

Uso de uma Rede Neural Convolutacional Unidimensional para detecção de falhas em processos industriais

Antonio L. S. Loca¹, Thomas W. Rauber¹

¹Programa de Pós-Graduação em Informática - Universidade Federal do Espírito Santo (UFES) Vitória – ES - Brasil

antonio.loca@ifes.edu.br, thomas@inf.ufes.br

Abstract. *In this paper we present the use of deep learning in the context of fault detection in industrial processes. A Convolutional Artificial Neural Network composed by a 1D convolution architecture is used. A feature selection proposal based on Spearman's rank correlation coefficient is presented, aiming at obtaining an efficient fault identification system with optimized performance in one-dimensional signals. The Tennessee Eastman Process chemical process simulator is used to evaluate the performance of the solution.*

Resumo. *Neste artigo é apresentado o uso de aprendizagem profunda - Deep Learning, no contexto de detecção de falhas em processos industriais. É empregada uma Rede Neural Artificial Convolutacional composta por uma arquitetura de convolução 1D. Apresenta-se uma proposta de seleção de características baseada no coeficiente de correlação de postos de Spearman visando à obtenção de um sistema eficiente de identificação de falhas com desempenho otimizado em sinais unidimensionais. O simulador de processo químico Tennessee Eastman Process é utilizado a fim de avaliar o desempenho da solução.*

Introdução

Para Paoletti e outros (2018), Redes Neurais Artificiais (RNA) têm sido amplamente utilizadas para classificação de dados, no entanto sua aplicação ainda enfrenta alguns desafios, especialmente relacionados ao processamento de informações de grande volume, pois tal cenário resulta em um aumento significativo no tempo de computação necessário para o aprendizado, além de provocar a saturação dos parâmetros da rede - *overfitting* e conseqüentemente causar sua paralisia.

Técnicas de aprendizagem profunda em RNA têm sido aplicadas a muitos campos onde estas produzem resultados, em alguns casos, superiores aos obtidos com especialistas humanos. Redes Neurais Profundas - *Deep Neural Network* (DNN), Redes Neurais Recorrentes - *Recurrent Neural Network* (RNN), e Redes Neurais Convolutacionais - *Convolutional Neural Network* (CNN) são as arquiteturas de aprendizado profundo mais frequentemente usadas. (GUO *et al.*, 2018, p. 3, tradução nossa).

Uma DNN é uma RNA com múltiplas camadas ocultas que podem modelar relações não lineares e extrair novas características implícitas nos dados. A CNN é uma classe de Redes Neurais Artificiais profundas que se tornou cada vez mais popular para classificação de informações. “[...] CNNs provaram ser muito eficazes para classificação de grandes conjuntos compostos por dados bidimensionais[...].” (PAOLETTI *et al.*, 2018, p. 1, tradução nossa). Para Lekha e outros (2017), a CNN consegue uma redução significativa nos dados de pré-processamento e elimina a necessidade de técnicas separadas de extração de características, aprendendo e extraíndo automaticamente dados

diretamente do sinal bruto. Este estudo teve como principal motivação a aplicabilidade da aprendizagem profunda, que tem como principais componentes o uso de arquiteturas convolucionais, em dados de natureza unidimensional buscando um modelo eficiente de detecção de falhas.

Aprendizagem profunda na indústria

Segundo Wu (2018), durante as últimas três décadas, os processos industriais, tais como os processos químicos, tornaram-se cada vez mais automatizados. No entanto, tem havido muitos acidentes trágicos em tais processos, que em muitas situações resultaram em acidentes fatais para os operadores e sérios danos ambientais. O contingenciamento das situações onde as falhas nos processos ocorrem está atualmente, em sua maior parte, confiado a operadores que precisam estar atentos às situações anormais e tomar decisões corretivas a tempo. Abdeljaber e outros, (2018) entendem que as CNNs unidimensionais alcançaram o desempenho de última geração na detecção de falhas por meio de sinais com origem em dados coletados por sensores. Para Zilong (2018), a convolução é o método mais importante para analisar informações no processamento digital de sinais. Parece, portanto natural para detectar falhas em tais dados o uso de uma CNN unidimensional.

Rede Neural Convolucional

As CNNs são bastante predominantes no campo da visão computacional devido às suas vantagens: invariância de tradução, compartilhamento de parâmetros e conectividade esparsa. CNNs 1D (Redes Neurais Convolucionais de uma Dimensão) também são ferramentas eficazes para sequenciamento de tempo. (Liu, 2018). Seu uso, diferente de abordagens tradicionais que utilizam pré-processamento dos sinais de forma estatística para posterior uso no aprendizado de uma RNA, possibilita que os dados sejam utilizados em sua forma bruta, dispensando a necessidade de qualquer processamento computacional que não seja o dispensado com a própria aprendizagem. A ideia por trás da aprendizagem profunda é descobrir múltiplos níveis de representação com a expectativa de que recursos de alto nível representem uma semântica mais abstrata dos dados. (GUO et al., 2017).

A aplicação de camadas de convolução em *data sets* poder ser utilizada como extratora de características implícitas nos dados. A convolução em dois sinais relacionados com o tempo e de função f e g respectivamente, é definida por

$$(f * g)(t) = h(t) = \int_{-\infty}^{\infty} f(\tau) \cdot g(t - \tau) d\tau \quad (1)$$

Uma CNN é uma arquitetura composta de três camadas distintas: uma camada de entrada, uma camada convolucional e uma camada de *pooling*. O parâmetro k especifica o número de mapas de recursos na camada convolucional

$$(f * g)[n] \equiv \sum_{m=-\infty}^{\infty} f[n - m]g[m]. \quad (2)$$

Onde f é a camada de entrada e g é um dos k filtros que a CNN irá otimizar para uma função objetiva durante o processo de aprendizagem.

Durante o trabalho, foram desenvolvidas diferentes arquiteturas de CNN com o propósito de encontrar a que otimizasse os quesitos de desempenho e exatidão na tarefa identificar os estados de falha a partir dos dados fornecidos. A acurácia obtida em cada uma das configurações foi utilizada como métrica para a escolha da arquitetura. A configuração utilizada neste estudo proporcionou o maior acerto, sendo composta por duas camadas de Convolução 1D, duas de *MaxPooling* 1D e uso da técnica de *Dropout*.

As estruturas para a Rede Neural foram montadas com o uso de *Keras*, que é uma API - (*Application Programming Interface*) de alto nível escrita em *Python* e que é executada sobre as bibliotecas *TensorFlow* ou *Theano*. (Chollet, 2015). Após a fase de aprendizado, foram aplicados testes de validação cruzada – *cross-validation* com dados oriundos de um segundo conjunto de dados para classificação que não foram utilizados na fase de aprendizado da rede. O coeficiente de correlação de postos de *Spearman* foi utilizado no estudo como método estatístico para avaliar o grau de dependência entre as variáveis envolvidas na simulação do processo, viabilizando a seleção dos lotes e um estudo mais aprofundado na relação de aprendizagem da Rede face a diferentes intensidades de dependência entre os atributos utilizados. Este parâmetro estatístico foi escolhido por ser apropriado quando as variáveis utilizadas podem estar distorcidas ou quando há valores extremos nos dados. (Mukaka, 2012). Tais situações se aplicam aos dados estudados.

O coeficiente de correlação de postos de *Spearman* é dado por

$$r_s = 1 - \frac{6 \sum_{i=1}^n D_i^2}{n(n^2 - 1)} \quad (3)$$

Onde D_i é a diferença nas classificações para x e y .

Simulador de processo químico

O simulador *Tennessee Eastman Process* (TE) foi utilizado como referência para fornecer os dados que serviram como treinamento da rede, avaliação de desempenho e validação dos resultados. Esta ferramenta possibilita a configuração de até 20 diferentes tipos de falhas que podem ser introduzidas em determinados momentos da execução da simulação do processo, assim como removidas no tempo desejado. Os dados produzidos pelo simulador são compostos de valores essencialmente unidimensionais e simbolizam medições realizadas por sensores localizados em partes críticas dos estágios de produção, representando o comportamento e estado dos equipamentos envolvidos e possibilitando o monitoramento do progresso da manufatura. O treinamento da Rede foi feito com amostras de 8 e 12 características selecionadas dentre as 52 fornecidas pelo TE. Tais lotes de variáveis foram escolhidos de acordo com um valor mínimo positivo predefinido do Coeficiente de Correlação *Spearman* apresentado de forma mútua entre elas. Para o estudo, foram usados os valores de 30, 50 e 70 de porcentagem de correlação entre as variáveis do lote analisado. Os dados utilizados no trabalho representam o equivalente a 30 dias de simulação, sendo os primeiros 15 dias de funcionamento normal do processo e os 15 dias restante com alguma falha. O método foi repetido para cada uma das 20 falhas possíveis do TE. Dentre as falhas, há diferentes níveis de dificuldade de reconhecimento destas nos dados gerados pelo simulador.

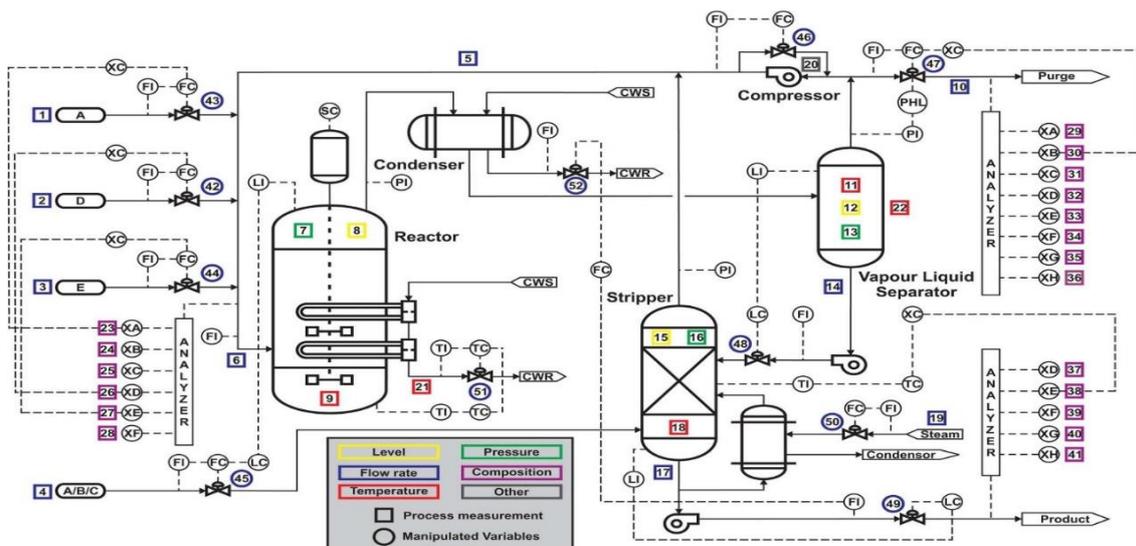


Figura 1. Fluxograma do processo *Tennessee Eastman*

Resultados

A utilização da estrutura de Rede Neural Convolutiva 1D proporcionou o aprendizado nos dados de forma satisfatória. Utilizando camadas de convolução unidimensionais nos dados e seguindo a metodologia descrita para comparação, foram alcançadas altas taxas de acurácia no aprendizado da Rede Neural. Com a escolha de características com correlação mútua igual ou superior a 70%, o fator de exatidão da rede alcançou valores acima de 90%. Na tabela 1 é possível verificar que houve um aumento no fator de aprendizagem da rede quando uma maior correlação entre os dados foi definida. Pode-se notar, também que com o uso de 12 características do simulador os ganhos nos valores de acurácia da rede tiveram um ligeiro aumento nas três faixas de correlação analisadas.

Tabela 1. Valores de acurácia do aprendizado com 8 variáveis x percentual de correlação mútua entre as características

	≤ 30 %	≤ 50 %	≥ 70 %		≤ 30 %	≤ 50 %	≥ 70 %
Falha 01	93.74	99.93	99.98	Falha 11	50.56	55.58	66.95
Falha 02	95.41	99.89	99.92	Falha 12	97.08	96.77	98.76
Falha 03	95.28	96.71	98.83	Falha 13	91.50	95.72	98.07
Falha 04	54.74	56.33	67.77	Falha 14	50.65	55.92	67.75
Falha 05	53.84	55.67	67.74	Falha 15	53.66	56.37	66.63
Falha 06	98.00	99.99	1	Falha 16	55.33	57.18	68.56
Falha 07	99.23	99.99	1	Falha 17	54.36	56.98	69.18
Falha 08	95.28	98.59	99.86	Falha 18	89.98	98.62	99.41
Falha 09	55.63	56.35	68.11	Falha 19	63.26	65.53	67.39
Falha 10	62.14	66.68	74.78	Falha 20	65.74	67.69	84.26

Tabela 2. Valores de acurácia do aprendizado com 12 variáveis x percentual de correlação mútua entre as características

	≤ 30 %	≤ 50 %	≥ 70 %		≤ 30 %	≤ 50 %	≥ 70 %
Falha 01	96.88	98.52	1	Falha 11	60.68	63.34	70.52
Falha 02	96.00	1	1	Falha 12	98.09	99.01	99.04
Falha 03	95.41	98.21	99.97	Falha 13	92.52	96.54	99.08
Falha 04	56.74	60.01	70.26	Falha 14	58.95	60.35	69.03
Falha 05	56.17	57.22	70.17	Falha 15	60.23	62.49	69.08
Falha 06	98.85	1	1	Falha 16	62.37	68.60	71.45
Falha 07	1	1	1	Falha 17	56.61	62.98	70.76
Falha 08	98.98	1	1	Falha 18	91.45	99.13	1
Falha 09	58.47	62.56	70.28	Falha 19	67.62	68.08	69.92
Falha 10	63.74	69.62	78.53	Falha 20	70.12	75.63	87.22

Discussão

Os resultados encontrados sugerem que a utilização de uma arquitetura de Rede Neural de aprendizagem profunda mostra-se eficaz para a detecção de falhas em dados amostrais de processos de fabricação e pode representar uma ferramenta importante para o gerenciamento da fábrica, contribuindo para preservar a integridade, qualidade e segurança dos processos, garantindo o bem-estar dos operários neles envolvidos. Com uma identificação precoce das falhas, torna-se possível o seu contingenciamento e prevenção de maiores problemas decorrentes.

A arquitetura apresentada permite uma maior taxa de aprendizado com menos pré-processamento dos dados e com menores recursos computacionais consumidos. Todos estes fatores se traduzem em confiabilidade no diagnóstico da Rede Neural em apresentar o reconhecimento de um estado de falha nos dados analisados durante a produção. A distinção dos valores dos resultados de acerto da classificação, quando analisados sob a ótica da correlação entre os diferentes atributos, reflete a importância da escolha de características para o aprendizado que representem a leitura de sensores de pontos do processo onde os estágios são interdependentes e podem evidenciar mais facilmente um estado de falha a partir de suas leituras.

Conclusão

O coeficiente de correlação *Spearman* mostrou ser um bom indicador para mensurar a interdependência nos dados e agrupá-los de forma a possibilitar a seleção das características mais significativas para o aprendizado. Os resultados obtidos apontam que o aprendizado é mais eficiente quando, na escolha das características para treinamento, são utilizadas as que apresentam maior correlação mútua. Tais informações podem contribuir para uma capacidade de aprendizado superior, tornando todo o processo de produção mais controlado e possível de se recuperar de um estado de falha. Diferentes arquiteturas de CNN 1D ainda podem ser desenvolvidas para um maior fator de acerto.

Referências

Abdeljaber, O., Avci, O., Kiranyaz, M. S., Boashash, B., Sodano, H., & Inman, D. J. (2018). 1-D CNNs for structural damage detection: verification on a structural health

- monitoring benchmark data. *Neurocomputing*, 275, 1308-1317. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0925231217315886>>. Acesso em: 20 jan. 2019.
- Chollet, F. (2015). Keras. Disponível em: <<https://keras.io>>. Acesso em: 20 jan. 2019.
- Guo, M. F., Zeng, X. D., Chen, D. Y., & Yang, N. C. (2018). Deep-Learning-Based Earth Fault Detection Using Continuous Wavelet Transform and Convolutional Neural Network in Resonant Grounding Distribution Systems. *IEEE Sensors Journal*, 18(3), 1291-1300. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8116617>>. Acesso em: 20 jan. 2019.
- Guo, T., Dong, J., Li, H., & Gao, Y. (2017, March). Simple convolutional neural network on image classification. In *2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA)* (pp. 721-724). IEEE. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8078730>>. Acesso em: 20 jan. 2019.
- Lekha, S., & Suchetha, M. (2018). Real-Time Non-Invasive Detection and Classification of Diabetes Using Modified Convolution Neural Network. *IEEE journal of biomedical and health informatics*, 22(5), 1630-1636. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8052493>>. Acesso em: 22 jan. 2019.
- Liu, Z., Meng, X. A., Cui, J., Huang, Z., & Wu, J. (2018, October). Automatic Identification of Abnormalities in 12-Lead ECGs Using Expert Features and Convolutional Neural Networks. In *2018 International Conference on Sensor Networks and Signal Processing (SNSP)* (pp. 163-167). IEEE. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8615916&tag=1>>. Acesso em: 26 jan. 2019.
- Mukaka, M. M. (2012). A guide to appropriate use of correlation coefficient in medical research. *Malawi Medical Journal*, 24(3), 69-71. Disponível em: <<https://www.ajol.info/index.php/mmj/article/download/81576/71739>>. Acesso em: 21 jan. 2019.
- Paoletti, M. E., Haut, J. M., Plaza, J., & Plaza, A. (2018). A new deep convolutional neural network for fast hyperspectral image classification. *ISPRS journal of photogrammetry and remote sensing*, 145, 120-147. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924271617303660>>. Acesso em: 20 jan. 2019.
- Wu, H., & Zhao, J. (2018). Deep convolutional neural network model based chemical process fault diagnosis. *Computers & Chemical Engineering*, 115, 185-197. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0098135418302990>>. Acesso em: 20 jan. 2019.
- Zilong, Z., & Wei, Q. (2018, March). Intelligent fault diagnosis of rolling bearing using one-dimensional multi-scale deep convolutional neural network based health state classification. In *Networking, Sensing and Control (ICNSC), 2018 IEEE 15th International Conference on* (pp. 1-6). IEEE. Disponível em: <<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8361296>>. Acesso em: 20 jan. 2019.