente, na Seção 6 apresentamos nossas conclusões.

2. Métodos de Regressão

Regressão é uma metodologia que possibilita obter uma relação funcional entre variáveis dependentes e variáveis independentes. Em outras palavras, a regressão consiste em calcular valores por meio de uma função obtendo uma resposta (no nosso caso uma predição) através de variáveis predictoras. Em sistemas complexos como o consumo de energia, a regressão pode ser observada como um processo iterativo, ou seja, onde sua saída é utilizada para identificar, validar, criticar e supostamente modificar suas entradas [Fumo e Biswas, 2015]. Nas próximas seções iremos apresentar uma análise mais detalhada sobre regressão linear, redes neurais perceptron multicamadas e máquina de vetores de suporte para regressão, que são os métodos utilizados em nosso estudo de caso.



2.1. Regressão Linear

2.1.1. Regressão Linear Simples

A regressão linear simples é um modelo que possui uma única variável independente x que tem uma relação com a variável dependente y . A equação para obtê-la é dada por [Montgomery et al., 2015], [Fumo e Biswas, 2015]:

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (1)$$

Onde β_0 e $\beta_1 x$ são os coeficientes de regressão estimados e ε é um erro que conta a discrepância entre o valor predito na Equação (1) e o valor observado. O valor predito na Equação (1) é dado por:

$$\bar{y} = \bar{\beta}_0 + \bar{\beta}_1 x \quad (2)$$

Onde \bar{y} é o valor predito, e $\bar{\beta}_0$ e $\bar{\beta}_1$ são os coeficientes de regressão estimados.

2.1.2. Regressão Linear Múltipla

A regressão linear múltipla é a generalização da regressão linear simples, permitindo mais de uma variável independente [Fumo e Biswas, 2015]. Segue abaixo a equação para obtê-la.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 \dots + \beta_p x_p + \varepsilon \quad (3)$$

Onde y é a variável de resposta, $x_1, x_2, x_3, \dots, x_p$ são as variáveis independentes sendo p o número de variáveis, $\beta_0 + \beta_1 + \beta_2 + \beta_3 + \dots + \beta_p$ são os coeficientes de regressão e ε é um erro que conta a discrepância entre o valor predito na Equação (1) e o valor observado. O valor predito na Equação (3) é:

$$\bar{y} = \bar{\beta}_0 + \bar{\beta}_1 x_1 + \bar{\beta}_2 x_2 + \bar{\beta}_3 x_3 \dots + \bar{\beta}_p x_p \quad (4)$$

Onde \bar{y} é o valor predito, e $\bar{\beta}_0, \bar{\beta}_1, \bar{\beta}_2, \bar{\beta}_3 \dots \bar{\beta}_p$ são os coeficientes de regressão estimados.

2.2. Redes Neurais Perceptron Multicamadas

As redes neurais artificiais foram desenvolvidas com o objetivo de criar um modelo científico computacional de aprendizado similar ao cérebro humano. Elas são capazes de aprender os principais padrões de informação dentro de um domínio de informação multidimensional. Para o seu funcionamento não é necessário haver uma informação detalhada sobre o sistema, pois ela funciona como um modelo caixa preta. Ela aprende a relação entre os parâmetros de entrada e as variáveis controladas e não controladas através do estudo dos dados previamente registrados [Kalogirou et al., 1997], [Olofsson et al., 1998]. De acordo com [Ahmad et al., 2014], as redes neurais possuem a vantagem de poder executar tarefas que um programa linear não pode e a desvantagem de ter um tempo de processamento elevado quando a rede neural é grande.

As redes neurais perceptron multicamadas (MLP) são constituídas de neurônios que interagem entre si utilizando conexões ponderadas [Pal e Mitra, 1992]. Elas obtiveram bons resultados em diversos problemas dentre estes, alguns considerados difíceis [Haykin, 2001]. Basicamente uma rede MLP é composta por uma camada de entrada, que consiste em um conjunto de unidades sensoriais (nós de fonte), uma ou mais camada(s) escondida(s) e uma camada de saída, sendo que as duas últimas camadas possuem capacidade computacional. O sinal de entrada propaga-se de camada em camada sempre para frente. A camada de entrada é onde reside os dados de entrada e é composta por unidades sensoriais. Sua função é encaminhar os dados à primeira camada oculta. A(s) camada(s) oculta(s) tem a função de receber os dados da camada de entrada, processá-los e encaminhá-los à camada de saída. A camada de saída tem a função de fornecer a resposta propagada pela camada oculta.



2.3. SVR

O algoritmo máquina de vetores de suporte para regressão (SVR) é um algoritmo de aprendizado de máquina supervisionado que tem como objetivo encontrar um modelo de decisão para representar a relação entre os atributos e o seu objetivo. Ele se baseia no princípio indutivo da minimização do risco estrutural, que procura minimizar um limite superior da generalização do erro que consiste na soma do erro de treinamento e um nível de confiança. Esse princípio faz com que muitos problemas no aprendizado de máquina tenham melhores desempenhos de generalização com o SVR do que com outras técnicas. O treinamento do SVR é equivalente a resolver um problema restrito de programação quadrática de forma linear de modo que a solução do algoritmo é sempre globalmente ótima e única, o que evita o risco de mínimos locais. A solução para o problema no SVR é dependente apenas de um subconjunto de pontos de dados de treinamento, chamados de vetores de suporte. A complexidade de tempo de treinamento em qualquer parte do SVR é quadrática ou cúbica em relação ao número de amostras de treinamento, uma das poucas desvantagens desse algoritmo. De acordo com a literatura, o SVR tem se mostrado um algoritmo muito eficiente para resolver problemas gerais de regressão [Dong et al., 2005], [Li et al., 2009], [Zhao e Magoulès, 2010].

Basicamente o objetivo do SVR consiste em encontrar uma função que aproxime da melhor maneira possível os pontos de treinamento com a meta de minimizar o erro de previsão [Üstün et al., 2005], [Dong et al., 2005], [Witten et al., 2016]. Dois parâmetros são especificados pelo usuário o ε e o C e a calibração deles é peça fundamental para a qualidade da previsão. O ε define um tubo em torno da função de regressão que controla o grau de aproximação da função aos dados de treinamento. E C é a constante de regularização, ela determina o limite superior de *tradeoff* entre o erro de previsão e o nivelamento do tubo ε .

3. Parâmetros de Avaliação

O critério utilizado em nosso estudo de caso para comparar o desempenho dos modelos é o Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error* - MAPE) ele foi escolhido por calcular através de uma comparação de cada resultado do erro relativo da previsão com o valor real da variável [Wang et al., 2009]. Uma previsão é considerada bem sucedida quando o seu MAPE é inferior a 10% [Hamzacebi e Es, 2014]. Ele é calculado da seguinte maneira:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - y_t^*}{y_t} \right|$$

Onde: y_t = Valor real e

y_t^* = Valor previsto

n = número de pontos analisados

4. Previsão do Consumo de Energia

O crescente consumo de energia tem mundialmente despertado preocupações referentes ao esgotamento dos recursos energéticos, aos pesados impactos ambientais na produção de energia e às dificuldades de abastecimento [Pérez-Lombard et al., 2008]. Encontrar o melhor caminho para fornecer energia, sem afetar a economia global e poluindo o mínimo possível é um problema urgente à todos os países [Hua et al., 2016]. Diante deste cenário, técnicas para a previsão do consumo de energia de forma acurada se apresentam com grande utilidade, pois estes dados podem ser aplicados para tomadas de decisão e um bom planejamento direcionados ao provimento ininterrupto e confiável de energia [Bianco et al., 2010]. Em países desenvolvidos e em desenvolvimento, a previsão de consumo de energia tem grande relevância ao governo, pois uma previsão abaixo do consumo real possibilitaria potenciais interrupções de energia e elevar os custos de operação ao fornecedor. Em contrapartida, uma previsão acima do consumo real poderia resultar em uma capacidade ociosa possibilitando desperdícios de recursos financeiros desnecessariamente. Logo, um modelo de previsão com uma boa precisão é fundamental para evitar erros caros [Kaytez et al., 2015]. Para realizar um



planejamento que seja ótimo, os formuladores de políticas energéticas se focam em modelagem e previsão de projeções que possuem qualidade e minimizam os problemas [Tutun et al., 2015].

A previsão do consumo de eletricidade a longo prazo desempenha um papel importante para os governos nos países em desenvolvimento, pois ela é a base para o planejamento do investimento no setor energético [Kaytez et al., 2015]. Além de serem muito importantes para sustentar a industrialização, a demanda crescente de energia elétrica necessita de políticas de energia estáveis a longo prazo. Uma previsão de qualidade é importante para planejar ferramentas que irão abastecer os consumidores quando necessário, tendo em vista que é impossível armazenar a corrente alternada [Hamzacebi e Es, 2014]. A previsão do consumo de energia é também muito útil para planejadores e gestores de energia [Bianco et al., 2010]. Através do conhecimento das elasticidades do preço e da renda as empresas concessionárias de energia podem criar políticas de demanda conveniente e assim auxiliar os formuladores de projetos a desenvolver propostas para reformar o setor de eletricidade. Tendo em vista que a previsão da demanda é importante para os potenciais investidores no setor elétrico e para as empresas envolvidas no negócio de eletricidade que precisam planejar suas estratégias futuras.

[Hamzacebi e Es, 2014] utilizaram um algoritmo que realiza previsões com dados incompletos e poucas informações denominado Gray Model Otimizado (OGM). Ele foi aplicado para efetuar a previsão do consumo de energia na Turquia nos anos de 2011 a 2025. Foram utilizadas duas abordagens OGM direto e OGM iterativo. O OGM direto utiliza somente os dados da base para realizar a previsão. A abordagem iterativa utiliza os dados da base mas suas próprias previsões para obter um resultado. A base de dados contém o consumo de energia no período de 1945 à 2010. Os anos de 1945 à 2005 foram utilizados para treinamento e os anos de 2006 à 2010 para teste. Os resultados do MAPE do OGM direto (3,28%) foram superiores aos do OGM iterativo (5,36%) e também dos apresentados na literatura (3,43% e 4,6%). [Kaytez et al., 2015] afirmaram que a técnica least squares support vector machines (LS-SVM) não havia sido aplicada na previsão do consumo de energia, baseando-se nisso ele apresentou o LS-SVM para a previsão do consumo e comparou os dados com os algoritmos de análise de regressão linear múltipla e redes neurais. Os algoritmos tiveram como entrada uma base de dados da Turquia com os atributos de produção bruta de eletricidade (TWh), população (milhões), capacidade instalada (Gw) e total de assinantes (milhões) compreendendo o período de 1970 à 2009. O LS-SVM obteve o melhor resultado que os outros algoritmos obtendo 0,876% de erro de treinamento e 1,004% de erro no teste utilizando a métrica MAPE, seu desempenho superou as redes neurais tendo 4,86% de erro de treinamento e 1,19% de erro no teste, e regressão linear múltipla com 4,01% de erro de treinamento e 3,34% de erro no teste.

[Günay, 2016] usou regressão linear múltipla e redes neurais perceptron multicamadas para a previsão da demanda bruta anual de energia da Turquia. Foi utilizado uma base de dados com os atributos: Dados históricos da população, PIB per capita, porcentagem de inflação, porcentagem de desemprego, média das temperaturas de verão e inverno de entrada e como atributo de saída a demanda de eletricidade. Os dados compreendem o período de 1975 a 2013. O estudo de caso foi realizado em 3 etapas sendo a primeira a determinação das variáveis significantes para a demanda de eletricidade, a segunda foi fazer a previsão com dados de 1975 à 2006 com os algoritmos regressão linear múltipla e redes neurais perceptron multicamadas e prever os resultados de 2007 à 2013 e a terceira etapa foi fazer a previsão da demanda dos anos de 2014 à 2028. Na primeira etapa a população e o PIB per capita foram os atributos que mais contribuíram para a previsão de boa qualidade, a porcentagem de inflação e a média da temperatura de verão influenciaram pouco na previsão enquanto a porcentagem de desemprego e a média da temperatura do inverno foram insignificantes para determinar as previsões de 1975 e 2013. Na segunda etapa as redes neurais perceptron multicamadas apresentaram uma previsão com qualidade muito alta superando as previsões do ministério de energia da Turquia, já o modelo de regressão linear múltipla não apresentou bons resultados. Na terceira etapa as previsões das redes neurais foram comparadas com as previsões do



Ministério de Energia, foi verificado que as previsões oficiais foram muito maiores que as previsões das redes neurais.

No Brasil, o crescimento do consumo de energia também se elevou com o passar dos anos. Segundo o IBGE, a população se elevou de aproximadamente 157 a 206 milhões no período de 1996 a 2016 [IBGE, 2017]. E o consumo de energia elétrica, conforme dados da Eletrobras - Centrais Elétricas Brasileiras S.A. aumentou de 20 mil GWh à 38 mil GWh no período de 1996 à 2016 [Eletrobras, 2017]. Como no mundo inteiro, tanto no campo econômico, quanto no campo político o setor elétrico está se modificando. Esse fator, dá-se à desregulamentação do setor elétrico e à privatização. No Brasil por exemplo, essa reforma teve início em 1995 com a publicação da Lei de concessão em 1995 [Campos, 2008]. As usinas hidrelétricas, são as que mais produzem energia no Brasil, no entanto o país têm enfrentado grandes problemas relacionados à energia, tendo em vista que para se construir uma hidrelétrica, gera-se um impacto socioambiental muito grande como: destruição da fauna e flora ao criar as represas com grandes áreas de alagamento e desapropriação de zonas rurais ou urbanas [Tidre et al., 2013]. Também foram desenvolvidos alguns trabalhos de previsão de consumo de energia no Brasil. [Rocha et al., 2007] utilizaram regressão linear e redes neurais para a predição do consumo de energia residencial. Seu objetivo, além de prever o consumo de energia foi permitir que as concessionárias pudessem conseguir contratos mais vantajosos de compra de energia no mercado futuro e indiretamente conseguir subsídios para a formulação de programas governamentais de inclusão social. Foram realizadas previsões a curto e a longo prazo. Em ambos os casos os modelos de regressão linear e redes neurais obtiveram bons resultados comparados com os modelos utilizados nas concessionárias de energia elétrica.

Em [Campos, 2008] foram utilizados modelos *autoregressive integrated moving average* (ARIMA), *nonlinear autoRegressive integrated moving average* (NARIMA), a rede neuro-fuzzy (RNF) e rede neural artificial para a previsão do consumo de energia elétrica. Em sua dissertação Roger utilizou duas bases de dados. A primeira foi aplicada utilizando dados da cidade de New England (EUA). A segunda do estado de Minas Gerais(Brasil). Os modelos foram avaliados utilizando as métricas MPE, MAPE e RMSE. Os resultados apresentaram que os modelos ARIMA, NARIMA, RNF e redes neurais são ferramentas eficazes para a previsão de 5 anos à frente nas duas bases aplicadas e que podem auxiliar na tomada de decisões e planejamento no setor elétrico. Em [Tidre et al., 2013] foram utilizados modelos de séries temporais para prever o consumo mensal de energia elétrica da região Norte do Brasil. Eles utilizaram o modelo matemático SARIMA sem e com intervenções. Os resultados foram medidos utilizando as métricas Akaike information Criterion (AIC), Information Bayesiano Criterion (BIC) e Erro quadrado médio de previsão. O modelo que apresentou o melhor resultado para a previsão do consumo de energia na região Norte foi o SARIMA com intervenção.

Em [Torrini, 2014] e [Torrini et al., 2016] propuseram uma metodologia de lógica fuzzy para prever a demanda anual de energia no Brasil. Segundo eles os modelos recentes apresentados na literatura sobre lógica fuzzy, envolvem somente o PIB ou variáveis de forma univariada. Por isso eles apresentaram um modelo contendo o total da população e o PIB. A base de dados compreende o período de 1979 à 2013 contendo os atributos: população, PIB e consumo de energia dos setores residenciais, industriais, comerciais e outros setores. Os primeiros 25 anos foram usados para treinamento e os últimos 10 anos para teste. Foi realizado uma previsão de 2014 à 2030. Na primeira etapa foi utilizado os dados do consumo total do Brasil, os resultados comparados com o modelo Holt 2-parameter utilizando a métrica MAPE(%). O modelo fuzzy obteve melhores resultados na previsão do Brasil contendo 1,46% de MAPE do que o modelo Holt 2-parameter que obteve 5,81% de MAPE. Na segunda etapa foram utilizados dados do consumo em classes, sendo divididas em: residencial, comercial, industrial e outros setores. Os resultados demonstraram que a incorporação da taxa de crescimento da população juntamente com o PIB teve uma grande contribuição para a qualidade da previsão dos modelos de consumo residencial e do consumo total do Brasil.



5. Estudo de Caso

5.1. Base de Dados e Ferramental

Para a realização deste trabalho, foram utilizadas bases de dados públicas do Brasil. Os dados de consumo de energia residencial em GWh estão disponibilizados no portal do IPEA [Eletrobras, 2017] tendo como fonte a Eletrobras. Os dados do PIB em reais é disponibilizado no portal do Banco Central em [SGS, 2017] tendo como fonte o IBGE. E os dados da projeção anual da população do Brasil foram obtidos pelo portal do IBGE [IBGE, 2016]. Todos os dados compreendem o período de 1980 a 2016. Foi utilizada a ferramenta Weka na versão 3.8 [Witten et al., 2016], [Hall et al., 2009] juntamente como plugin Time Series Analysis and Forecasting 1.1.25 [Hall]. As redes neurais perceptron multicamadas foram aplicadas utilizando os seguintes parâmetros: taxa de aprendizado (3), momentum (0, 2), número de épocas (500), limiar para o número de erros consecutivos (20). Para as camadas ocultas da rede foram utilizadas (7) quando as instâncias eram somente o consumo de energia, (12) quando as instâncias eram o consumo de energia e PIB e (17) quando as instâncias eram o consumo de energia juntamente com o PIB e a população. O SVR na Weka foi implementado pelo algoritmo SMOreg. Ele foi aplicado utilizando os seguintes parâmetros: kernel (polinomial kernel), C (1) e ε (0,001). Vale salientar que esses parâmetros são os que obtiveram os melhores resultados na análise dos algoritmos.

5.2. Análise dos Resultados

Nossa técnica consiste em prever um ano à frente do período de dados utilizados para gerar o modelo. Por exemplo, se pegarmos uma série no período de 1980 a 2014, teremos a previsão para o ano de 2015. Nossos testes foram realizados em duas etapas. A primeira etapa consistiu em gerar previsões para os anos de 2004 a 2013. A segunda etapa consistiu em gerar previsões de 2014 a 2016. Nas duas etapas os resultados foram comparados com [Torrini, 2014] que utilizou o modelo fuzzy para gerar suas previsões, este trabalho é um dos mais recentes na literatura.

Tabela 1: Valor do Erro Percentual Absoluto Médio para todas às combinações

Modelo	MAPE %		
	Consumo	Consumo + PIB	CPP
Fuzzy [Torrini, 2014]	3,7590	3,7235	1,6658
R. Linear	0,0470	0,0677	0,0620
MLP	0,0588	0,0810	0,0771
SVR	0,0239	0,0332	0,0282

CPP = Consumo + PIB + População.

Na primeira etapa, por estarmos somente interessados nas previsões futuras, foi calculado somente o MAPE dos períodos preditos, no trabalho de [Torrini, 2014] é apresentado como MAPE de validação. Conforme pode-se observar, a regressão linear, as redes neurais perceptron multicamadas e o máquina de vetores de suporte para regressão obtiveram melhores valores de MAPE que o modelo fuzzy. No entanto informações como o PIB e a população não reduziram a taxa de MAPE das previsões dos modelos de SVR, regressão linear e MLP. O SVR apresentou as melhores taxas de acerto seguido da regressão linear os resultados são apresentados na Tabela 1. Na segunda etapa foram realizadas previsões dos anos de 2014 à 2016. Nossas abordagens foram comparadas com o valor real do consumo de energia, com a previsão da Empresa de Pesquisa Energética - EPE [EPE, 2017] e com a abordagem Fuzzy [Torrini, 2014] os resultados são apresentados na Tabela 2.

Conforme pode-se observar, na Tabela 2 a abordagem de regressão linear utilizando o consumo de energia juntamente com o PIB e População obteve a melhor previsão para 2014 seguida da abordagem utilizando o SVR com o consumo de energia juntamente com o PIB. Baseado nestes dados podemos verificar que para o modelo de RL o PIB juntamente com a população obtiveram



Tabela 2: Previsões de 2014 a 2016 para todas as abordagens

Abordagem	2014	2015	2016
Valor Real	132072	131073	132895
EPE	129983	135785	142078
FPP [Torrini, 2014]	124886	124914	124941
R. L + PIB + População	132179	135534	126546
MLP + PIB + População	125059	126726	124830
SVR + PIB + População	130636	136390	133316
R. L + PIB	120980	142536	138848
MLP + PIB	126229	128735	134214
SVR + PIB	132785	139643	141870
R.L	123194	131036	133593
MLP	129827	132514	132457
SVR	129503	136666	136948

FPP = Fuzzy + PIB + População

uma grande contribuição para os resultados, no entanto somente o PIB com o consumo diminuiu a capacidade de acerto para o modelo neste ano. Em contrapartida o consumo juntamente com PIB apresentou o melhor resultado para o SVR na previsão de 2014. Na Figura 1 podemos observar que a melhor predição para este ano através da abordagem de regressão linear utilizando o consumo juntamente com o PIB e População obteve um resultado bem próximo ao valor real comparados com as previsões da EPE e do modelo fuzzy. Na previsão para o ano de 2015 as abordagens de regressão linear e rede neural perceptron multicamadas ambas utilizando somente o consumo de energia obtiveram os dois melhores resultados respectivamente. Neste caso podemos observar que as variáveis PIB e PIB juntamente com a população não contribuíram para a qualidade dos resultados neste ano. Na Figura 1 podemos observar que a melhor predição para este ano através da abordagem de regressão linear também obteve um resultado bem próximo ao valor real comparados com as previsões da EPE e do modelo fuzzy.




Figura 1: Resultados de previsão para 2014, 2015 e 2016

Já na previsão para o ano de 2016 conforme apresentada na Tabela 2 a abordagem do SVR utilizando o consumo de energia juntamente com PIB e população obteve o melhor resultado, seguido da rede de perceptron multicamadas somente com o consumo de energia. O que mostra para a previsão do ano de 2016 as variáveis PIB e consumo de energia contribuíram para a melhora da qualidade da previsão. Na Figura 1 podemos observar que a melhor predição para este ano através da abordagem do SVR juntamente com o consumo de energia e PIB também obteve um resultado bem próximo ao valor real comparados com as previsões da EPE e do modelo fuzzy. Em todas as previsões pelo menos uma das abordagens dos modelos de redes neurais perceptron multicamadas, regressão linear e máquina de vetores de suporte para regressão obtiveram melhores resultados que o modelo Fuzzy que utiliza dados da população e PIB proposto por [Torrini, 2014].



6. Conclusão

Prever o consumo de energia de forma acurada é bastante importante para o governo, pois uma previsão abaixo do consumo real pode acarretar em potenciais interrupções de energia e elevar os custos de operação do fornecedor. Em contrapartida, uma previsão acima do consumo real pode resultar em uma capacidade ociosa gerando desperdícios de recursos financeiros desnecessariamente. Logo um modelo de previsão com uma boa precisão é fundamental para evitar erros que podem se tornar custosos.

Os resultados presentes neste artigo podem ser de grande valia ao governo brasileiro, pois permitem a seleção das técnicas mais adequadas para auxiliar no planejamento e investimento no setor de energia do país. Vale salientar que a extração e análise de dados de consumo elétrico é um passo fundamental no processo de implantação de cidades inteligentes, que, no futuro, permitirão que usinas hidrelétricas e vários fornecedores de energia alternativa estejam conectados entre si e aos consumidores urbanos para a compra e venda de energia por meio de medidores inteligentes.

O foco deste estudo foi avaliar o desempenho modelos de redes neurais perceptron multicamadas, regressão linear e máquina de vetores de suporte para regressão na previsão do consumo de energia residencial no cenário nacional. Os modelos foram gerados utilizando como dados de entrada dados de consumo residencial, dados de consumo residencial juntamente com o PIB e dados de consumo residencial juntamente com o PIB e a população do Brasil. Os resultados de nossas abordagens demonstraram uma performance superior comparado com a abordagem do modelo fuzzy que é um dos trabalhos mais recentes na literatura.

Em um próximo passo, pretendemos verificar se é possível melhorar as nossas abordagens levando em consideração o acréscimo de dados climáticos, salário mínimo e outros dados que reflitam o contexto dos consumidores no Brasil. Esses dados podem ser obtidos através do portal de dados abertos disponibilizados pelo governo. Além disso pretendemos aplicar esses algoritmos em regiões específicas com o objetivo de verificar o aumento da qualidade da previsão.

Referências

- Ahmad, A., Hassan, M., Abdullah, M., Rahman, H., Hussin, F., Abdullah, H., e Saidur, R. (2014). A review on applications of ann and svm for building electrical energy consumption forecasting. *Renewable and Sustainable Energy Reviews*, 33:102–109.
- Askarzadeh, A. (2014). Comparison of particle swarm optimization and other metaheuristics on electricity demand estimation: A case study of iran. *Energy*, 72:484–491.
- Bianco, V., Manca, O., e Nardini, S. (2009). Electricity consumption forecasting in italy using linear regression models. *Energy*, 34(9):1413–1421.
- Bianco, V., Manca, O., Nardini, S., e Minea, A. A. (2010). Analysis and forecasting of nonresidential electricity consumption in romania. *Applied Energy*, 87(11):3584–3590.
- Campos, R. J. (2008). *Previsão de séries temporais com aplicações a séries de consumo de energia elétrica*. PhD thesis, Universidade Federal de Minas Gerais.
- CIA (2016). Central Intelligence Agency - The World Factbook. URL <https://www.cia.gov/library/publications/the-world-factbook/geos/xx.html>. Acessado em: 17-02-2016.
- Coelho, I. M., Coelho, V. N., da S. Luz, E. J., Ochi, L. S., Guimarães, F. G., e Rios, E. (2017). A gpu deep learning metaheuristic based model for time series forecasting. *Applied Energy*, p. –. ISSN 0306-2619.
- Coelho, V. N., Coelho, I. M., Coelho, B. N., Reis, A. J., Enayatifar, R., Souza, M. J., e Guimarães, F. G. (2016). A self-adaptive evolutionary fuzzy model for load forecasting problems on smart grid environment. *Applied Energy*, 169:567 – 584. ISSN 0306-2619.



- Dong, B., Cao, C., e Lee, S. E. (2005). Applying support vector machines to predict building energy consumption in tropical region. *Energy and Buildings*, 37(5):545–553.
- Eletrobras (2017). IPEADATA - Instituto de Pesquisa Econômica Aplicada. Acessado em: 20-02-2017.
- EPE (2017). Empresa de Pesquisa Energética. URL <http://www.epe.gov.br/>. Acessado em: 28-02-2017.
- Fumo, N. e Biswas, M. R. (2015). Regression analysis for prediction of residential energy consumption. *Renewable and Sustainable Energy Reviews*, 47:332–343.
- Günay, M. E. (2016). Forecasting annual gross electricity demand by artificial neural networks using predicted values of socio-economic indicators and climatic conditions: Case of turkey. *Energy Policy*, 90:92–101.
- Hall, M. Time Series Analysis and Forecasting with Weka-Pentaho Data Mining. *Pentaho.com*. (<http://wiki.pentaho.com/display/DATAMINING/Time+Series+Analysis+and+Forecasting+with+Weka>). Acessado em: 28-02-2017.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., e Witten, I. H. (2009). The WEKA data mining software: an update. *ACM SIGKDD explorations newsletter*, 11(1):10–18.
- Hamzacebi, C. e Es, H. A. (2014). Forecasting the annual electricity consumption of turkey using an optimized grey model. *Energy*, 70:165–171.
- Haykin, S. S. (2001). *Redes Neurais—Princípios e Prática*.
- Hua, Y., Oliphant, M., e Hu, E. J. (2016). Development of renewable energy in australia and china: A comparison of policies and status. *Renewable Energy*, 85:1044–1051.
- IBGE (2016). IBGE - Instituto Brasileiro de Geografia e Estatística - Séries Históricas e Estatísticas. URL <http://seriesestatisticas.ibge.gov.br>. Acessado em: 20-02-2017.
- IBGE (2017). IBGE - Instituto Brasileiro de Geografia e Estatística. URL <http://www.ibge.gov.br/home/>. Acessado em: 21-02-2017.
- IEA, I. E. A. (2015). International Energy Agency - Key World Energy Statistics.
- Kalogirou, S., Neocleous, C., e Schizas, C. (1997). Building heating load estimation using artificial neural networks. In *Proceedings of the 17th international conference on Parallel architectures and compilation techniques*, volume 8, p. 14.
- Karnouskos, S. e De Holanda, T. N. (2009). Simulation of a smart grid city with software agents. In *Computer Modeling and Simulation, 2009. EMS'09. Third UKSim European Symposium on*, p. 424–429. IEEE.
- Kaytez, F., Taplamacioglu, M. C., Cam, E., e Hardalac, F. (2015). Forecasting electricity consumption: a comparison of regression analysis, neural networks and least squares support vector machines. *International Journal of Electrical Power & Energy Systems*, 67:431–438.
- Li, Q., Meng, Q., Cai, J., Yoshino, H., e Mochida, A. (2009). Applying support vector machine to predict hourly cooling load in the building. *Applied Energy*, 86(10):2249–2256.
- Montgomery, D. C., Peck, E. A., e Vining, G. G. (2015). *Introduction to linear regression analysis*. John Wiley & Sons.



- Olofsson, T., Andersson, S., e Östin, R. (1998). A method for predicting the annual building heating demand based on limited performance data. *Energy and Buildings*, 28(1):101–108.
- Pal, S. K. e Mitra, S. (1992). Multilayer perceptron, fuzzy sets, and classification. *IEEE Transactions on neural networks*, 3(5):683–697.
- Pan, G., Qi, G., Zhang, W., Li, S., Wu, Z., e Yang, L. T. (2013). Trace analysis and mining for smart cities: issues, methods, and applications. *IEEE Communications Magazine*, 51(6):120–126.
- Pérez-Lombard, L., Ortiz, J., e Pout, C. (2008). A review on buildings energy consumption information. *Energy and buildings*, 40(3):394–398.
- Rocha, C. A., Rego, L., e Gato, V. (2007). Estratégias de previsão de carga e de consumo de energia elétrica baseadas em modelos estatísticos e redes neurais artificiais: Um estudo de caso nas concessionárias de energia do estado do Pará.
- Schaffers, H., Komninos, N., Pallot, M., Trousse, B., Nilsson, M., e Oliveira, A. (2011). Smart cities and the future internet: Towards cooperation frameworks for open innovation. In *The Future Internet Assembly*, p. 431–446. Springer.
- SGS (2017). Banco Central do Brasil - SGS - Sistema Gerenciador de Séries Temporais - Produto Interno Bruto em R\$ correntes. Acessado em: 20-02-2017.
- Tidre, P. V. V., Biase, N. G. G., e de Sousa Silva, M. I. (2013). Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região norte do Brasil. *Matemática e Estatística em Foco*, 1(1):57–66.
- Todesco, J. L., Pimentel, F. J., e Bettiol, A. L. (2004). O uso de famílias de circuitos e rede neural artificial para previsão de demanda de energia elétrica. *Revista Produção Online*, 4(4).
- Torrini, F. C. (2014). *Modelos de Lógica Fuzzy para a Previsão de Longo Prazo de Consumo de Energia*. PhD thesis, PUC-Rio.
- Torrini, F. C., Souza, R. C., Oliveira, F. L. C., e Pessanha, J. F. M. (2016). Long term electricity consumption forecast in Brazil: A fuzzy logic approach. *Socio-Economic Planning Sciences*, 54: 18–27.
- Tutun, S., Chou, C.-A., e Canıyılmaz, E. (2015). A new forecasting framework for volatile behavior in net electricity consumption: A case study in Turkey. *Energy*, 93:2406–2422.
- Üstün, B., Melssen, W., Oudenhuijzen, M., e Buydens, L. (2005). Determination of optimal support vector regression parameters by genetic algorithms and simplex optimization. *Analytica Chimica Acta*, 544(1):292–305.
- Wang, W.-C., Chau, K.-W., Cheng, C.-T., e Qiu, L. (2009). A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of hydrology*, 374(3):294–306.
- Witten, I. H., Frank, E., Hall, M. A., e Pal, C. J. (2016). *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann.
- Zhao, H. e Magoulès, F. (2010). Parallel support vector machines applied to the prediction of multiple buildings energy consumption. *Journal of Algorithms & Computational Technology*, 4 (2):231–249.