

Previsão de deslocamentos em barragens: uma aplicação da rede neural artificial LSTM

Dam displacement prediction: an application of the LSTM artificial neural network

RESUMO

Matheus Pabis Esteves
mth.pesteves@gmail.com
Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

Suellen Ribeiro Pardo Garcia
suellenpardo@utfpr.edu.br
Universidade Tecnológica Federal do Paraná, Toledo, Paraná, Brasil

Modelos estatísticos são amplamente utilizados para prever o comportamento de instrumentos de monitoramento de barragens de concreto, porém com o avanço do processamento computacional as redes neurais artificiais surgem como alternativa para previsões. Tais métodos têm como objetivo detectar mudanças no comportamento da barragem, possibilitando à correção de possíveis falhas. O principal objetivo deste trabalho é comparar um modelo estatístico de previsões com uma rede neural artificial para previsões. Foram utilizadas as medidas do pêndulo direto do bloco F19 da barragem de Itaipu, datados de 2005 a 2017. Implementou-se o modelo dinâmico autoregressivo de defasagens distribuídas (ADL) no software R com auxílio do pacote dLagM, e a rede neural artificial Long Short-Term Memory (LSTM) com regressões e treinamento baseado no método Backpropagation Through Time na linguagem Python, assim mediu-se a raiz do erro quadrático médio (RMSE). Constatou-se que a rede neural artificial teve RMSE menor que o modelo estatístico, neste caso a rede neural artificial apresentou-se melhor que o modelo estatístico.

PALAVRAS-CHAVE: Barragens de concreto. Previsão. Pêndulo direto. Software R. Python.

Recebido: 19 ago. 2019.

Aprovado: 01 out. 2019.

Direito autorial: Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



ABSTRACT

Statistical models are widely used to predict the operation of concrete dam monitoring instruments, but with the advancement of computational processing as artificial neural networks and alternatives for forecasting. Such methods have to change behavioral changes, make possible the correction of possible failures. The main objective of this paper is to compare a statistical forecasting model with an artificial neural network for forecasting. We used the direct pendulum measures of block F19 of the Itaipu dam, dated from 2005 to 2017. Implementation of the data propagation autoregression (ADL) model without Software R with the aid of dLagM package, and artificial neural network long short-term memory (LSTM) with regressions and backpropagation through time-based training the python language, as well as the root of the mean square error (RMSE). Therefore, this is an artificial neural network had less than the statistical model, in this case an artificial neural network is better than the statistical model.

KEYWORDS: Concrete dams. Prediction. Direct Pendulum. R Software. Python.

INTRODUÇÃO

Os desastres em Barragens de Usinas Hidrelétricas são eventos de características únicas, como o grave acidente de Sayano-Shushenskaya em 2009, na Rússia, que custou a vida de mais de 70 pessoas e paralisou o sistema elétrico do país causando vários transtornos. O acidente primário ocorreu na unidade 2, provocando uma sequência de acidente nas outras unidades (CBDB).

O rompimento de uma barragem pode ter consequências diversas, sendo de caráter social, econômico, governamentais, ambientais e perdas humanas (SERRANO-LOMBINHO, MORALE-TORRES, GARCÍA-KAB, 2012). Conforme Sarmiento e Molina (2014), a evolução de situações comuns de serem solucionadas para situações mais graves, se dá pela não adoção de providências relacionadas ao monitoramento das barragens.

Uma das maneiras de detectar mudanças no comportamento da barragem é utilizar a previsão de modelos estatísticos para os dados dos instrumentos considerando ações de variáveis ambientais como a variação do nível do reservatório e variações da temperatura ambiente (GARCIA, 2016).

As redes neurais artificiais têm grande relevância atualmente, devido a sua capacidade de aprender padrões por treinamento, portanto o objetivo deste trabalho é comparar a eficácia de um modelo estatístico de previsões com uma rede neural artificial para previsões.

MATERIAL E MÉTODOS


Os dados utilizados foram obtidos pelo sistema ADAS (*Automatic Data Acquisition System*) que a Barragem de Itaipu possui desde 2005, as leituras são feitas a cada 30 minutos, além das realizadas manualmente por técnicos. Utilizou-se as leituras do sensor pêndulo direto do bloco F19 que calcula o deslocamento da crista da barragem.

O modelo estatístico de previsões escolhido foi o modelo dinâmico autoregressivo de defasagens distribuídas (ADL) que inclui regressores dos valores defasados da componente dependente e valores correntes e defasados das componentes independentes. Foi implementado em Software R com auxílio do pacote dLagM que provê modelos de séries temporais de regressão.

Optou-se pela utilização de *Long Short Term Memory* (LSTM) que são um tipo de redes neurais recorrentes (RNR) capazes de aprender dependências de longo prazo. Foram introduzidos por Hochreiter e Schmidhuber (1997), refinados e popularizados para trabalharem em uma grande variedade de problemas. São projetados para evadir o problema de dependência de longo prazo, ou seja, lembrar informações por longos períodos de tempo é o seu padrão (COLAH, 2015).

Conforme Colah (2015) os LSTMs possuem uma estrutura de cadeia semelhante as RNRs, mas o módulo de repetição é diferente, em vez de ter uma camada de rede neural, existem quatro. A Figura 1 demonstra a representação do módulo de repetição de um LSTM.

Figura 1 – Módulo de repetição de um LSTM



Fonte: Colah (2015).

O funcionamento dos LSTMs é por estado da célula, que é como uma correia transportadora, assim as informações percorrem toda estrutura em interações lineares menores e não sofrem alterações. A capacidade de adicionar ou remover informações no estado da célula é regulado por estruturas chamadas portas, compostas por uma camada de rede neural *sigmoid*, que decide quando cada componente deve ser liberado, e uma operação de multiplicação pontual (COLAH, 2015).

Brownlee (2016) diz que os LSTM são desenvolvidos de diferentes maneiras, porém são comumente utilizados:

- Regression*: modelo mais simples, que implementa o modelo teórico;
- Regression com Windows Method*: baseado no modelo teórico, porém implementado para utilização de múltiplas variáveis;
- Memory Between Batches*: utiliza memória entre os módulos de repetição, fazendo-se capaz de guardar longas sequência de dados;
- Stacked com Memory Between Batches*: utiliza o empilhamento de arquiteturas de redes neurais profundas.

O método de treinamento mais utilizado em LSTMs é o *Backpropagation Through Time* (BPTT), seu funcionamento começa desdobrando uma RNR no tempo, a rede contém entradas e saídas, mas todas as cópias da rede compartilham os mesmos parâmetros. Em seguida, o algoritmo de retro propagação é usado para encontrar o gradiente do custo em relação a todos os parâmetros da rede (BROWNLEE, 2017).

O BPTT traz como vantagem um treinamento mais rápido para RNRs, porém ele possui certa dificuldade com local optimum, criando respostas caóticas para alguns tipos de redes neurais artificiais (BROWNLEE, 2017).

A metodologia utilizada iniciou pela obtenção da raiz do erro quadrático médio (RMSE) do modelo estatístico, através do código já implementado em Software R de projeto anterior. Implementou-se os modelos de LSTMs citados anteriormente em Python utilizando a biblioteca de redes neurais *Keras* e obteve-se os RMSE. Por fim comparou-se os RMSEs do modelo ADL e dos LSTMs.


RESULTADOS E DISCUSSÕES

Neste tópico, apresenta-se como foi realizado a construção dos algoritmos dos LSTMs em Python com auxílio do Keras para previsão das leituras do pêndulo direto e comparação com modelo ADL.

Os passos para os modelos de LSTMs são iguais, somente alteram-se no momento da criação e treinamento da rede neural. Tem-se, localizar, carregar e normalizar os dados, dividi-los em duas partes, treinamento e testes (optou-se por 67% dos dados para treinamento e os 33% restante para testes), modelar os dados em $X=t$ e $Y=t+1$, modelar as entradas em [exemplos,período,previsões], criar e treinar a rede neural LSTM, fazer as previsões, calcular o RMSE e plotar as previsões de treinamento e testes.


As Figuras de 2 a 5 apresentam os resultados obtidos com os modelos de LSTMs. Em azul apresenta-se os dados originais, em alaranjado as previsões para os dados de treinamento e em verde são as previsões para os dados de testes.

Figura 2 – Previsões do modelo Regression




Fonte: Autoria Própria (2019).

Figura 3 – Previsões do modelo Regression com Windows Method




Fonte: Autoria Própria (2019).

Figura 4 – Previsões do modelo Memory Between Batches



Fonte: Autoria Própria (2019).

Figura 5 – Previsões do modelo Stacked com Memory Between Batches



Fonte: Autoria Própria (2019).

Os RMSEs são apresentados na Tabela 1.

Tabela 1 – RMSEs dos modelos

Modelo	RMSE
ADL	0,45
LSTM - Regression	0,09
LSTM - Regression com Windows Method	0,11
LSTM - Memory Between Batches	0,23
LSTM - Stacked com Memory Between Batches	0,24

Fonte: Autoria Própria (2019).

Nota-se que o RMSE dos modelos do LSTM é menor que do modelo ADL, e que o modelo Regression obteve o melhor resultado entre os modelos LSTM.

CONCLUSÃO

Com este trabalho foi possível evidenciar a aplicabilidade da rede neural LSTM na previsão de instrumentos de barragens de concreto. Identificou-se que as previsões feitas pelo LSTM possuem um RMSE menor do que o modelo estatístico ADL.

Como trabalhos futuros pretende-se estender os algoritmos para realizar previsões de diferentes instrumentos de segurança de barragem e considerar as variáveis independentes de nível do reservatório e temperatura ambiente.

REFERÊNCIAS:

BROWNLEE, J. **A Gentle Introduction to Backpropagation Through Time**. 2017. Disponível em: <https://machinelearningmastery.com/gentle-introduction-backpropagation-time/>. Acesso em: 14 ago. 2019.

BROWNLEE, J. **Time Series Prediction with LSTM Recurrent Neural Networks in Python with Keras**. 2016. Disponível em: <https://machinelearningmastery.com/time-series-prediction-lstm-recurrent-neural-networks-python-keras/>. Acesso em: 14 ago. 2019.

CBDB. Comitê Brasileiro de Barragens. **O grave acidente verificado na UHE-Sayano-Shushenskaya sobre o Rio Yenisei (Sibéria), na Rússia**. Disponível em: www.cbdb.org.br/documentos/news/acidenterussia.doc. Acesso em: 9 ago. 2018.

COLAH. **Understanding LSTM Networks**. 2015. Disponível em: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>. Acesso em: 14 ago. 2019.

GARCIA, S. R. P. **Modelagem e previsão de deslocamentos em barragens de concreto**: aplicação a dados de instrumentação da usina hidrelétrica de Itaipu. Universidade Federal do Paraná. Curitiba. 2016.

SARMENTO, F. J.; MOLINA, O. A. **Barragem Camará -PB: o deplecionamento evitaria a catástrofe?**. 2004. Disponível em: <http://www.acquatol.com.br/paginas/pub-camara.pdf>. Acesso em: 9 ago. 2018.

SERRANO-LOMBILHO, A.; MORALES-TORRES, A.; GARCÍA-KAB, L. Consequence estimation in risk analysis. **Risk Analysis, Dam Safety, Dam Security and Critical Infrastructure Management**, p. 107-112, 2012.