

## **AUTOMAÇÃO DO SISTEMA DE DOSAGEM DE PRODUTOS QUÍMICOS EM UMA ESTAÇÃO DE TRATAMENTO DE ÁGUA COM USO DE INTELIGENCIA ARTIFICIAL – CASE ETA JARDIM JAPÃO, COTIA-SP**

### **Walison de Carvalho<sup>(1)</sup>**

Licenciatura em Química pela Universidade Camilo Castelo Branco. Especialista em Elaboração e Gerenciamento de Projetos para a Gestão Municipal de Recursos Hídricos pelo Instituto Federal de Ciências e Tecnologia do Ceará. Especialista em Geoprocessamento da Pontifícia Universidade Católica de Minas Gerais. Técnico em Sistemas de Saneamento da Companhia de Saneamento Básico de São Paulo.

### **Marcia Carvalho da Silva<sup>(2)</sup>**

Técnico Químico pela Organização Sorocabana de Ensino Colégio Oswaldo Cruz. Bacharel em Farmácia e Bioquímica pela Universidade Paulista. Técnico em Sistema de Saneamento da Companhia de Saneamento Básico de São Paulo 2

### **Geraldo Kulicz da Silva<sup>(3)</sup>**

Engenheiro Ambiental pela Faculdade Oswaldo Cruz. Especialista em Engenharia de Saneamento Ambiental pela Universidade Presbiteriana Mackenzie. Pós-graduando em Gestão e Tecnologias em Cidades Inteligentes pela Faculdade de Engenharia de Sorocaba.

### **Anderson José Ferreira<sup>(4)</sup>**

Técnico em Análise Química Industrial pelo SENAI Fundação Zerrenner

**Endereço<sup>(1)</sup>:** Est. Municipal do Aguassai, 1100 – Jardim Japão - Cotia - SP - Brasil - Tel: +55 (11) 4611-4516  
- e-mail: [walisondecarvalho@yahoo.com.br](mailto:walisondecarvalho@yahoo.com.br)

## **RESUMO**

O crescimento demográfico da Região Metropolitana de São Paulo nas últimas décadas ocasionou vários problemas de desabastecimento em alguns municípios da Zona Oeste, como Cotia, Santana do Parnaíba e Pirapora do Bom Jesus. Em Cotia, mais precisamente no distrito de Caucaia do Alto, a dificuldade no abastecimento de água nos bairros Jardim Japão, Aguassai e Água Espreada pelo sistema produtor Alto Cotia, fez com que fosse criado em fevereiro de 1998 um sistema isolado de tratamento, utilizando como manancial o rio Sorocamirim para suprir a demanda hídrica desta região. O Sistema Isolado do Jardim Japão é formado pela estação elevatória de água bruta, localizada a 200 m da ETA e utilizando o sistema de captação superficial, estação de tratamento convencional por ciclo completo, estação elevatória de água tratada, reservatório de apoio e booster. A necessidade em aumentar a eficiência operacional dos sistemas de tratamento de água da Companhia de Saneamento Básico de São Paulo, em alinhamento com o mapa operacional, foi iniciado em 2018 um projeto de automatização das estações de tratamento de água, empregando eletrodos de processo para o monitoramento on-line dos parâmetros de controle e qualidade da água produzida e automação dos sistemas de dosagem de produtos químicos utilizando inteligência artificial. Diversas ferramentas de modelagem foram desenvolvidas para tentar simular os processos operacionais em estações de tratamento de água e esgoto, no entanto as incertezas, variáveis, interações e dinâmica destes processos geralmente levam a dificuldades na obtenção do desempenho desejado na operação destes sistemas de tratamento. O uso da inteligência artificial é uma abordagem eficaz para lidar com as complexidades acima descritas, por exemplo, as complexas inter-relações entre os vários fatores e atividades de um sistema podem ser explicadas através do processo de aquisição de conhecimento. Além disso, a lacuna entre o resultado gerado pelos esforços detalhados de modelagem e a aplicabilidade desse resultado a uma situação prática pode ser preenchida através da construção de um sistema automatizado, permitindo a incorporação de considerações implícitas e muitas vezes qualitativas consideradas cruciais pelos engenheiros e operadores. O presente trabalho *teve* como objetivo apresentar as principais mudanças na estrutura, nos processos de tratamento da ETA Jardim Japão com a implementação deste sistema.

**PALAVRAS-CHAVE:** Automação, Rede neural, tratamento de água, ETA Jardim Japão

## **INTRODUÇÃO**

O rápido desenvolvimento de novas tecnologias de inteligência artificial (IA), combinadas com novas fontes de energia mais eficientes é uma realidade que está cada vez mais próxima do nosso cotidiano. Isso, por sua vez, permitirá uma transformação revolucionária de modelos, processos operacionais, atividades de pesquisa e

vários outros aspectos que vão desde a segurança nacional ao bem-estar e a economia (URAIKU et al., 2007; ZHAO et al., 2016). Yin et al. (2015) descreveram um breve panorama evolucionário de técnicas baseadas em dados nas últimas duas décadas, onde o recente desenvolvimento de aplicações industriais modernas é apresentado principalmente a partir das perspectivas de monitoramento e controle, e sua metodologia, baseada em medições de processos e modelos de dados. Jeschke et al. (2016) desenvolveram a ciência do sistema central necessária para permitir o desenvolvimento de complexos sistemas ciber-físicos de fabricação (CPS). Lund et al., (2014) descreveram as questões centrais que contribuem e caracterizam o crescimento mundial e regional da internet das coisas (IOT).

Existem diversos algoritmos de IA para o monitoramento de processos produtivos e da integridade de máquinas, dentre eles podem ser citado o método de redes neurais recorrentes (RNN) para o aprendizado e extração de estruturas finitas de estado autômato (GILES et al., 1992), a abordagem RNN de tempo contínuo para sistemas dinâmicos (FUNAHASHI; NAKAMURA, 1993), o esquema de rede neural artificial (RNA) para memória de curto prazo de longa duração (GERS et al., 2000), a abordagem da rede de estado de eco para a formação de RNA (JAEGER, 2000), o algoritmo RNA para a aprendizagem de temporização precisa (GERS et al., 2003), o decodificador de RNA para codificação frases e aprendizado de representações (CHOO et al., 2014), o método RNA para modelagem de sequências (CHUNG et al., 2014) e o método de redes neurais convolucionais para reconhecimento de dígitos manuscritos (ZHAO et al., 2016).

Diversas ferramentas de modelagem foram desenvolvidas para simular processos operacionais em estações de tratamento de água e esgoto, incineradores de resíduos e instalações de medição e controle da poluição atmosférica, no entanto, as incertezas, interatividade e dinâmica destes processos geralmente levam a dificuldades na obtenção do desempenho desejado na operação destes sistemas (ARAÚJO, 2008; BIANCHI, 1998). O uso da IA é uma abordagem eficaz para lidar com as complexidades descritas, por exemplo, as complexas inter-relações entre os vários fatores e atividades de um sistema podem ser explicadas através do processo de aquisição de conhecimento. Além disso, a lacuna entre o resultado gerado pelos esforços detalhados de modelagem e a aplicabilidade desse resultado a uma situação prática pode ser preenchida através da construção de um sistema automatizado, permitindo a incorporação de considerações implícitas e muitas vezes qualitativas consideradas cruciais pelos engenheiros e operadores (CHANG; HUANG, 2003).

A aplicação de IA para controlar um processo envolve vários subprocessos que precisam ser gerenciados ou automatizados, por exemplo, em um ambiente de onde o objetivo seja a mitigação da poluição gerada por determinado processo produtivo, há vários níveis para resolver o problema de gerenciamento e controle. No nível mais baixo, existem instrumentos de monitoramento, detecção e manipulação das variáveis de processo, onde os instrumentos são frequentemente conectados a uma estrutura que é capaz de implementar uma sequência lógica de controle. Nos próximos níveis, o principal componente é o *host* de supervisão, que mantém os aplicativos de controle com as funções principais, como o banco de dados (COSTA, 2006; SELLITTO, 2002).


O sistema de RNA é uma técnica de inteligência artificial que tenta imitar a capacidade do cérebro humano de resolver problemas. As redes neurais artificiais são capazes de auto-organização e aprendizado, através de padrões e conceitos que podem ser extraídos diretamente de dados históricos (BAXTER et al., 1999). Em geral, redes neurais artificiais podem ser aplicadas aos mais diversos tipos de problemas, como por exemplo a classificação padrão, o agrupamento, a categorização, a aproximação de função, a previsão, a otimização, a associação e a memória de controle processos (JAIN et al., 1996). Quando apresentados com padrões de dados, conjuntos de entradas e saídas históricas que descrevem o problema a ser modelado, as RNAs mapeiam os relacionamentos de causa e efeito entre a entrada do modelo dados e dados de saída. Esse mapeamento dos relacionamentos de entrada e saída na arquitetura do modelo RNA permitem desenvolver modelos a serem usados para prever o valor do parâmetro de saída do modelo, dada qualquer combinação razoável de entrada dos dados.

Quando aplicada as estações de tratamento de água, a técnica de RNA apresenta várias vantagens sobre os métodos de modelagem. Com relação ao processamento de dados, o tipo o relacionamento entre os dados de entrada e saída é determinado exclusivamente a partir das informações apresentadas, sem pressupostos da rede.

Além disso, a técnica de RNA é tolerante a falhas no desenvolvimento de modelos e em aplicações subsequentes, descontinuidades nos dados, diferentes níveis de precisão. Existem sete componentes principais em um modelo de RNA, que são conhecidas coletivamente como arquitetura de RNA, as unidades de processamento ou neurônios; o estado de ativação; a função de saída para cada neurônio; o padrão de conectividade ou pesos entre unidades; uma regra de propagação para padrões de atividades através dos pesos; uma função de ativação para combinar as entradas que colidem com uma unidade com o estado atual dessa

unidade, produzindo assim um novo nível de ativação para essa unidade e uma regra de aprendizagem em que pesos são modificados pela experiência (RUMELHART et al., 1986). Dependendo do software da RNA utilizado, alguns ou todos esses componentes podem ser ajustados ou modificados pelo desenvolvedor do modelo. O processo de aprendizado da RNA para tratamento de água envolve modelos de processo, nos quais um ou dois parâmetros de saída estão sendo modelados, este é um processo de otimização não-linear de saída com várias entradas (CHOO et al., 2014; CHUNG et al., 2014).

As redes neurais artificiais aprendem reorganizando sua estrutura interna de acordo com uma regra ou algoritmo de aprendizado para minimizar o erro entre o valor de saída real e o valor de saída previsto pelo modelo para todo o conjunto de padrões de dados. A Figura 1 apresenta uma descrição do processo de aprendizagem da RNA, descrevendo uma rede *feed-forward* de  $n$  camadas com retropropagação de erro (BAXTER et al., 1999).



**Figura 1: Componentes de uma rede neural artificial de propagação simples. Fonte: Adaptado de Santos et al., 2017.**

As inúmeras interfaces da RNA podem ser classificadas em dois grupos de acordo com a aplicação a que se destina, as interfaces de otimização de processos e as interfaces virtuais de laboratório. As interfaces de otimização de processos permitem que os técnicos de processos otimizem custos e a dosagem de produtos químicos on-line em tempo real de acordo com variações na qualidade da água do manancial. As interfaces virtuais de laboratório são tipicamente aplicativos offline que use dados históricos e permite que os técnicos e outras pessoas realizar experimentos virtuais em larga escala, afim de obter diverentes modelos dos fatores que afetam os processos da estação de tratamento.

Como tal, dados os valores das entradas do processo, os valores de todos, exceto um dos parâmetros de controle do processo, e um valor desejado do parâmetro de saída do processo, o modelo prevê o valor ideal de um parâmetro do processo. Os métodos diretos e indiretos podem ser combinados para desenvolver um sistema de controle de processo automatizado confiável. Dentro do contexto de controle do processo de tratamento de água, um valor desejado da saída do processo é selecionado e o modelo inverso do processo é usado para selecionar as condições ideais de dosagem necessárias para atingir a meta. O modelo de processo é usado para fornecer erro de feedback entre a saída real do processo e o valor previsto de a saída do processo (SANTOS et al., 2017).

## OBJETIVO

Diante do acima exposto, este trabalho tem como objetivo apresentar as mudanças na estrutura e nos processos da Estação de Tratamento de Água do Jardim Japão com a implementação do sistema automático de dosagem de dosagem de produtos químicos utilizando uma rede neural para o controle ajuste e monitoramento do processo de tratamento.

## **METODOLOGIA**

O rápido crescimento demográfico da região sudoeste do distrito de Caucaia do Alto, no município de Cotia, e a dificuldade no abastecimento de água nos bairros Jardim Japão, Aguassai e Água Espraiada, através do sistema produtor Alto Cotia, resultou na criação de um sistema isolado de tratamento de água para essa região, utilizando o rio Sorocamirim como manancial. Para suprir esta demanda foi iniciado em fevereiro de 1998 ETA Jardim Japão (Figura 2), cujo objetivo principal era para abastecer o bairro homônimo, reforçando também o abastecimento do bairro Água Espraiada.



**Figura 2: Vista parcial da ETA Jardim Japão. Fonte: Acervo pessoal**

Em virtude da necessidade em aumentar a eficiência operacional dos sistemas de tratamento de água e, em alinhamento com o mapa operacional da Companhia, foi iniciado em 2018 o projeto de automação das estações de tratamento de água da Sabesp. Este projeto foi baseado na utilização de eletrodos de processo para o monitoramento on-line dos parâmetros de controle e qualidade da água produzida e automação dos sistemas de dosagem de produtos químicos utilizando inteligência artificial. Diversas ferramentas de modelagem foram desenvolvidas para tentar simular os processos operacionais em estações de tratamento de água, no entanto as incertezas, variáveis, interações e dinâmica destes processos geralmente levam a dificuldades na obtenção do desempenho desejado na operação destes sistemas.

O início do processo de automação foi à contratação de uma empresa para o fornecimento dos dados de monitoramento do processo de tratamento, sendo esta, remunerada de acordo com o número de análises realizadas mensalmente. Este tipo de licitação foi precursora na Companhia, gerando uma economia significativa, uma vez que os transdutores correspondem a aproximadamente 90% dos custos de automação de um sistema. A empresa vencedora do certame, instalou em novembro de 2018 a casa de analisadores com os instrumentos de monitoramento de turbidez, pH, potencial de óxido-redução, condutividade, teor de cloro residual livre, teor de fluoretos e temperatura, onde cada amostra de água, proveniente das diferentes etapas do processo de tratamento passam por duas baterias de instrumentos distintas, de modo que as divergências entre as análises de um mesmo parâmetro são monitoradas on-line (Figura 3).

Outra alteração decorrente do processo de automação foi a implantação de misturadores hidráulicos em série para cada produto químico utilizado no processo de tratamento de água (Figura 3). Estes misturadores dispõem de um sistema de entrada de produto químico e, em sua extremidade oposta a saída da amostra, de modo que o sistema de RNA consiga respostas rápidas das alterações na dosagem de produtos químicos e a resposta da água frente a estas alterações.

Por se tratar de uma unidade piloto neste programa de automação, foram surgindo diversos desafios no decorrer do tempo que foram superados e se tornaram aprendizados. Percalços, como por exemplo, a encrustação e obstrução da rede coletora de amostras, necessidade de alteração nos pontos de coleta, desenvolvimento de uma torre de equalização para o controle da pressão da água no sequenciador de amostras, desenvolvimento de um sistema de auto lavagem da rede coletora e recirculação de água nos no sistema de amostragem em caso de paradas prolongadas podem ser citados como alguns dos entraves que surgiram no decorrer desta fase de implantação.

Em agosto de 2019 foi iniciado o modo automático assistido, onde o controle do sistema de dosagem e ajuste nos parâmetros de processo, realizado pelos técnicos nas diferentes etapas do tratamento da água, estão sendo identificados pelo controlador lógico programável e, transformado em entrada de dados da RNA. Durante este período, que terá a duração de pelo menos doze meses, serão acompanhadas todas as características e peculiaridades do manancial e a resposta do processo de tratamento nas diferentes estações do ano. Nesta etapa, as entradas de controle da RNA serão as correlações das características da água bruta com os set points em cada etapa do processo e, a saída será o ajuste automático de cada set point do pré tratamento, tendo como referencial a turbidez da água decantada.



**Figura 3: Casa de analisadores instalado na ETA Jd° Japão e instalação dos misturadores hidráulicos em série. Fonte: Acervo pessoal.**

Para verificarmos a eficiência do sistema automático dosagem, foram compilados os dados de consumo de produtos químicos utilizados no tratamento da água com a ETA operando em modo manual, ou seja, sem a utilização do software de controle de dosagem e também com a estação utilizando o sistema automático de dosagem.

## RESULTADOS

O processo de automação visa aumentar a eficiência das estações de tratamento, onde a quantidade de análises realizadas on-line supera em muito os tradicionais ensaios de bancada. Aumento de performance, economia no consumo de produtos químicos, diminuição do quadro de funcionários e maior controle operacional são alguns dos pontos positivos do processo de automação do tratamento de água.

Com a utilização do sistema automático, foi observado a redução na dosagem de todos os produtos químicos quando comparado os modos automáticos e manual de operação. O cloreto férrico apresentou redução de 28,9% o consumo de hidróxido de cálcio em suspensão reduziu 14,62%, o ácido fluossilícico 31,4% e o hipoclorito de sódio 49,8% (Figura 4). Esta redução no consumo de produtos químicos é decorrente do ajuste realizado pelo software de controle baseados nos intervalos de análise das amostras de água

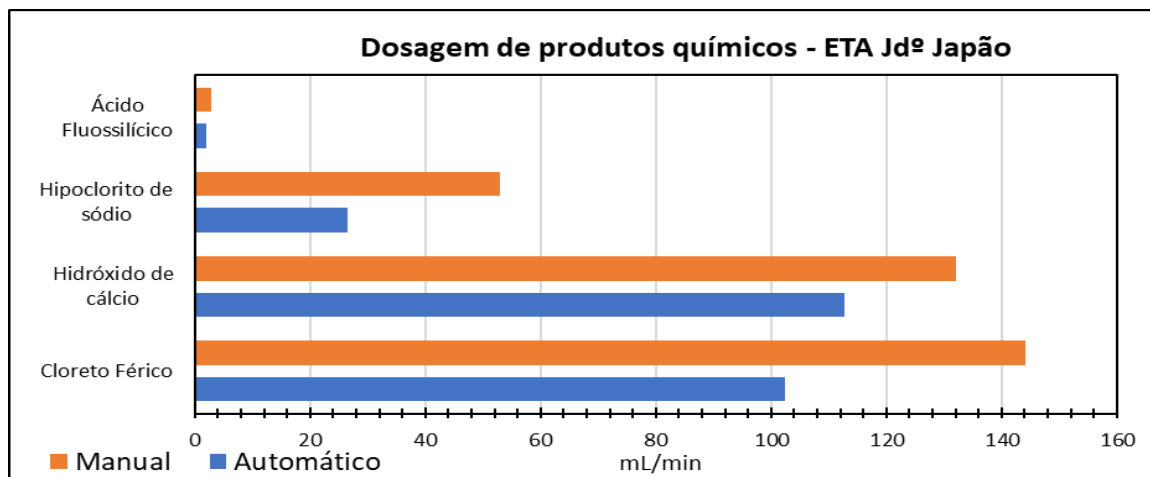


Figura 4: Gráfico comparativo dos sistemas de dosagens.

## CONCLUSÕES

O uso da inteligência artificial é uma abordagem eficaz para lidar com as complexidades acima descritas, por exemplo, as complexas inter-relações entre os vários fatores e atividades de um sistema podem ser explicadas através do processo de aquisição de conhecimento. Além disso, a lacuna entre o resultado gerado pelos esforços detalhados de modelagem e a aplicabilidade desse resultado a uma situação prática pode ser preenchida através da construção de um sistema automatizado, permitindo a incorporação de considerações implícitas e muitas vezes qualitativas consideradas cruciais pelos engenheiros e operadores, mas para que este objetivo seja alcançado, é necessário o engajamento de todos os profissionais que estão envolvidos na operação da estação de tratamento, onde os técnicos que operam o sistema ocupam papel de destaque nesta mudança estrutural, profissional, tecnológica e também cultural, pois a entrada de dados da RNA será baseada exclusivamente no comportamento e resposta dos operadores as mudanças do processo de tratamento.

## REFERENCIAS BIBLIOGRÁFICAS

1. ARAÚJO, W. R. Aplicação de técnicas de inteligência artificial visando eficiência energética e estimação de parâmetros em sistemas motrizes industriais. Campo Grande, 2008. Dissertação de mestrado- Universidade Federal de Mato Grosso do Sul, 2008.
2. BAXTER, C. W.; STANLEY, S. J.; ZHANG, Q. Development of a full-scale artificial neural network model for the removal of natural organic matter by enhanced coagulation. *Aqua*, v. 48, n. 4, p. 129-136, 1999.

3. BIANCHI, R. A. C. Uma arquitetura de controle e distribuída para um sistema de visão computacional propositada. São Paulo, 1998. Dissertação de mestrado- Escola Politécnica, Universidade de São Paulo, 1998.
4. CHAN, C. W.; HUANG, G. H. Artificial intelligence for management and control of pollution minimization and mitigation process. *Engineering Applications of Artificial Intelligence*, v. 16, p. 75-90, 2003.
5. CHO, K.; VAN MERRIENBOER, B.; GULCEHRE, C. L.; BAHDANAU, D.; BOUGARES, F.; SCHWENK, H.; BENGIO, Y. Learning phrase representations using RNN encoder-Decoder for statistical machine translation. In: *Conference on Empirical Methods in Natural Language Processing (EMNLP) 2014*, Doha, Qatar, p. 1724-1734, 2014.
6. CHUNG, J.; GULCEHRE, C.; CHO, K.; BENGIO, Y. Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv*, p. 1-9, 2014.
7. COSTA, H. R. N. Aplicação de técnicas de inteligência artificial em processos de fabricação de vidro. Tese (Doutorado em Engenharia). Escola Politécnica da Universidade de São Paulo, São Paulo, 2006.
8. CUN, Y. L.; BOSER, B.; DENKER, J. S.; HOWARD, R.E.; HABBARD, W.; JACKEL, L. D.; HENDERSON, D. Handwritten digit recognition with a back-propagation network. In: *Advances in Neural Information Processing Systems 2*; David, S.T., (Org). Ed. Morgan Kaufmann Publishers Inc., p. 396-404, 1990.
9. FUNAHASHI, K. I.; NAKAMURA, Y. Approximation of dynamical systems by continuous time recurrent neural networks. *Neural Network*, v. 6, p. 801-806, 1993.
10. GERS, F. A.; SCHMIDHUBER, J.; CUMMINS, F. Learning to forget: Continual prediction with LSTM. *Neural Computation*, v. 12, p. 2451-2471, 2000.
11. GERS, F. A.; SCHRAUDOLPH, N. N.; SCHMIDHUBER, J. Learning precise timing with LSTM recurrent networks. *Journal of Machine Learning Research*, v.3, p. 115-143, 2003.
12. GILES, C.L.; MILLER, C.B.; CHEN, D.; CHEN, H.H.; SUN, G.Z.; LEE, Y.C. Learning and extracting finite state automata with second-order. *Neural Computation*, v. 4, p. 393-405, 1992.
13. JAEGER, H. Tutorial on Training Recurrent Neural Networks, Covering BPPT, RTRL, EKF and the Echo State Network Approach; GMD Report; German, National Research Center for Information Technology, 2002.
14. JAIN, A.K.; MAO, J.C.; MOHIUDDIN, K.M. Artificial neural networks: a tutorial. *Computer*, v. 29, n. 3, p. 31-44, 1996.
15. JESCHKE, S.; ISENHARDT, H.; HEES, F.; HENNING, K. *Automation, Communication and Cybernetics in Science and Engineering 2015/2016*. Springer, 2016.
16. LUND, D.; MACGILLIVRAY, C.; TURNER, V.; MORALES, M. Worldwide and Regional Internet of Things (IoT) 2014-2020. Forecast: A Virtuous Circle of Proven Value and Demand. IDC, Document number: 248451, 2014.
17. RUMELHART, D. E.; HINTON, G.E; MCCLELLAND, J. L. A general framework for parallel distributed processing. In: RUMELHART, D. E.; HINTON; G. E.; WILLIAMS, R .J. *Parallel distributed processing: explorations in the microstructure of cognition*. The Massachusetts Institute of Technology Press, Cambridge, Mass., p. 45-76, 1986.
18. SANTOS, F. C. R; LIBRANTZ, A. F. H.; DIAS, C. G.; RODRIGUES, S. G. Intelligent system for improving dosage control. *Acta Scientiarum. Technology*, v. 39, n.1, p. 33-38., 2017.

19. SELLITTO, M. A. Inteligência artificial: uma aplicação em uma indústria de processo contínuo. *Gestão e Produção*, v.9, n.3, p.363-376, 2002.
20. URAIKUL, V.; CHAN, C. W., TONTIWACHWUTHIKUL, P. Artificial intelligence for monitoring and supervisory control of process systems. *Engineering Applications of Artificial Intelligence*, v. 20, p.115-131, 2007.
21. ZHAO, R.; WANG, J.; YAN, R.; MAO, K. Machine health monitoring with LSTM networks. In: *Proceedings of the 10th International Conference on Sensing Technology (ICST)*, China, p. 1-6, 2016.
22. ZHAO, R.; YAN, R.; WANG, J.; MAO, K. Learning to monitor machine health with convolutional bi-directional LSTM networks. *Sensors*, v.17, n.2, p. E273, 2017.