

Previsão de Curto Prazo da Potência Ativa em Instalação de Médio Porte Utilizando um Conjunto de Redes Neurais Artificiais

Arthur Weyll*, Eduardo F. Simas Filho*, Kim Samejima† e Fabio da C. Cruz‡

*Programa de Pós Graduação em Engenharia Elétrica, PPGEE, Universidade Federal da Bahia - UFBA

E-mails: arthur.lucide@ufba.br, eduardo.simas@ufba.br

†Departamento de Estatística - Instituto de Matemática, UFBA

E-mail: samejimal@ufba.br

‡Department of Electrical and Computer Engineering, University of Québec at Trois-Rivières Trois-Rivières, QC, Canada

E-mail: fabio.da.conceicao.cruz@uqtr.ca

Resumo—A previsão de carga é um processo fundamental para uma operação confiável em sistemas elétricos de potência, principalmente em instalações que dispõem de sistemas de geração distribuída que podem ser dinamicamente integrados a rede. No entanto, equilibrar demanda e geração em tempo real não é uma tarefa fácil, devido à forte influência de fatores meteorológicos e variáveis exógenas na previsão da potência. Neste trabalho, é proposta a utilização de conjuntos de redes neurais artificiais para a previsão de potência consumida em uma instalação de médio porte no horizonte de 15 minutos a frente. Arquiteturas tipo perceptron de múltiplas camadas e rede de função de base radial foram utilizadas e os resultados comparados com modelos ARIMA e de Persistência. Os erros médio absoluto (MAE) e médio absoluto percentual (MAPE) foram utilizados para avaliar e comparar o desempenho dos preditores. As combinações de redes neurais artificiais propostas registraram MAPE menor que 3% e MAE máximo menor que 21 kW para todos os conjuntos de testes no horizonte de previsão de 15 minutos.

Palavras-chave—Previsão de carga, demanda, geração, tempo real, conjunto de redes neurais artificiais.

I. INTRODUÇÃO

A previsão da potência ativa é essencial para minimizar os custos operacionais e aumentar a confiabilidade de sistemas de potência que empregam redes inteligentes. Dispondo de uma previsão de carga confiável, é possível preparar o sistema para suprir de forma otimizada a demanda futura [1]. Propor um modelo de previsão preciso é uma tarefa difícil, pois variáveis exógenas (impacto humano, eventos sociais e culturais em um determinado dia) e variáveis meteorológicas (temperatura e umidade relativa) podem aumentar os erros na previsão [2].

Duas técnicas de otimização do consumo de energia comumente aplicadas em sistemas de potência são: o gerenciamento pelo lado da demanda (GLD) e a previsão de demanda. Na primeira, como exemplo de uma das técnicas do GLD, ações de planejamento, implementação e monitoramento são combinadas para remanejar a utilização das cargas para horários em que a geração de energia torna o consumo favorável. Dessa forma, é possível alterar o perfil e a magnitude da curva de carga nos horários de pico, período no qual a energia elétrica é

mais cara. Nesse âmbito, o GLD se apresenta como uma ferramenta muito interessante, gerando melhorias no desempenho do sistema elétrico e benefícios para o consumidor [3].

As redes inteligentes (*smart grids*) são componentes essenciais nos sistemas de energia mais novos [4]. Sistemas distribuídos, com produção de energia volátil (solar e eólica), necessitam de gerenciamento para que a parcela de energia gerada disponível seja utilizada de forma eficiente [5]. Com a possibilidade de fluxo bidirecional de dados e energia, as redes inteligentes possibilitam monitorar o consumo e o fluxo de potência das cargas conectadas a ela em tempo real.

O conceito de previsão de potência de curto prazo (com horizontes de até um dia) tem sido amplamente tratado devido ao seu impacto na confiabilidade dos sistemas de energia [1].

O tema previsão de demanda é tratado desde o final dos anos 60 [6]. Os métodos mais tradicionais que tratam do problema são baseados em modelos matemáticos e análises de regressão [7]. Estudos recentes empregam filtros de *Kalman* [8], método autorregressivo integrado de médias móveis (ARIMA) [9], modelo de espaços de estados [10] e modelo *Box-Jenkins* [11].

Os métodos baseados em inteligência artificial também são muito aplicados na área de previsão de potência, dentre eles, estão inclusos modelos combinados de redes neurais artificiais [2], redes neurais de base radial [12], métodos de inferência *fuzzy* [13], [14], algoritmos genéticos [15], computação evolucionária [16], regressão de vetor de suporte (SVR) [17], etc.

No âmbito das diversas metodologias e modelos, destacam-se as redes neurais, que possuem aplicações em quase todos os campos das Ciências. As redes neurais tem sido aplicadas em diversos modelos de classificação e predição. Esta técnica tem recebido grande destaque devido ao desempenho superior quando comparadas a outros sistemas [18], [19], [20].

Neste trabalho, será realizada previsão de potência de curta duração utilizando dados da Potência Ativa de uma Universidade no estado da Bahia utilizando modelos combinados de redes neurais para prever no horizonte de 15 minutos à frente. A concessionária de energia local integraliza e registra as medições de potência a cada 15 minutos, devido a este fato

e por ser um intervalo de tempo satisfatório para preparar um sistema elétrico para uma carga futura, o horizonte foi escolhido para a pesquisa. Em primeira instância, será realizada uma análise da série temporal de potências para selecionar os parâmetros de entrada dos modelos preditores. Os métodos ARIMA e de Persistência também foram aplicados e os resultados serão comparados com os modelos combinados.

A Figura 1 mostra um esquema simples de um sistema elétrico que emprega uma rede inteligente.

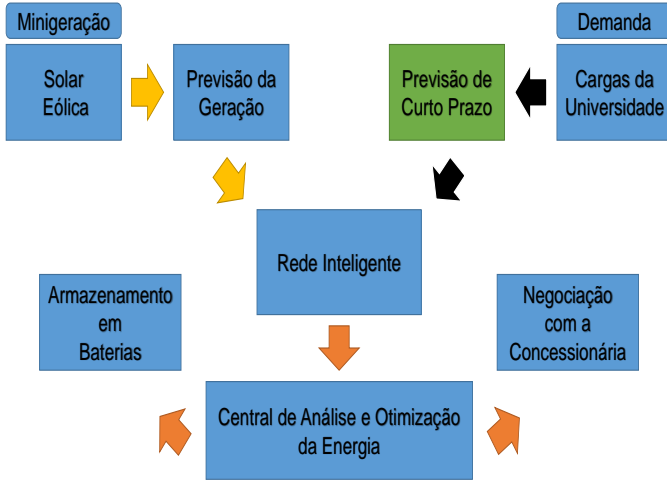


Figura 1. Esquema elétrico com emprego de previsão de potência de curto prazo e rede inteligente.

A Figura 1 foi utilizada para identificar o ponto de aplicação deste trabalho em um sistema elétrico com uma rede inteligente. É necessário salientar que é um esquema meramente ilustrativo, visto que a universidade não possui nenhum tipo de minigeração.

Este trabalho propõe diferentes métodos para tratar o problema da previsão de potência de curto prazo e mostra como a combinação de redes neurais pode melhorar a eficiência da previsão. O *ensemble* ou combinação trata-se de juntar redes neurais e treiná-las com os mesmos dados para solucionar uma única tarefa, combinando suas saídas em uma única saída para o conjunto.

II. MÉTODOS DE PREVISÃO DE DEMANDA

A. Redes Neurais Artificiais Feedforward

Inspiradas na estrutura do cérebro humano, as redes neurais foram criadas para processar informações. Neste aspecto, são excelentes ferramentas para encontrar o melhor mapeamento entrada-saída de dados observados durante a etapa de treinamento [2]. As redes utilizadas neste trabalho são as *feedforward* e as redes de base radial, com os pesos do treinamento determinados por algoritmos de otimização iterativa por gradiente descendente. A estrutura mais simples de redes neurais preparada para realizar tarefas de previsão utiliza atrasos da série temporal como entrada, considerando um mapeamento da seguinte forma:

$$x_t = f(x_{t-1} + \dots + x_{t-N}, w) + e_t \quad (1)$$

Onde x_t representa o valor da série temporal x no instante t no qual as previsões serão realizadas, w representa os pesos e e_t o erro associado.

As redes neurais *feedforward* utilizadas são formadas por três camadas, camada de entrada, camada oculta e camada de saída. Os dados vão sempre para frente, até alcançar a saída. A Figura 2 mostra uma rede neural *feedforward*.




Figura 2. Estrutura da rede *feedforward* utilizada.

Na Figura 2, as elipses representam os neurônios, x_{t-n} representam as entradas, x_t a saída, v_{ij} os pesos entre as entradas e a camada oculta e w_{ij} os pesos entre a camada oculta e a camada de saída.

As redes neurais artificiais utilizadas neste trabalho foram criadas com a seguinte estrutura:

- Uma camada oculta e um neurônio na saída;
- Função de ativação *Log-sigmoid*;
- Algoritmo de treino *Levenberg-Marquadt*.

A seleção dos atrasos temporais será feita na seção IV, no apêndice A e o número de neurônios na camada oculta no apêndice B.

B. Redes Neurais Artificiais de Base Radial

A rede neural de base radial (RB - *Radial Basis*) é muito utilizada na previsão de séries temporais não lineares e possui a mesma estrutura de entrada e saída da rede *feedforward*, a diferença entre as duas está na camada oculta [21]. A camada oculta de uma rede RB possui neurônios cuja função de ativação é de base radial. A gaussiana é uma função RB muito utilizada e pode ser expressa da seguinte forma:

$$R(x_p - c_i) = e^{\left(-\frac{1}{2(\sigma_j)^2} \|x_p - c_i\|^2\right)} \quad (2)$$

onde: $\|x_p - c_i\|$ é a distância euclidiana, c e σ são o centro e o desvio padrão da função gaussiana. O termo $\frac{1}{2(\sigma_j)^2}$ representa a constante de espalhamento da função gaussiana de base radial. O erro médio quadrático máximo permitido no treino, o número máximo de neurônio da camada oculta da rede que será criada e a constante de espalhamento são os três parâmetros ajustáveis no treinamento das redes RBF implementadas neste trabalho.

A Figura 3 mostra uma rede neural de base radial, a segunda proposta de redes utilizadas como preditores.

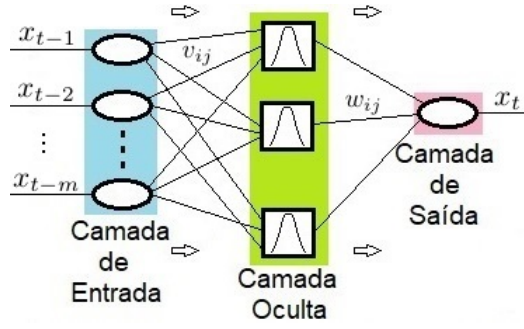


Figura 3. Diagrama de uma Rede RB.

Na Figura 3, as elipses representam os neurônios da camada de entrada e saída, os quadrados os neurônios RB, x_{t-m} representam as entradas, x_t a saída, v_{ij} os pesos entre as entradas e a camada oculta e w_{ij} os pesos entre a camada oculta e a camada de saída.

1) O Modelo do Neurônio de Base Radial: O neurônio de base radial pode ser representado pela Figura 4:




Figura 4. Modelo de um neurônio de base radial.

Na Figura 4, p representa o vetor de entradas, w representa o vetor de pesos, b o *bias* e a a saída do neurônio.

Na RBF, a função de base radial recebe como entrada o vetor distância entre o vetor peso w e o vetor de entradas p , multiplicado pelo *bias* b . A função de base radial entrega 1 para a saída a quando recebe 0 na entrada, e isso acontece quando a diferença entre o vetor de peso w e o vetor de entrada p é 0.

C. Combinação (Ensemble) de Redes Neurais

Redes Neurais podem ser combinadas para conseguir melhores resultados do que uma única rede. A ideia deste método é treinar mais de uma rede para um mesmo problema e combinar suas saídas para melhorar a previsão de potência [22]. A combinação das M redes utilizada neste trabalho foi feita a partir da média aritmética das saídas (y_i):

$$\hat{y}_{ens}(\mathbf{x}_t) = \frac{1}{M} \sum_{i=1}^M \hat{y}_i(\mathbf{x}_t) \quad (3)$$

A Figura 5 mostra um esquema de combinação de redes neurais.

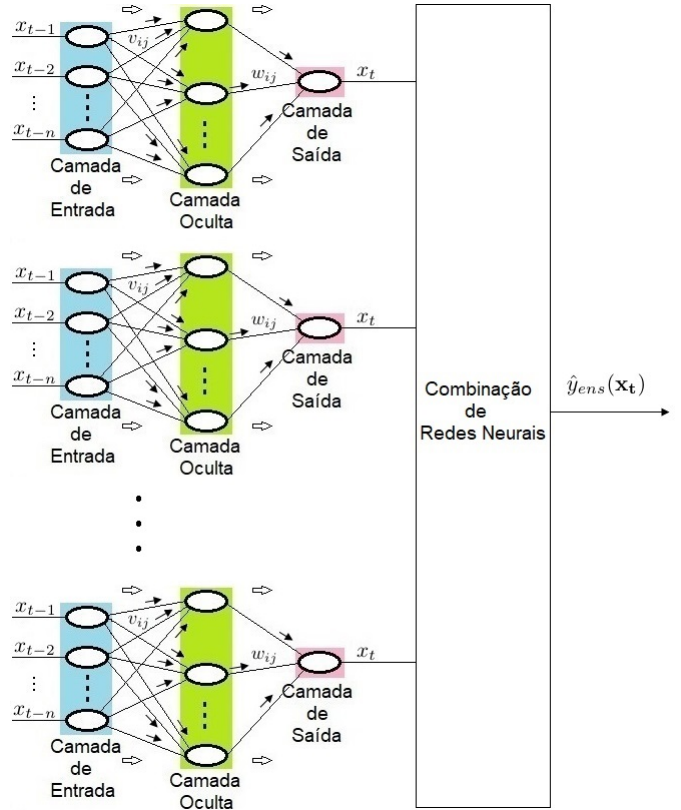


Figura 5. Combinação de Redes Neurais alimentadas para frente.

D. Modelo ARIMA

Um modelo de séries temporais é certamente a primeira escolha quando se trata de algum problema de previsão. O modelo ARIMA (auto-regressivo integrado de médias móveis, do inglês *autoregressive integrated moving average*) considera a não estacionariedade dos dados e foi apresentado no trabalho de Box e Jenkins [23]. Nesse modelo, valores futuros de um determinado conjunto de dados são representados como uma função linear das observações passadas mais um erro (com média zero e variância finita). Uma vez introduzido o operador de atraso e operador da n -ésima diferença:

$$B^k x_t = x_{t-k} \quad (4)$$

$$\Delta^n x_t = (1 - B)^n x_t \quad (5)$$

o modelo ARIMA não sazonal de ordem (p,d,q) representando a série temporal pode ser expresso como:

$$\phi(B) \Delta^d x_t = \theta(B) e_t \quad (6)$$

onde x_t são os valores da série temporal no tempo t , e_t são os resíduos estimados, B representa o operador de atrasos, $\Delta^d = (1 - B)^d$, d é a ordem de diferenças regulares, $\phi(B)$ e $\theta(B)$ são definidos como $\phi(B) = 1 - \phi_1 B - \phi_2 B^2, \dots, -\phi_p B^p$ e $\theta(B) = 1 - \theta_1 B - \theta_2 B^2, \dots, -\theta_q B^q$. Particularmente, assume-se que e_t é uma variável aleatória normal, independente e

identicamente distribuída com média zero e variância finita, e que as raízes de $\phi(x) = 0$ e $\theta(x) = 0$ estão situadas fora do círculo unitário [24]. Usando a segunda expressão, de forma similar, um modelo sazonal pode ser escrito da seguinte forma:

$$\phi(B)\psi(B^s)\nabla_s^D\Delta^d x_t = \theta(B)\Theta(B^s)e_t, \quad (7)$$

onde $\Psi(B^s) = 1 - \Psi_1 B^s - \Psi_2 B^{2s} - \dots - \Psi_P B^{Ps}$, $\Theta(B^s) = 1 - \Theta_1(B^s) - \Theta_2(B^{2s}) - \dots - \Theta_Q(B^{Qs})$, D é o número de diferenças sazonais e s é o período. Se a série temporal tem média $\mu \neq 0$, é necessário substituir x_t por $x_t - \mu$.

1) *Diferenciação da Série*: A diferenciação é uma técnica aplicada nos dados de séries temporais afim de tornar a série estacionária [23]. Sendo uma série temporal estacionária, suas propriedades não dependem do tempo em que a mesma está sendo observada [25]. De forma simples, a primeira diferenciação de uma série pode ser equacionada da seguinte forma:

$$\Delta x_t = (1 - B)x_t = x_t - x_{t-1} \quad (8)$$

onde Δx_t representa o resíduo da primeira diferença da série, x_t representa a série temporal e x_{t-1} o primeiro atraso da série.

O processo de diferenciação elimina mudanças no nível da série temporal, removendo tendências e sazonalidade e como consequência, estabiliza a média da mesma [23]. Dentro deste processo, a diferenciação sazonal também é realizada, tomando a diferença entre uma observação e a observação onde o caráter sazonal se repete. A diferenciação sazonal pode ser equacionada da seguinte forma:

$$\Delta x_t = (1 - B^s)x_t = x_t - x_{t-s} \quad (9)$$

onde s é a observação em que o caráter sazonal se repete.

Os dados da série diferenciada são utilizados para a estimar um modelo ARIMA.

2) *Identificação do Modelo*: Uma forma comum de se identificar o modelo é analisar as funções de autocorrelação (*Autocorrelation Function - ACF*) e autocorrelação parcial (*Partial Autocorrelation Function - PACF*) da série, elas são ferramentas usadas para verificar o desempenho e a especificação dos modelos de séries temporais [26]. A ACF descreve a correlação entre dois termos da série que ocorrem em tempos diferentes e pode ser equacionada da seguinte forma:

$$\rho_t = cov(X_t, X_{t+\tau}) \quad (10)$$

onde k é inteiro, tal que $-\infty \leq k \leq \infty$.

A PACF descreve a correlação entre dois valores da série desconsiderando a influência dos termos intermediários e pode ser equacionada da seguinte forma:

$$\phi_{hh} = corr(X_t - \hat{x}_t, X_{t+h} - \widehat{x_{t+h}}) \quad (11)$$

onde \hat{x}_t é o efeito linear de $x_{t+1}, \dots, x_{t+h-1}$ em X_t e $\widehat{x_{t+h}}$ é o efeito linear de $x_{t+1}, \dots, x_{t+h-1}$ em X_{t+h} .

Para identificar o modelo, em [27], os autores relacionam os seguintes padrões das funções de ACF e PACF que classificam o comportamento das séries temporais:

- Não estacionariedade: a ACF decai de forma lenta e a PACF exibe valor significativo (positivo ou negativo) no atraso 1;
- Não estacionariedade sazonal: a ACF é próxima de zero, exceto nos atrasos $s, 2s, \dots$ e também decai de forma lenta. A série pode se tornar estacionária através da diferenciação sazonal;
- Comportamento autorregressivo: a PACF é diferente de zero para os atrasos $1, 2, \dots, p$ e zero para os demais;
- Comportamento autorregressivo sazonal: a PACF é diferente de zero para os atrasos $s, 2s, \dots$ e zero para os demais;
- Comportamento média móvel: a ACF é diferente de zero para os atrasos $1, 2, \dots, q$ e zero para os demais;
- Comportamento média móvel sazonal: a ACF é diferente de zero para os atrasos $s, 2s, \dots$ e zero para os demais.

E. Modelo de Persistência

O modelo de Persistência é um método simples de previsão [28] e pode ser equacionado da seguinte forma:

$$x_t = x_{t-S} \quad (12)$$

este modelo entrega como resultado da previsão no tempo t , o valor observado exatamente no período de S passos anteriores.

A Figura 6 ilustra graficamente a previsão utilizando o método.



Figura 6. Previsão utilizando o método de persistência.

A curva de previsão do modelo de Persistência nada mais é do que a própria série deslocada de S passos a frente.

III. METODOLOGIA PROPOSTA

Os dados utilizados neste trabalho contemplam o intervalo de medições de potência ativa das instalações elétricas da universidade de março de 2014 a março de 2015. Os registros foram fornecidos pela concessionária de energia elétrica local. Na Figura 7, foi plotado o conjunto de dados utilizado.

Na Figura 7, pode-se notar que nos meses mais frios (junho, julho e agosto) a potência ativa mostrou valores mais baixos,




Figura 7. Potência Ativa da universidade de março de 2014 a março de 2015.

com destaque para o mês de julho, que além de frio é um período de férias, e a potência durante todo o mês não ultrapassou 1.000 kW. Na Tabela I o valor mínimo de toda a série histórica foi encontrado em Agosto. Os parâmetros da potência ativa estão apresentados na Tabela I.

Tabela I
PARÂMETROS DA POTÊNCIA ATIVA INSTANTÂNEA (MARÇO DE 2014 A MARÇO DE 2015)

Parâmetros	Mês	Dados da Potência Ativa (kW)
Máximo	Março/2015	1.868,2
Mínimo	Agosto	240,8
Número de Amostras		23.808

O conjunto de dados possui integralização (intervalo de registro) de medidas de quinze minutos, sendo um total de 96 amostras por dia. Para este artigo, foram utilizados os dados do dia 06/03/2014 às 00:00h ao dia 31/03/2015 às 23:45h.

Neste trabalho, as previsões são focadas no horizonte de 15 minutos a frente (1 passo) visando alocar dinamicamente de forma otimizada a parcela gerada disponível. Sendo 15 minutos o menor intervalo entre medidas de potência, é possível realizar previsões de curto prazo precisas para preparar um sistema para uma carga futura visando a máxima economia.

Como primeiro passo, foi feito um pré processamento dos dados com o objetivo de condicioná-los antes da separação em conjuntos (treino e teste). Inicialmente os *outliers*, registros onde a potência decaiu para zero foram removidos utilizando suavização por médias móveis. Na suavização, os registros foram substituídos pela média dos sete termos anteriores. Os fins de semana e feriados também foram removidos, com base no calendário da instituição. Dias atípicos, nos quais a curva de potência ativa muda muito em relação ao padrão esperado foram mantidos.

Após o tratamento inicial e seleção dos parâmetros de entrada, foram definidos os conjuntos de treino e teste. Para o treino, concatenou-se os dados das três primeiras semanas dos meses de março de 2014 a março de 2015. Para o teste, foram organizados 13 conjuntos, cada um correspondendo aos dados da última semana de cada mês. O conjunto de teste foi utilizado para teste e para validação. A Figura 11 ilustra o processo de separação dos conjuntos.

Os conjuntos (treino e teste) foram normalizados com base no maior valor de potência ativa do conjunto de treino.




Figura 8. Separação dos conjuntos de treino e teste.

A função de ativação e algoritmo de treino utilizados na criação dos preditores foram respectivamente *Log-sigmoid* e *Levenberg-Marquadt*.

A. Erros de Previsão

O desempenho da previsão dos modelos foi avaliado neste trabalho por meio dos erros definidos pelas equações (10) e (11) [29]:

1) Erro Médio Absoluto (MAE):

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (13)$$

2) Erro Médio Absoluto Percentual (MAPE):

$$MAPE(y, \hat{y}) = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (14)$$

onde, y_t representa o valor real da medição, \hat{y}_t o valor predito e n a quantidade de amostras.

IV. RESULTADOS

A. Seleção dos Parâmetros de Entrada

Os parâmetros de entrada dos preditores foram definidos após a identificação do modelo ARIMA, através da análise das sequências de autocorrelação (*Autocorrelation Function - ACF*) e autocorrelação parcial (*Partial Autocorrelation Function - PACF*) da série. A Figura 8 mostra as sequências de autocorrelação e autocorrelação parcial da série para 1000 atrasos.




Figura 9. ACF e PACF da série temporal para 1000 atrasos.

Da Figura 8, observa-se que a amplitude da ACF decai lentamente e a PACF mostra valor significativo no primeiro

atraso, o que é comportamento típico de uma série não estacionária. Na tentativa de tornar a série estacionária, tomou-se a primeira diferença, da seguinte forma:

$$\Delta x_t = x_t - x_{t-1} \quad (15)$$

A Figura 9 mostra as funções de ACF e PACF da série temporal diferenciada para 1000 atrasos.




Figura 10. ACF e PACF da série temporal diferenciada para 1000 atrasos.

Da Figura 9, observou-se os quatro primeiros atrasos com magnitudes diferentes de zero e a série se acomodando com alguns picos sazonais, dessa forma identificou-se um modelo autorregressivo AR(4) na PACF. Na ACF da Figura 9, nota-se que a série diferenciada possui atrasos sazonais que não decaem para zero, e que a cada 96 atrasos a magnitude mostra picos, portanto, existe também uma diferença sazonal. Na tentativa de tirar a sazonalidade da série e identificar o modelo, tomou-se a diferença sazonal de atraso 96. A Figura 10 mostra as funções de ACF e PACF da série de diferenças sazonais para 1000 atrasos.




Figura 11. ACF e PACF para 1000 atrasos da série de diferenças sazonais.

Analisando a Figura 10, a série de diferenças sazonais possui um comportamento de um modelo MA(1), com a ACF mostrando magnitude diferente de zero no atraso 1 e zero para os demais atrasos até o atraso 96 e em seguida é igual a zero até o fim da ACF. Dessa forma, o modelo utilizado foi um ARIMA (4, 1, 0) × (0, 1, 1).

A partir do estudo das funções de ACF e PACF e da tomada das diferenças da série temporal, os atrasos selecionados para os preditores foram:

- $L = [1, 2, 3, 4, 96, 97]$.

B. Treino das Redes Feedforward

Definidos os conjuntos, foram treinadas 5 RNAs. A quantidade de neurônios na camada oculta foi definida posteriormente, variando-se os neurônios de 3 em 3 até 45 e avaliando o MAPE médio das 5 redes para todos os conjuntos de teste. Seguindo essa metodologia, as Figuras 12 e 13 foram geradas para o horizonte de previsão de 15 minutos.




Figura 12. Variação dos neurônios na camada oculta.

Na Figura 12, os círculos negros representam o ponto de erro mínimo de cada curva ou conjunto de teste.




Figura 13. Box plot dos dados da Figura 7.

Considerando a menor média e o menor intervalo de variação na amplitude das curvas baseado nas Figuras 12 e 13, foi selecionada a rede de 30 neurônios na camada oculta para o horizonte de 15 minutos.

C. Treino das Redes RBF

Foram treinadas 5 redes RBF para o horizonte de previsão de 15 minutos. No treino, define-se:

- Número máximo de neurônios de base radial na camada oculta;
- Erro médio quadrático (MSE) máximo de treinamento;
- Constante de espalhamento da função de ativação dos neurônios.

As redes foram criadas definindo a quantidade máxima de neurônios na camada oculta como 200 e erro médio quadrático de treinamento 0,00018. A função de criação das RBFs adiciona neurônios na camada oculta até que o valor do MSE definido no treino seja atingido. Nesse processo, caso o total de neurônios definidos já tenham sido alocados e o MSE não tenha sido alcançado, a rede é criada com o número máximo de neurônios, dando fim ao treino. Para o horizonte

de previsão de 15 minutos, as configurações das redes RBF foram descritas na Tabela II.

Tabela II
CONFIGURAÇÃO DAS REDES RBF

Horizonte de Previsão: 15 minutos	
Constante de Espalhamento	Número de Neurônios
1	25
2	23
3	27
4	23
5	27

A Tabela III mostra os erros médios das cinco redes e os erros do modelo combinado de redes *Feedforward* para o horizonte de previsão de 15 minutos.

Tabela III
ERROS DA PREVISÃO DAS REDES *Feedforward*, HORIZONTE DE PREVISÃO DE 15 MINUTOS.

Teste	MAE		MAPE(%)	
	Média	Ensemble	Média	Ensemble
Mar	18,07	17,45	2,54	2,48
Abr	16,17	15,63	2,55	2,48
Mai	15,66	15,30	2,48	2,43
Jun	13,16	12,98	2,41	2,38
Jul	11,50	11,37	2,43	2,41
Ago	13,34	13,19	2,16	2,13
Set	14,72	14,60	2,31	2,30
Out	14,89	14,72	2,12	2,09
Nov	14,25	13,96	1,89	1,86
Dez	13,70	13,28	2,89	2,82
Jan15	14,93	14,68	2,34	2,31
Fev15	19,90	19,27	2,75	2,69
Mar15	18,26	17,34	2,03	1,96

A Tabela IV mostra os erros médios das cinco redes e os erros do modelo combinado de redes RBF.

Tabela IV
ERROS DA PREVISÃO DAS REDES RBF, HORIZONTE DE PREVISÃO DE 15 MINUTOS.

Teste	MAE		MAPE(%)	
	Média	Ensemble	Média	Ensemble
Mar	19,26	19,01	2,72	2,70
Abr	16,90	16,80	2,70	2,68
Mai	15,89	15,80	2,57	2,55
Jun	12,89	12,83	2,39	2,38
Jul	11,55	11,49	2,48	2,46
Ago	13,32	13,27	2,18	2,17
Set	15,04	15,00	2,38	2,38
Out	15,30	15,23	2,20	2,18
Nov	14,68	14,57	1,97	1,96
Dez	13,71	13,60	2,92	2,90
Jan15	15,25	15,19	2,42	2,41
Fev15	20,77	20,60	2,89	2,87
Mar15	18,21	17,93	2,08	2,06

A Tabela V mostra o MAE e MAPE dos métodos ARIMA e de persistência para o horizonte de previsão de 15 minutos.

Das Tabelas III e IV, nota-se que os modelos combinados de redes, de forma geral mostraram desempenho melhor do que a média dos erros das cinco redes.

Tabela V
ERROS DA PREVISÃO DOS MÉTODOS ARIMA E DE PERSISTÊNCIA, HORIZONTE DE PREVISÃO DE 15 MINUTOS.

Teste	ARIMA		Persistência	
	MAE	MAPE(%)	MAE	MAPE(%)
Mar	115,05	16,92	25,98	3,53
Abr	184,91	28,32	25,78	3,63
Mai	84,21	12,58	22,80	3,44
Jun	152,88	24,15	18,01	3,36
Jul	31,19	6,49	15,85	3,27
Ago	90,92	16,53	21,78	3,56
Set	112,94	15,72	24,47	3,77
Out	130,87	17,75	26,33	3,74
Nov	170,78	20,34	29,20	3,74
Dez	80,82	18,37	17,58	3,65
Jan15	128,91	18,10	24,55	3,70
Fev15	285,59	35,42	33,53	4,39
Mar15	109,64	11,81	34,63	3,96

Nota-se também, que os modelos combinados de redes neurais mostraram desempenho similar em todos os conjuntos de teste, mas as redes *feedforward* apresentaram melhor desempenho. Da Tabela V em relação às demais, nota-se que os métodos de persistência e ARIMA registraram os maiores erros e que o ARIMA foi o que mostrou o pior desempenho.

A Figura 14 mostra a curva real e as curvas de previsão dos modelos de persistência, ARIMA e modelos combinados de redes *feedforward* e RB.




Figura 14. Curvas da previsão de potência do mês de março de 2014, horizonte de previsão de 15 minutos.

A Figura 15 mostra o erro absoluto dos modelos em relação à curva real.




Figura 15. Curvas do erro absoluto do mês de março de 2014, horizonte de previsão de 15 minutos.

É importante destacar na Figura 14 que mesmo contendo um dia atípico (sexta 28/03), os modelos combinados propostos e o modelo de persistência foram robustos, com MAPE e MAE

menores do que 3% e 21 kW nos modelos combinados de redes neurais e menores do que 4,5% e 35 kW no modelo de persistência. O conjunto de teste do mês de Fevereiro de 2015 mostrou os maiores valores para o MAE entre os demais de uma forma geral, pois além de conter um dia atípico na última semana, contém também *outliers* nas curvas de carga. O ARIMA não foi capaz de seguir a tendência da curva de potência nos dias atípicos, presentes na maioria dos conjuntos de testes, e portanto teve o pior desempenho dos preditores.

Da Figura 15, nota-se que o modelo de persistência e o método ARIMA mostraram os maiores erros absolutos, com modelo de persistência registrando picos de erros maiores que 200 kW e o ARIMA no dia atípico registrando erros maiores que 500 kW. As combinações de redes neurais mostraram-se robustas, registrando baixos valores de erro absoluto de uma forma geral.

V. CONCLUSÕES

As combinações dos modelos de redes neurais artificiais propostos neste trabalho registraram MAPE menor que 3% e MAE máximo menor do que 21 kW para todos os conjuntos de testes no horizonte de previsão de 15 minutos. O modelo de persistência, apesar de ser um modelo simples, apresentou um bom desempenho para o horizonte de previsão de 15 minutos, com erros MAPE e MAE menores do que 4,5% e 35 kW. O ARIMA, por não ter apresentado um bom desempenho na previsão das curvas de potência nos dias atípicos registrou os maiores erros e mostrou o pior desempenho entre os preditores aplicados no trabalho. Apesar de bom desempenho, o modelo de persistência mostrou picos de erro absoluto atingindo magnitudes superiores a 200 kW, o que reforça a ideia da aplicação de métodos mais robustos. Como prospecção de trabalhos futuros pretende-se avaliar o desempenho de redes realimentadas na tarefa de previsão.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, do CNPq e da FAPESB.

REFERÊNCIAS

- [1] Raza, M. Q., Nadarajah, M., Hung, D. Q., Baharudin, Z., "An intelligent hybrid short-term load forecasting model for smart power grids," *Sustainable Cities and Society* 31 (2017): 264-275.
- [2] De Felice, M., Yao, X., "Short-term load forecasting with neural network ensembles: A comparative study," *IEEE Computational Intelligence Magazine*, 6(3), 47-56, 2011.
- [3] Zortea, A., Fardin, J., Rocha, H., Fiorotti, R., "Gerenciamento pelo lado da demanda aplicado à sistemas industriais: metodologias e desafios." XLIX Simpósio Brasileiro de Pesquisa Operacional, 2017.
- [4] Wietfeld, C., Cardenas, A. A., Chen, H. H., Popovski, P., & Wong, V. W., "Smart Grids." *IEEE Wireless Communications*, 24(2), 8-9, 2017.
- [5] Jun, Z., Junfeng, L., Jie, W., & Ngan, H. W., "A multi-agent solution to energy management in hybrid renewable energy generation system." *Renewable Energy*, 36(5), 1352-1363, 2011.
- [6] Ghadimi, N., Akbarimajd, A., Shayeghi, H., & Abedinia, O., "A new prediction model based on multi-block forecast engine in smart grid." *Journal of Ambient Intelligence and Humanized Computing*, 9(6), 1873-1888, 2018.

- [7] Liu, Yang, Wei Wang, and Noradin Ghadimi. "Electricity load forecasting by an improved forecast engine for building level consumers." *Energy* 139 (2017): 18-30.
- [8] Zhang, Min, et al. "Research on processing of short-term historical data of daily load based on Kalman filter." *Power System Technology* 10.009 (2003): 200.
- [9] Wei, Li, and Zhang Zhen-gang. "Based on time sequence of ARIMA model in the application of short-term electricity load forecasting." 2009 International Conference on Research Challenges in Computer Science. IEEE, 2009. p. 11-14.
- [10] Akbary, Paria, et al. "Extracting appropriate nodal marginal prices for all types of committed reserve." *Computational Economics* 53.1 (2019): 1-26.
- [11] Meslier, F. "New advances in short term load forecasting using Box and Jenkins approach." *IEEE PES Winter Meeting*, 1978. 1978.
- [12] Zhao, Bing, et al. "Short-Term Load Forecasting Based on RBF Neural Network." *Journal of Physics: Conference Series*. Vol. 1069. No. 1. IOP Publishing, 2018. p. 012091.
- [13] Ghadimi, Noradin, et al. "Application of a new hybrid forecast engine with feature selection algorithm in a power system." *International Journal of Ambient Energy* (2017): 1-10.
- [14] Morsali, Roozbeh, et al. "A new multiobjective procedure for solving nonconvex environmental/economic power dispatch." *Complexity* 20.2 (2014): 47-62.
- [15] Sharifi, Shokoufeh, et al. "Environmental economic dispatch using improved artificial bee colony algorithm." *Evolving Systems* 8.3 (2017): 233-242.
- [16] Unsihuay-Vila, C., et al. "Electricity demand and spot price forecasting using evolutionary computation combined with chaotic nonlinear dynamic model." *International journal of electrical power and energy systems* 32.2 (2010): 108-116.
- [17] Gollou, Abbas Rahimi, and Noradin Ghadimi. "A new feature selection and hybrid forecast engine for day-ahead price forecasting of electricity markets." *Journal of Intelligent and Fuzzy Systems* 32.6 (2017): 4031-4045.
- [18] Neto, A. H., Fiorelli, F. A. S., "Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption." *Energy and buildings*, 40(12), 2169-2176, 2008.
- [19] Aydinalp-Koksal, M., Ugursal, V. I., "Comparison of neural network, conditional demand analysis, and engineering approaches for modeling end-use energy consumption in the residential sector," *Applied Energy*, 85(4), 271-296, 2008.
- [20] Belshaw, M., Taati, B., Snoek, J., Mihailidis, A., "Towards a single sensor passive solution for automated fall detection." In *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE* (pp. 1773-1776). IEEE, 2011.
- [21] Wu, X., Hong, B., Peng, X., Wen, F., Huang, J., "Radial basis function neural network based short-term wind power forecasting with Grubbs test." In *Electric Utility Deregulation and Restructuring and Power Technologies (DPRT), 2011 4th International Conference on IEEE* (pp. 1879-1882). IEEE.
- [22] Saviozzi, M., S. Massucco, and F. Silvestro. "Implementation of advanced functionalities for Distribution Management Systems: Load forecasting and modeling through Artificial Neural Networks ensembles." *Electric Power Systems Research* 167 (2019): 230-239.
- [23] Box, George EP, et al, "Time series analysis: forecasting and control," John Wiley & Sons, 2015.
- [24] Tseng, Fang-Mei, Hsiao-Cheng Yu, and Gwo-Hsiung Tzeng. "Combining neural network model with seasonal time series ARIMA model." *Technological forecasting and social change* 69.1 (2002): 71-87.
- [25] Shumway, Robert H., and David S. Stoffer, "Time series analysis and its applications: with R examples," Springer, 2017.
- [26] Gruginiskie, L., "Proposta de função executável em R para ajuste de modelos ARIMA (P,D,Q)," XXX Encontro Nacional de Engenharia de Produção, 2010.
- [27] Shumway, Robert H., and Lauren Kelly, "Applied statistical time series analysis," Englewood Cliffs, NJ: Prentice-Hall, 1988.
- [28] Nagbe, K., Cugliari, J., & Jacques, J., "Short-term electricity demand forecasting using a functional state space model." *Energies*, 11(5), 1120, 2018.
- [29] Vazquez, R., Amaris, H., Alonso, M., Lopez, G., Moreno, J. I., Olmeda, D., Coca, J., "Assessment of an adaptive load forecasting methodology in a smart grid demonstration project," *Energies*, vol. 10, no. 2, pp. 190, 2017.