

Modelos de Previsão de Carga: Abordagens imunoinspiradas baseadas em Similaridade de Padrões

Guilherme Costa Silva¹, Adriano C. Lisboa², Douglas A. G. Vieira³,
Cristiano L. Castro⁴, and Rodney R. Saldanha⁴

¹ Programa de Pós Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais - Av. Antônio Carlos, 6627 31270-901, Belo Horizonte, MG, Brazil

`guicosta@ufmg.br`

² Gaia Solutions on Demand - Rua Professor José Vieira Mendonça, 770, 31270-901, Belo Horizonte, MG, Brasil

`adriano.lisboa@gaiasd.com`

³ ENACOM Handcrafted Technologies - Rua Professor José Vieira Mendonça, 770, 31270-901, Belo Horizonte, MG, Brasil

`douglas.vieira@enacom.com.br`

⁴ Departamento de Engenharia Elétrica - Universidade Federal de Minas Gerais - Av. Antônio Carlos, 6627 31270-901, Belo Horizonte, MG, Brazil

`{crislcastro,rodney}@cpdee.ufmg.br`

Abstract. O problema de previsão de carga a curto prazo consiste em estimar a demanda futura de um período de até uma semana e possui fundamental importância nas operações de um sistema elétrico. Tal problema pode ser modelado em termos de similaridades de padrões, permitindo o uso de algoritmos de regressão baseados em aprendizado de máquina aplicados a análise de séries temporais. Neste trabalho, dois modelos imunoinspirados são avaliados e incorporados a um método de transformação. Os experimentos apresentam resultados interessantes, comprovando a aplicabilidade dos modelos e da estratégia adotada.

Key words: Previsão de Carga a Curto Prazo, Análise de Séries Temporais, Similaridade de Padrões, Sistemas Imunoinspirados

1 Introdução

A demanda de carga pode ser considerada como uma das informações mais importantes a serem utilizadas na operação de sistemas de energia. A operação dos sistemas de energia é bastante dependente de tal informação, da qual decorre o funcionamento bem sucedido de geradores, subestações e linhas, assim como o planejamento de novas unidades no sistema de distribuição de energia.

Desta forma, a realização da previsão da carga a curto prazo possui um papel fundamental, sobretudo nas tarefas de controle, agendamento e segurança dos sistemas elétricos. Considerando este fato, um grande número de modelos têm sido propostos, sejam estes baseados em regressão, análise estatística,

suavizações, ou baseados em análise paramétrica, considerando a relação entre o consumo de energia e outros fatores.

Vários métodos têm sido aplicados ao problema, que é uma aplicação recorrente de previsão baseada na análise de séries temporais. Dentre alguns exemplos estão os modelos auto regressivos integrados baseados em médias móveis (ARIMA) e os modelos de suavização exponencial de Holt–Winters de acordo com [1]. No entanto, com o crescimento das pesquisas em inteligência computacional, modelos baseados em redes neurais passaram a ser bastante utilizados como em [2, 3, 10].

Em [9], é proposto um modelo de previsão de carga baseado em similaridade de padrões. Este modelo facilita a utilização de diversos algoritmos de aprendizado de máquina em problemas baseados em séries temporais e provê, de forma intuitiva, a previsão baseada em padrões previamente conhecidos.

O trabalho em questão discute alguns algoritmos baseados neste modelo e a utilização destes em problemas de previsão de carga a curto prazo, provendo uma análise aprofundada de alguns modelos, sobretudo os modelos inspirados no sistema imune, propostos em [9] e empregando o uso e validação destes em quatro bases de dados de previsão de carga.

2 Previsão de carga a curto prazo

O problema de previsão de carga a curto prazo consiste em prever a demanda de carga em um intervalo de poucas horas antes até algumas semanas a frente, conforme a taxonomia ilustrada na Figura 1. Neste problema, é possível prever estatisticamente um padrão de consumo distinto resultante da totalidade das cargas individuais, de acordo com [4].

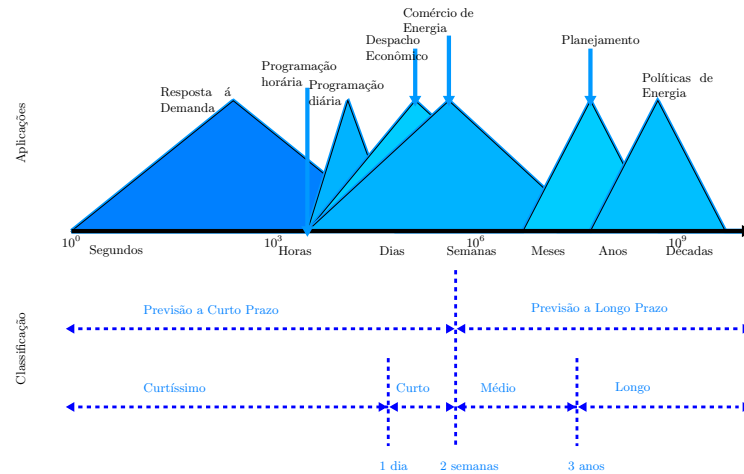


Fig. 1. Taxonomia e aplicações da previsão de carga, segundo [5].

Algumas classes de fatores podem exercer influência no comportamento da carga do sistema, tais como fatores sazonais, econômicos e climáticos, ou mesmo alguns efeitos aleatórios. Em [7], são listados três objetivos para o problema, como o agendamento da geração, prover uma operação mais segura e confiável das usinas, e aumentar a confiabilidade do sistema.

Dessa forma, é possível modelar a demanda de carga em séries temporais considerando algumas tendências apresentadas no comportamento das operações de sistemas de energia. Com isso, tais informações podem ser previstas, como, por exemplo, em modelos de séries temporais Box e Jenkins.

A metodologia estudada neste trabalho é a abordagem proposta em [9], que trata a previsão de carga usando métodos imunoinspirados baseados em similaridade de padrões, utilizados para prever as cargas de acordo com a demanda diária considerada. A Transformação de Box-Cox é empregada com o objetivo de aprimorar o resultado das técnicas adotadas.

3 Abordagem baseada em similaridade de padrões

3.1 Metodologia

Em [8], foram discutidos os principais aspectos do problema de previsão de carga e a adequação de métodos de reconhecimento de padrões ao problema. Considerando os fatores de sazonalidade e as tendências, é possível transcrever um problema simples e univariado baseado em métricas de similaridades. O modelo implica em um simples processo de otimização que requer poucos procedimentos tais como definir o período de amostragem.

O problema da previsão de carga a curto prazo define o período de amostragem em dias, com a informação horária da demanda de energia. Apesar do problema ser univariado, a demanda horária é tratada como dimensão do problema, representando um fragmento da série temporal, usados em pares \mathbf{x} e \mathbf{y} , que representam as partes em análise e o fragmento a ser previsto respectivamente.

O modelo de previsão baseado em similaridades de padrões pode ser definido pelos seguintes passos:

1. Mapeamento da série temporal (ciclos sazonais) em padrões pareados \mathbf{x} e \mathbf{y} .
2. Seleção dos padrões \mathbf{x} similares ao padrão consultado \mathbf{x}^* .
3. Definição dos padrões \mathbf{y} que formam pares com os padrões \mathbf{x} para a previsão do padrão $\hat{\mathbf{y}}$ relacionado a \mathbf{x}^* .
4. Decodificação de $\hat{\mathbf{y}}$ no ciclo sazonal referente ao padrão $\hat{\mathbf{z}}$.

Este modelo de previsão considera o pré processamento da série temporal em diferentes funções utilizadas para tratar especificidades na série a ser analisada ou simplesmente para realizar normalizações nos dados. Alguns exemplos destes modelos podem ser conferidos em [8].

Além do pré processamento, são definidas funções de similaridades, baseadas em mapeamento linear ou não linear das métricas de distâncias D consideradas (ex.: distância euclideana). Com estas métricas, os dados referentes aos padrões

\mathbf{x} são comparados. No treinamento, dados referentes aos padrões \mathbf{y} também são analisados e a correlação entre as distâncias é verificada. No teste, o padrão \mathbf{y} é estimado por meio das observações referentes aos padrões \mathbf{x} .

Usualmente, a métrica adotada para avaliar a qualidade das previsões realizadas é o erro percentual médio absoluto (MAPE) entre o dado previsto F_t e o dado real A_t no período de n instantes em (1).

$$MAPE = \frac{100}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{A_t} \quad (1)$$

Esta métrica é utilizada conforme seu uso tradicional em problemas de previsão de carga. Os interquartis do erro de previsão, aplicados em [8], indicam informações sobre dispersão de erros e seus valores menores apontam modelos mais precisos, uma vez que os erros são centrados em torno do valor médio.

Tal abordagem determina que os padrões \mathbf{x} similares possuem uma relação de vizinhança definida pela função de afinidade. Já a similaridade dos padrões \mathbf{y} depende da relação de estabilidade entre as cargas codificadas no par \mathbf{x} e \mathbf{y} .

3.2 Modelagem

Considere dois padrões: \mathbf{x} sendo um vetor de cargas do sistema de energia com as informações periódicas relativas ao dia que precede o dia da previsão: $x = [x_1, x_2, \dots, x_n]$, e \mathbf{y} com as informações periódicas relativas ao dia da previsão $y = [y_1, y_2, \dots, y_n]$, onde $n = 24$, referente às horas do dia. Os vetores são pré processados com base na série temporal original z , de forma a suprimir fatores como tendência e sazonalidade e simplificar o modelo. Os padrões são definidos a seguir:

$$x_t = f_x(z_{i,t}, \phi_i) \quad (2)$$

$$y_t = f_y(z_{i+\tau,t}, \phi_i) \quad (3)$$

Neste contexto, z representa a sequência da série temporal de origem no período i , onde $z_i = [z_{i,1}, z_{i,2}, \dots, z_{i,n}]$, e τ representa o período de previsão relativo a i . A variável ϕ_i é utilizada no pré processamento, descrevendo um processo no passado mais próximo, permitindo levar em consideração a variabilidade atual do processo e assegura a possibilidade de descodificação. Geralmente, o pré processamento é definido da seguinte forma:

$$f_x(z_{i,t}, \phi_i) = \frac{z_{i,t} - \phi_i}{\sqrt{\sum_{j=1}^N z_{i,j} - \phi_i}} \quad (4)$$

$$f_y(z_{i+\tau,t}, \phi_i) = \frac{z_{i+\tau,t} - \phi_i}{\sqrt{\sum_{j=1}^N z_{i,j} - \phi_i}} \quad (5)$$

onde consideramos ϕ_i como a carga média diária durante um dia avaliado. Note que na construção de \mathbf{y} são usados apenas os dados conhecidos a priori, uma vez que os valores de \mathbf{y} não são conhecidos no instante da previsão.

Com isso, é utilizado um algoritmo supervisionado de forma que este seja capaz de mapear $x \rightarrow y$ e em seguida, sejam apresentados novos padrões \mathbf{x} para que o padrão \mathbf{y} seja obtido como saída do modelo.

4 Algoritmos estudados

Nesta seção, alguns métodos baseados em similaridades de padrões são discutidos, sobretudo os sistemas imunoinspirados discutidos em [9] para previsão de carga a curto prazo. A escolha por estes modelos se dá devido aos mecanismos de reconhecimento que oferecem fortes analogias com os procedimentos de previsão de séries temporais estudados e que podem prover modelos robustos.

4.1 Modelo Imunoinspirado I

O modelo imunoinspirado I consiste em um algoritmo baseado no mecanismo de seleção clonal [15] aplicado à previsão de séries temporais, que representam a memória imune a ser gerada pelos anticorpos (clusters) de acordo com antígenos (dados de treinamento) apresentados, que seguem a estrutura definida na Figura 2.




Fig. 2. Estrutura dos padrões x e y usados no Modelo Imunoinspirado I.

O modelo descrito acima é resumido de acordo com os seguintes passos:

Passo 1. A população dos antígenos de treinamento AG é formada contendo dados y representando informações diárias a serem previstas, em relação aos dados x , de acordo com a modelagem dos pares de padrões \mathbf{x} e \mathbf{y} .

Passo 2. Os anticorpos AB são criados copiando os dados contidos em AG de treinamento: $v_k = u_k, k = 1, 2, \dots, N$. A população inicial de AB possui o mesmo tamanho que AG . O limiar de reatividade cruzada r é definido na inicialização.

Passo 3. A afinidade do k -ésimo anticorpo para o j -ésimo AG depende da afinidade entre seus respectivos padrões \mathbf{x} :

$$a(p_k, x_j) = \begin{cases} 0, & \text{se } d(p_k, x_j) > r \\ 1 - \frac{d(p_k, x_j)}{r}, & \text{caso contrário} \end{cases} \quad (6)$$

onde $a(p_k, x_j) \in [0, 1]$. Supõe-se que se a afinidade em (6) é maior que 0, logo o antígeno j é reconhecido pelo anticorpo k , que é ativado pelo antígeno. A afinidade $a(p_k, x_j)$ define o grau de associação do antígeno j ao cluster representado pelo anticorpo k . A afinidade é máxima quando $p_k = x_j$.

Passo 4. Para cada anticorpo, o conjunto de antígenos que se encontra em sua região de reconhecimento (AG com afinidade maior que zero para determinado AB). Para os anticorpos do conjunto, A previsão de carga codificada no padrão y com base em AB é determinada e seu erro é calculado:

$$\delta_{k,j} = \frac{100}{n} \sum_{t=1}^n \left| \frac{z_{j+\tau,t} - f^{-1}(q_{k,t}, \phi_j)}{z_{j+\tau,t}} \right| \quad (7)$$

onde $z_{j+\tau,t}$ é o valor da série temporal antes do pré processamento e $f^{-1}(q_{k,t}, \phi_j)$ é uma função inversa que aproxima o dado de previsão $q_{k,t}$ de acordo com um valor de referência ϕ_j para o dado $\hat{z}_{j+\tau,t}$.

A medida de avaliação dos anticorpos é o erro médio de previsão, considerando os anticorpos em sua região de reconhecimento:

$$\bar{\delta}_k = \frac{1}{|\Psi_k|} \sum_{j \in \Psi_k} \delta_{k,j} \quad (8)$$

Passo 5. Entra no loop do algoritmo de seleção clonal, onde é realizada a manutenção da população de anticorpos, com a geração sucessiva destes, de forma a realizar a previsão das cargas contidas nos padrões y com erro decrescente. O loop inclui clonagem, hipermutação, avaliação e a seleção clonal, mediante a um critério de parada.

Passo 5.1.1. Cada anticorpo em AB secreta um número de clones proporcional ao número de antígenos contidos em sua região de reconhecimento, conforme definido no Passo 3 e no Passo 4.

Passo 5.1.2. Cada clone gerado sofre hipermutação, de forma a maximizar as habilidades de reconhecimento e previsão, cujo cálculo é definido a seguir:

$$v_k^j = v_k - \eta(u_j - v_k) \quad (9)$$

sendo v_k a posição do anticorpo de origem k , u_j a posição do antígeno j , v_k^j a posição do clone do anticorpo k referente ao antígeno j e η é um coeficiente de ajuste, definido por uma função sigmoideal:

$$\eta_k^j = \frac{2}{1 + \exp(-\beta \delta_{k,j} |\kappa_{k,j}|)} - 1 \quad (10)$$

sendo β um valor de inclinação $\kappa_{k,j}$ um valor de perturbação em distribuição normal de θ até 1. Com isso, A hipermutação gera novos clones dentro da região do cluster representada pelo anticorpo de origem.

Passo 5.2. e **Passo 5.3.** Idem ao Passo 3 e Passo 4, respectivamente.

Passo 5.4. Para cada antígeno, o conjunto de anticorpos ativado é determinado e o anticorpo com a melhor pontuação (8) é selecionado e se torna um dos principais anticorpos na próxima iteração. Na prática, o número de anticorpos requeridos é reduzido considerando a ativação destes por vários antígenos e o valor escolhido de r .

Passo 6. Com a memória imune gerada, os anticorpos formados durante o treinamento representam agrupamentos de possíveis antígenos. Na etapa de previsão, novos antígenos são apresentados com apenas o padrão \mathbf{x} . O conjunto de anticorpos ativados é então determinado.

Passo 7. O padrão \mathbf{y} dos novos antígenos são calculados por meio da seguinte equação de regressão:

$$m(x) = \frac{\sum_{k \in \Theta} a(p_k, \mathbf{x}^*) \mathbf{q}_k}{\sum_{k \in \Theta} a(p_k, \mathbf{x}^*)} \quad (11)$$

Os anticorpos que mostram maior afinidade pelo antígeno apresentado possuem um impacto maior na definição do padrão \mathbf{y} . Caso o dado não seja reconhecido por nenhum anticorpo, significa \mathbf{y} representa uma nova curva de carga diferente daquelas contidas no conjunto de treinamento e é representada pelo padrão \mathbf{x} do antígeno. A relação entre os padrões (Passos 3 e 4) é ilustrada na Figura 3.




Fig. 3. Relação entre os padrões x e y no Modelo Imunoinspirado I. [9]

A ideia central do algoritmo consiste em minimizar o número de anticorpos e o erro de previsão da série temporal avaliada. O algoritmo conta com os seguintes parâmetros: o limiar de reatividade cruzada r , o parâmetro de inclinação β , o parâmetro de largura da distribuição normal θ , e o número de iterações S , que determina o critério de parada do algoritmo.

4.2 Modelo Imunoinspirado II

O modelo imunoinspirado II, diferente do modelo anterior, opera de acordo com a similaridade entre os padrões x e y e o cálculo da probabilidade condicional da estimulação simultânea de ambos os padrões.

O modelo descrito acima é resumido de acordo com os seguintes passos:

Passo 1. A população dos antígenos de treinamento AG possui padrões y que representam dados históricos diários relativos ao dia a ser previsto e os padrões x que representam dados correspondentes ao dia em análise.

Passo 2. Os anticorpos AB são criados copiando os dados contidos em AG de treinamento: $p_k = x_k, q_k = y_k$, para $k = 1, 2, \dots, N$ para ambos os padrões. A população AB é fixa e possui o mesmo tamanho que AG . Os limiares de reatividade cruzada r e s não requerem inicialização.

Passo 3. A região de reconhecimento do padrão x do anticorpo k deverá cobrir apenas os antígenos que satisfazem as seguintes condições:

1. possuir padrões x semelhantes a p_k , e
2. possuir padrões y similares ao do k -ésimo anticorpo em q_k .

A condição 1 é avaliada conforme a métrica de distância, já a condição 2 é avaliada conforme o erro de previsão médio, da mesma forma que em (7), conforme o Passo 4 do Método I.

Os antígenos são divididos em tipos, conforme as condições analisadas: se $\delta_{k,j} \leq \delta_{thr}$, onde δ_{thr} é um limiar de erro, presume-se que o padrão y do antígeno j é semelhante ao do anticorpo k , sendo este definido como classe A, assim como o seus respectivos padrões x . Quando a condição não é atendida, o antígeno é definido como classe B, sendo a classe A o indicativo de alta semelhança entre os padrões y dos antígenos e anticorpos analisados.

Passo 4. Uma vez definidas as classes dos antígenos, o cálculo dos limiares de reatividade cruzada é definido. Para o padrão x , o limiar r_k é calculado:

$$r_k = d(p_k, x_A) + c[d(p_k, x_B) - d(p_k, x_A)] \quad (12)$$

onde x_B corresponde ao antígeno da classe B mais próximo ao anticorpo k e x_A indica o antígeno da classe A mais distante. O parâmetro c permite o ajuste do valor do limiar de reatividade cruzada em ambas as regiões definidas.

Da mesma forma, para os padrões y , o limiar s_k é calculado:

$$s_k = d(q_k, y_A) + b[d(q_k, y_B) - d(q_k, y_A)] \quad (13)$$

onde y_B, y_A e b possuem as mesmas funções em relação a x_B, x_A e c em (12), respectivamente.

Passo 5. Quando as populações da memória imune são geradas, os sucessivos pares (x, y) dos antígenos são apresentados: $(AGx_l, AGy_l), l = 1, 2, \dots, N$. Para cada par, os conjuntos de anticorpos definidos pelos pares (x, y) estimulados são determinados e as probabilidades condicionais são estimadas: $P(ABy_j | ABx_i) = L_{j,i}/N$, onde $L_{j,i}$ é o número de ocorrências da estimulação simultânea dos padrões x e y de um anticorpo pelos antígenos.

Passo 6. Na etapa de previsão, novos antígenos são apresentados, de forma similar ao Modelo I.

Passo 7. O padrões y dos novos antígenos são calculados por meio da seguinte equação de regressão:

$$m(x^*) = \sum_{j=1}^N w_j(x^*) q_j \quad (14)$$

onde:

$$w_j(x^*) = \frac{\sum_{i \in \Theta} P(AB y_j | AB x_i) a(p_i, \mathbf{x}^*)}{\sum_{k=1}^N \sum_{i \in \Theta} P(AB y_k | AB x_i) a(p_i, \mathbf{x}^*)} \quad (15)$$

$$a(p_k, x_j) = \begin{cases} 0, & \text{se } d(p_k, x^*) > r \text{ ou } r_i = 0 \\ 1 - \frac{d(p_k, x^*)}{r}, & \text{caso contrário} \end{cases} \quad (16)$$

Da mesma forma que no primeiro modelo, a previsão dos antígenos não reconhecidos são representadas pelo padrão \mathbf{x} (modelo naïve). A relação entre os padrões (Passo 4) é ilustrada na Figura 4.




Fig. 4. Relação entre os padrões x e y no Modelo Imunoinspirado II. [9]

O procedimento de aprendizagem é determinístico e requer apenas uma avaliação dos dados de treinamento. Isso permite respostas estáveis e um processamento mais rápido nos passos de treinamento. O método possui três parâmetros: limiar de erro δ_{thr} e os parâmetros de ajustes de reatividade cruzada b e c .

4.3 Transformação de Box-Cox

Neste trabalho, a parte de pré processamento será complementada por um método de transformação bastante recorrente na literatura: a transformação de Box-Cox, que consiste em obter o parâmetro λ e o vetor Z a partir da série temporal de origem:

$$Z_t^\lambda = \begin{cases} \frac{Z_t^\lambda - 1}{\lambda} & \lambda \neq 0 \\ \ln(Z_t) & \lambda = 0 \end{cases} \quad (17)$$

com isto, são obtidos os padrões \mathbf{x} e \mathbf{y} utilizados nos algoritmos estudados a partir de Z . Para calcular o valor previsto, basta aplicar a transformação inversa:

$$\hat{z}_{i+\tau} = \begin{cases} \left(\lambda \hat{Z}_t^\lambda + 1\right)^{1/\lambda} & \lambda \neq 0 \\ \exp(\hat{Z}_t) & \lambda = 0 \end{cases} \quad (18)$$

o procedimento acima complementa a normalização realizada na série temporal e pode, inclusive, ser utilizado antes da aplicação de qualquer método de normalização definido em [8].

5 Estudo de caso

Nesta seção, será analisado o desempenho dos dois algoritmos apresentados dentro da metodologia estudada ao treinar e otimizar os modelos para tarefas de previsão de carga horária com horizonte de um dia, testando-os em quatro séries temporais de carga elétrica:

1. Previsão da carga horária do sistema polonês de energia no período de 2002–2004. Os dados de teste são referentes ao ano de 2004, excluindo 13 dias atípicos;
2. Previsão da carga de meia hora do sistema francês a partir do período de 2007–2009. Os dados de teste são referentes ao ano de 2009, excluindo 21 dias atípicos;
3. Previsão da carga de meia hora do sistema britânico no período de 2007–2009. Os dados de teste são referentes ao ano de 2009, excluindo 18 dias atípicos,
4. Previsão da carga de meia hora do sistema de Victoria, Austrália, no período de 2006–2008. Os dados de teste são referentes ao ano de 2008, excluindo 12 dias atípicos;

Todas as bases de dados foram utilizadas nos trabalhos de [9]. Os modelos imunoinspirados serão avaliados conforme o percentual do erro médio absoluto (MAPE), seu interquartil (IQR) e o número de padrões não reconhecidos (UP). Os dias atípicos são substituídos pelo dado histórico médio do dia da semana equivalente, exceto para os primeiros dias do mês de janeiro, que neste caso são omitidos da avaliação. Os parâmetros considerados são listados na Tabela 1, utilizados em todos os testes.

Os resultados são apresentados na Tabela 2, considerando o procedimento normal e o uso da transformação de Box-Cox. Em ambos os casos, os padrões x e y foram obtidos por meio das equações (4) e (5) respectivamente. Além disso, no teste da base 4 com a transformação de Box-Cox, foi considerado $\delta_{thr} = 1$, devido aos baixos valores do erro percentual no treinamento.

Ambos os métodos conseguem prover um modelo próximo da série temporal de referência. Porém, em alguns casos, o segundo método não consegue reconhecer um padrão novo com exatidão, mesmo considerando um número maior de agrupamentos. Isto não acontece no modelo I com o número de iterações padrão.

Table 1. Parâmetros usados pelos métodos estudados.

Variável	Descrição	Valor	Modelo
S	Número de iterações	10	I
Δ	Limiar de reatividade cruzada	0.03	I
β	Fator de inclinação da mutação	0.02	I
θ	Fator de perturbação da mutação	0.01	I
δ_{thr}	Limiar de erro percentual tolerado	2	II
b	Limiar de reatividade cruzada do padrão x	1	II
c	Limiar de reatividade cruzada do padrão y	1	II

Table 2. Resultados obtidos com os modelos imunoinspirados.

Teste	Modelo Imunoinspirado I						Modelo Imunoinspirado II					
	Normal			Transformação			Normal			Transformação		
Base	MAPE	IQR	UP	MAPE	IQR	UP	MAPE	IQR	UP	MAPE	IQR	UP
1	3.7401	3.4024	0.0	1.5488	1.5210	0.0	2.9446	2.8295	18.35	1.0886	0.9288	4.66
2	3.6759	2.9787	0.0	0.5942	0.4941	0.0	3.4701	2.4556	12.88	0.5211	0.4155	0.27
3	3.2839	2.7894	0.0	2.8997	2.4486	0.0	2.9489	1.8459	14.52	2.4744	1.5320	8.22
4	4.0453	3.9584	0.0	0.0749	0.0842	0.0	4.8082	5.3109	37.97	0.1234	0.1475	3.54

A transformação de Box-Cox, aplicada aos dados antes da normalização, garantiu melhorias nos resultados, além de aprimorar o reconhecimento dos padrões no modelo II.

Em geral, o modelo II apresentou previsões mais exatas em relação modelo I, provavelmente devido ao processamento dos dados, fator que requer uma análise mais profunda em termos de procedimentos. O Modelo II também apresentou um custo computacional menor.

Vale ressaltar que os resultados obtidos apresentam diferenças em relação aos estudos feitos em [9], devido a refinamentos mais detalhados, como a similaridade entre dias da semana, por exemplo. A transformação de Box-Cox, útil para reduzir os impactos de tendências e sazonalidades, conseguiu aprimorar os resultados da pesquisa.

6 Conclusões e trabalhos futuros

O trabalho apresentou duas metodologias imunoinspiradas que consistem em resolver problemas de previsão de carga com base em similaridade de padrões. Os resultados obtidos estão próximos dos obtidos na literatura, além da possibilidade de aprimoramentos pela Transformação de Box-Cox.

As abordagens baseadas em similaridades de padrões torna possível a aplicação dos algoritmos de aprendizado de máquina em problemas de previsão de séries temporais, podendo ser combinadas com filtros ou métodos de transformação antes da normalização dos dados.

Além destes métodos, é possível aplicar séries temporais *fuzzy*, definidas em [16], aos procedimentos de similaridades de padrões, provendo modelos mais

robustos e com tratamento de incertezas. Como forma de aprimoramento, outros algoritmos de otimização podem ser utilizados, seja na otimização de parâmetros ou da modelagem da previsão pelos métodos usados, seja na avaliação do modelo, como no caso do algoritmo clonal, usado no Modelo Imunoinspirado I. Finalmente, conforme [9], abordagens com base em previsões probabilísticas também podem ser elaboradas e comparadas com os modelos clássicos.

Agradecimentos. O presente trabalho contou com os apoios das agências CAPES, FAPEMIG e CNPq. Agradecimentos especiais ao Dr. Grzegorz Dudek (Czestochowa Univ. of Technology) pelos dados disponibilizados.

References

1. R. Weron, *Modeling and Forecasting Electricity Loads and Prices*, Wiley, Chichester, 2006.
2. K. Lang, M. Zhang, Y. Yuan, *Improved Neural Networks with Random Weights for Short-Term Load Forecasting*. PLOS ONE 10(12): e0143175, 2015.
3. S. Wei, L. Mohan, *Application of improved artificial neural networks in short-term power load forecasting* Journal of Renewable and Sustainable Energy, 7:4, 2015.
4. G. Gross, F. D. Galiana, *Short-term load forecasting*, Proceedings of the IEEE, vol.75, no.12 (1987), pp.1558–1573.
5. T. Hong, S. Fan, Probabilistic electric load forecasting: A tutorial review, International Journal of Forecasting, Volume 32, Issue 3, 2016, pp. 914–938.
6. A. K. Srivastava, A. S. Pandey, D. Singh, *Short-term load forecasting methods: A review*, 2016 International Conference on Emerging Trends in Electrical Electronics & Sustainable Energy Systems (ICETEESES), Sultanpur, 2016, pp. 130-138.
7. M. Q. Raza, A. Khosravi, *A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings*, Renewable and Sustainable Energy Reviews, vol. 50 (2015), pp. 1352–1372.
8. G. Dudek, *Pattern similarity-based methods for short-term load forecasting - Part 1: Principles*, Appl. Soft Comput., vol. 37 (2015), Pages 277–287.
9. G. Dudek, *Pattern similarity-based methods for short-term load forecasting - Part 2: Models*, Appl. Soft Comput., vol. 36 (2015), Pages 422–441.
10. G. Dudek, *Neural networks for pattern-based short-term load forecasting: A comparative study*, Neurocomputing, vol. 205 (2016), pp. 64–74.
11. G. Dudek, *Pattern-based local linear regression models for short-term load forecasting*, Electric Power Systems Research, vol. 130 (2016), Pages 139–147.
12. S. Li, L. Goel, P. Wang, *An ensemble approach for short-term load forecasting by extreme learning machine*, Appl. Energy, Vol. 170 (2016), pp. 22–29.
13. C. Antunes, A. L. Oliveira, *Temporal data mining: an overview*, KDD Workshop on Temporal Data Mining (2001), pp. 1–13.
14. T.-C. Fu, *A review on time series data mining*, Eng. Appl. of Artif. Intel., vol. 24, no. 1 (2011), pp. 164–181.
15. L. N. de Castro and F. J. Von Zuben, "Learning and optimization using the clonal selection principle," in IEEE Transactions on Evolutionary Computation, vol. 6, no. 3, pp. 239-251, Jun 2002.
16. Q. Song and B. S. Chissom, *Fuzzy time series and its models*, Fuzzy Sets and Systems vol. 54, no. 3 (1993), pp. 269–277. North-Holland. Elsevier.