


PREVISÃO DA TEMPERATURA INTERNA DE UM FORNO DE CARVÃO DE ALVENARIA UTILIZANDO REDE NEURAL ARTIFICIAL DO TIPO LSTM

 <https://doi.org/10.22533/at.ed.135162517034>

Data de aceite: 02/07/2025

Rogério Santos Maciel

Theles de Oliveira Costa

Fernando Colen

Nilton Alves Maia

Sidney Pereira

Edy Eime Pereira Barauna

Talita Baldin

Luiz Henrique de Souza

métodos da janela, memória entre lotes e LSTM's empilhados com memória entre lotes. A métrica utilizada para avaliar os modelos foi o RMSE- *Root Mean Square Error*. Essa métrica verifica a distância entre os dados da série temporal original e os dados preditos pela LSM. Ao final do trabalho foi possível verificar que a LSTM configurada com o método da janela foi a que melhor se adequou para tarefa de prever a temperatura em um forno de carvão.

Palavras chave: Forno de Carvão, Rede Neural Artificial, Predição Térmica.

RESUMO: Neste trabalho foi avaliada a capacidade de uma Rede Neural Artificial do tipo LSTM - *Long Short Term Memory* para prever a temperatura em um forno de carvão vegetal. Este tipo de forno é amplamente usado no Brasil devido a sua facilidade de construção e pelo seu bom desempenho com um rendimento que pode chegar a 30% de carvão. A LSTM é um tipo de Rede Neural Artificial recorrente amplamente utilizada para predição de séries temporais e que têm demonstrado bons resultados. Foram testadas três diferentes modelos de Rede Neural Artificial configurados respectivamente com os

PREDICTION OF THE INTERNAL TEMPERATURE OF A MASONRY COAL OVEN USING LSTM ARTIFICIAL NEURAL NETWORK

ABSTRACT: In this work, the ability of a Long Short-Term Memory (LSTM) Artificial Neural Network was evaluated for predicting the temperature in a charcoal furnace. This type of furnace is widely used in Brazil due to its ease of construction and its good performance, with a yield that can reach up to 30% of charcoal. LSTM is a type of recurrent artificial neural network widely used for time series prediction and has demonstrated good results. Three different

Artificial Neural Network models were tested, configured respectively with the window method, batch memory, and stacked LSTM with batch memory. The metric used to evaluate the models was the RMSE (Root Mean Square Error). This metric measures the distance between the data from the original time series and the data predicted by the LSTM. In the end, it was possible to verify that the LSTM configured with the window method was the one that best suited the task of predicting the temperature in a charcoal furnace.

KEYWORDS: Coal Furnace, Neural Network, Thermal Prediction.

INTRODUÇÃO

O carvão vegetal tem seu uso descrito desde tempos, este é um produto obtido por meio da exposição da madeira a altas temperaturas, entre 300°C e 500°C, processo conhecido como carbonização (MENDES *et al.*, 1982; MACHADO *et al.*, 2014). Durante a carbonização ou pirólise da madeira como também é conhecido o processo de produção de carvão vegetal, o monitoramento e o controle da temperatura deve ser acompanhado. Para isso é necessário a presença de um carvoeiro, pessoa encarregada em fazer esse controle 24 horas por dia, tarefa exaustiva e perigosa já que os ambientes das carvoarias são descritos como insalubres. Atualmente o carvoeiro monitora a temperatura interna do forno de modo subjetivo. Para cada etapa da pirólise o carvoeiro observar a coloração da fumaça, além de verificar a presença de brasas em saídas de ar na parte inferior dos fornos que são conhecidas como tatus. Em todas as etapas é necessário que o operador faça fechamento e aberturas desses tatus, mantendo assim contato direto com gases tóxicos e altamente perigosos para a saúde humana (SILVA *et al.*, 2014).

Uma forma de melhorar as condições de trabalho nas carvoarias é promover a implantação de sistemas eletrônicos, tais como sensores que sejam capazes de ler e transmitir os valores da temperatura interna dos fornos e sistemas de controle que possam atuar diretamente no controle da temperatura (CARVALHO *et al.*, 2012).

Nesse sentido uma Rede Neural Artificial pode auxiliar no controle de temperatura durante a pirólise da madeira, pois as Redes Neurais Artificiais são modelos matemáticos inspirados no cérebro humano e que são capazes de adquirir, armazenar e utilizar o conhecimento através da experiência (RAMOS, 2003). Além disso as Redes Neurais Artificiais são sistemas adaptativos fáceis de treinar e são capazes de generalizar (JUNIOR, 2010).

Neste trabalho foi avaliada a capacidade de uma Rede Neural Artificial do tipo LSTM para prever a temperatura em um forno de carvão vegetal. Essas são redes recorrentes utilizadas em diferentes cenários de processamento de dados.

REVISÃO DE LITERATURA

Redes Neurais Artificiais

O desenvolvimento das Redes Neurais Artificiais data de 1943, quando McCulloch e Pitts introduziram o primeiro modelo de Rede Neural Artificial simulando máquinas, o modelo básico de auto-organização e modelo Perceptron de aprendizado supervisionado. O modelo de neurônio de McCulloch e Pitts é capaz de separar duas variáveis *booleanas*, entretanto não é possível treinar esse neurônio, pois nenhum método para adaptar os pesos do neurônio foi desenvolvido por McCulloch e Pitts (PICCININI, 2004).

As Redes Neurais Artificiais têm como inspiração o neurônio biológico e o sistema nervoso humano. Aquelas são sistemas que imitam as capacidades do sistema nervoso biológico utilizando um grande número de neurônios artificiais interconectado. As Redes Neurais Artificiais são classificadas como sistemas computacionais estruturados que são capazes de memorizar os padrões fazendo o ajuste dos padrões dos pesos sinápticos que estão presentes em um conjunto de dados (BRAGA *et al.*, 2000).

Em uma Rede Neural Artificial, os neurônios que recebem a informação do meio exterior são chamados de neurônios de entrada, o que corresponde aos órgãos dos sentidos biológicos. Os neurônios que têm a capacidade de mudar o mundo exterior são chamados de neurônios de saída que correspondem aos motoneurônios ou seja, são como os neurônios biológicos que excitam os músculos. Existem ainda os neurônios que não são nem de entrada nem de saída, e são os neurônios internos ou escondidos (FERREIRA *et al.*, 2011).

As Redes Neurais Artificiais podem ter dezenas, centenas e até milhares de unidades de processamento, isto é, neurônios que interagem entre si, um transmitindo informação a outro. Uma Rede Neural Artificial é uma estrutura inteligente que se assemelha ao cérebro humano e apresenta alguns aspectos tais como: aquisição de conhecimento a partir do processo de aprendizagem e conexão entre os neurônios mantendo a troca de informações (RELVAS, 2009). Uma Rede Neural Artificial também pode ser descrita como técnica computacional que aplica um modelo matemático baseado na estrutura neural de organismos inteligentes, e que vão acumulando conhecimento através da experiência (RUSSEL; NORVIG, 1995).

Redes Recorrentes

Uma Rede Neural Artificial recorrente é aquela que apresenta no mínimo um ciclo de realimentação, onde o sinal retorna para a camada anterior. Esse retorno da informação faz com que o processo de treinamento da rede seja ainda mais complexo.

As Redes Neurais Recorrentes são um tipo de rede que recebe sinais de entrada de duas fontes, um vem do passado que foi processado pela rede, que é a realimentação e outro do presente. A rede deve analisar esses dois sinais e verificar como será tratado o próximo sinal de entrada, esse processo é chamado de *feedback*, ou seja, o dado de saída é retornado à entrada. Essa característica das redes neurais funciona como uma memória, o que aproxima ainda mais a capacidade das RNAs da capacidade humana. As redes recorrentes podem conter uma camada de entrada, uma intermediária ou oculta e uma de saída, com os neurônios da camada de entrada conectados as da camada oculta seguinte, até à camada de saída (HAYKIN, 1998).

Redes LSTM

As redes neurais LSTM são redes recorrentes que podem agregar ciclos em seus algoritmos e têm sido aplicadas com sucesso para tarefas que envolvem a predição de séries temporais (SPANCERSKI, SANTOS, 2021). Além disso essas redes têm como objetivo a aprendizagem de padrões complexos em estruturas com vários estágios de processamento. As redes LSTM possuem as mesmas características das redes recorrentes convencionais, no entanto possuem a capacidade de guardar informações por longos períodos de tempo durante o processamento de uma série temporal (GREFF *et al.*, 2016).

O objetivo das redes neurais LSTM é compensar a falta de memória de longo prazo de uma Rede Neural Artificial retendo informações que vêm dos sinais de entrada. Essas redes apresentam em sua estrutura o mecanismo que recebe o nome de comporta que é responsável por regular o fluxo de informações nas células da memória. De modo resumido, as redes LSTM são compostas por uma cadeia de células de memória e por comportas que são responsáveis por manipular a informação (ALMEIDA *et al.*, 2020).

Métrica de Desempenho

Para análise do desempenho das redes foi utilizada a Raiz do Erro Quadrático **Médio, ou simplesmente RMSE** (*Root Mean Squared Error*) obtido a cada simulação. Esta métrica verifica a distância entre os dados preditos e os dados que compõem a série temporal original. Esse método foi utilizado por Gois *et al.*, (2018) que afirmam que quanto menor o valor encontrado, melhor será o modelo de rede. O cálculo do RMSE foi realizado através da Eq. (1).

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(y_i - \hat{y}_i)^2}{n}} \text{Eq. (1)}$$

Onde y_i representa o valor original, \hat{y}_i o valor predito e n o número de amostras utilizadas na simulação.

Fornos de Carvão de Alvenaria

A tecnologia de produção de carvão vegetal em fornos de alvenaria é altamente difundida e apresenta grande aceitação no Brasil. São fornos de fácil construção e não necessitam de um elaborado projeto de engenharia. No processo de operação dos fornos o carvoeiro necessita de informações simples, contudo, com elevada carga de subjetividade, uma vez que o desenvolvimento da rampa de aquecimento se dá por meio da coloração dos gases emitidos durante a carbonização (BARCELLOS, 2023).

Ademais, os fornos de carvão de alvenaria são construídos com tijolos comuns e sem chaminé. Nestes fornos a admissão do ar necessário para que ocorra a carbonização é feita por meio de aberturas localizadas na base do forno e são conhecidas como tatus. Estes são operados manualmente por meio de abertura e fechamento, isto é, ação de controlar os níveis de ar atmosférico para o processo de carbonização da madeira, que ocorre na ausência ou limitação de oxigênio no ambiente de pirólise. Também são usadas para inspeção visual do processo pois através dessas aberturas é possível verificar a presença de brasas na parte interna do forno (REZENDE; OLIVEIRA, 2001).

MATERIAL E MÉTODOS

Para realização deste estudo foram implementados três diferentes modelos de Rede Neural Artificial LSTM utilizando a linguagem Python dentro da plataforma de programação *Spyder* Anaconda. A linguagem Python é popular em computação técnica e científica: é muito versátil em modelagens e simulações, visualização de gráficos, desenvolvimento de algoritmos, análises numéricas, etc.

O computador utilizado para desenvolver a programação das Redes LSTM possui a seguinte configuração: sistema operacional *Windows* 10 de 64 *bits*, processador AMD A8-6500B APU com *Radeon* (tm) HD *Graphics*, 3,50 GHz, 4,00 GB de memória RAM instalada.

Os valores de temperatura que compõe o banco de dados utilizado nesse estudo foram coletados em um forno de carvão de alvenaria instalado no Instituto de Ciências Agrárias da Universidade Federal de Minas Gerais na Cidade de Montes Claros/MG. A coleta de temperatura foi feita utilizando o sensor de temperatura conhecido como termopar tipo k que é capaz de medir temperaturas entre 0 e 900°C. Este sensor foi utilizado em conjunto com um módulo leitor temperatura Max6675 que possui resolução de 0,25 °C.

Para instalação do sensor de temperatura foi seguida a metodologia descrita por (BRASÍLIA, 2019), o qual afirma que o melhor ponto para efetuar a medição da temperatura em um forno de alvenaria é em sua cúpula, local onde os valores de temperatura são mais constantes durante o processo de carbonização.

Após o sensor ser instalado na cúpula do forno o mesmo foi conectado ao módulo Max6675 e este módulo foi conectado a uma placa Raspberry Pi3 model B, processador Quad-core 64-bit arm Cortex A53 com clock de 1,2 GHz, 1GB, onde os valores de temperatura foram registrados. A justificativa de uso da placa Raspberry ocorre por esta ser um computador completo, pois apresenta diversas entradas e saídas, o que permite a conexão de um monitor e de um teclado, além da possibilidade do uso de um cartão micro SD para armazenamento do sistema operacional e um SSD externo ou um HD para aumentar a capacidade de armazenamento. A seguir na Figura 1 está demonstrado o diagrama de ligação do circuito onde é possível visualizar a conexão entre o termopar, o conversor de temperatura e a placa Raspberry.




Figura 1: Diagrama de ligação dos componentes

Fonte: Autores (2023)

As amostras de temperatura foram coletadas durante o processo de pirólise da madeira, isto é, ao longo da marcha de carbonização que compreende diversas fases de aquecimento do forno. Assim, durante esse tempo foram coletadas 470 amostras em intervalos de 5 minutos. Destaca-se que não foi contemplando a etapa de resfriamento do forno.

A primeira configuração testada foi com o método da janela. Nesta, diversas etapas de tempo podem ser usadas para efetuar a previsão da próxima etapa. Este procedimento recebe o nome de janela, por exemplo, dado o tempo atual (t) para prever o próximo valor de t na sequência ($t+1$) é possível utilizar o tempo atual (t) ou dois tempos anteriores ($t-1$ e $t-2$) como dados de entrada, neste caso a variável de saída será ($t+1$). Para formular esta situação foi utilizada a função *create_dataset* e para modificar o argumento foi utilizada a função *look_back* = 4, sendo este valor mantido para as configurações posteriores.

A segunda configuração testada foi com memória entre lotes. Normalmente o estado dentro da rede é redefinido após cada etapa de treinamento bem como a cada chamada para o *model.evaluate()* ou *model.fit()*. No método como memória entre lotes os dados de treinamento não são embaralhados, além disso este requer uma redefinição explícita da rede após cada exposição aos dados de treinamento. Para isso foi criado o próprio *loop* externo de épocas e dentro de cada época foram chamadas as funções *model.fit()* e *model.reset_states()*. Assim é feito o controle de quando o estado interno da rede LSTM é limpo. Deste modo é possível criar um estado durante toda a sequência de treinamento e se necessário manter este estado para fazer previsões.

O outro método testado foi com LTM's empilhados com memória entre lotes. Neste método foi acrescentado o parâmetro *return_sequences* na camada e este foi definido como *true*. Em todos os modelos de rede foi utilizado o otimizador adam e número de épocas utilizado foi igual a 100.

RESULTADOS E DISCUSSÃO

Na Tabela 1 são apresentados os resultados referentes aos três modelos de rede LSTM. Todos os métodos foram testados 10 vezes cada e em seguida foi calculado o valor médio do RMSE encontrado para cada rede, também foi calculado o desvio padrão a fim de verificar a uniformidade dos dados.

Ciclo	LSTM com o método da janela		LSTM com memória entre lotes		LTM's empilhados com memória entre lotes	
	RMSE		RMSE		RMSE	
	Treino	Teste	Treino	Teste	Treino	Teste
1	16,78	3,62	16,31	8,21	15,80	9,88
2	16,38	3,46	16,35	4,66	16,76	6,87
3	16,28	3,42	16,08	7,26	16,06	7,87
4	16,64	3,44	16,40	4,62	16,60	7,37
5	16,31	4,41	15,93	5,89	16,84	10,58
6	16,21	3,45	15,98	4,03	16,53	12,01
7	15,61	4,55	16,20	4,41	17,00	5,96
8	15,71	3,81	16,14	4,95	16,81	8,65
9	15,58	4,39	16,21	4,34	17,14	6,12
10	15,63	4,28	16,59	3,91	16,46	8,84
Média	16,11	3,88	16,21	5,22	16,60	8,41
Desvio padrão	0,42	0,44	0,19	1,37	0,39	1,87
Coefficiente de variação (%)	2,61	11,34	1,17	26,25	2,35	22,24

Tabela 1:RMSE das Redes Neurais LSTM

Fonte: Autores (2023)

Ao analisar os dados presentes na Tabela 1 é possível constatar que a Rede Neural Artificial LSTM com método da janela foi a que apresentou o menor erro médio de acordo como a métrica escolhida. Apesar do desvio padrão dessa rede ser superior ao da rede com memória entre lotes e da rede com LSTM's empilhados durante a etapa de treinamento é possível notar que nos 10 ciclos de treino e teste o valor médio do erro calculado é menor quando foi utilizada a rede com o método da janela, ainda que o coeficiente de variação das outras duas redes seja menor durante o treino, os valores médios de RMSE da rede com método da janela são menores. Vale ressaltar que foram utilizados 70% das amostras para treinar as redes e os 30% restantes foram utilizados na etapa de teste.

Além da análise das métricas escolhidas também foram gerados gráficos referentes aos dados de treinamento e de teste das redes neurais. Na Figura 2 pode ser visualizado o gráfico referente a predição realizada pela rede LSTM com método da janela, nesta é possível notar que existem diversos pontos de correspondência entre os dados da série temporal original e os dados que são usados nas etapas de treinamento e teste da rede.

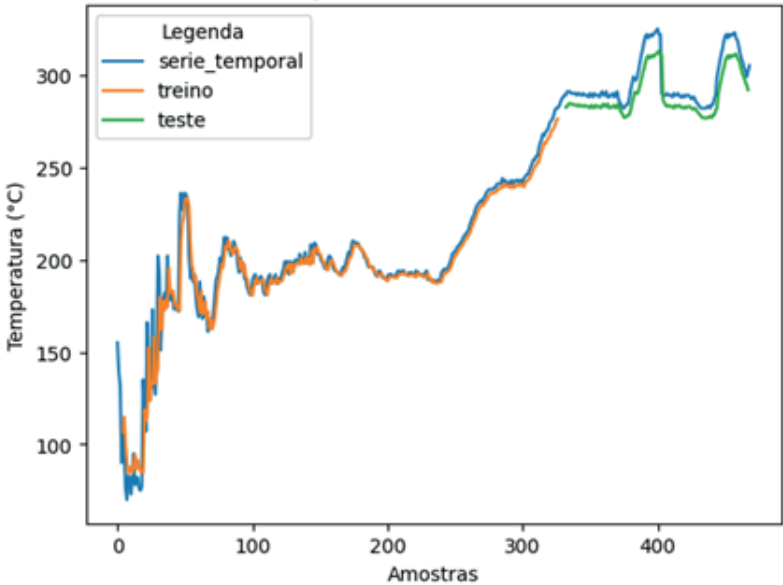


Figura 2: Predição feita pela rede LSTM com método da janela

Fonte: Autores (2023)

Na Figura 3 é apresentado o gráfico referente a predição realizada pela Rede Neural Artificial LSTM com memória entre lotes. Nesta é possível visualizar diversos pontos de correspondência entre os dados da série temporal original que são fornecidos a rede e os dados que são previstos pela Rede Neural Artificial.




Figura 3: Predição efetuada pela rede LSTM com memória entre lotes

Fonte: Autores (2023)

O gráfico referente a Rede Neural Artificial com LSTMs empilhados com memória entre lotes é apresentado na Figura 4, neste é possível observar que também existem diversos pontos de correspondência entre os dados da série temporal original e os dados que são usados nas etapas de treinamento e teste da rede.




Figura 4: Predição efetuada pela rede com LSTMs empilhados

Fonte: Autores (2023)

CONCLUSÃO

Os resultados deste trabalho mostram que a Rede Neural Artificial LSTM com o método da janela foi a que obteve melhor desempenho, sendo portanto, a configuração que melhor se adequou para a tarefa de prever a temperatura em um forno de carvão vegetal. Assim é possível constatar que as Redes Neurais Artificiais LSTM são eficazes quando são utilizadas para prever a temperatura interna de um forno de carvão vegetal podendo auxiliar no controle de temperatura durante o processo de carbonização da madeira.

REFERÊNCIAS

ALMEIDA, A., *et al.* Modelagem e Predição temporal de Parâmetros de Qualidade de Água usando Redes Neurais Profundas. Anais do Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais (WCAMA), p. 121-130, 2020.

BARCELLOS, D. Tipos de Fornos de Carvão Vegetal. Disponível em: <https://danielbarcellos.com/tipos-de-fornos-de-carvao-vegetal/>. Acesso em 1 de fevereiro de 2023.

BRAGA, A.; LUDERMIR, T. B.; CARVALHO, A.C.P.L.F. Redes Neurais Artificiais teoria e aplicações, Rio de Janeiro: LTC – Livros Técnicos e Científicos Editora S.A, 2000.

BRASÍLIA. Siderurgia Sustentável. Produção Sustentável de Carvão. Sistema Fornos-Fornalha, Manual de Operação. Distrito Federal, 2019.

CARVALHO, S.R., *et al.* Instrumentação Térmica Aplicada ao Processo de Produção de Carvão Vegetal em Fornos de Alvenaria. Revista Árvore, Viçosa-MG, v.36, n.4, 2012.

FERREIRA, L., *et al.*, Utilização de Redes Neurais Artificiais Como Estratégia de Previsão de Preços no Contexto de Agronegócio. Revista de Administração e Inovação, São Paulo, v.8, n.4, 2011.

GOIS, G.A., *et al.* Redes Neurais Artificiais para Predição do Consumo Total de Combustível de um Alto-Forno. Associação Brasileira de Metalurgia, São Paulo, 2018.

GREFF, K., *et al.* Lstm: a search space obyssey. IEEE transactions on neural networks and learning systems, 2016.

HAYKIN, S. Neural Networks: A Comprehensive Foundation. Prentice Hall PTR, Upper Saddle River. NJ, USA, 2 ed, 1998.

JUNIOR, A.D.A. Nonlinear Prediction of Oil Production Curves via Recursive Neural Networks, Master's Dissertation, UFRN, Natal, 2010.

MACHADO, G. O.; VOGEL, F.; SILVA, M. M. Influência da temperatura final de carbonização nas características físicas, químicas e mecânicas do carvão de cinamomo (*Melia azedarach* L.). *Âmbiência*, Guarapuava, v. 10, n. 1, 2014.

MENDES, M.G.; GOMES, A.P.; OLIVEIRA, J.B. Propriedades e controle de qualidade do carvão vegetal. In: PENEDO, W.R. (Ed.). *Produção e utilização de carvão vegetal*. Belo Horizonte: CETEC. (Série de Publicações Técnicas, 8), 1982.

PICCININI, G. The first computational theory of mind and brain: a close at McCulloch and Pitts's. Logical calculus of ideas immanent in nervous activity. Kluwer Academic Publisher, vol, 141, 2004.

RAMOS, M.A.F. Sistema de Identificação e Localização de Faltas em Linhas de Transmissão Baseado em Redes Neurais. Tese, Pontifícia Universidade Católica do Rio de Janeiro - PUC-RIO, 2003.

RELVAS, M.P. Fundamentos Biológicos da Educação: Despertando Inteligências e Afetividade no Processo de Aprendizagem. 2. ed. Rio de Janeiro: Wak, 2009.

REZENDE, J. L. P.; OLIVEIRA, A.D. Análise econômica e social de projetos florestais. Viçosa, MG: Universidade Federal de Viçosa, 2001.

RUSSEL, S.J.; NORVIG, P. Artificial Intelligence: a modern approach. Prentice Hall, 1995.

SILVA, D.A.L., *et al.* Análise de Viabilidade Econômica de Três Sistemas Produtivos de Carvão Vegetal por Diferentes Métodos. Revista Árvore, Viçosa-MG, v.38, n.1, 2014.

SPANCERSKI, J.S.; SANTOS. J.A.A. Previsão da produtividade de arroz: uma aplicação de redes neurais recorrentes LSTM. Revista Cereus. Vol. 13. N.2, 2021.