

ESTIMAÇÃO DE ÍNDICE DE CLARIDADE UTILIZANDO OS ALGORITMOS k -NN E k -NN RECURSIVO

Guilherme Santos Martins * Mateus Giesbrecht *

* Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, SP, (e-mails: gmartins@dsif.fee.unicamp.br, mateus@fee.unicamp.br).

Abstract: With the increase in solar energy penetration in electric power systems, it is necessary to predict future solar radiation. With this, the solar power generation capacity can be predicted, allowing accurate scheduling for the other sources. In this paper, two methods were proposed to predict the clearness index (CI), which is related to solar radiation. The first one solves the k -Nearest Neighbors (k -NN) regression algorithm for time series forecasting with the most usual approach, in which the training data set remains constant. The second one performs the method developed by the authors, in which the training data set is updated recursively. The methods were implemented in MatLab[®] and compared for short-term and long-term predictions. The results illustrate that the approach proposed by authors outperformed the most usual approach found in the literature.

Resumo: Com o aumento da penetração da energia solar nos sistemas de energia elétrica, é necessário prever a radiação solar futura. Com isso, é possível prever a capacidade de geração de energia solar, permitindo um agendamento preciso para as demais fontes. Neste trabalho, são apresentados dois métodos para previsão de índice de claridade, que está relacionado à radiação solar. O primeiro realiza o algoritmo de regressão k -Nearest Neighbours (k -NN) para previsão de séries temporais usando uma abordagem mais usual, em que o conjunto de dados de treinamento permanece constante. Na segunda abordagem, proposta pelos autores, o conjunto de dados de treinamento é atualizado recursivamente. Os métodos foram implementados em MatLab[®] e comparados para previsões de curto e longo prazo. Os resultados ilustram que a abordagem proposta pelos autores obteve resultados melhores se comparados aos do método usualmente utilizado na literatura.

Keywords: Solar radiation; Clearness Index; k -Nearest Neighbors.

Palavras-chaves: Radiação solar; Índice de claridade; k - Vizinhos mais próximos

1. INTRODUÇÃO

A demanda de energia elétrica está aumentando significativamente a cada ano. Fontes convencionais de energia, tais como carvão, nuclear e petróleo, têm disponibilidade limitada e causam poluição ambiental significativa (Mathiesen et al., 2011). O objetivo de reduzir a crise energética e a poluição deve ser alcançado ajustando a estrutura energética, de forma que as fontes renováveis de energia sejam priorizadas (Jiang et al., 2019).

Nos últimos anos, o desenvolvimento de fontes de energia renováveis se tornou gradualmente o consenso da comunidade internacional (Jiang et al., 2019) e (Niu et al., 2018). Muitos países estão focados no desenvolvimento de fontes renováveis de energia, o que é uma decisão essencial para garantir o desenvolvimento sustentável da humanidade, da sociedade e da economia (Jiang et al., 2019). Por essas razões, as fontes renováveis de energia, principalmente a

solar e a eólica, vêm sendo estudadas cada vez mais. A produção de energia elétrica por intermédio destas fontes é uma atividade promissora, devido a suas vantagens e também ao progresso tecnológico alcançado desde a década de 70 (Tolmasquim, 2016) e (Pinto, 2013).

A geração de energia elétrica a partir da energia solar está em constante crescimento em países em desenvolvimento como o Brasil. Segundo a Associação Brasileira de Energia Solar Fotovoltaica (ABSOLAR, 2020), no mês de janeiro de 2019, a participação desta fonte era de 1,1% com uma capacidade de geração de energia solar centralizada (grandes plantas geradoras) instalada em torno de 1798 MW. Já em abril de 2021, a participação da fonte na matriz energética era de 1,8%, com uma capacidade de geração de energia solar centralizada instalada em torno de 3.293 MW.

A previsão de radiação solar ¹ é muito importante no cenário atual. Neste contexto, os métodos de estimação

* O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

¹ Radiação (Solar) - Um termo genérico que cobre todas as formas de energia radiante que caem na superfície da terra e se originam do sol. (Às vezes, insolação é usada com este significado). É a densidade

podem ser usados para planejar o agendamento e o despacho da unidade pelos operadores do sistema e maximizar o lucro dos comerciantes de eletricidade (Pinto, 2013). Além disso, a melhoria no desempenho da ferramenta de previsão de energia solar apresenta impactos econômicos e técnicos significativos, aumentando a confiabilidade dessa fonte. No entanto, prever a capacidade de geração de energia elétrica a partir da energia solar é uma tarefa desafiadora. Isso ocorre pois os fenômenos atmosféricos associados fornecem uma natureza probabilística a esse recurso energético.

Embora vários trabalhos tenham abordado a previsão da irradiação solar, conforme discutido nos parágrafos anteriores, o mesmo problema pode ser resolvido prevendo o índice de claridade (do inglês *clearness index* ou CI), que é uma medida da claridade da atmosfera.

A principal vantagem de utilizar o CI é que essa medida é normalizada. Além disso, o uso do CI ao invés da irradiação aumenta a acurácia de previsão dos algoritmos, uma vez que o efeito da irradiação de céu limpo, que é um fenômeno altamente variante, mas conhecido, é excluído da análise. O CI é relativamente simples de calcular, uma vez que são necessários apenas os dados medidos de irradiância solar global e um modelo de céu limpo (Mousavi Maleki et al., 2017) e (Lai et al., 2017).

1.1 Objetivos do trabalho

Neste trabalho, o CI é obtido a partir da irradiação solar medida em três estações meteorológicas localizadas em capitais brasileiras e do modelo de céu limpo, aplicando o algoritmo apresentado em (Lai et al., 2017). Os dados são aplicados a um modelo de inteligência artificial (do inglês *artificial intelligence* ou AI) usualmente encontrado na literatura e a uma variação desse modelo desenvolvida pelos autores.

O método de AI utilizado nesse trabalho é o modelo de regressão k -Nearest Neighbours (k -NN). Algumas vantagens desse método podem ser destacadas. A primeira é o tempo de treinamento instantâneo, supondo que os metaparámetros já estejam definidos. Outra vantagem é que o algoritmo de regressão k -NN é simples de implementar, pois são necessários apenas os dados históricos, uma métrica de distância e dois metaparámetros.

Neste artigo também é proposta uma variante recursiva do k -NN, incorporando os dados de medição mais recentes no conjunto de treinamento. Essa abordagem recursiva foi comparada ao método tradicional k -NN. Até onde os autores sabem, a aplicação desse método para resolver o problema de previsão de CI não foi publicada na literatura.

Por fim, é realizada uma comparação entre os dois métodos, tanto em acurácia quanto em tempo de execução.

Este artigo está organizado da seguinte maneira: na Seção 2 é apresentada a base de dados utilizada, na Seção 3 é apresentado o cálculo do índice de claridade, na Seção 4 é apresentado o método k -NN para previsão de séries temporais, na Seção 5 a metodologia, na Seção 6 os resultados e na Seção 7 é apresentada a conclusão.

do fluxo da radiação solar, medida em W/m^2 . Fontes: (EEP, 2021), (Loschi, 2017).

2. BASE DE DADOS

A base de dados utilizada no desenvolvimento deste trabalho está disponível em (INMET, 2020). Os dados foram coletados para três estações meteorológicas, que estão localizadas nas cidades de Natal - RN, Salvador - BA e Rio de Janeiro - RJ. A escolha das três cidades é feita a fim de comparar o desempenho das previsões do CI para diferentes tipos climáticos.

Os dados de radiação solar são medidos minuto a minuto e a cada hora são integrados. A medição dos dados de irradiação, que é o foco do estudo apresentado neste trabalho, é feita com piranômetros. Mais detalhes podem ser encontrados em (INMET, 2020).

A medição da radiação solar ao longo de um ano consiste em um conjunto de 8759 dados. Cada amostra é equivalente à radiação solar durante o intervalo de 1 hora. Porém, neste trabalho, são utilizados apenas os dados dos horários em que há radiação solar, ou seja, no período das 7h às 17h, contabilizando em 4.015 amostras por ano.

Os dados foram coletados no período de três anos, 2017 a 2019. Os primeiros dois anos foram usados como um conjunto de treinamento enquanto o último ano é utilizado como conjunto de validação.

3. ÍNDICE DE CLARIDADE

O CI é uma variável que indica as condições atmosféricas, mostrando as variações da radiação global em função de inúmeros fatores (Tomaszewski et al., 2018). Existem várias propostas para o cálculo do CI a partir da irradiação solar global e do modelo de céu limpo. Nesse trabalho, foi escolhido o procedimento realizado por (Lai et al., 2017).

O índice de claridade em um dado instante k , denotado por CI_k , é definido como sendo a razão entre a irradiação solar medida a partir da estação meteorológica automática ($I_{medido,k}$) e o modelo de irradiação do céu limpo ($I_{modelo,k}$), conforme expresso na equação (1):

$$CI_k = \frac{I_{medido,k}}{I_{modelo,k}}. \quad (1)$$

O termo $I_{modelo,k}$, expresso na equação (1), pode ser calculado a partir do procedimento detalhado em (Lai et al., 2017), (Rigollier et al., 2000) e (Scharmer et al., 2000). Os autores do presente artigo também já detalharam anteriormente o procedimento para o cálculo de CI em (Martins and Giesbrecht, 2020), em que um método estatístico foi utilizado para a previsão dessa série temporal.

Neste trabalho, o CI_k é a série temporal a ser prevista e também é denotada por y_k em que $k = 1, \dots, N_s$, em que N_s é o número total de amostras coletadas. Os métodos aplicados para prever a série temporal são discutidos nas seções seguintes.

4. PREDIÇÃO DE SÉRIES TEMPORAIS UTILIZANDO O MÉTODO K -NN

O algoritmo k -NN é um método de aprendizado de máquina supervisionado e não paramétrico usado para classificação ou regressão. Esse algoritmo é composto por

algumas características: as variáveis explicativas, também chamadas de atributos, e as variáveis explicadas ou variáveis de predição, também chamadas de rótulos. Dado um novo conjunto de atributos, o método k -NN tem como objetivo encontrar um conjunto com k_{NN} instâncias de treinamento mais próximas da nova instância de acordo com alguma métrica de distância. Deste modo, o método retorna a média entre os alvos das instâncias mais próximas no conjunto de treinamento como um rótulo predito para o novo conjunto de atributos (Martínez et al., 2019). A variável k_{NN} é um dos metaparâmetros que deve ser escolhido pelo usuário.

Na predição de séries temporais, os atributos são todos os conjuntos possíveis com W amostras passadas consecutivas da série temporal, onde W é o segundo metaparâmetro do método, também conhecido como tamanho da janela. Para cada conjunto de atributos, as variáveis de previsão são h amostras consecutivas à frente. Se a predição de um passo à frente for considerada, haverá apenas uma variável de predição, ou seja, $h = 1$.

O algoritmo k -NN já foi usado no campo da predição de séries temporais. Em (Sorjamaa et al., 2007) é proposta uma metodologia baseada em k -NN para a predição de séries temporais de longo prazo para o conjunto de dados de carga de eletricidade. Em (Lachut et al., 2014), um algoritmo k -NN é analisado, entre outros algoritmos de aprendizado de máquina, e comparado a um algoritmo baseado em estatística. Outras aplicações podem ser encontradas em (Ahmed et al., 2010), (Martínez et al., 2019), e (Zhang et al., 2017). Até onde os autores sabem, essa técnica ainda não foi usada para predição de CI.

O algoritmo pode ser resumido em 7 etapas conforme a seguir:

- 1º) Insira a série temporal a ser analisada;
- 2º) Selecione o número de vizinhos mais próximos (k_{NN});
- 3º) Selecione o tamanho da janela W ;
- 4º) Calcule a distância entre a nova instância e as instâncias de treinamento, que são agrupadas na matriz de instâncias passadas. Nesse trabalho, é utilizada a métrica de distância Euclidiana;
- 5º) Classifique as instâncias de treinamento em ordem crescente de distância;
- 6º) Encontre os k_{NN} alvos do k -Vizinhos Mais Próximos;
- 7º) Calcule a média dos alvos encontrada na etapa 6. Essa média é a predição futura.

O diagrama esquemático do método k -NN padrão é ilustrado na Figura 1.

Para avaliar a estratégia, o erro quadrático médio (do inglês Mean Square Error ou MSE) é calculado, dado por:

$$\text{MSE} = \frac{1}{j} \sum_{j=1}^{J_f} (y_{N_s+j} - \hat{y}_{N_s+j})^2 \quad (2)$$

em que y_{N_s+j} e \hat{y}_{N_s+j} são os valores reais e os valores preditos, respectivamente e J_f o horizonte de predição.

5. METODOLOGIA

Nessa seção são apresentadas as metodologias utilizadas nesse artigo. Os métodos são detalhados a seguir.

5.1 Escolha dos metaparâmetros

Geralmente, nas implementações do método de regressão k -NN, os metaparâmetros k_{NN} e W são selecionados *a priori*. Neste trabalho, um algoritmo de busca em grade foi implementado para testar diferentes valores de k_{NN} e W , variando de 1 a $k_{NN\max}$ e a W_{\max} , respectivamente. Os metaparâmetros que implicam em predições de maior acurácia para o segundo ano, utilizando o primeiro ano como conjunto de treinamento, são escolhidos.

Os meta-parâmetros obtidos são utilizados para realizar as predições para o terceiro ano com dois métodos diferentes, conforme detalhado a seguir:

5.2 Método k -NN tradicional

A implementação do k -NN padrão, ou seja, sem atualização de dados, foi executada para prever os dados de 2019 usando 2017 e 2018 como dados de treinamento. O fluxograma do método k -NN padrão é ilustrado na Figura 2. Os resultados são mostrados na Seção 6.2.

5.3 Método k -NN recursivo

O algoritmo de predição padrão k -NN não é capaz de incorporar novos dados de treinamento. A proposta introduzida neste artigo é agregar novos dados de treinamento a cada nova iteração, resultando em um algoritmo k -NN recursivo.

Um método direto para incorporar novos dados no método k -NN seria executar todo algoritmo novamente, atualizando o conjunto de treinamento a cada novo instante de tempo. Esse procedimento seria demorado, uma vez que a montagem da matriz de instâncias passadas completa é um procedimento computacionalmente complexo. Como alternativa, a matriz de instâncias passadas pode ser atualizada a cada instante de tempo. O fluxograma do método k -NN recursivo é ilustrado na Figura 3. O resultado dessa implementação é ilustrado na Seção 6.3.

6. RESULTADOS

Nesta seção são mostrados os resultados dos algoritmos apresentados na Seção 5. Todos os cálculos foram programados em MatLab® e executados utilizando um computador com as seguintes configurações: Workstation com um processador: Intel® Xeon® E3-1240V5 (4-Core @ 3.5GHz com HT, Cache 8MB) e Memória: 64 GB (4x 16GB) RAM, rodando em um sistema operacional Ubuntu.

6.1 Escolha dos metaparâmetros do algoritmo k -NN

Para selecionar os metaparâmetros ótimos k_{NN} e W , foi realizada uma busca em grade dessas duas variáveis, nas

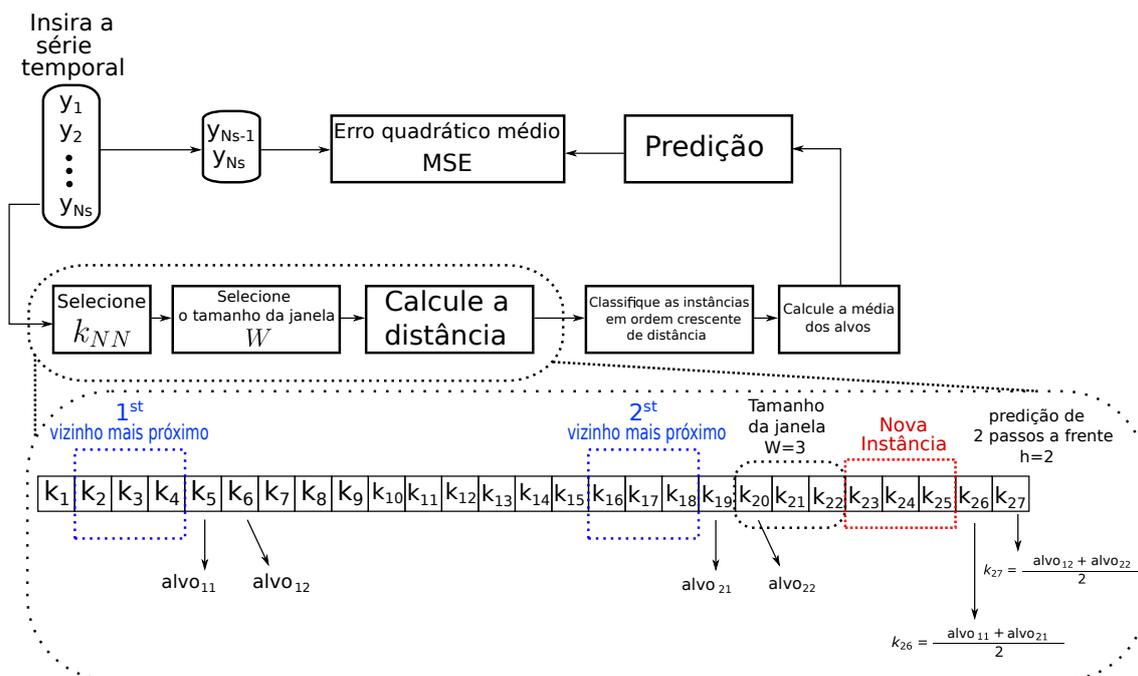


Figura 1. Diagrama esquemático do método k -NN padrão para previsão de séries temporais considerando $k_{NN} = 2$, $W = 3$ and $h = 2$.

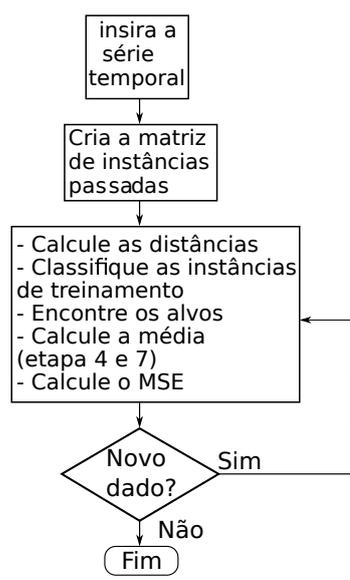


Figura 2. Fluxograma do método k -NN padrão para previsão de séries temporais.

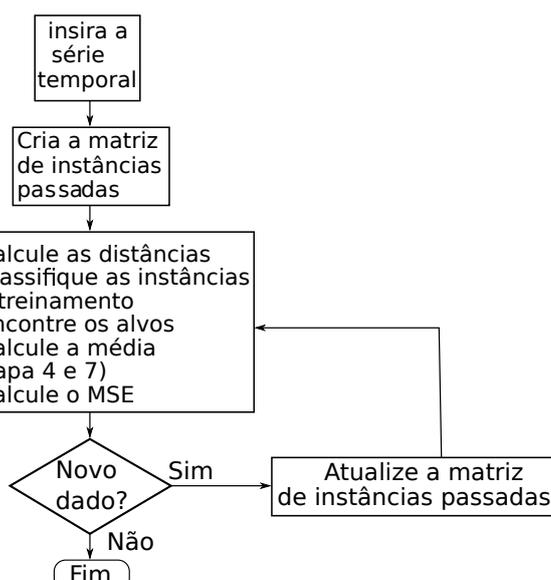


Figura 3. Fluxograma do método k -NN recursivo para previsão de séries temporais.

quais ambas foram variadas de 1 a 50. Em seguida, os dados do ano de 2017 foram utilizados para prever o CI durante 2018 e os metaparâmetros que resultaram em uma previsão com um MSE menor foram escolhidos.

A partir das simulações realizadas para a cidade de Natal é observado que o menor MSE foi obtido para $k_{NN} = 26$ e $W = 12$, conforme mostrado na Tabela 1. A escolha dos metaparâmetros para as demais cidades foram realizadas utilizando o mesmo procedimento, e os resultados são apresentados na mesma tabela. Para as três cidades, o MSE foi aproximadamente igual, demonstrando que o método pode ser utilizado para prever o CI para diferentes tipos de clima.

Na Figura 4 são apresentadas as previsões de k -NN para o ano de 2018 na cidade de Natal com o conjunto mais preciso de metaparâmetros utilizando o ano de 2017 como dados de treinamento.

Tabela 1. Metaparâmetros ótimo e MSE para os dados de 2018.

Cidade	k_{NN} ótimo	W ótimo	MSE
Natal- RN	26	12	0.0211
Rio de Janeiro - RJ	12	12	0.0232
Salvador - BA	11	22	0.0229

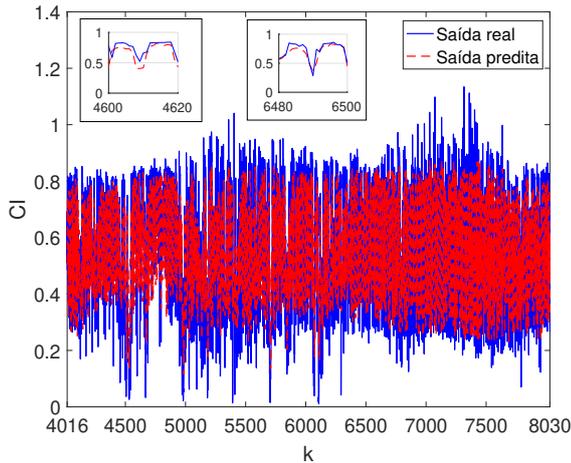


Figura 4. Saídas reais durante 2018 em Natal e saídas estimadas utilizando o algoritmo k -NN recursivo com o conjunto ótimo de metaparâmetros considerando 2017 como dados de treinamento

O tempo total de execução do procedimento descrito nesta seção, incluindo a busca em grade, é mostrado na Tabela 2.

Tabela 2. Tempo de execução total para o procedimento de determinação dos metaparâmetros ótimos.

Cidade	Tempo total de execução (s)
Natal- RN	7.14×10^3
Rio de Janeiro - RJ	6.797×10^3
Salvador - BA	6.904×10^3

6.2 Predição utilizando o método k -NN tradicional

Na Figura 5 são ilustrados a saída real e a predita para o CI na cidade de Natal durante o ano de 2019 utilizando o método k -NN tradicional com os metaparâmetros da Tabela 1. Os resultados para as cidades de Rio de Janeiro e Salvador também foram obtidos utilizando os respectivos metaparâmetros ótimos. Para cada cidade, os MSEs totais das predições são apresentados na Tabela 3. Na mesma tabela, as médias e os desvios padrão dos tempos de execução por iteração, ou seja, o tempo utilizado para prever o CI a cada instante de tempo de 2019, também são apresentados.

Tabela 3. MSE, tempo médio de execução e desvio padrão utilizando o método k -NN tradicional.

Cidade	MSE	Tempo médio de execução (s)	Desvio padrão
Natal- RN	0.0369	0.1166	0.0018
Rio de Janeiro - RJ	0.0386	0.115	0.0012
Salvador - BA	0.0411	0.179	0.0018

6.3 Predição utilizando o método k -NN recursivo

Na Figura 6 são ilustrados o CI real e predito para a cidade de Natal no ano de 2019 utilizando a metodologia descrita na Seção 5.3. Os metaparâmetros, k_{NN} e W utilizados são os mostrados na Tabela 1.

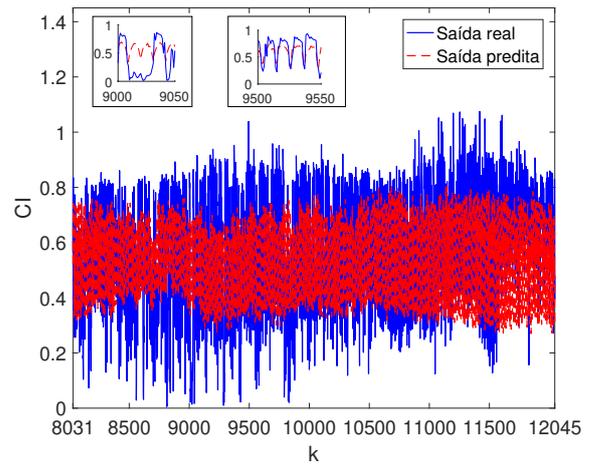


Figura 5. Saída Real e Saída predita para o CI utilizando o método k -NN tradicional durante o ano de 2019.

Os resultados da predição do CI utilizando o método k -NN recursivo nas cidades de Rio de Janeiro e Salvador também foram obtidos utilizando os metaparâmetros ótimos obtidos para cada cidade. Na Tabela 4 os resultados são apresentados. O MSE para as três cidades é comparável, demonstrando que o método é adequado para diferentes tipos de clima.

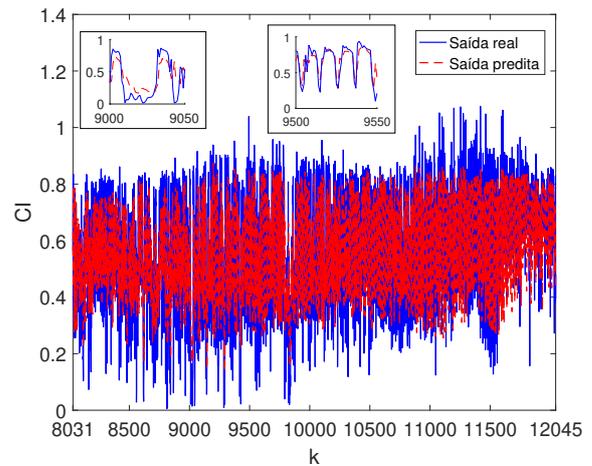


Figura 6. Saída real e Saída predita para o CI utilizando o método k -NN recursivo durante o ano de 2019.

Tabela 4. MSE, tempo médio de execução e desvio padrão utilizando o método k -NN recursivo.

Cidade	MSE	Tempo médio de execução (s)	Desvio padrão
Natal- RN	0.0218	3.39	0.1214
Rio de Janeiro - RJ	0.020	3.418	0.0762
Salvador - BA	0.0230	4.563	0.227

6.4 Discussão

Comparando as Tabelas 3 e 4, é possível notar que a abordagem recursiva k -NN proposta neste trabalho é quase duas vezes mais precisa do que o algoritmo k -NN padrão para as três cidades. Este comportamento é esperado uma

vez que os resultados mostrados na Seção 6.3 são obtidos atualizando os dados de treinamento, conforme discutido na Seção 5.3, enquanto no algoritmo k -NN tradicional, os dados de treinamento permanecem fixos. O preço para o aumento da acurácia é a carga computacional, já que o tempo médio de execução por iteração para o k -NN padrão é uma ordem de grandeza menor do que o k -NN recursivo. Isso também é esperado, uma vez que o conjunto de dados de treinamento cresce a cada iteração no algoritmo recursivo, aumentando o número de distâncias que devem ser calculadas. Embora consuma mais recursos computacionais do que o k -NN padrão, o k -NN recursivo pode ser usado para a predição de CI, pois seu tempo médio de execução por iteração é consideravelmente menor do que o horizonte de previsão de uma hora.

7. CONCLUSÕES

Nesse trabalho, duas metodologias para predição do CI foram apresentadas. A primeira metodologia foi o modelo de regressão k -NN para predição de séries temporais usualmente utilizada na literatura, enquanto o segundo método foi proposto pelos autores. Posteriormente, foram apresentados os resultados dos métodos propostos para validação dos dados.

O método de regressão k -NN proposto pelos autores, apresentou resultados mais precisos comparado com a metodologia usualmente encontrada na literatura, sendo quase duas vezes mais precisa do que o algoritmo k -NN padrão para as três cidades.

Nos próximos passos desta pesquisa, algoritmos estatísticos, como o apresentado em (Martins and Giesbrecht, 2020) e de aprendizado de máquina serão comparados, a fim de observar o tempo de execução e o erro quadrático médio, em horizontes de curto e longo prazo. Também serão exploradas alternativas para redução do conjunto de treinamento sem redução de acurácia, o que pode reduzir o tempo de execução do algoritmo k -NN recursivo.

AGRADECIMENTOS

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

REFERÊNCIAS

- ABSOLAR (2020). Energia solar fotovoltaica no brasil, infográfico absolar. <http://www.absolar.org.br>. Acesso em: 5 Jun. 2020.
- Ahmed, N.K., Atiya, A.F., Gayar, N.E., and El-Shishiny, H. (2010). An empirical comparison of machine learning models for time series forecasting. *Econometric Reviews*, 29(5-6), 594–621.
- EEP, E.E.P. (2021). Glossário. <http://www.exemplary.com.au>. Acesso em: 07 Fev. 2021.
- INMET, I.N.d.M. (2020). Base de dados. <https://portal.inmet.gov.br/> Acesso em: 04 Jan. 2021.
- Jiang, P., Yang, H., and Heng, J. (2019). A hybrid forecasting system based on fuzzy time series and multi-objective optimization for wind speed forecasting. *Applied energy*, 235, 786–801.
- Lachut, D., Banerjee, N., and Rollins, S. (2014). Predictability of energy use in homes. In *International green computing conference*, 1–10. IEEE.
- Lai, C.S., Jia, Y., McCulloch, M.D., and Xu, Z. (2017). Daily clearness index profiles cluster analysis for photovoltaic system. *IEEE Transactions on Industrial Informatics*, 13(5), 2322–2332.
- Loschi, H.J. (2017). *Proposta de um método complementar de predição da irradiância solar global para curtos intervalos de tempo, baseado em processos de Markov*. Dissertação de Mestrado, UNICAMP.
- Martínez, F., Frías, M.P., Pérez, M.D., and Rivera, A.J. (2019). A methodology for applying k-nearest neighbor to time series forecasting. *Artificial Intelligence Review*, 52(3).
- Martins, G.S. and Giesbrecht, M. (2020). Estimação de índice de claridade utilizando método de aoki e observador ótimo de estado com inicialização exata. *Anais da Sociedade Brasileira de Automática*, 2(1).
- Mathiesen, B.V., Lund, H., and Karlsson, K. (2011). 100% renewable energy systems, climate mitigation and economic growth. *Applied energy*, 88(2), 488–501.
- Mousavi Maleki, S.A., Hizam, H., and Gomes, C. (2017). Estimation of hourly, daily and monthly global solar radiation on inclined surfaces: Models re-visited. *Energies*, 10(1), 134.
- Niu, T., Wang, J., Zhang, K., and Du, P. (2018). Multi-step-ahead wind speed forecasting based on optimal feature selection and a modified bat algorithm with the cognition strategy. *Renewable Energy*, 118, 213–229.
- Pinto, M.d.O. (2013). *Fundamentos de energia eólica*. Grupo Gen - LTC, Brasil.
- Rigollier, C., Bauer, O., and Wald, L. (2000). On the clear sky model of the esra european solar radiation atlas with respect to the heliosat method. *Solar energy*, 68, 33–48.
- Scharmer, K., Greif, J., and Dogniaux, R. (2000). *The European solar radiation atlas*, volume 2. Les Presses de l'école des mines.
- Sorjamaa, A., Hao, J., Reyhani, N., Ji, Y., and Lendasse, A. (2007). Methodology for long-term prediction of time series. *Neurocomputing*, 70(16-18), 2861–2869.
- Tolmasquim, M.T. (2016). *Energia renovável: hidráulica, biomassa, eólica, solar, oceânica*. Empresa de Pesquisa Energética: Rio de Janeiro, Brasil.
- Tomaszewski, G.A., Soares, R.S., and Haag, R. (2018). Obtenção do índice de claridade atmosférica para diferentes localidades do estado do rio grande do sul. *VII Congresso Brasileiro de Energia Solar, Gramado*.
- Zhang, N., Lin, A., and Shang, P. (2017). Multidimensional k-nearest neighbor model based on eemd for financial time series forecasting. *Physica A: Statistical Mechanics and its Applications*, 477, 161–173.