

# ESTUDO DE CASO DE LSTM E AUTOENCODER LSTM PARA PREVISÃO A CURTO PRAZO UTILIZANDO MÚLTIPLAS SÉRIES TEMPORAIS

**Fernando Vasconde de Arruda** – fernandovasconde@hotmail.com

Universidade Federal de São Paulo, Instituto do Mar

**Marcelo Pinho Almeida**

Universidade de São Paulo, Instituto de Energia e Ambiente

**Fernando Ramos Martins**

Universidade Federal de São Paulo, Instituto do Mar

**Resumo.** A energia elétrica é um dos principais recursos utilizados por nossa sociedade e o desenvolvimento tecnológico faz com que a demanda cresça. Com a crescente preocupação com os impactos associados ao efeito estufa e pactos globais pela redução das emissões, a relevância das fontes renováveis de energia está crescendo. A intermitência da geração fotovoltaica associada com as condições meteorológicas é um desafio tecnológico que vem sendo investigado intensamente. Com base nisso, investigamos métodos de previsão para horizonte de poucas horas adiante baseados em redes neurais LSTM (Long Short-Term Memory) pura ou combinada com uma rede autoencoder utilizando dados da planta fotovoltaica na Universidade de São Paulo. Os modelos LSTM revelam potencial promissor, mesmo com arquiteturas mais simples, exibindo margens de erro reduzidas, com RMSE variando entre 6.0% e 7.46%. No entanto, o uso do autoencoder, embora resulte em um RMSE ligeiramente superior, destacou-se pela sua estabilidade do valor dos desvios RMSE da previsão em torno de 8,2% em horizontes de previsão de até 3 horas.

**Palavras-chave:** Previsão Energia Solar, Redes Neurais LSTM, Sustentabilidade Energética

## 1. INTRODUÇÃO

A energia elétrica é um dos principais pilares da sociedade moderna e essencial para o desenvolvimento tecnológico, sendo difícil imaginar o mundo moderno sem esse recurso. As projeções recentes indicam um aumento na demanda de energia de aproximadamente 75% a 80% até 2050 (BP, 2022).

O relatório *Statistical Review of World Energy* de 2022 da *British Petroleum*, mostra que no ano de 2021 foram consumidos 595 EJ de energia no mundo, 82% provenientes de combustíveis fósseis. Esses combustíveis são os responsáveis pela contribuição da emissão dos gases de efeito estufa, que são apontados como os protagonistas das mudanças climáticas sentidas nas últimas décadas. Os acordos de Paris, em 2016, e Glasgow, em 2022, propuseram limitar o aumento da temperatura global em 1.5°C com a redução da emissão de gás carbônico em 45%, até 2030 e a neutralização até 2050. A Agenda 2030 proposta pela ONU em 2015, traz metas de desenvolvimento sustentável (ODS) que visam enfrentar desafios do mundo moderno, tendo entre eles o objetivo 13 que trata das mudanças climáticas e o objetivo 7 que visa promover acesso à energia para todos e fomentar a transição energética com redução do uso de fontes fósseis de energia. Com base nisso, os recursos renováveis surgem como estratégia tecnológica para suprir a demanda elétrica global, havendo a energia solar como uma alternativa promissora devido a distribuição espacial e modularidade das tecnologias de conversão (SMIL, 2019).

No Brasil o principal recurso utilizado para geração elétrica é o hidráulico representando 61.9% da oferta interna (EPE, 2023). A concentração da matriz elétrica em um recurso energético se mostrou frágil devido a influência da variabilidade climática que podem ocasionar períodos prolongados de secas reduzindo a capacidade de atender a demanda. Eventos recentes de secas extremas obrigaram o acionamento de usinas termelétricas para suprir a demanda interna, segundo o ONS. A utilização do recurso solar representa somente 4.4% da oferta interna, havendo aproximadamente 30.1 GWh de capacidade instalada nas centrais elétricas, sejam elas de serviço público ou de autoprodução (EPE, 2023). Pereira *et al.* (2017) avalia o potencial do território brasileiro e conclui que em localizações com menor irradiância solar, o potencial supera países como a Alemanha.

A expansão da utilização do recurso solar apresenta dificuldades a serem vencidas, dentre elas a intermitência. Sabe-se que a radiação solar sofre processos de interação com a atmosfera até atingir um módulo fotovoltaico. Esses processos radiativos são responsáveis por atenuar a quantidade de recursos disponíveis para conversão em energia elétrica. Conhecer a disponibilidade e variabilidade do recurso para um horizonte de tempo no futuro, é essencial para auxiliar no planejamento e gerenciamento da operação de plantas de geração distribuída ou centralizada.

Inman *et al.* (2013), traz uma revisão de técnicas que podem ser utilizadas para realização de previsão de recurso solar destacando métodos de regressão, técnicas de inteligência artificial, previsão numérica do tempo e modelos de detecção remota. Os autores destacam as redes neurais artificiais devido sua capacidade de trabalhar com problemas não lineares, estocásticos e de múltiplas variáveis, além de obter boa performance em ambientes pobres ou ricos em dados. Shamshirband *et al.* (2019) desenvolvem uma revisão bibliográfica com as técnicas de aprendizado profundo (*deep*

*learning*) utilizadas para previsão de recursos solar e eólico. Dentre os trabalhos analisados para previsão solar, o modelo LSTM (*long-short-term-memory*) se destacou dos demais, tendo uma variante a autoencoder-LSTM a que apresentou melhor performance (Gensler *et al.* 2016).

Nesse trabalho, avaliamos a performance dos modelos LSTM e Autoencoder-LSTM para previsão de geração fotovoltaica, similar ao desenvolvido por Gensler *et al.* (2016). Contudo, este estudo utiliza múltiplas séries temporais de variáveis meteorológicas enquanto Gensler *et al.* utilizaram somente a série temporal da potência do sistema. Os dados utilizados para treinamento do modelo são de origem da planta de geração fotovoltaica instalada na Universidade de São Paulo e as previsões foram realizadas para o intervalo de 1 até 3 horas. A mesma base de dados já foi utilizada por Ferreira Fonseca (2021) que utilizou redes neurais recorrentes em sua metodologia de previsão de curto prazo.

## 2. MATERIAL E MÉTODOS

### 2.1 Área de estudo

Os dados utilizados durante o projeto são da planta de geração fotovoltaica localizada na Cidade Universitária, campus da USP localizado na zona oeste da região metropolitana de São Paulo (Fig. 1). A região é caracterizada por ser a mais populosa do Brasil e apresenta elevados valores de emissão de gases do efeito estufa, tendo emitido 15 milhões de toneladas de CO<sub>2</sub> em 2017, sendo 61% relacionados ao transporte, 31% relacionados a energia estacionária e 8% a resíduos (São Paulo/Município, 2021). A região é caracterizada pelo clima subtropical úmido e com predominância de chuvas entre os meses de outubro e março como média superior a 1500 mm (INMET, 2020). A irradiação global horizontal na região tem média de 4,7 Wh/m<sup>2</sup>.dia, podendo atingir máximo de 6,2 Wh/m<sup>2</sup>.dia e mínimo de 3,7 Wh/m<sup>2</sup>.dia (Pereira *et al.*, 2017).



Figura 1 - Localização do gerador fotovoltaico (marcado em amarelo no canto inferior esquerdo) e da estação de coleta dos dados meteorológicos (marcado em amarelo no canto superior direito). A distância linear entre os pontos é de aproximadamente 140 metros.

### 2.2 Base de dados observados

A base de dados utilizada abrange três conjuntos de dados. A primeira são dados observados da estação meteorológica instalada no Laboratório de Sistemas Fotovoltaicos (LSF-IEE-USP), para as variáveis temperatura ambiente (°C), umidade relativa (%), velocidade do vento (m/s), pressão barométrica (mmHg), precipitação (mm), irradiação global (tanto na horizontal quanto no plano inclinado em 27°) (ambas em Wh/m<sup>2</sup>) e irradiação horizontal difusa. A resolução temporal de registro dos dados é horária e abrange o período de 2016 a 2021. A segunda base de dados é referente aos ângulos da posição solar, zenital e azimutal, que foram obtidos utilizando a biblioteca PVLIB em Python. Por fim, a base de dados do gerador fotovoltaico (SCADA) com os registros de potência do gerador, variável alvo em nosso trabalho. Os dados de potência são registrados com frequência de um minuto tornando necessário calcular a integral (Eq. 1) para converter os dados para resolução horária. A série temporal dos dados contempla o período entre 2015 e 2021, contudo, este estudo foi realizado com dados a partir de 2018.

$$E_h = \int_{h+0}^{h+59} E_{min} dt \quad (1)$$

onde  $E_h$  é a energia gerada pelo sistema fotovoltaico para a hora  $h$ .

## 2.3 Modelagem numérica baseada em aprendizado de máquinas

### 2.3.4 Long Short Term Memory (LSTM)

Os valores de geração fotovoltaica num dado instante futuro próximo não é independente dos valores observados no presente e no passado recente. A autocorrelação da série temporal é reduzida à medida que a defasagem entre o instante futuro e passado cresce. As RNN são redes neurais com uma configuração interna que permite a propagação de dados do passado, agindo como uma memória de eventos. Contudo, durante o treinamento, os pesos dos neurônios decaem para zero rapidamente para os atributos mais distantes no passado. Esse efeito, conhecido como *vanish gradient*, impede que o modelo represente adequadamente a autocorrelação da série temporal reduzindo o desempenho na simulação do processo físico para um futuro próximo. Com intuito em solucionar esse problema, Hochreiter e Schmidhuber (1997) propuseram uma nova arquitetura de rede recorrente denominada LSTM (Fig. 2), no qual o objetivo é lembrar de informações por períodos de tempo mais longos. Sua célula tem uma estrutura que transmite a informação de unidade para unidade, chamada de estado da célula (*cell state*), nela pode haver interações que adicionam (*input gate*) ou removem (*output gate*) informações. Além disso, o estado da célula também pode ser utilizado para determinar a saída da célula (*output gate*).

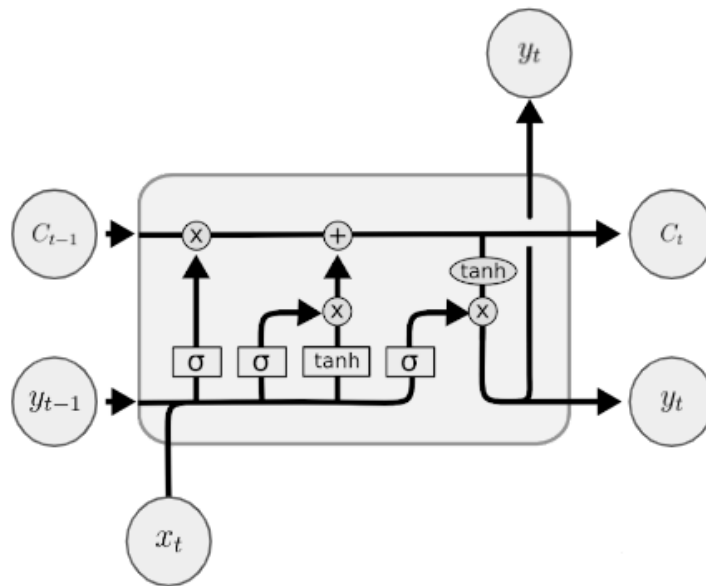


Figura 2 - Arquitetura da unidade LSTM

### 2.3.5 Autoencoder LSTM (AUTO-LSTM)

A arquitetura Auto-LSTM combina uma arquitetura de rede neural *autoencoder* com uma rede LSTM. O *autoencoder* é uma arquitetura cujo objetivo é reconstruir os dados de entrada na saída da rede. Sua topologia tem camadas inicial (para entrada de dados) e final (para saída de dados produzidos pela rede) de mesmo tamanho. A camada de entrada de dados (*input layer*) é seguida por uma região chamada de *encoder* na qual o número de neurônios é reduzido a cada nova camada. O processo se inverte com um conjunto de camadas de neurônios que espelha a região anterior, ampliando a quantidade de neurônios nas camadas, essa região se chama *decoder*.

O uso combinado das redes autoencoder e LSTM tem como foco aproveitar a capacidade de redução de dimensionalidade da região *encoder* para alimentar a rede LSTM. Dessa forma, o conjunto de informação dos dados de entrada é “comprimida” otimizando a quantidade de informação representativa para descrição do processo físico a ser simulado pela rede LSTM (Fig. 3).




Figura 3 - Fluxograma de funcionamento do modelo.

## 2.4 Seleção de preditores

A fim de avaliar os preditores a serem utilizados para o treinamento dos modelos utilizamos duas técnicas. A primeira é a correlação de Pearson que quantifica a relação linear entre duas variáveis contínuas. A outra técnica é conhecida como Informação Mútua que identifica a quantidade de informação que um atributo contém sobre a variável selecionada como alvo, ou seja, quanto maior o valor do parâmetro estatístico de informação mútua, maior será a dependência ou relação intrínseca entre o possível preditor e a grandeza física alvo da simulação numérica (Cover e Thomas, 2005).

## 2.5 Treinamento dos modelos

O treinamento das redes LSTM diferem das redes neurais mais convencionais, sendo necessário utilizar uma matriz tridimensional com os seguintes parâmetros: quantidade de mini séries temporais, os *timesteps* e a quantidade de atributos que serão utilizados. A criação das mini séries temporais estão relacionadas com os *timesteps*, que seria a quantidade de dados do passados que serão utilizados na simulação. Por exemplo, para utilizar um dia de dados do passado precisamos converter as séries temporais em mini séries temporais com dados de 24 horas no passado a fim de serem utilizadas como entrada para o modelo de previsão.

A base de dados foi dividida em três conjuntos: treino, teste e validação. O conjunto de dados para treino contém dados referentes aos anos de 2018 a 2020. Já para a base de teste e validação utilizamos o ano de 2021, para que ambas houvessem dados de todos os meses realizamos uma divisão, ou seja, para cada mês separamos uma fração dos dias para uso na etapa de teste e outra fração para uso na validação. Dessa forma mantivemos uma proporção de 60% da base voltada para o treinamento, 20% voltada para teste e 20% voltada para validar o modelo. Após esse processo os dados foram normalizados a fim de mantê-los no intervalo entre 0 e 1.

O processo de treinamento da Auto-LSTM se diferencia pelo fato de ser necessário treinar um autoencoder e posteriormente utilizar somente a região do encoder. Para treinamento do autoencoder utilizamos os dados de 2016 e 2017 e realizamos uma divisão em três conjuntos de dados (treino, teste e validação) similar com o treinamento da LSTM, só que dessa vez a divisão foi feita de forma aleatória respeitando a proporção de 60% para treinar e 20% tanto para testar quanto para validar.

Também limitamos a base de dados para ângulos zenitais menores que  $70^\circ$  para que o modelo fosse treinado para prever em condições que o gerador estivesse iluminado pela radiação solar. Dessa forma evitamos os horários noturnos em que não há radiação solar ou em que as incertezas dos dados são elevados em razão da baixa altitude do Sol.

Além disso, utilizamos um algoritmo de parada antecipada (*Early Stopping*) durante o treinamento para evitar que o modelo fique super ajustado (*overfitting*) à base de treinamento. Esse algoritmo compara o valor de erro entre as épocas. Nele há um contador chamado de paciência cuja função é avaliar se a função de erro continua a cair, neste trabalho utilizamos a paciência em dez, isso significa que, se o valor da função erro não melhorar em dez épocas o treinamento deve parar e o modelo deve considerar os pesos da época com menor erro (Goodfellow, *et al.* 2016).

Como forma de identificar os melhores hiperparâmetros para as topologias de rede, utilizamos um algoritmo de busca exaustiva, o *Grid Search CV*. Esse algoritmo testa diversas combinações de parâmetros e retorna aquela configuração que apresenta o menor erro. Para esse trabalho avaliamos a quantidade de unidades LSTM (as opções eram 100, 200 e 300) e os *timesteps* (as opções eram 12, 24 e 48).

## 2.6 Avaliação das incertezas da previsão do modelo

Para avaliação da performance dos modelos foram utilizados os seguintes indicadores estatísticos: raiz do erro quadrático médio (RMSE), o viés e o coeficiente de regressão ( $R^2$ ), Eq. 2, 3 e 4. Sendo que, N representa a quantidade de amostras utilizadas pelo treinamento/validação, a variável “x” representa os valores medidos em superfície e a variável “y” representa os valores previstos pelo modelo. Shamsheerband *et al.* (2019) em sua revisão bibliográfica, levanta as

principais métricas utilizadas para a avaliação de modelos de previsão para energia solar, tendo esses citados anteriormente como os mais utilizados nos trabalhos citados.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \tag{2}$$

$$Vies = \frac{\bar{y} - \bar{x}}{\bar{x}} \tag{3}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (\bar{x} - x_i)^2} \tag{4}$$

### 3. RESULTADOS

#### 3.1 Seleção de preditores

A Fig. 4 mostra o mapa de calor referente ao resultado da correlação de Pearson. O mapa de calor indica a correlação praticamente nula da pressão barométrica e da precipitação com a variável alvo do modelo de previsão (Pot\_BT) e as demais grandezas físicas avaliadas como possíveis preditores. Vale destacar também que a variável ângulo azimutal apresenta baixa correlação positiva (negativa) com a temperatura ambiente e velocidade do vento (umidade relativa). O ângulo azimutal apresenta correlação nula com a variável alvo e com as demais grandezas avaliadas.




Figura 4 - Mapa de calor com os valores da correlação de Pearson entre as variáveis. Quanto mais vermelho indica correlação positiva e quanto mais azul indica correlação negativa.

A Tab. 1 apresenta os resultados relativos ao teste de informação mútua. Nota-se que os valores estatísticos da pressão barométrica e da precipitação são 0.004 e 0 respectivamente. Esses valores reforçam o resultado da análise de correlação de Pearson que indica a não relevância desses preditores para a variável alvo. Por outro lado, o ângulo azimutal é o terceiro atributo que mais acrescenta informação à variável alvo, indicando sua relevância como preditor.

Tabela 1- Resultado referente ao teste de informação mútua, no qual os atributos testados com a Potência do gerador

ATRIBUTO TESTADO	VALOR DE INFORMAÇÃO
Temperatura ambiente (°C)	0.269
Umidade relativa (%)	0.333
Velocidade do vento (m/s)	0.225
Pressão barométrica (mm Hg)	0.004
Precipitação (mm)	0
Ângulo zenital	0.84
Ângulo azimutal	0.504
GHI (kWh/m <sup>2</sup> )	1.076

Como base nos resultados citados selecionamos os preditores de temperatura ambiente, velocidade do vento, umidade relativa, GHI e os ângulos zenitais e azimutais para serem utilizados como preditores em nosso modelo.

### 3.2 Resultados do treinamento

Os hiperparâmetros definidos pelo algoritmo de busca exaustiva foram 200 unidades e 48 *timesteps*. Além disso, para o autoencoder utilizamos uma arquitetura com 6 neurônios de *input* e *output* e 4 neurônios em sua camada latente.

Com intuito de avaliar-se a performance do modelo com o autoencoder, utilizamos os mesmos hiperparâmetros utilizados na LSTM. Vale destacar que neste trabalho não testamos uma arquitetura de LSTM com camadas profundas. Os resultados alcançados das métricas RMSE e Viés podem ser observados na Tab. 2. O modelo LSTM apresenta desvios menores variando entre 6.4% e 7.58%, já a versão com autoencoder já apresenta maior estabilidade no horizonte de previsões, variando entre 8.02% e 8.40%.

Tabela 2 - Avaliação dos modelos para previsão no horizonte de 3 horas.

		Previsão		
		1 hora	2 horas	3 horas
LSTM	RMSE (%)	6.00	6.81	7.46
	Viés (%)	-0.15	0.03	-3.5
	R <sup>2</sup>	0.60	0.66	0.70
AUTO-LSTM	RMSE (%)	8.08	8.02	8.40
	Viés (%)	3.62	4.95	12.97
	R <sup>2</sup>	0.55	0.49	0.60

A Fig. 5 traz os gráficos de dispersão dos dados de potência medidos pelos previstos. Podemos notar que nos momentos de maior geração de energia, os modelos apresentam assertividade melhor quando comparado em condições de menor geração. Também pode-se notar que o Auto-LSTM superestimou as previsões em condições de menor produção, como indica o valor do viés que variou de 3.62% no horizonte de 1 hora para 12.97% para o horizonte de 3 horas.

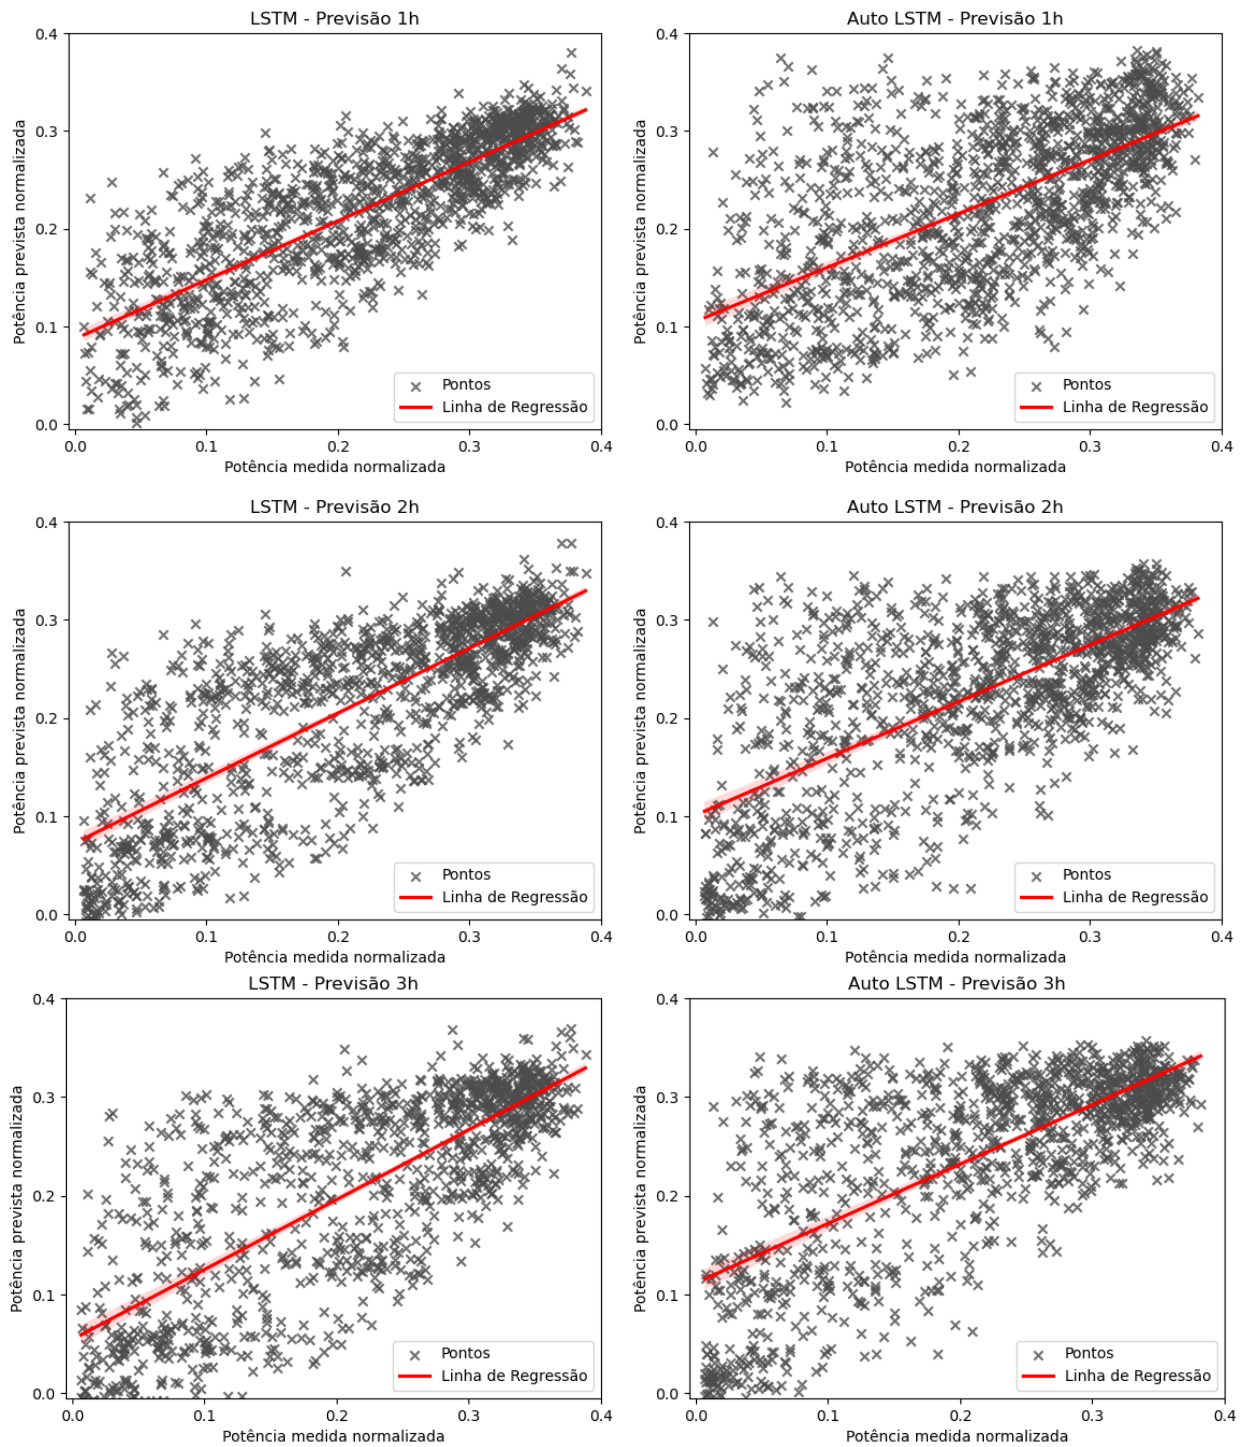


Figura 5 - Gráficos de dispersão dos modelos LSTM (a esquerda) e Auto-LSTM (a direita)

Também foi avaliado o desempenho sazonal do modelo, considerando a estação chuvosa entre os meses de novembro e abril e os meses mais secos no qual variam entre maio e outubro. O resultado do RMSE dos testes pode ser visto na Tab. 3.

Observou-se que as previsões produzidas pelo LSTM puro apresentou desvios crescentes com o aumento do horizonte de previsão tanto para os meses secos quanto para a estação chuvosa. Durante a estação seca, os desvios de RMSE passaram de 6.06% no horizonte de 1 hora para 7.31% no horizonte de 3 horas. Já na estação chuvosa, os desvios variaram de 6.73% até 7.80% para os mesmos horizontes mencionados anteriormente.

O modelo combinando autoencoder-LSTM diferente do LSTM puro, apresentou um erro menor nos meses chuvosos no qual teve variação do RMSE entre 7.66% e 8.26%. Já nos meses secos, no horizonte de 1 hora e 3 horas teve um valor de 8.68% e 8.60%, enquanto que no horizonte de 2 horas o valor foi de 8.37%, demonstrando não haver uma tendência de desvio para esses meses como nos outros.

Os resultados apontam que o modelo LSTM-puro tem desempenho superior a versão com autoencoder tanto nos meses secos quanto nos meses chuvosos, contudo o modelo Auto-LSTM é mais estável no decorrer do horizonte de

previsões. Enquanto que o modelo LSTM apresenta desvios de 1.47 e 1.46 nos meses secos e chuvosos respectivamente, o Auto-LSTM não apresenta tendência nos meses secos e o desvio nos meses chuvosos é de 0.6.

Tabela 3 - Avaliação dos modelos para previsão no horizonte de 3 horas durante meses secos e chuvosos.

		Previsão Meses Secos			Previsão Meses Chuvosos		
		1 hora	2 horas	3 horas	1 hora	2 horas	3 horas
LSTM	RMSE (%)	5.67	6.44	7.14	6.26	7.11	7.72
	Viés (%)	-0.97	-1.16	-5.20	0.62	1.16	-2.10
	R <sup>2</sup>	0.57	0.65	0.68	0.61	0.67	0.73
AUTO-LSTM	RMSE (%)	8.68	8.37	8.60	7.66	7.77	8.26
	Viés (%)	6.49	7.10	14.68	1.55	3.43	11.81
	R <sup>2</sup>	0.43	0.55	0.61	0.59	0.58	0.59

#### 4. CONCLUSÃO

Os resultados mostram o potencial da utilização de modelos baseados em LSTM, já que mesmo com arquiteturas mais simples conseguem fornecer previsões de geração fotovoltaica com desvios reduzidos com RMSE variando entre aproximadamente 6.0% e 7.46%. Já a aplicação do autoencoder como redutor de dimensionalidade obteve valor de RMSE maior variando entre 8.08% e 8.40%, porém demonstra um desempenho com incertezas mais estáveis no horizonte de previsão de até 3 horas. Há de destacar que a área de estudo é desafiadora no que tange a condição atmosférica ao longo do ano. Durante a estação seca, a concentração de aerossóis atinge valores elevados (Bet, 2022) modificando o fator espectral da irradiância solar incidente na superfície durante dias de céu com baixa nebulosidade. Outro aspecto é a partição da irradiância solar incidente nas componentes direta e difusa decorrente da elevada carga de aerossóis presentes na atmosfera em períodos longos sem precipitação na área urbana onde a planta fotovoltaica está instalada.

A pesquisa terá continuidade visando avaliar novas arquiteturas de LSTM, como a LSTM estacada, encoder decoder LSTM, entre outras, com objetivo de alcançar melhor performance. Também iremos avaliar a estabilidade do modelo em horizontes de eventos maiores do que 3 horas e em condições de céu claro, nublado e parcialmente nublado. Algoritmos evolutivos, como o algoritmo genético, serão aplicados para identificar os melhores hiperparâmetros, uma vez que esse tipo de abordagem permite uma busca mais ampla. Os estudos futuros incluirão a avaliação de novos hiperparâmetros, como a curva de ativação das unidades LSTM e hiperparâmetros específicos para cada arquitetura de LSTM. Ainda há espaço para redução de incertezas por meio de otimização de preditores utilizados e topologia das redes implementadas.

#### Agradecimentos

Os autores agradecem à FAPESP pelo auxílio da bolsa de mestrado disponibilizado no processo 2022/10281-6, e ao Instituto Nacional de Mudanças Climáticas (INCT-MC) - processos CNPq 465501/2014- 1, FAPESP 2014/50848-9 e CAPES/FAPS Nº 16/2014. Os autores registram o agradecimento à Universidade Federal de São Paulo e à Universidade de São Paulo pelo suporte de infraestrutura e apoio institucional para o desenvolvimento da pesquisa.

#### REFERÊNCIAS

- Bet, L. G., et al. Estudo sobre o impacto dos aerossóis atmosféricos no fator espectral de módulos fotovoltaicos em São Paulo. *Revista Brasileira de Energia Solar* 13.2 (2022): 146-156.
- BP (British Petroleum) Statistical Review of World Energy edição 2022. Disponível em: <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/statistical-review/bp-stats-review-2022-full-report.pdf>. Acessado em: 16/06/2022
- Cover, T. M.; Thomas, J. A. *Elements of Information Theory*. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2005. ISBN 978047121959
- EPE (Empresa em pesquisa energética), Balanço energético nacional. 2023. Link: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-748/topico-687/BEN2023.pdf>
- Ferreira Fonseca, Wellington Winicius. Rede neural recorrente para previsão de curto prazo da usina fotovoltaica de 540 kWp da USP. 2021. Tese de Mestrado. Universidade de São Paulo.



- Gensler, A.; Henze, J.; Sick, B.; Raabe, N. Deep learning for solar power forecasting—An approach using autoencoder and LSTM neural networks, in Proc. IEEE Int. Conf. Syst., Man, Cybern. (SMC), , pp. 2858–2865, Oct. 2016.
- Goodfellow, I., Yoshua B., and Aaron C.. Deep learning. MIT press, 2016.
- Hochreiter, S., and Jürgen S.. Long short-term memory. Neural computation 9.8 (1997): 1735-1780.
- Inman, R. H.; PEDRO, H. T. C.; COIMBRA, C. F. M. , Solar forecasting methods for renewable energy integration, Progress in Energy and Combustion Science, vol. 39, no. 6, pp. 535–576, 2013.
- INMET. Gráficos Climatológicos: São Paulo – SP. 2020. Disponível em: <https://clima.inmet.gov.br/GraficosClimatologicos/SP/83782>
- ONS, Flexibilização das restrições hidráulicas gerou economia de R\$ 27 bi durante a crise hídrica 2020/2021, disponível em: [https://www.ons.org.br/Paginas/Noticias/20221103\\_Flexibilizacao\\_das\\_restricoes\\_hidraulicas\\_gerou\\_economia\\_de\\_R\\_27\\_bi\\_durante\\_a\\_crise\\_hidrica\\_2020\\_2021.aspx](https://www.ons.org.br/Paginas/Noticias/20221103_Flexibilizacao_das_restricoes_hidraulicas_gerou_economia_de_R_27_bi_durante_a_crise_hidrica_2020_2021.aspx). Acessado em 30/11/2023
- Pereira, E. B. et al. Atlas brasileiro de energia solar. 2. ed. São José dos Campos: INPE, 2017. ISBN 978-85-17-00089-8. 2017.
- SÃO PAULO. Plano de Ação Climática do Município de São Paulo 2020-2050. 2021. Disponível em: [https://www.prefeitura.sp.gov.br/cidade/secretarias/upload/meio\\_ambiente/arquivos/PlanClimaSP\\_BaixaResolucao.pdf](https://www.prefeitura.sp.gov.br/cidade/secretarias/upload/meio_ambiente/arquivos/PlanClimaSP_BaixaResolucao.pdf) (acessado em 30/05/2022).
- Shamshirband, S., Rabczuk, T., & Chau, K. W. A survey of deep learning techniques: application in wind and solar energy resources. IEEE Access, 7, 164650-164666. 2019.
- Smil, V. Distributed Generation and Megacities: Are Renewables the Answer?, IEEE Power and Energy Magazine, vol. 17, no. 2, pp. 37-41, March-April 2019, doi: 10.1109/MPE.2018.2884112.

## CASE STUDY OF LSTM AND LSTM AUTOENCODER FOR SHORT-TERM FORECASTING USING MULTIPLE TIME SERIES

**Abstract.** *Electricity is one of the main resources used by our society and technological development means that demand is growing. With growing concern about the impacts associated with the greenhouse effect and global pacts to reduce emissions, the relevance of renewable energy sources is growing. The intermittency of photovoltaic generation associated with weather conditions is a technological challenge that is being investigated intensively. Based on this, we investigated forecasting methods for a horizon of a few hours ahead based on vanilla LSTM (Long Short-Term Memory) neural networks or combined with an autoencoder network using data from the photovoltaic plant at the University of São Paulo. The LSTM models show promising potential, even with simpler architectures, exhibiting low error margins, with RMSE ranging from 6.0% to 7.46%. However, the use of the autoencoder, although resulting in a slightly higher RMSE, stood out for its stability of the value of the RMSE deviations of the forecast at around 8.2% over forecast horizons of up to 3 hours.*

**Keywords:** *Solar Energy Forecasting, LSTM Neural Networks, Energy Sustainability*