



UMA REVISÃO DA LITERATURA NA PREVISÃO DE CONSUMO DE ENERGIA ELÉTRICA RESIDENCIAL UTILIZANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA

Leonardo Pio Vasconcelos, José Viterbo Filho

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

Flavia Cristina Bernardini

Instituto de Ciência e Tecnologia – Universidade Federal Fluminense (UFF)
Campus Rio das Ostras, Rio das Ostras, RJ - Brazil
fcbernardini@id.uff.br

João Marcos Meirelles da Silva

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

RESUMO

Devido ao crescimento populacional nas cidades, é cada vez mais necessário o desenvolvimento de soluções urbanas para melhoria da qualidade de vida. Cidades Inteligentes vêm ganhando atenção como um cenário para a implementação de soluções tecnológicas e computacionais que auxiliam na melhoria dos serviços aos cidadãos em diversas áreas. Predizer a quantidade necessária de energia elétrica a ser consumida por edifícios permite planejar a real demanda no fornecimento contínuo com qualidade, sendo assim um serviço de grande utilidade. Diversos modelos preditivos construídos utilizando aprendizado de máquina vêm sendo utilizados para previsão de consumo de energia elétrica, porém há poucos trabalhos que relatam estudos brasileiros para previsão de consumo de energia em edifícios. O objetivo deste trabalho é apresentar uma revisão de trabalhos sobre predição de consumo de energia baseados em SVM e Redes Neurais, bem como discutir potenciais pesquisas nessa área, e suas implicações para o Brasil e o mundo.

PALAVRAS CHAVE. Previsão do Consumo de Energia Elétrica; Redes Neurais; SVM.
Tópicos (SS1 - Sessão Especial 1 - Pesquisa Operacional & Cidades Inteligentes)

ABSTRACT

Due to the urban population growth, develop urban solutions to improve the quality of life is increasingly necessary. Smart Cities have gained attention as a scenario for implementation of technological and computational solutions that help in improvement of services provided to citizens in several areas. Predicting the required amount of electricity to be consumed by buildings allows planning the real demand for continuous supply with quality, thus being a service of great utility. Several electricity consumption predictive models have been used to forecast electricity consumption. However, there are only a few studies that report Brazilian studies to forecast energy consumption in buildings. The purpose of this work is to present a literature review on SVM-based and Neural Network-based electricity consumption forecast, as well as to discuss potential research in this area, and its implications for Brazil and the world.

KEYWORDS. Electric Energy Consumption Forecast; Neural Networks; SVM.
Paper topics (SS1 - Special Session 1 - Operational Research & Smart Cities)



1. Introdução

A população mundial vem crescendo em grande escala, tendo saltado de 3 bilhões de pessoas em 1960 para 7 bilhões em 2015 [CIA, 2016], ou seja, um crescimento de 4,2% a.a. (ao ano), o que reflete diretamente em aumento no consumo de energia¹. No entanto, a taxa de aumento do consumo de energia elétrica mundial foi muito maior que a taxa de aumento da população em um período relativamente próximo, segundo [Pérez-Lombard et al., 2008]: nos setores públicos, residenciais e agrícola, entre 1971 e 2012 o consumo se elevou de 4,65 a 18,6 bilhões de GWh, ou seja, um crescimento de 9,8% a.a. No Brasil, também houve diferença entre as taxas de crescimento — a população se elevou de aproximadamente 157 para 190 milhões no período de 1996 a 2010 segundo [IBGE, 2016], ou seja, um aumento de 8,6% a.a., e o consumo de energia aumentou de 1,7 mil GWh para 2,4 mil GWh no período de 1997 à 2007, segundo a ANEEL (Agência Nacional de Energia Elétrica) [ANEEL, 2008], ou seja, aumento de 14,1% a.a.

Além disso, as concentrações urbanas estão se expandindo cada vez mais, com maior migração do campo para cidades, ao redor do mundo. Segundo a OECD (*Organization for Economic Cooperation and Development*) [OECD, 2017], estima-se que a população aumente para 9,3 bilhões de pessoas, com 97% desse crescimento ocorrendo em países em desenvolvimento. Mais de 54% da população do mundo vive atualmente em centros urbanos, e a expectativa é que aumente para 70% em 2050. Esse cenário tem levado à necessidade de um melhor planejamento urbano em relação a diversos serviços, que devem ser prestados aos cidadãos. Assim, surgiram diversas definições de cidades inteligentes [Cocchia, 2014], sendo comum em todas elas o uso da tecnologia para melhorar a qualidade dos serviços ao cidadão. São algumas delas Internet das Coisas (IoT — *Internet of Things*) e sistemas computacionais para coletar informações de diferentes dispositivos, oferecer apoio à decisão aos governantes e aos cidadãos, dentre outros. Para tudo isso é fundamental a oferta de energia com qualidade.

Para atender as necessidades dos grandes centros urbanos, cada vez mais edifícios são construídos, com capacidade para atendimento de uma grande quantidade de moradia de famílias e escritórios de negócios e serviços [Santamouris et al., 2001]. Nos EUA, 41% da energia consumida vão para comércios e residências [Wilson, 2013]. Como nos grandes centros urbanos a maioria das residências e comércios são estabelecidos em edifícios, conclui-se que há uma grande demanda de consumo de energia neste setor. Diante deste cenário, técnicas para a previsão do consumo de energia se apresenta com grande utilidade, pois estes dados podem ser aplicados para um bom planejamento de produção e distribuição de energia para seu provimento ininterrupto e confiável [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 possibilita potenciais interrupções de energia, e assim elevar os custos de operação ao fornecedor. Por outro lado, uma previsão acima do consumo real pode resultar em uma capacidade ociosa de energia, levando a desperdícios de recursos financeiros, pois esses recursos poderiam ser utilizados para outros fins [Kaytez et al., 2015]. Essa previsão de consumo pode também auxiliar na identificação de períodos de consumo excessivo, permitindo assim a redução de picos de demanda que encarecem o custo de energia [Platon et al., 2015], na identificação de anomalias de uso [Liu e Chen, 2013], dentre outros.

Uma boa estimativa do consumo é de fundamental para planejar os recursos necessários para o abastecimento dos consumidores à medida de sua demanda, tendo em vista que não se pode estocar a corrente alternada [Hamzacebi e Es, 2014]. De acordo com [Todesco et al., 2004], uma concessionária de energia tem como objetivo principal oferecer um bom serviço, com um preço justo tendo um gerenciamento eficiente de distribuição de energia elétrica. Na Turquia por exemplo, as estimativas oficiais de consumo são revisadas semestralmente pelos órgãos oficiais do governo, por serem superiores aos valores do consumo de energia real [Kaytez et al., 2015]. No Brasil, parte

¹Neste trabalho, o termo “energia” refere-se a energia elétrica.



dos consumidores não possuem maturidade para consumir energia de forma consciente, por esse motivo, desperdiçam energia utilizando aparelhos elétricos inadequadamente sem se preocupar com as consequências futuras. Por isso dados sobre previsão de consumo podem ser úteis para orientar a população, focando em orientar o consumo consciente de energia [Tidre et al., 2013].

Nos trabalhos apresentados na literatura, diversas abordagens são aplicadas, em função das necessidades de cada problema em particular. Nessas abordagens, muitas envolvem a construção de um modelo, com o objetivo de atender um determinado caso, que pode estar fortemente relacionado à realidade de um país ou região. Isso pois, para se obter um modelo com uma boa acurácia, as características a serem consideradas na construção do modelo devem ser avaliadas em cada domínio de aplicação, ou seja, devem ser bem definidos os parâmetros que afetam o consumo de eletricidade em cada região [Kaytez et al., 2015]. Vários métodos propostos na literatura são baseados em técnicas de aprendizado de máquina para previsão de consumo de energia, como árvores de decisão [Yu et al., 2010], inferência fuzzy [Kubota et al., 2000], regressão linear [Bianco et al., 2009], [Lam et al., 2010], entre outros. O trabalho [Coelho et al., 2016a] aborda um modelo fuzzy híbrido evolutivo com calibração automática dos parâmetros para a previsão de carga de energia no ambiente de rede inteligente. Já o trabalho [Coelho et al., 2016b] propõe um framework para previsão de séries temporais, implementado como um algoritmo paralelo, baseado em deep learning e um modelo híbrido fuzzy, aplicada a uma base de dados desagregada REDD. Estes dois trabalhos apresentam contribuições relevantes para a predição de consumo de energia, no entanto, por tratarmos especificamente de previsão de consumo em edifícios, eles não serão abordados neste artigo.

Em [Ahmad et al., 2014], é apresentada uma revisão bibliográfica e uma análise experimental para previsão de consumo de energia em edifícios, nos quais SVMs (*Support Vector Machines*, ou Máquinas de Vetor Suporte) e RNAs (Redes Neurais Artificiais) apresentam melhores taxas de acurácia. Por esse motivo que neste trabalho foi delimitado o escopo de estudo de trabalhos que utilizam esses algoritmos (SVMs e RNAs) e suas variações para previsão de consumo em edifícios. Outros trabalhos foram considerados além dos apresentados em [Ahmad et al., 2014]. Ainda, foram estudados também trabalhos que relatam aplicações brasileiras.

Este artigo tem como objetivo apresentar uma revisão da literatura, descrevendo trabalhos que utilizam algoritmos de aprendizado de máquina para a previsão do consumo de energia elétrica em edifícios, destacando suas metodologias, como foram implementados, os algoritmos que obtiveram melhores resultados e, além disso, apresentar também uma análise do que vem sendo realizado no Brasil. Para isso, na Seção 2 são apresentados conceitos básicos para melhor entendimento do trabalho. Na Seção 3, é descrito o processo de seleção dos trabalhos, e são descritos os trabalhos selecionados na literatura relacionado a previsão de energia. Na Seção 4, é apresentada uma discussão sobre trabalhos realizados no Brasil. Para finalizar, na Seção 5 são apresentadas as conclusões e necessidades de trabalhos futuros.

2. Conceitos Básicos

Em aprendizado supervisionado, foco deste trabalho, a entrada do algoritmo de aprendizado consiste de um conjunto de exemplos S , com N exemplos $T_i, i = 1, \dots, N$, escolhidos de um domínio X , com uma distribuição D fixa, desconhecida e arbitrária, da forma $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)\}$, para alguma função desconhecida $y = f(\mathbf{x})$. Os \mathbf{x}_i são tipicamente vetores da forma $(x_{i1}, x_{i2}, \dots, x_{iM})$ com valores discretos ou numéricos. x_{ij} refere-se ao valor do atributo, ou dimensão, j , denominado \mathbf{X}_j , do exemplo $T_i = (\mathbf{x}_i, y_i)$. Os valores y_i referem-se ao valor do atributo Y , frequentemente denominado classe. Quando os valores de Y , ou seja, o domínio de Y ($dom(Y)$) pertence a um conjunto discreto de somente dois valores possíveis, o problema de aprendizado é de classificação binária; quando $dom(Y)$ pertence a um conjunto discreto de mais de dois valores possíveis, o problema de aprendizado é de classificação multiclasse; e quando $dom(Y) \in \mathbb{R}$, o problema é de regressão. Dado um conjunto S de exemplos a um algoritmo de aprendizado, um



modelo \mathbf{h} será construído. O modelo consiste da hipótese feita sobre a verdadeira (mas desconhecida) função f . Dado um novo exemplo \mathbf{x} , o modelo \mathbf{h} prediz o valor correspondente y . Como este trabalho está focado em fazer uma discussão sobre o uso de aprendizado de máquina para previsão do consumo de energia em edifícios, e segundo [Ahmad et al., 2014] a maioria dos trabalhos utiliza SVMs e/ou RNAs, a seguir são brevemente descritos ambos os algoritmos:

SVMs As Máquinas de Vetor Suporte são modelos utilizados para classificação ou regressão baseados em vetores de suporte. Assim, solução para o problema de construção da SVM é dependente apenas de um subconjunto de exemplos de treinamento, que são os vetores de suporte. Para sua construção, são utilizados algoritmos de aprendizado baseados na teoria de aprendizado estatístico. Inicialmente foram propostos para problemas de classificação binária linear, mas posteriormente o conceito no qual se baseiam esses algoritmos foi ampliado para ser utilizado em problemas de classificação não linear, agrupamento de dados (aprendizagem não-supervisionada), classificação multiclasse e regressão. Esses algoritmos resolvem um problema de otimização quadrática, para minimização de uma função lagrangiana, cuja solução possui ampla e estabelecida teoria matemática. A complexidade de tempo de treinamento da maioria dos algoritmos para construção de SVMs é quadrática ou cúbica em relação ao número de amostras de treinamento, o que é uma das desvantagens desses algoritmos. Ainda, são diversos os parâmetros que podem ser utilizados para sua construção, o que também demanda tempo de experimentação para cada domínio de aplicação. Ainda assim, têm sido bastante exploradas pois em muitos problemas no aprendizado de máquina as SVMs têm apresentado bons resultados [Faceli et al., 2011]. O algoritmo mais utilizado para problemas de regressão é o SVR (*Support Vector Regression*), e um algoritmo utilizado para melhorar a performance de SVMs é o WSVM (*Weighted SVM*), que associa uma ponderação aos exemplos de treinamento.

RNAs Foram desenvolvidas com o objetivo de criar um modelo computacional análogo ao cérebro humano. Em geral, são redes de apenas uma ou múltiplas camadas, nas quais diversos neurônios encapsulam uma função de agregação das entradas do neurônio (em geral um somatório ponderado sobre suas entradas), e uma função de ativação sobre o sinal resultante da função de agregação. O algoritmo de construção de uma RNA aprende a relação entre os atributos (ou dimensões) de entrada e as variáveis de saída, ou atributo classe [Kalogirou et al., 1997], [Olofsson et al., 1998]. RNAs possuem a vantagem de poder executar tarefas que um programa linear não pode, pois a RNA pode ser vista como uma função não linear dos atributos de entrada, e a desvantagem de ter um tempo de aprendizado elevado quando a rede neural é grande, ou quando o número de exemplos de treinamento N é grande [Ahmad et al., 2014]. O algoritmo mais utilizado para indução de RNAs para classificação é o de retropropagação, ou *Backpropagation*.

Em muitas situações, a quantidade de atributos é muito grande, o que dificulta o aprendizado dos modelos. Assim, técnicas de construção e seleção de algoritmos podem ser utilizados. Uma técnica bastante utilizada é a de Análise de Componentes Principais, ou PCA (*Principal Component Analysis*), que realiza uma transformação ortogonal nos dados originais, que resulta em um conjunto de atributos não correlacionados, cujo número é igual ou menor que o conjunto de atributos original. Outra técnica que tem sido recentemente utilizada é a KPCA (*Kernel PCA*), que utiliza um Kernel para transformação dos exemplos, ao invés da transformação linear original do PCA [Faceli et al., 2011]. Alguns trabalhos apresentados neste artigo utilizam essas técnicas.

O aprendizado de máquina é dito em lote (*batch*) quando o conjunto de dados S está completo para o treinamento de \mathbf{h} , ou é dito *online* quando os exemplos de treinamento são obtidos em tempo real. Algoritmos de aprendizado *online* são propostos especificamente para este fim, pois devem ser projetados para as seguintes especificidades: curto tempo de acesso por exemplo T_i ;



uso de quantidade fixa de memória, independentemente de N ; capacidade de construção de h pela leitura de T_i de no máximo uma vez — pode não haver tempo de revisitar antigos exemplos, e os exemplos podem não estar disponíveis em armazenamento secundário no futuro —; capacidade de disponibilização de um modelo h utilizável a qualquer tempo; e atualização de h para “esquecer” informações desatualizadas sem perder informações do passado que não se tornaram desatualizadas. Assim, há adaptações de diversos algoritmos, incluindo de RNAs e SVMs, para aprendizado online.

3. Revisão da Literatura

Para obter os trabalhos selecionados na literaturas desta pesquisa, foram coletados dados do portal virtual Google Acadêmico Brasil, no período de 1995 a 2016. Como critério de inclusão, adotou-se artigos, teses online e dissertações que abordassem especificamente o título e/ou resumo das palavras chaves apresentadas na Tabela 1. Nessa busca, foi encontrado o trabalho de [Ahmad et al., 2014], que afirma que há três abordagens para previsão de energia em edifícios: abordagem baseada em engenharia, estatística e baseada em aprendizado de máquina. A primeira é bastante complexa, pois necessita que a modelagem seja muito específica para cada caso, e a segunda apresenta taxas de acurácia mais baixas que a terceira. Por essa razão que abordagens baseadas em aprendizado de máquina têm sido mais utilizados, e ainda diversos trabalhos apontam para melhores taxas de acurácia utilizando SVM (*Support Vector Machine*) e Redes Neurais (RNA).

Tabela 1: Termos de busca

prediction + annual + energy + consumption + building + neural + network	building + heating + load energy + consumption + neural + network
prediction + energy + consumption + building + neural + network	prediction + energy + consumption + building + SVM
prediction + buildings + electricity + consumption	prediction + energy + consumption + SVR
forecast + energy + consumption + building	building + cooling + load + forecasting
prediction + energy + consumption + building	

Após a leitura de diversos outros artigos além desse, identificamos que as previsões podem ser para consumo, carga e demanda de energia elétrica. O consumo de energia é o uso de energia como uma fonte de calor ou de energia, ou como uma entrada de matéria-prima para um processo de produção. A carga de energia é a caracterização da demanda do sistema, em um determinado ponto de interesse, definida por uma ou mais das seguintes grandezas: potência ativa, demanda de energia ativa e demanda de energia reativa, segundo a ANEEL. Já a demanda de energia é a média das potências elétricas ativas ou reativas, solicitadas ao sistema elétrico pela parcela da carga instalada em operação na unidade consumidora, durante um intervalo de tempo especificado, expressa em quilowatts (kW) e quilovolt-ampère-reactivo (kvar), respectivamente. As previsões de consumo de energia em edifícios se subdividem em duas categorias: previsões gerais e previsões específicas. As previsões gerais englobam o edifício por completo, como iluminação, aquecimento, refrigeração, escada rolante, entre outros. As previsões específicas se focam somente em um determinado equipamento do edifício por exemplo: previsão do consumo de iluminação, previsão do consumo de aquecimento, previsão do consumo de ar condicionado, entre outros. Assim, os trabalhos da literatura considerados relevantes para predição de energia em edifícios são descritos a seguir, divididos nessas duas categorias.

3.1. Previsões gerais

Na Tabela 2 são apresentados os trabalhos selecionados relacionados aos objetivos de previsão de consumo para um edifício inteiro (considerados objetivos gerais), nas colunas — consumo mensal de energia, consumo anual de energia, consumo de energia por hora, e carga horária de energia —, e os métodos empregados, nas linhas. O primeiro trabalho a utilizar SVMs, e compará-la com RNAs, na previsão do consumo de energia em edifícios foi Dong *et al.* [Dong et al., 2005]. Os autores selecionaram dados de quatro edifícios da região tropical de Cingapura, para prever o consumo mensal. A base continha os atributos: dados meteorológicos, umidade relativa do



ar, radiação solar global e sistemas de: ar condicionado, ventilação, iluminação, elevadores. Foram utilizados dados de três anos para treinamento. O modelo gerado foi aplicado em dados de um ano. Os resultados utilizando SVMs foram melhores do que RNA e programação genética.

Tabela 2: Previsões gerais — Métodos e Objetivos de Previsão

Métodos	Objetivos			
	Consumo mensal de energia	Consumo anual de energia	Consumo de energia por hora	Carga horária de energia
SVM	[Dong et al., 2005]	[Li et al., 2010]		
RNA			[Neto e Fiorelli, 2008] e [Platon et al., 2015]	
RNA Recorrente				[González e Zamarrero, 2005]
CBR			[Platon et al., 2015]	

[Li et al., 2010] utilizaram SVM, algoritmo de Retropropagação utilizando função *RBF* e RNA de Regressão Geral para prever o consumo anual de eletricidade em edifícios. Os dados foram coletados em 59 edifícios de Guangdong (China), sendo que dados de 9 deles foram utilizados somente para teste (avaliação dos modelos). Foram utilizados como atributos de entrada os coeficientes de transferência de calor, tamanho do edifício, absorção de radiação solar, dentre outros. Nesses experimentos, a SVM obteve melhores resultados segundo o erro médio relativo e o erro médio quadrático.

[Platon et al., 2015] utilizaram algoritmos para construção de um modelo de Raciocínio Baseado em Casos (*Case Based Reasoning* — CBR) e modelos de RNAs para previsão do consumo de energia em tempo real (a cada hora) em edifícios. Ele utilizou uma base de dados de um sistema AVAC (aquecimento, ventilação e ar condicionado) da sede de uma instituição canadense que possuía atributos como: temperatura da água, ar quente, ar interior, configurações de controle do abastecimento do ventilador e informações sobre dados climáticos. Para reduzir o número de entradas sem prejudicar a qualidade do modelo ele utilizou o método de seleção de atributos PCA. Ele variou a janela de previsão de 1 a 6 horas para estudar o impacto sobre o desempenho do modelo, e observou que o erro médio quadrático relativo variou de aproximadamente 7,3% a 8,5% na RNA e 13,2% a 13,7% no CBR, indicando que a RNA também obteve melhores resultados nesse caso.

[González e Zamarrero, 2005] utilizaram RNA Recorrente para prever a carga de energia elétrica. A base continha atributos como temperatura, hora, dia, carga de entrada e de saída. O resultado foi considerado excelente, com uma precisão comparável aos melhores resultados na literatura. No entanto, os autores mencionaram que o número de neurônios da camada oculta da rede neural, o tamanho ideal da janela de dados e os parâmetros do algoritmo de treinamento não foram profundamente analisados.

Devido à diferença das aplicações, não é possível comparar os trabalhos entre si, no entanto é interessante observar que RNAs e SVMs têm obtido melhores resultados nas previsões de consumo de energia de um edifício inteiro.

3.2. Previsões específicas

Na Tabela 3 são apresentados os trabalhos selecionados relacionados aos objetivos da previsão para alguns itens específicos de consumo de energia em edifícios, nas colunas — carga horária de refrigeração, demanda elétrica de refrigeração por hora, carga diária e horária de ar condicionado, carga horária de aquecimento, consumo de energia por hora em iluminação, e demanda de aquecimento anual —, e os métodos empregados, nas linhas.

[Hou e Lian, 2009] utilizaram o SVM para a previsão de carga de refrigeração de um sistema de AVAC na China. O SVM obteve melhores resultados de erro absoluto e erro relativo que



Tabela 3: Previsões específicas — Métodos e Objetivos de Previsão

Métodos	Objetivos de Previsão					
	Carga horária de refrigeração	Demanda elétrica de refrigeração por hora	Carga diária e horária de ar condicionado	Carga horária de aquecimento	Consumo de energia por hora em iluminação	Demanda de aquecimento anual
SVM	[Hou e Lian, 2009]					
SVR	[Li et al., 2009]			[Zhao e Magoulès, 2010]	[Liu e Chen, 2013]	
PCA-WSVM	[Jinhu et al., 2010]					
KPCA-SVR	[Xuemei et al., 2010]					
RNA		[Yang et al., 2005]	[Liao, 2014]	[Kalogirou et al., 1997]		[Olofsson e Andersson, 2001]

o modelo de regressão ARIMA (modelo auto-regressivo integrado de média móvel). Li et al. [2009] construíram uma SVM para regressão para prever a carga horária de refrigeração de um prédio de escritórios em Guangzhou, China. Foram utilizados atributos como temperatura externa de bulbo seco, umidade relativa e radiação solar. Comparado com as RNAs *Backpropagation*, o desempenho do SVR foi superior e com melhores generalizações.

[Jinhu et al., 2010] utilizaram o WSVM para prever a carga horária de refrigeração de um edifício e compararam com o resultado do SVR e SVM. A base escolhida foi da Universidade de Zhongkong composta por dados relativos a data, condições climáticas diárias, e dados de 24 pontos em cada dia. Foi utilizado o método de seleção de atributos PCA para reduzir as variáveis antes do treinamento do modelo. O modelo híbrido PCA-WSVM apresentou melhores resultados que o SVR e PCA-SVM. [Xuemei et al., 2010] empregaram o KPCA (Kernel Análise de componentes Principais), uma melhoria do PCA, associado ao SVM para prever a carga de refrigeração horária de edifícios nos mesmos dados de [Jinhu et al., 2010]. Os resultados mostraram que SVM associado ao uso de KPCA possui melhor precisão, generalização e baixa dependência de dados da amostra que os modelos gerados pelo SVR, utilizando ou não PCA.

[Yang et al., 2005] aplicaram RNAs para a previsão online e em tempo real da demanda de energia elétrica de refrigeração por hora. Para a criação do modelo foram utilizadas uma base sintética e uma real. A base sintética é composta por atributos como temperatura externa de bulbo seco, temperatura externa de bulbo úmido, temperatura de saída de água do refrigerador e demanda elétrica do refrigerador. A base real é composta por atributos como status do compressor, temperatura da água entrando no tanque de gelo, temperatura da água saindo do evaporador, umidade relativa do ar exterior e temperatura exterior. Nesse trabalho foram propostos dois tipos de métodos para treinar as RNAs, sendo eles o treinamento acumulativo e janela deslizante. Nos dados sintéticos os dois métodos obtiveram um desempenho igual. Nos dados reais a técnica de janela deslizante apresentou melhores resultados.

[Liao, 2014] utilizou RNA para o problema de previsão de carga diária e horária de ar condicionado. Foram utilizados dados coletados de um edifício de 20 andares, e foram utilizados atributos como temperatura externa, umidade e radiação solar. Foi utilizada a transformada de Wavelet nos dados. Os resultados do método proposto obtiveram um menor valor de erro percentual absoluto médio quando comparado a outros algoritmos. A rede proposta se apresentou como uma abordagem vantajosa e prática. [Zhao e Magoulès, 2010] utilizaram o software de simulação de energia *energy plus* para simular o consumo de energia dos edifícios, com o objetivo final de prever a carga horária de aquecimento em edifícios. Eles treinaram o modelo SVM com dados de



vários edifícios e testaram o modelo em dados de um edifício novo. Foram utilizados atributos como condições meteorológicas, estrutura dos edifícios, comportamento dos ocupantes, cronograma de uso de luz, etc. Como havia muitos dados para treinamento, a geração do modelo iria demorar muito tempo, então eles propuseram um algoritmo SVM paralelo para acelerar a criação do modelo de treinamento. O SVR apresentou bons resultados e o SVM paralelo se apresentou como uma solução boa e prática, agilizando a previsão de dados extremamente grandes.

[Kalogirou et al., 1997] utilizaram RNAs para prever a carga de aquecimento necessário de edifícios. Foram utilizados atributos como os dados físicos do prédio as dimensões de salas e área de parede externa. A acurácia do modelo foi maior que 90% o que, segundo os autores, está dentro do nível aceitável usados pelos engenheiros de projeto. [Liu e Chen, 2013] utilizaram o SVR para a prever o consumo de energia em iluminação. Os dados são de edifícios de escritórios tendo atributos como consumo de energia por hora em iluminação e número de pessoas no escritório. Eles utilizaram as métricas erro quadrático médio e coeficiente de determinação. Os resultados foram comparados com as RNAs. O SVR obteve um melhor desempenho.

[Olofsson e Andersson, 2001] utilizaram RNAs para, por meio de previsões de curto prazo, fazer previsões a longo prazo da demanda de aquecimento anual. Eles utilizaram dados de 6 edifícios unifamiliares da cidade de Umeå na Suécia. Ainda, utilizaram atributos como temperaturas interiores e exteriores e utilização de energia para o espaço de aquecimento, água quente para uso doméstico e para aparelhos domésticos diferentes. Seu método que usa previsões semanais para fazer previsões anuais se apresentou como uma abordagem promissora para se tornar uma ferramenta de fácil utilização na previsão de demanda de um edifício unifamiliar.

Também nesse caso, pode-se observar que são muitos os objetivos e métodos distintos utilizados, tendo destaque as SVMs, que quando comparadas com RNAs, obtém melhores resultados.

4. Cenário no Brasil

Nesta seção são apresentados trabalhos encontrados na literatura que apresentam aplicações no Brasil para previsão de energia elétrica. Somente o trabalho de [Neto e Fiorelli, 2008] foi encontrado no Brasil que propõe um método para previsão de energia elétrica em edifícios. [Neto e Fiorelli, 2008] construíram dois tipos de modelos para a previsão de consumo de energia de forma geral, sendo o primeiro baseado em RNAs e o segundo baseado no software de simulação *energy plus*. A base de dados utilizada para a construção dos dois modelos foi oriunda de um edifício administrativo de uma universidade, e o objetivo dos modelos era prever o consumo por hora. Ambos modelos obtiveram bons resultados, sendo que as RNAs apresentaram melhor acurácia. [Platon et al., 2015], descrito na Seção 3.1, apresentaram uma proposta que evolui a de [Neto e Fiorelli, 2008]. O estudo, realizado em 2015 no Canadá, também utiliza um modelo de previsão por hora, porém se diferencia do que foi proposto por [Neto e Fiorelli, 2008] por utilizar um modelo de aprendizado online, com entradas reduzidas e de fácil generalização. Esse método poderia também ser aplicado em diferentes problemas no Brasil.

Outros trabalhos foram encontrados para previsão de consumo de energia elétrica de maneira mais geral, mas que podem inspirar na modelagem de modelos de previsão para consumo de energia em edifícios. [Todesco et al., 2004] utilizaram famílias de circuito e RNAs para a previsão de demanda de energia elétrica. As famílias de circuito compreendem os setores residencial, comercial, industrial, rural, público e outros. Primeiramente os autores aplicaram o algoritmo k-médias de clusterização em 427 medições de circuitos de baixa tensão. Os circuitos foram divididos em duas famílias: residencial e não residencial. Foi treinada uma RNA para cada uma dessas famílias. As classes residencial e não residencial obtiveram erros médios de 8,31% e 12,53% respectivamente. Segundo os autores os resultados das RNAs foram muito bons comparados a Regressão Linear Simples e Múltipla.

[Campos, 2008] utilizou os modelos AutoRegressive Integrated Moving Average (ARIMA), Nonlinear AutoRegressive Integrated Moving Average (NARIMA), Rede Neuro-Fuzzy (RNF) a Rede Neural (RNA) para a previsão do consumo de energia elétrica. Em sua dissertação Campos



utilizou duas bases de dados, sendo a primeira da cidade de New England (EUA), e a segunda do estado de Minas Gerais (Brasil). Os modelos foram avaliados utilizando as métricas *Mean Percentage Error* (MPE), *Mean Absolute Percentage Error* (MAPE) e *Root Mean Squared Error* (RMSE). Os resultados apresentaram que os modelos ARIMA, NARIMA, RNF e RNA 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.

[Rocha et al., 2007] utilizaram Regressão Linear e Redes Neurais para a previsão do consumo de energia residencial. Seu objetivo, além de prever o consumo de energia, era 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 que eram utilizados nas concessionárias de energia elétrica.

[Moreira, 2015] utilizou RNAs e Regressão Linear para a previsão de médio prazo de consumo de energia elétrica. O autor utilizou dados de consumo fornecidos pela Eletrobrás, FGV, BCB e IPEADATA. As Regressões Lineares obtiveram melhor resultado e as RNAs obtiveram pouca aderência às séries na maioria dos casos de teste selecionados. O autor concluiu que, para um modelo produzir bons resultados, necessita de uma calibração paramétrica, além de uma boa aderência às variáveis de entrada.

Esses trabalhos reforçam a aplicabilidade do uso de RNAs para previsão de consumo de energia em edifícios. Observa-se também que nenhum desses trabalhos explora o uso de SVMs na previsão do consumo de energia, o que mostra que há uma lacuna de pesquisa importante na realidade brasileira. No entanto, não foram encontrados conjuntos de dados disponibilizados no Brasil para esse tipo de estudo, que permitissem neste trabalho uma análise aprofundada da aplicabilidade de RNAs e SVMs na previsão de consumo em edifícios. É desconhecido se esses conjuntos não são encontrados por não serem disponibilizados pela ANEEL, ou outras concessionárias, ou se não há coleta que permita esse tipo de inferência. Tal carência justifica o estudo de maneiras de coleta e métodos de inferência no país, em especial a pesquisa de técnicas para melhorar a acurácia de alguns dos modelos apresentados e adaptá-los para utilização no Brasil.

5. CONCLUSÃO

A previsão do consumo de energia em edifícios é necessária, principalmente nos grandes centros, para permitir estimar, com maior precisão, a demanda de energia. Uma boa previsão dessa demanda permite a identificação de necessidade de produção de energia, o que leva a uma maior precisão na predição de investimento no setor elétrico, tanto no Brasil quanto no mundo. Isso é cada vez mais necessário quando há diversas cidades no mundo necessitando implementar soluções de Cidades Inteligentes, para melhoria da qualidade de vida do cidadão.

Diante deste cenário, este artigo apresenta uma revisão da literatura sobre trabalhos que tratam da previsão do consumo de energia, mais especificamente, consumo de energia em edifícios, com base em técnicas de aprendizado de máquina. Foram selecionados trinta artigos da literatura, considerados mais relevantes para o problema abordado. Verificou-se que os algoritmos SVM e RNAs são os mais empregados, e com melhores resultados, em diversas aplicações em países fora do Brasil. Observou-se que o uso de dados sobre o comportamento climático, associados aos dados térmicos e estruturais dos edifícios, pode influenciar positivamente na acurácia das previsões. Além disso, foi possível concluir que o pré-processamento tem grande influência na acurácia do modelo, atuando para reduzir os ruídos nos dados coletados. É interessante observar que o PCA foi o método de seleção de atributo mais utilizado no pré-processamento. Por outro lado, observa-se que há uma grande variedade de métricas utilizadas nos trabalhos, o que oferece espaço de pesquisa para identificar quais métricas de avaliação para problemas de regressão são melhor aplicáveis para o problema em questão.



É importante ressaltar que há dois trabalhos que apresentam uma revisão dos métodos de previsão de consumo de energia em edifícios. [Zhao e Magoulès, 2012] apresentam um estudo de diversos artigos que comparam os modelos de engenharia, estatísticos e de inteligência artificial. Já [Ahmad et al., 2014] apresentam os métodos SVM, RNA e modelos híbridos em sua revisão da literatura. O diferencial deste trabalho em relação a esses dois está em (i) apresentar os métodos que podem ser utilizados, sua forma detalhada na implementação, e o objetivo da previsão — previsão geral para um edifício inteiro, ou previsão de itens específicos de consumo de energia, como ar condicionado, aquecimento, dentre outros; e (ii) apresentar o que vem sendo desenvolvido no Brasil, o que é considerado pouco em relação ao que se apresenta de estudos em outras partes do mundo.

Apesar da importância do tema, foi encontrado um único trabalho realizado no cenário nacional. Esta carência demonstra que é necessário realizar mais estudos sobre essas metodologias em nosso país. Como trabalhos futuros podem ser realizadas pesquisas de técnicas e métodos para implementação de dispositivos em edifícios brasileiros para coleta de informações para previsão de consumo em edifícios, pesquisas de métodos para melhorar a acurácia dos modelos apresentados em [Platon et al., 2015], [Dong et al., 2005], [Li et al., 2010], que tratam do consumo por hora, mensal e anual, respectivamente.

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.
- ANEEL (2008). *Atlas de Energia Elétrica do Brasil*. Disponível em <http://www2.aneel.gov.br/arquivos/PDF/atlas3ed.pdf>. Acessado em 15-04-2017.
- 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*. Acessado em: 17-02-2016.
- Cocchia, A. (2014). *Smart City: How to Create Public and Economic Value with High Technology in Urban Space*, chapter Smart and Digital City: A Systematic Literature Review (Chapter 2). Progress in IS Series, Springer Verlag.
- Coelho, V. N., Coelho, I. M., Coelho, B. N., Reis, A. J., Enayatifar, R., Souza, M. J., e Guimarães, F. G. (2016a). A self-adaptive evolutionary fuzzy model for load forecasting problems on smart grid environment. *Applied Energy*, 169:567–584.
- Coelho, V. N., Coelho, I. M., Rios, E., Alexandre Filho, S., Reis, A. J., Coelho, B. N., Alves, A., Netto, G. G., Souza, M. J., e Guimarães, F. G. (2016b). A hybrid deep learning forecasting model using gpu disaggregated function evaluations applied for household electricity demand forecasting. *Energy Procedia*, 103:280–285.
- 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.
- Faceli, K., Lorena, A., Gama, J., e Carvalho, A. (2011). *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*. LTC.



- González, P. A. e Zamarreno, J. M. (2005). Prediction of hourly energy consumption in buildings based on a feedback artificial neural network. *Energy and Buildings*, 37(6):595–601.
- Hamzacebi, C. e Es, H. A. (2014). Forecasting the annual electricity consumption of turkey using an optimized grey model. *Energy*, 70:165–171.
- Hou, Z. e Lian, Z. (2009). An application of support vector machines in cooling load prediction. In *Intelligent Systems and Applications, 2009. ISA 2009. International Workshop on*, p. 1–4. IEEE.
- IBGE (2016). Sistema IBGE de Recuperação Automática (SIDRA) — Censo Demográfico/Pessoas. Disponível em <https://sidra.ibge.gov.br/home/pms/brasil>. Acessado em: 21-02-2016.
- Jinhu, L., Xuemei, L., Lixing, D., e Liangzhong, J. (2010). Applying principal component analysis and weighted support vector machine in building cooling load forecasting. In *Computer and Communication Technologies in Agriculture Engineering (CCTAE), 2010 International Conference On*, volume 1, p. 434–437. IEEE.
- 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.
- 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.
- Kubota, N., Hashimoto, S., Kojima, F., e Taniguchi, K. (2000). Gp-preprocessed fuzzy inference for the energy load prediction. In *Evolutionary Computation, 2000. Proceedings of the 2000 Congress on*, volume 1, p. 1–6. IEEE.
- Lam, J. C., Wan, K. K., Liu, D., e Tsang, C. (2010). Multiple regression models for energy use in air-conditioned office buildings in different climates. *Energy Conversion and Management*, 51(12):2692–2697.
- 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.
- Li, Q., Ren, P., e Meng, Q. (2010). Prediction model of annual energy consumption of residential buildings. In *Advances in Energy Engineering (ICAEE), 2010 International Conference on*, p. 223–226. IEEE.
- Liao, G. C. (2014). Hybrid improved differential evolution and wavelet neural network with load forecasting problem of air conditioning. *International Journal of Electrical Power & Energy Systems*, 61:673–682.
- Liu, D. e Chen, Q. (2013). Prediction of building lighting energy consumption based on support vector regression. In *Control Conference (ASCC), 2013 9th Asian*, p. 1–5. IEEE.
- Moreira, M. (2015). Um estudo de caso para previsão de médio prazo de consumo de energia elétrica. Dissertação de Mestrado — Unicamp.
- Neto, A. H. e Fiorelli, F. A. S. (2008). Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption. *Energy and buildings*, 40(12): 2169–2176.



- OECD (2017). Governing Cities. Disponível em <http://www.oecd.org/gov/cities.htm>. Acessado em 07-04-2017.
- Olofsson, T. e Andersson, S. (2001). Long-term energy demand predictions based on short-term measured data. *Energy and Buildings*, 33(2):85–91.
- 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.
- Pérez-Lombard, L., Ortiz, J., e Pout, C. (2008). A review on buildings energy consumption information. *Energy and buildings*, 40(3):394–398.
- Platon, R., Dehkordi, V. R., e Martel, J. (2015). Hourly prediction of a building's electricity consumption using case-based reasoning, artificial neural networks and principal component analysis. *Energy and Buildings*, 92:10–18.
- Rocha, C., 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. In *CBRN — Congresso Brasileiro de Redes Neurais*.
- Santamouris, M., Papanikolaou, N., Livada, I., Koronakis, I., Georgakis, C., Argiriou, A., e Assimakopoulos, D. (2001). On the impact of urban climate on the energy consumption of buildings. *Solar energy*, 70(3):201–216.
- 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 Bettioli, 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).
- Wilson, A. (2013). Energy use by buildings. Publicado em 30 de maio de 2013. Disponível em <http://www.greenbuildingadvisor.com/blogs/dept/energy-solutions/energy-use-buildings>. Acessado em 07-04-2017.
- Xuemei, L., Lixing, D., Jinhu, L., Gang, X., e Jibin, L. (2010). A novel hybrid approach of KPCA and SVM for building cooling load prediction. In *Knowledge Discovery and Data Mining, 2010. WKDD'10. Third International Conference on*. IEEE.
- Yang, J., Rivard, H., e Zmeureanu, R. (2005). On-line building energy prediction using adaptive artificial neural networks. *Energy and buildings*, 37(12):1250–1259.
- Yu, Z., Haghghat, F., Fung, B. C., e Yoshino, H. (2010). A decision tree method for building energy demand modeling. *Energy and Buildings*, 42(10):1637–1646.
- 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.
- Zhao, H. e Magoulès, F. (2012). A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews*, 16(6):3586–3592.