

Detecção de Anomalias com Redes Neurais Artificiais em Séries Temporais Multivariáveis Compactadas com SAX^{*}

Paulo Victor Q. Correia^{*} Andressa Stéfany S. de Oliveira^{*}
Yuri Thomas P. Nunes^{*} Luiz Affonso Guedes^{*}

^{*} *Departamento de Engenharia de Computação e Automação,
Universidade Federal do Rio Grande do Norte, RN
(e-mail:{paulocorreiaufrn, astefanysoliveira,
yuri.tpinheiro}@gmail.com, affonso@dca.ufrn.br).*

Abstract:

In this article, it is proposed the use of the algorithm for the compression of multivariate time series, named SAX, together with an artificial neural network to anomaly detection of industrial process operation. To optimize the application of this methodology, an exhaustive search was made with a set of parameters of the *Symbolic Aggregate Aproximation*(SAX) algorithm and artificial neural network architecture. In order to validate our proposal, the Tennessee Eastman Process simulator disturb was used with the presence of a component feed disturbance. The detection model was tested against two different component feed disturbances, which resulted in accuracy and recall above 85%. This approach allows, by reducing the dimensionality of time series and the type of data that will be stored, to increase storage capacity in data warehouses and has the potential to accelerate the detection of anomalies in the context of Big Data.

Resumo:

Neste artigo, é proposto a utilização do algoritmo *Symbolic Aggregate Aproximation*(SAX) para a compressão de séries temporais multivariáveis para detecção de anomalias em processos industriais por redes neurais artificiais. Para otimizar a aplicação desta metodologia, foi feita uma busca exaustiva em um espaço de busca com diversos valores de parâmetros do algoritmo SAX e arquitetura da rede neural artificial. Para realizar o treinamento da rede neural, foi utilizado o simulador *Tennessee Eastman Process* com a presença de um distúrbio na alimentação dos componentes. O modelo foi testado contra outros dois distúrbios na alimentação de componentes, em que resultaram em acurácias e *recall* acima de 85%. Esta abordagem permite, ao reduzir a dimensionalidade das séries temporais e o tipo de dado que será armazenado, aumentar a capacidade de armazenamento em historiadores e tem o potencial de acelerar a detecção de anomalias no contexto de *Big Data*.

Keywords: Anomaly Detection; Machine Learning; SAX; Artificial Neural Networks; Tennessee Eastman Process; Big Data.

Palavras-chaves: Detecção de Anomalias; Aprendizagem de Máquina; SAX; Redes Neurais Artificiais; *Tennessee Eastman Process*; Big Data.

1. INTRODUÇÃO

Ao longo das últimas décadas houve um desenvolvimento cada vez mais frequente de técnicas de monitoramento e controle de processos industriais, com o objetivo claro de ampliar a produção e tornar os processos de manufaturação mais seguros, por meio da automatização de diversos processos dentro do contexto da indústria (Xu et al., 2020), como atividade de monitoramento inteligente de operação de seus processos industriais para fins de detecção de anomalias. Este novo paradigma ficou conhecido como Indústria 4.0, trazendo diversas tecnologias inovadoras para a manufatura, como a Internet das Coisas e a computação

em nuvem, permitindo que as companhias adotassem estratégias orientadas a dados, pois com essas tecnologias se tornou possível coletar dados através de todo ciclo de vida útil do produto, como variáveis de processo e propriedades dos materiais (Li et al., 2020).

Como consequência dessas novas tecnologias, a quantidade de dados gerados por esses processos indústrias é extremamente elevada, necessitando de estruturas especialmente preparadas para armazenar estes dados e algoritmos de análise de dados. Entretanto, para a quantidade de dados disponíveis atualmente, algoritmos convencionais utilizados para a detecção de anomalias em operação de processos industriais são computacionalmente custosos, sendo necessário utilizar estratégias para acelerar a busca por comportamentos anômalos nesses sistemas complexos. Em termos

^{*} O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001

computacionais, os dados de variáveis de processos são séries temporais multivariáveis representadas em formato de ponto flutuante nos sistemas de armazenamento de dados industriais, que são denominados de historiadores de dados de processo. Então, para viabilizar o armazenamento e processamento da extremamente elevada quantidade de dados gerada por essas variáveis, invariavelmente há a necessidade de se empregar técnicas de compressão de dados de séries temporais, como o algoritmo SAX (*Symbolic Aggregate Approximation*).

No contexto de detecção de anomalias, o algoritmo SAX foi adotado em Park & Jung (2020), que propuseram a utilização deste algoritmo com a mineração de regras de associação em processos multivariáveis complexos. Entretanto, essa abordagem permite sua aplicação apenas em contexto de detecção *offline*. Num contexto geral, Senin et al. (2015) propuseram a criação de regras com gramáticas livres de contexto a partir da representação simbólica com SAX, com o objetivo de achar segmentos de uma série temporal com um comportamento anômalo. Porém, este método é aplicado apenas para processos uni-variados e de modo *offline*. Há também a utilização do SAX juntamente com o uso de *Hidden Markov Models* para identificar de forma *online* o comportamento de variáveis de processo, gerando gráficos para um operador monitorar o comportamento das variáveis. Todavia, não informa ao operador se a planta está sofrendo um distúrbio (Yiakopoulos et al., 2016). Zhang et al. (2019) realiza uma melhora no algoritmo SAX, com o objetivo de obter informações mais precisas de séries temporais para a classificação e detecção de anomalias de sinais pouco ruidosos de forma *offline*.

Considerando o contexto de detecção de anomalias sem aplicação de algoritmos de compressão, Alguliyev et al. (2017) formulou dois algoritmos de agrupamento de dados com o objetivo de minimizar a compacidade dos grupos e maximizar a separação dos agrupamentos. Outra abordagem é feita por Hochenbaum et al. (2017), o qual desenvolve duas técnicas de detecção automática de anomalias em séries temporais, os quais filtram as tendências e os componentes sazonais das mesmas para, em seguida, utilizarem métricas estatísticas robustas para a detecção precisa destas anomalias, mesmo diante de picos sazonais das séries, não sendo aplicada em modelos multivariáveis. Ambos os trabalhos não utilizaram a compressão de séries temporais, podendo comprometer a velocidade da mineração de dados em séries temporais muito longas.

Diante destes problemas, este trabalho propõe a compressão de séries temporais correspondentes às variáveis de processos via o algoritmo SAX em conjunto com uma rede neural *Multilayer Perceptron* (MLP) para a detecção de anomalias em operação de processos industriais, com o objetivo de acelerar esse processo e reduzir os custos de armazenamento em larga escala.

Para validação da abordagem proposta neste artigo, será utilizada o *benchmark Tennessee Eastman Process* (TEP). Avaliando-se a aplicação desta estratégia em situações com distúrbios desconhecidos para o modelo, comparando o desempenho entre diversos parâmetros do algoritmo SAX, com o objetivo de compreender o *tradeoff* entre o nível de compressão de dados, realizado pelo SAX, e o desempenho do detector de anomalias. A escolha do TEP

como *benchmark* se deve ao fato de ser um simulador de uma planta industrial amplamente utilizado na literatura para a detecção de anomalias (Yiakopoulos et al., 2016; Oliveira et al., 2019; Vilar et al., 2019; Santos et al., 2019; Basha et al., 2020; Wei & Weng, 2020).

Este artigo está organizado da seguinte forma: a Seção 2 apresenta o funcionamento do algoritmo SAX. A Seção 3 contém a metodologia do trabalho, em que são detalhadas todas as etapas para a realização da detecção de anomalias por rede neural MLP. A Seção 4 apresenta as configurações experimentais, descrevendo o simulador utilizado (TEP), como os dados deste processo são gerados, como é realizado o treinamento da rede neural, otimização do sistema e as métricas de avaliação utilizadas. Após isso, na Seção 5, serão apresentados os resultados e discussões. Finalmente, na Seção 6, serão feitas as considerações finais, assim como, possíveis trabalhos futuros.

2. APROXIMAÇÃO AGREGADA SIMBÓLICA

A Aproximação Agregada Simbólica, em inglês *Symbolic Aggregate Approximation* (SAX), propõe uma compressão de séries temporais de forma que as características principais da série não são perdidas, assim tornando mais rápida a realização da mineração de dados (Lin et al., 2007). Este algoritmo consiste em duas etapas: aplicação do algoritmo da Aproximação Agregada Particionada (em inglês *Piecewise Aggregate Approximation*, ou PAA) para a compressão da série e a conversão simbólica para reduzir o tamanho da representação anterior.

Na etapa do PAA, a série temporal é normalizada, pois considera-se que a distribuição dos pontos é gaussiana (Lin et al., 2007). Assumindo uma série temporal C de tamanho n , esta pode ser representada por uma série de tamanho w , em que $w \ll n$, sendo o vetor $\bar{C} = \{\bar{c}_1, \bar{c}_2, \dots, \bar{c}_w\}$, em que o i -ésimo elemento deste novo espaço vetorial é definido pela Equação 1.

$$\bar{c}_i = \frac{w}{n} \sum_{j=\frac{n}{w}(i-1)+1}^{\frac{n}{w}i} c_j \quad (1)$$

Sendo w/n a taxa de compressão da série temporal original com a nova representação e n/w é o tamanho de cada partição em que será calculada a média para os elementos contidos nela.

Como ilustrado na Figura 1, na segunda etapa, é feita a transformação dos elementos do vetor \bar{C} em η símbolos, os quais são representados pelas duas linhas horizontais que interceptam a gaussiana dividindo em áreas equiprováveis, cujo o valor limítrofe de cada área é definido por β_i (Lin et al., 2007). Para realizar esta etapa, a equação que rege a transformação do vetor de pontos flutuantes \bar{C} em um vetor de símbolos \hat{C} é definida pela Equação 2, na qual cada elemento do vetor é convertido para o símbolo α_j correspondente do intervalo β_{j-1} e β_j .

$$\hat{c}_i = \alpha_j, \text{ se } \beta_{j-1} \leq \bar{c}_i < \beta_j \quad (2)$$

3. METODOLOGIA PROPOSTA

Este trabalho propõe o uso do algoritmo SAX em conjunto com uma rede neural do tipo MLP para detecção de anomalias em operação de processos industriais. O algoritmo

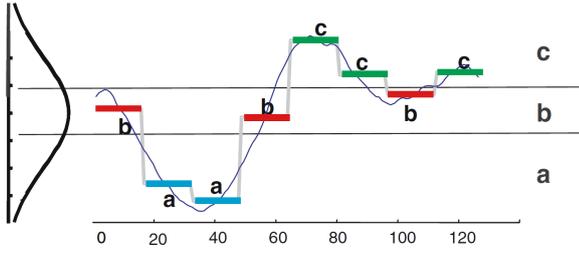


Figura 1. Como o algoritmo SAX converte os números obtidos pelo PAA em símbolos. Fonte: Lin et al. (2007)

SAX é empregado para reduzir a quantidade de dados necessária para representar as séries temporais associadas às variáveis de processos, mantendo as características fundamentais das séries originais, permitindo o aumento da eficiência computacional do processamento da informação sem prejudicar a qualidade dos resultados (Yu et al., 2019). A rede neural tem como entrada os valores das séries processadas pelo SAX e é utilizada para a detecção de anomalias.

Assim, a proposta deste artigo é constituída de duas etapas. A primeira etapa consiste na atividade de comprimir as variáveis da série temporal, utilizando-se o algoritmo SAX. A janela de compressão ρ do algoritmo define a quantidade de amostras do sinal original utilizada para se converter em um símbolo. Após serem processados pelo SAX, os dados das variáveis de processos são armazenados num historiador simbólico, como ilustrado na Figura 2. Posteriormente, é iniciada a segunda etapa, ocorrendo a seleção de variáveis de processo utilizadas para a construção do modelo de detecção de anomalias. No caso, são selecionadas as variáveis que apresentam mudanças significativas quando o processo industrial é submetido a um determinado distúrbio. Todavia, em casos reais é importante que essa escolha seja realizada por um especialista do processo (Oliveira et al., 2019).

Após a seleção das variáveis de processos, inicia-se a atividade de pré-processamento, que corresponde basicamente em transformar os símbolos obtidos no processo de compressão do SAX em números representados em ponto flutuante. Como os símbolos obtidos são ordenados, considera-se que cada um deles representa valores de 1 até η (tamanho do alfabeto). Também é efetuada a normalização desses valores para o intervalo entre 0 e 1, com o objetivo de reduzir a escala dos dados.

Logo após, inicia-se o estágio de detecção de anomalias, onde a entrada da rede neural será definida pelo valor SAX de índice t e suas γ amostras anteriores, para cada uma das variáveis de processo selecionadas. Para cada valor de entrada, a saída da rede neural será 1 para anomalia e 0 para comportamento normal da planta. Após todo o processamento do sinal, obtém-se um vetor binário, o qual passará por um pós-processamento, que por sua vez, consiste na aplicação de um filtro de média móvel. Neste caso, esse filtro é utilizado para suavizar flutuações curtas do vetor gerado pela rede neural.

4. CONFIGURAÇÕES EXPERIMENTAIS

Nesta Seção, é apresentado o simulador *Tennessee Eastman Process* - TEP, que será utilizado como *benchmark*

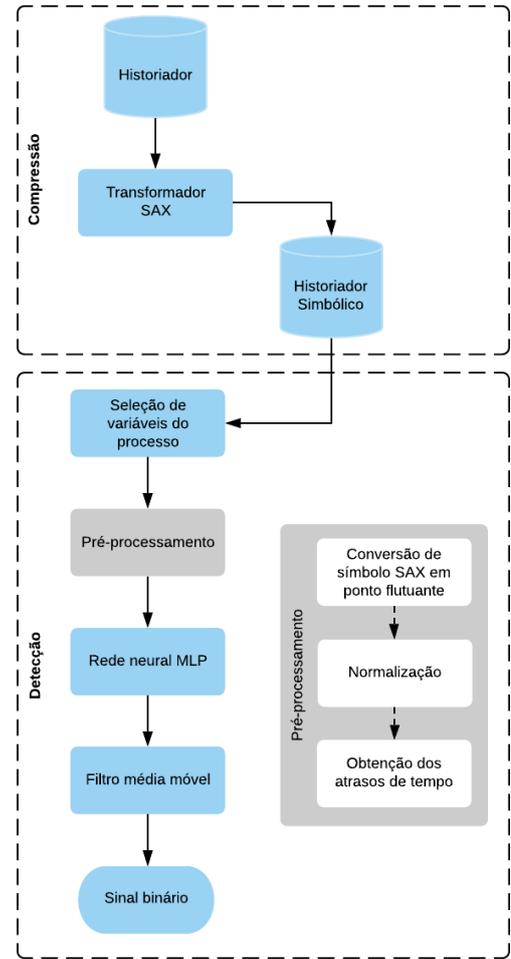
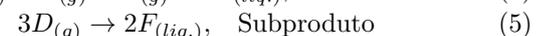
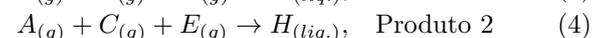
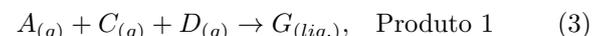


Figura 2. Diagrama de blocos da metodologia.

para validação da nossa proposta de detecção de anomalias de processos industriais, com suas respectivas configurações de distúrbios, as métricas adotados para a avaliação do desempenho da proposta, a estruturação de como foi feito o treinamento da rede MLP e a otimização dos parâmetros de compressão e a arquitetura da rede neural utilizada para detecção.

4.1 Tennessee Eastman Process

O *Tennessee Eastman Process* (TEP) é um simulador de uma planta industrial de um processo químico real, baseado na planta do grupo *Eastman Chemical Company* (Downs & Vogel, 1993). O processo consiste na produção de dois produtos e dois subprodutos a partir de quatro reações químicas, as quais são representadas pelas Equações 3 a 6, utilizando 8 componentes químicos distintos: A, B, C, D, E, F, G e H. Para a realização de todo esse processo, as principais máquinas utilizadas são um separador de vapor-líquido, um compressor de reciclagem, um reator, o condensador de produto e a decapagem.



Além disso, o TEP possui um conjunto de 41 variáveis, sendo 22 de sensores realizando leituras em pontos específicos e 19 medidas de composição de componentes em tubulações específicas. Neste trabalho, focaremos nas 22 variáveis provenientes de sensores simulados. Com o objetivo de simular anomalias em um processo industrial real, há 20 distúrbios possíveis de serem aplicados à planta (Downs & Vogel, 1993).

4.2 Geração dos Dados

Tendo em vista que os dados gerados para este trabalho foram adquiridos por meio de simulações computacionais utilizando o TEP, a configuração da simulação possui um período de amostragem de 0,01 hora, isto é, uma amostra a cada 36 segundos, totalizando 100 amostras por hora.

Foi gerado um conjunto de dados para treinamento com duração de 178 horas, como apresentado na Tabela 1, onde a planta industrial é iniciada com seu funcionamento normal, sendo o distúrbio IDV8, que é uma variação imprevisível na composição dos componentes A, B e C na tubulação de entrada, ativado entre as 120 e 130 horas, seguidamente de 48 horas de estabilização.

Para a realização dos testes, foram gerados dois conjuntos de dados com duração de 158 horas, os quais possuem os distúrbios IDV1 e IDV2 entre o intervalo de 100 e 110 horas de funcionamento, seguido de 48 horas de estabilização, como consta na Tabela 2. Os distúrbios IDV1 e IDV2 também causam variações na composição dos componentes A, B e C. Entretanto, ambos possuem variação na composição de forma previsível: a IDV1 muda a razão da quantidade dos componentes A e C enquanto a IDV2 influencia a quantidade do componente B.

Tabela 1. Configuração de simulação para treinamento.

Parâmetros	Configurações
Distúrbio	IDV8
Duração do Distúrbio(h)	10
Início do Distúrbio(h)	120
Fim do Distúrbio(h)	130
Duração da Estabilização(h)	48

Tabela 2. Configuração das simulações de teste com IDV1 e IDV2

Parâmetros	Configurações	
	IDV1	IDV2
Distúrbio	IDV1	IDV2
Duração do Distúrbio(h)	10	10
Início do Distúrbio(h)	100	100
Fim do Distúrbio(h)	110	110
Duração da Estabilização(h)	48	48

As variáveis de processo do TEP utilizadas para este artigo foram as variáveis XMEAS01, XMEAS10 e XMEAS21, as quais pertencem ao conjunto de 22 sensores reais extraídos da planta, cuja descrição está presente na Tabela 3 (Downs & Vogel, 1993).

4.3 Métricas de Avaliação

Neste artigo o cálculo das métricas de avaliação serão apresentadas de duas formas: considerando e desconsiderando a

Tabela 3. Descrição das variáveis de processo utilizadas.

Variável	Descrição
XMEAS01	Alimentação do Componente A
XMEAS10	Taxa de eliminação de resíduos do compressor
XMEAS21	Temperatura da água de resfriamento do reator

área de transição. Essa área é caracterizada pela mudança do estado normal para o anômalo, como também, do anômalo para o estado normal. Isso foi feito com o intuito de comparar os dois resultados, verificando a relevância das regiões de transição, pois as variáveis de processo não reagem instantaneamente à mudança ocasionada pela ativação do distúrbio.

A zona de transição da região normal para anômalo foi definida como sendo o momento da ativação do distúrbio até a primeira identificação de estado anômalo realizada pela rede neural na região anômalo do sinal. Já a transição da região anômalo para normal foi definida do instante de desativação do distúrbio ao instante em que a rede identifica, pela primeira vez, a região normal.

Dessa forma, para avaliar o desempenho do sistema proposto, serão utilizadas as métricas acurácia, precisão, *recall* e *F1-Score*, definidas pelas Equações 7, 8, 9 e 10, respectivamente (Davis & Goadrich, 2006).

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FN + FP} \quad (7)$$

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (8)$$

$$\text{Recall} = \frac{VP}{VP + FN} \quad (9)$$

$$F1\text{-Score} = \frac{2 \cdot \text{Recall} \cdot \text{Precisão}}{\text{Recall} + \text{Precisão}} \quad (10)$$

Em que VP denota verdadeiro positivo, quando a entrada é uma anomalia e foi identificada como anomalia. Já VN simboliza verdadeiro negativo, quando a entrada não é anomalia e foi reconhecida como não anomalia. O FN remete a falso negativo, quando a entrada é anomalia e é prevista como pertencente a área normal. Finalmente, o FP representa o falso positivo, quando a entrada é pertencente à região normal e é prevista como anomalia.

4.4 Treinamento da Rede Neural

O conjunto de treinamento que será utilizado nesta etapa possui o número de *features* equivalente ao número de variáveis do processo vezes a quantidade de γ amostras anteriores mais a atual. Por exemplo, para um modelo que utiliza 3 variáveis de processo e $\gamma = 4$, tem-se 15 variáveis de entradas (*features*).

Para identificar a localização das anomalias no vetor de estado, devido à compressão realizada pelo SAX na série temporal, é necessário realizar as operações das Equações 11 e 12, em que os índices na amostragem original de onde começa e termina o distúrbio são divididos pelo tamanho da janela ρ , onde todos os elementos do vetor de estado da planta nesse intervalo pertencem a área

anômala, a qual é representada como 1, e as demais regiões, são representadas como 0.

$$\hat{T}_{início} = \frac{T_{início}}{\rho} \quad (11)$$

$$\hat{T}_{final} = \frac{T_{final}}{\rho} \quad (12)$$

A rede neural MLP utilizada no modelo de detecção de anomalias foi construída utilizando o método *MLPClassifier* do pacote *scikit-learn*. A atualização dos pesos da rede foi feito utilizando o algoritmo *Adam* com uma taxa de aprendizagem inicial de 0,001, além do treinamento da rede ser realizado em 200 épocas, em que cada época possui 200 iterações. Todavia, para fins de realizar a otimização dos parâmetros do sistema, não houve a inicialização aleatória, como também não foi realizada a validação cruzada devido a base de dados utilizada se tornar pequena após a compressão. Para todos os experimentos realizados, a função de ativação de todos os neurônios foi a função retificadora.

4.5 Otimização do Sistema

É realizado uma busca exaustiva por parâmetros ótimos para o sistema de detecção de anomalias. Os parâmetros buscados para o algoritmo SAX foram os tamanhos de janela (ρ) de cálculo da média de amostras, de 20 até 50 com passo 5, e o tamanho do alfabeto (η), de 3 até 8 com passo 1. Também foram buscados valores para a quantidade de atrasos (γ), de 2 até 6 com passo 1.

Ademais, para a MLP, houve a busca pelo número de neurônios da camada oculta, variando de 5 a 15 neurônios, e pela quantidade de camadas, de 1 a 3 camadas, utilizando parâmetros como taxa de aprendizagem 0,001 e função de ativação retificadora de acordo com o modelo *MLPClassifier* da biblioteca *sklearn*.

O conjunto de parâmetros que com a melhor *acurácia* para o sistema de detecção de anomalias foi utilizado no modelo final de detecção.

5. RESULTADOS E DISCUSSÃO

Conforme apresentado na metodologia, os dados das séries temporais obtidos a partir do TEP foram comprimidos utilizando o algoritmo SAX, onde a parametrização foi de $\rho = 35$ e $\eta = 7$. Essa compressão resultou em uma redução no espaço ocupado na memória de 379,224 quilobytes para 10,848 quilobytes, para os conjuntos de dados das simulações que continham os distúrbios IDV1 e IDV2, e de 427,224 quilobytes para 12,216 quilobytes para o conjunto que continha o distúrbio IDV8, resultando em uma taxa de compressão de aproximadamente 2,86% nesses conjuntos. Para a entrada da rede neural, foi obtido $\gamma = 5$, isto é, cada variável de processo passará o valor SAX de índice t e suas 5 amostras anteriores, totalizando 18 entradas.

Além disso, foi definido a arquitetura da rede MLP com 3 camadas ocultas e 15 neurônios em cada uma delas, como consta na Tabela 4, além de apenas um neurônio na camada de saída.

No treinamento, a utilização desses parâmetros obtiveram uma *acurácia* de 98,8%, a *precisão* de 100%, o *recall* de

Tabela 4. Parâmetros utilizados para a detecção de anomalias.

Parâmetros	Valor
Tamanho da Janela de Compressão (ρ)	35
Tamanho do Alfabeto (η)	7
Quantidade de atrasos (γ)	5
Arquitetura da MLP	(18, 15, 15, 15, 1)

78,6% e o *F1-Score* de 88,0%, como mostra a quinta linha da Tabela 5.

5.1 Conjunto de Teste com o Distúrbio IDV1

O primeiro resultado de teste a ser apresentado será o conjunto do distúrbio IDV1. Ao considerar as regiões de transição, do estado normal para o anômalo e vice-versa, os resultados com o melhor modelo obtido tem *acurácia* de 96,4%, *precisão* de 66,0%, *recall* de 85,7% e *F1-Score* de 75,0%, como mostra a Tabela 5.

Para fins de comparação, os resultados de *acurácia* podem ser visualizados na Figura 3, na qual é possível identificar que quanto menor o valor de ρ e quanto maior é o valor de η melhor é o desempenho da MLP em detectar anomalias, pois há uma perda menor de informação sobre a série original.

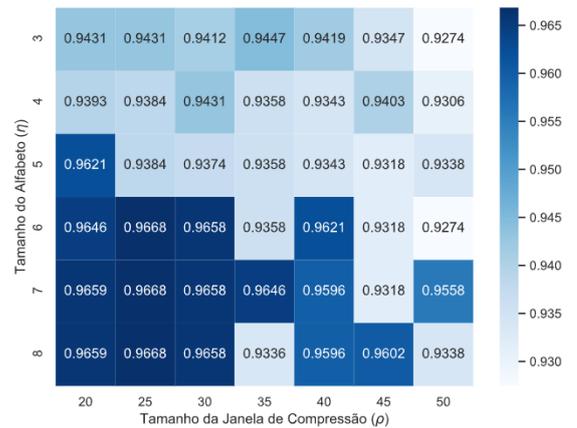


Figura 3. Acurácias dos modelos com o conjunto de teste do distúrbio IDV1 variando η e ρ .

Mais adiante, ao desconsiderar as regiões de transição, nota-se que há uma melhora significativa nas métricas, com a *acurácia* de 99,8%, *precisão* de 96,0%, *recall* de 100,0% e *F1-Score* de 97,9%, como mostra a Tabela 5.

Esses resultados obtidos sem considerar as regiões de transição se devem ao fato de que, em situações reais, não se sabe se as regiões de transição estão em estado normal ou anômalo, visto que as variáveis de processo demoram a responder aos distúrbios aplicados à planta.

O resultado do modelo para a detecção de anomalias do tipo IDV1 pode ser vista na Figura 4, o qual utiliza as configurações ótimas obtidas na busca exaustiva e considera as regiões de transição da planta. Note a região cinza, a qual indica onde o distúrbio foi aplicado durante a simulação, a curva azul indica o comportamento das variáveis XMEAS01, XMEAS10 e XMEAS21; e a curva vermelha indica o sinal da detecção realizada pelo sistema.

Tabela 5. Métricas de teste na detecção de anomalias e atrasos em amostras de tempo para detecção do distúrbio IDV1 e IDV2.

Distúrbio	Acurácia	Precisão	Recall	F1-Score	Ativação	Desativação
IDV1*	0,964	0,66	0,857	0,75	140	385
IDV1**	0,998	0,96	1,0	0,979	-	-
IDV2*	0,951	0,607	0,607	0,607	385	350
IDV2**	0,997	0,944	1,0	0,971	-	-
IDV8*	0,988	1,0	0,786	0,88	-	-

* Com região de transição
 ** Sem região de transição

É possível notar também, pela figura, que há um pequeno atraso na detecção na zona de transição da região normal para a anômala, e um atraso maior na zona de transição do estado anômalo para o normal.

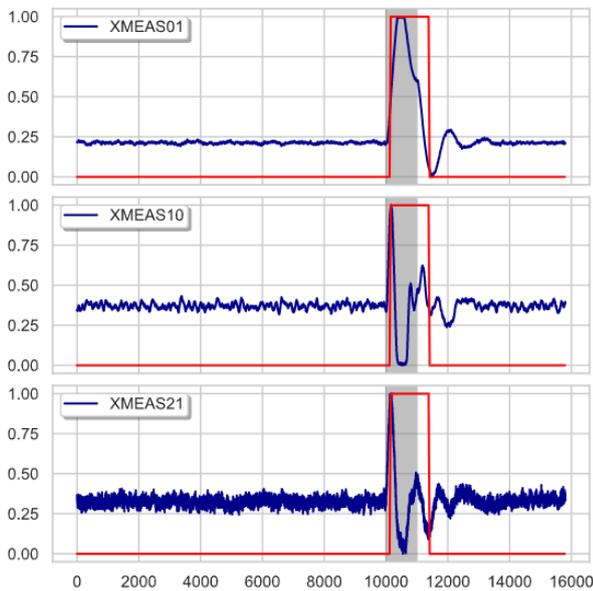


Figura 4. Resultado da detecção de anomalias do distúrbio IDV1.

Este atraso na detecção de anomalias que ocorreu no modelo pode ser visto na primeira linha da Tabela 5, em que houve a conversão dos resultados do domínio SAX para o domínio da amostragem original. Ocorreu um atraso de 140 amostras para a detecção de anomalias, correspondente a 1 hora e 24 minutos de atraso de detecção, e um atraso de 385 amostras na transição de anomalia para região normal, equivalente a 3 horas e 51 minutos.

Então, pode-se considerar que, ao treinar um modelo de detecção com o distúrbio IDV8, obtém-se bons resultados na detecção de anomalias do tipo IDV1 através da metodologia proposta neste trabalho, indicando uma semelhança entre os distúrbios IDV8 e IDV1.

5.2 Conjunto de Teste com o Distúrbio IDV2

Para o conjunto de teste do distúrbio IDV2, considerando as regiões de transição para a avaliação do modelo, foi obtido acurácia de 95,1%, precisão de 60,7%, recall de 60,7% e *F1-Score* também de 60,7%, como mostra a terceira linha da Tabela 5.

A Figura 5 contém as acurácias para os modelos testados com o distúrbio IDV2 com a variação do conjunto de parâmetros do algoritmo SAX utilizados neste trabalho. Nota-se um desempenho mais baixo que o teste com o IDV1, o que indica que o comportamento das variáveis no distúrbio IDV2 não é muito semelhante ao distúrbio IDV8.

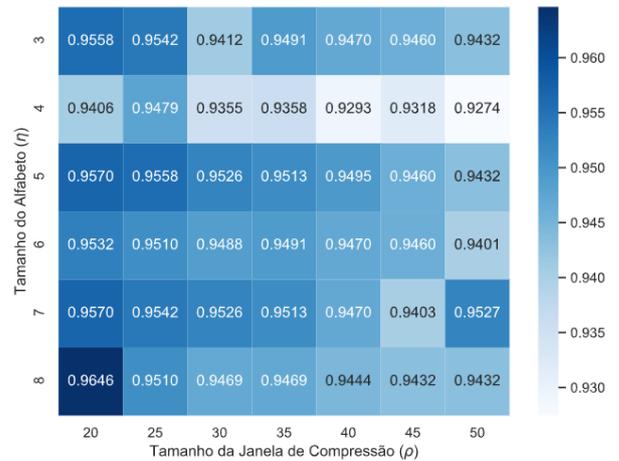


Figura 5. Acurácias dos modelos com o conjunto de teste do distúrbio IDV2 variando η e ρ .

Ao desconsiderar as regiões de transição, os resultados obtidos foram: acurácia de 99,7%, precisão de 94,4%, recall de 100,0% e *F1-Score* de 97,1%, como exposto na quarta linha da Tabela 5.

Como mostra a terceira linha da Tabela 5, o atraso na detecção de anomalias para o distúrbio IDV2 foi de 385 amostras na região de transição do comportamento normal para o anômalo, o que corresponde a 3 horas e 51 minutos. E, o atraso para a identificação de que a planta retornou para o estado normal foi de 350 amostras, equivalente a 3 horas e 30 minutos.

O resultado da predição do modelo para o distúrbio IDV2 pode ser visto na Figura 6, na qual as linhas vermelhas representam o que o modelo detectou, a faixa cinza é a região em que o distúrbio IDV2 está ativado e, em azul, tem-se o sinal das variáveis de processo.

Finalmente, diante dos resultados apresentados para o teste do modelo de detecção de anomalias com o distúrbio IDV2, é possível notar que houveram resultados inferiores a detecção do distúrbio IDV1 pelo mesmo modelo, indicando que o distúrbio em questão não é muito semelhante ao distúrbio IDV8 utilizado no treinamento da rede MLP. Apesar dos distúrbios terem raiz na mesma região física

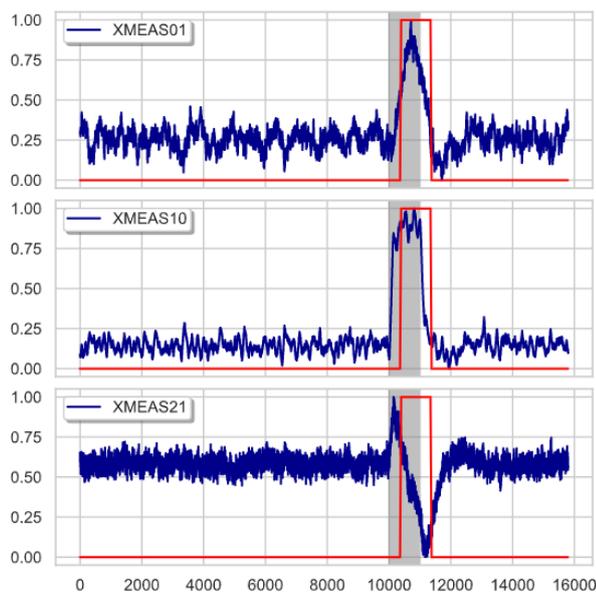


Figura 6. Resultado da detecção de anomalias do distúrbio IDV2.

da planta, as repercussões são distintas o suficiente para prejudicar as métricas de desempenho.

6. CONCLUSÃO

Neste trabalho foi proposto uma abordagem baseada no algoritmo SAX e em rede neural MLP para detecção eficiente de anomalias de processos industriais. A aplicação do algoritmo de compressão SAX permitiu reduções significativas na quantidade de dados das séries temporais associadas às variáveis de processos, o que proporcionou melhoria no processamento e redução no armazenamento de dados industriais, sem comprometer a eficiência da atividade de detecção de anomalias.

Para trabalhos futuros, pretende-se incluir mais variáveis de processo para a detecção de anomalias, bem como o uso de redes neurais de aprendizado profundo, visto que o tamanho do conjunto de entrada aumentará significativamente. Acredita-se que isso auxiliará no processo de classificação em casos como o visto com a IDV2 neste trabalho. Além disso, utilizar uma variedade maior de tipos de distúrbios para o treinamento da rede, permitindo uma melhoria na generalização da mesma. Uma outra abordagem, seria a utilização de variações do algoritmo SAX, como ESAX, TFSAX e aSAX.

REFERÊNCIAS

Alguliyev, R., Aliguliyev, R., & Sukhostat, L. (2017). Anomaly detection in big data based on clustering. *Statistics, Optimization & Information Computing*, 5(4), 325.

Basha, N., Sheriff, M.Z., Kravaris, C., Nounou, H., & Nounou, M. (2020). Multiclass data classification using fault-detection-based techniques. *Computers & Chemical Engineering*, 106786.

Davis, J. & Goadrich, M. (2006). The relationship between precision-recall and roc curves. In *Proceedings of the 23rd international conference on Machine learning*, 233–240.

Downs, J.J. & Vogel, E.F. (1993). A plant-wide industrial process control problem. *Computers & chemical engineering*, 17(3), 245–255.

Hochenbaum, J., Vallis, O.S., & Kejariwal, A. (2017). Automatic anomaly detection in the cloud via statistical learning. *arXiv preprint arXiv:1704.07706*.

Li, Y., Dai, J., & Cui, L. (2020). The impact of digital technologies on economic and environmental performance in the context of industry 4.0: A moderated mediation model. *International Journal of Production Economics*, 107777.

Lin, J., Keogh, E., Wei, L., & Lonardi, S. (2007). Experiencing sax: a novel symbolic representation of time series. *Data Mining and knowledge discovery*, 15(2), 107–144.

Oliveira, A.S.S.d., Nunes, Y.T., Abreu, R.S.d., & Guedes, L.A. (2019). Detecção de Falhas em Processos Industriais Baseada no Algoritmo Evolutivo SOSTream. *Anais do 14º Simpósio Brasileiro de Automação Inteligente*, 1719–1725. doi:10.17648/sbai-2019-111386.

Park, H. & Jung, J.Y. (2020). Sax-arm: Deviant event pattern discovery from multivariate time series using symbolic aggregate approximation and association rule mining. *Expert Systems with Applications*, 141, 112950.

Santos, M.R., Bezerra, C.G., Guedes, L.A., & Nunes, Y.T. (2019). Classificação de Falhas em Processos Industriais Utilizando o Algoritmo Auto-Cloud. *Anais do 14º Simpósio Brasileiro de Automação Inteligente*, 1777–1782. doi:10.17648/sbai-2019-111396.

Senin, P., Lin, J., Wang, X., Oates, T., Gandhi, S., Boedihardjo, A.P., Chen, C., & Frankenstein, S. (2015). Time series anomaly discovery with grammar-based compression. In *Edbt*, 481–492.

Vilar, E., Nunes, Y.T., & Guedes, L.A. (2019). Abordagem Baseada em Aprendizado de Máquina para Detecção de Alarmes Industriais. *Anais do 14º Simpósio Brasileiro de Automação Inteligente*, 2128–2134. doi:10.17648/sbai-2019-111453.

Wei, Y. & Weng, Z. (2020). Research on the process fault diagnosis method based on dbn and dropout. *The Canadian Journal of Chemical Engineering*, 98(6), 1293–1306.

Xu, B., Shen, J., Liu, S., Su, Q., & Zhang, J. (2020). Research and development of electro-hydraulic control valves oriented to industry 4.0: A review. *Chinese Journal of Mechanical Engineering*, 33, 1–20.

Yiakopoulos, C., Gryllias, K., Chioua, M., Hollender, M., & Antoniadis, I. (2016). An on-line sax and hmm-based anomaly detection and visualization tool for early disturbance discovery in a dynamic industrial process. *Journal of Process Control*, 44, 134–159.

Yu, Y., Zhu, Y., Wan, D., Zhao, Q., & Liu, H. (2019). A novel trend symbolic aggregate approximation for time series. *arXiv preprint arXiv:1905.00421*.

Zhang, Y., Duan, L., & Duan, M. (2019). A new feature extraction approach using improved symbolic aggregate approximation for machinery intelligent diagnosis. *Measurement*, 133, 468–478.