



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
TRABALHO DE DIPLOMAÇÃO EM ENGENHARIA QUÍMICA



Análise de Correlação e Causalidade Entre Dados de Sensores Aplicada a Alarmes Industriais

Autor: Mateus Kochhann Trentz

Orientador: Prof. Dr. Pedro Rafael Bolognese Fernandes

Coorientador: M.Sc. Ariel Kempf

Porto Alegre, maio de 2021

Autor: Mateus Kochhann Trentz

Análise de Correlação e Causalidade Entre Dados de Sensores Aplicada a Alarmes Industriais

Trabalho de Conclusão de Curso apresentado à COMGRAD/ENQ da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Bacharel em Engenharia Química

Orientador: Prof. Dr. Pedro Rafael Bolognese Fernandes

Coorientador: M.Sc. Ariel Kempf

Banca Examinadora:

Prof. Dr. Marcelo Farenzena, Universidade Federal do Rio Grande do Sul

M.Sc. José Eduardo Weber dos Santos, Universidade Federal do Rio Grande do Sul

Porto Alegre

2021

AGRADECIMENTOS

À minha mãe, Clarinha Kochhann, pelo apoio em todas as situações e desde sempre.

Ao meu orientador, Pedro Fernandes, pelo suporte e paciência.

RESUMO

A busca por metodologias computacionais automáticas que detectem a interação entre elementos dentro de um processo é comum em vários campos da ciência. O objetivo deste trabalho é investigar métodos automáticos que ajudem a analisar dados de sistema de alarmes, buscando a causa raiz da ativação de alarmes pela análise de correlação e causalidade entre dados de sensores. Os resultados das análises são exibidos em forma de gráficos de rede, permitindo o fácil entendimento das relações entre os dados dos sensores. As análises foram feitas utilizando-se dados de duas simulações computacionais de processos distintos. Para o cálculo da correlação foi utilizado o coeficiente de correlação de Pearson, calculado entre janelas de tempo de forma a capturar detalhadamente a progressão do relacionamento entre as séries. Este coeficiente também foi calculado levando em conta possíveis defasagens entre as séries, assim, o resultado do cálculo da correlação entre um par de séries é uma matriz que contém a informação da progressão da correlação para diversas defasagens, tornando simples o processo de busca automática por zonas de alta correlação. A causalidade entre as séries foi obtida pelo teste de causalidade de Granger, porém, os resultados indicam que este método não é satisfatório quando utilizado para os dados de sensores das simulações deste estudo, visto que várias das correlações positivas encontradas estavam incorretas. O método do cálculo da correlação entre séries em janelas de tempo e levando em conta a defasagem mostrou-se útil e resiliente, apresentando-se como um bom candidato para ser utilizado em análises similares com dados de sensores reais.

Palavras-chave: causalidade, correlação, alarmes, coeficiente de Pearson

ABSTRACT

The search for automatic computational methodologies that can detect interaction between components within a process is common in several fields of science. The objective of this study is to investigate automatic methods that will serve as help for analyzing alarm system data, looking for the root cause of alarm activation through correlation and causality analysis between sensor data. The final results are displayed in the form of network graphs, allowing for an easy understanding of the relationship between the data. The analyzes were made using data from two computer simulations of different processes. Pearson's correlation coefficient was used to calculate the correlation between time series and, in order to capture in detail the evolution of the relationship of the variables during the process, the calculations were done in windows of time. To also take into account possible lags in the effects of both series, the correlation coefficient was also calculated shifting one series in time for multiple times, thus, the output of this method is a matrix that contains the correlation progression in one axis and the lagged correlation in the other, making it simple to automatically analyze it when looking for high correlation zones. The causality between time series was obtained by the Granger causality test, however, the results indicate that this method is not satisfactory when applied for the simulated sensor data of this study, since several of the positive correlations found were incorrect. The method of calculating the correlation between series in time windows and taking into account the lag proved to be useful and resilient, presenting itself as a good candidate to be used in similar analyzes with data from real sensors.

Keywords: *causality, correlation, alarms, Pearson coefficient*

Sumário

Lista de Figuras	ix
Lista de Tabelas	x
Lista de Símbolos	xi
1 Introdução	1
1.1 Motivação e Objetivo	2
2 Revisão Bibliográfica e Fundamentação Teórica	5
2.1 Revisão Bibliográfica	5
2.1.1 Detecção de Falhas	6
2.1.2 Área Biológica	7
2.2 Fundamentação Teórica	8
2.2.1 Correlação	8
2.2.2 Causalidade	10
3 Metodologia	15
3.1 Softwares	15
3.2 Dados de processo	16
3.3 Análise dos dados	18
3.3.1 Correlação	18
3.3.2 Buscas de pontos de interesse	24
3.3.3 Diagramas de Causalidade e Correlação	26
3.3.4 Metodologia Consolidada	28
4 Resultados e Discussão	31
4.1 Resultados Gerais	31
4.2 Resultados da simulação A	32
4.3 Resultados da simulação B	33
5 Conclusões e Trabalhos Futuros	37
5.1 Conclusão sobre o cálculo da correlação	37
5.2 Conclusão sobre o cálculo da causalidade	37
5.3 Conclusão sobre o uso dos gráficos de rede	38
5.4 Trabalhos Futuros	38

Lista de Figuras

Figura 2.1	Exemplo de relações entre variáveis com as linhas de tendências que melhor explicam o tipo de relação. (a) Relação linear positiva entre x e y . (b) relação linear negativa. (c) relação quadrática.	9
Figura 2.2	Exemplo de séries temporais não estacionárias (a) e estacionárias (b).	11
Figura 3.1	Fluxograma do processo da simulação A.	16
Figura 3.2	Progressões de algumas séries de dados da simulação A.	17
Figura 3.3	Fluxograma do processo da simulação B.	18
Figura 3.4	Gráfico temporal do coeficiente de correlação calculado para janela de tamanho 15 entre um par de séries.	19
Figura 3.5	Gráfico temporal do coeficiente de correlação calculado para janela de tamanho 100 entre um par de séries.	21
Figura 3.6	Gráfico temporal do coeficiente de determinação (r^2) calculado para janela de tamanho 100 entre um par de séries.	22
Figura 3.7	Exemplo do valor de Pearson calculado para diferentes defasagens entre um par de séries.	23
Figura 3.8	Análise híbrida do coeficiente de determinação.	24
Figura 3.9	(a) Matriz binária. (b) Matriz com suas ilhas identificadas e enumeradas.	25
Figura 3.10	Ponto do centro de massa marcado com um x , calculado a partir dos valores dos coeficientes de determinação, em uma ilha isolada.	26
Figura 3.11	Exemplo do gráfico de rede gerado automaticamente para a série L1, monitorada pelo alarme A1.	27
Figura 4.1	Exemplo típico de mapas de calor entre séries que apresentam correlação (a) e séries que não apresentam correlação (b).	32
Figura 4.2	Gráfico de rede gerado para a análise de correlação e causalidade da simulação A.	33
Figura 4.3	Gráficos de rede gerados para cada série monitorada por alarmes na simulação B. Em (a) o resultado da ativação do alarme A1, o qual monitorava L1. Em (b) para o alarme A2, monitorando T1. Em (c) para alarme A3, o qual monitorava L2.	34
Figura 4.4	(a) Exemplo do comportamento incomum das correlações envolvendo a série C1, que apresenta relações não lineares com outras variáveis. (b) Comportamento típico de séries que são afetadas por um mesmo evento. (c) Correlação entre séries na qual uma delas sofre uma variação em forma de degrau.	35

Lista de Tabelas

Tabela 3.1	Número de componentes da simulação A.	16
Tabela 3.2	Número de componentes da simulação B.	18
Tabela 3.3	Exemplo da correlação de Pearson entre pares de séries.	19

Lista de Símbolos

δ	Valor de defasagem da série	—
\bar{x}	Média da amostra x	—
$\rho_{X,Y}$	Correlação de Pearson entre população X e Y	—
σ_X	Desvio padrão da população X	—
I	Intensidade da ilha de correlação	—
l	Comprimento da janela	—
N	Comprimento total da série	—
n	Valor máximo de defasagem	—
P	Pontuação da ilha de correlação	—
r^2	Coefficiente de determinação	—
$r_{x,y}^D$	Coefficiente de correlação de Pearson entre x e y , no qual uma das séries é defasada	—
$r_{x,y}^{J,D}$	Coefficiente de correlação de Pearson entre x e y , calculado entre intervalos de janela, no qual uma das série é defasada	—
$r_{x,y}^J$	Coefficiente de correlação de Pearson em janelas de tempo entre x e y	—
$r_{x,y}$	Coefficiente de correlação de Pearson amostral entre x e y	—
T	Tamanho da ilha de correlação	—
x^δ	série x defasada δ vezes	—
x_i	Elemento i da amostra x	—
x_o	Primeiro elemento de x	—
x'_t	Elemento de índice t de x , diferenciado sazonalmente	—
$cov(X, Y)$	Covariância entre X e Y	—

Capítulo 1

Introdução

Alarmes industriais são empregados para evidenciar condições inesperadas ou anômalas num dado processo, com o intuito de que todos os desvios da normalidade possam ser tratados com antecedência para garantir a segurança do mesmo. Porém, o excesso de alarmes ativos durante a operação de uma planta também é indesejável, pois cada alarme demanda uma ação por parte do pessoal de operação. Este fato pode se tornar uma causa de risco caso os operadores fiquem sobrecarregados durante a operação normal de processo e especialmente em condições críticas. Deste modo, existe um compromisso entre o número de alarmes ativos num dado instante e o benefício trazido por estes.

Dentre os diversos alarmes instalados em uma planta industrial moderna, irão existir vários problemáticos, alguns sendo simplesmente mal configurados e outros totalmente desnecessários. A classificação para problemas comuns em sistema de alarme são (PINTO; FARINHA, 2007):

1. **Excesso de alarmes durante emergências (*Alarm Flooding*):** Provocado por alarmes desnecessários ou correlacionados, de modo que um único problema causa a ativação de diversos alarmes ao mesmo tempo.
2. **Alarmes que disparam com alta frequência (*Bad Actors*):** Ativam-se durante situação normal da planta. Podem tanto ser desnecessários ou somente mal configurados.
3. **Alarmes espúrios (*Chattering Alarms*):** Entram e saem de ativação várias vezes em um curto período, em função de má configuração.

4. **Alarmes congelados ou permanentes (*Standing Alarms*):** Ficam ativos durante grande parte da operação. São desnecessários, pois nenhuma ação os trará para o estado normal.

A técnica chamada de *racionalização de alarmes* busca exatamente reduzir o número de alarmes ativos em um dado processo para o nível mínimo que preserve a segurança da planta, de forma que alarmes críticos não sejam ignorados (YANG et al., 2010). Essa redução no número de alarmes ativos é feita primeiramente pela redução do número de alarmes na planta, removendo aqueles que apresentam alta frequência de ativação. Além disso, as técnicas de racionalização buscam pela decisão dos limites destes alarmes, o que visa a diminuir o número de alarmes falsos e garantir que alarmes não deixem de disparar em situações de risco.

Uma outra possibilidade para o controle dos alarmes é a investigação de relações de causalidade entre os alarmes e as demais variáveis de processo, especialmente com base em históricos de dados, o que pode ajudar a entender, analisar e otimizar o sistema de alarmes. Com isto, pode-se atingir inclusive o nível *preditivo* do sistema de alarmes (BROWN, 2003), que permite a atuação antecipada em face de problemas operacionais.

1.1 Motivação e Objetivo

Este estudo se propõe a investigar métodos que ajudem a analisar dados de sistemas de alarmes, buscando a causa raiz da ativação de alarmes no processo pela análise da correlação e causalidade entre dados de sensores. Particularmente, objetiva-se que esta análise possa ser feita de forma automática, por exemplo, em um sistema de monitoramento de alarmes, o qual geraria as conclusões sobre a ocorrência de um determinado evento de alarme. Embora este objetivo guarde similaridade com outras técnicas, tais como a análise estatística de processos, a análise de falhas e a modelagem empírica, entre outros, um aspecto particular é que se busca associar eventos específicos (ativação de alarmes) com sua causa geradora, e não a relação entrada-saída usual entre as variáveis.

Além disto, a análise criada neste estudo visa ser útil para a configuração de

sistema de alarmes. Os objetivos específicos que este estudo busca atingir são:

- Calcular a correlação entre dados de sensores de forma robusta, ou seja, considerando a progressão da correlação durante o processo e a correlação entre os dados defasados.
- Filtrar automaticamente pares de séries que não apresentem correlação.
- Aplicar testes de causalidade entre séries correlacionadas.
- Exibir a informação das análises de causalidade e correlação em gráficos de rede direcionais, permitindo o entendimento de relações entre causas e efeitos.

Estes objetivos serão realizados por um programa que realiza os cálculos necessários e gera os gráficos de redes. O programa será criado com o objetivo de ser utilizado de forma preventiva, após a ocorrência de um alarme, analisando uma batelada de dados referente ao período determinado pelo usuário.

Capítulo 2

Revisão Bibliográfica e Fundamentação Teórica

Neste capítulo, serão revisadas técnicas similares àquela proposta neste trabalho e usadas tanto na engenharia quanto em outras áreas da ciência, visto que não foram encontrados na literatura outros trabalhos com os mesmos objetivos deste estudo. Será também revisada a teoria sobre o cálculo da causalidade e correlação.

2.1 Revisão Bibliográfica

A busca por metodologias computacionais automáticas que detectem a interação entre elementos dentro de um processo ou ecossistema é comum em vários campos da ciência. Nas indústrias um problema importante é a detecção de falhas que busca por maneiras de identificar as causas de um certo defeito com o intuito de preveni-lo (VENKATASUBRAMANIAN, 2003). Já a área biológica adotou a modelagem computacional de sistemas complexos, como a interação entre genes (TANK et al., 2018) (PRILL et al., 2010) ou o relacionamento de sinais elétricos de células musculares (Tucker, 1999), com o objetivo de gerar entendimento sobre esses processos pela análise da correlação entre as variáveis.

2.1.1 Detecção de Falhas

Venkatasubramanian, em sua série de três artigos (VENKATASUBRAMANIAN, 2003) (VENKATASUBRAMANIAN et al., 2003a) (VENKATASUBRAMANIAN et al., 2003b), classifica os métodos de detecção de falhas em três categorias: baseados em modelos quantitativos, baseados em modelos qualitativos e baseados em histórico.

Dentre os modelos quantitativos duas das técnicas mais populares são as relações de paridade e os filtros de Kalman. Uma relação de paridade pode ser estabelecida com base no modelo em espaço de estados da planta ou na diferença entre sua entrada e saída. A principal ideia deste método é comparar o desvio entre o estado real, medido por sensores na planta, do estado ideal, operação em estado estacionário perfeito. Pode-se aplicar então os filtros de Kalman que assumem todos os distúrbios da planta como sendo gaussianos e agem de forma recursiva sobre o sistema com o intuito de corrigir, a cada etapa, possíveis desvios entre o que está sendo medido e o estado estável do processo.

Para os modelos qualitativos, a principal característica é que se torna necessário o conhecimento fundamental físico e químico do processo. O exemplo mais básico são os sistemas especialistas (do inglês, *expert systems*), programas formados por diversas regras em forma de IF-ELSE com o objetivo de tomar decisões baseadas em situações já conhecidas. A limitação desse tipo de sistema é seu baixo entendimento do processo no seu nível mais fenomenológico.

Árvores de falha são similares aos sistemas especialistas, fazendo uma busca sequencial no processo e adicionando às regras do programa mais lógicas como AND e XOR (*exclusive OR*). A partir de um acontecimento num nível hierárquico superior, o sistema propõe diversas questões com o objetivo de descobrir o motivo de origem que levou ao resultado observado. Uma desvantagem desses sistemas é que ele depende totalmente do conhecimento de quem o programou. Venkatasubramanian et al. (2003a)

Os métodos baseados em dados históricos não necessitam da modelagem da planta ou do processo. Logo, podem ser criados sem que haja conhecimento físico e químico da operação. Venkatasubramanian (2003) classifica os métodos históricos por

sua vez novamente em qualitativos e quantitativos.

Nos métodos históricos qualitativos, são empregados novamente os sistemas especialistas, porém, desta vez, acompanhados de análises de extração de padrões aplicadas nos dados históricos do sistema. A vantagem deste método está na sua fácil compreensão, visto que as regras são criadas a partir do que foi observado como sendo o estado de funcionamento padrão do processo. A desvantagem continua sendo a superficialidade de técnica, que impossibilita o entendimento da fenomenologia geral do processo.

Para os métodos históricos quantitativos, fazendo contraposto aos sistemas especialistas, tem-se a aplicação de redes neurais, as quais conseguem detectar padrões intrincados nos dados, porém não apresentam fácil interpretabilidade. Becraft e Lee (1993) propõe o uso de redes neurais em conjunto aos sistemas especialistas com o objetivo de usar inicialmente a rede para filtrar problemas recorrentes e destacar a localização da falha, que então seria analisado por um modelo específico e de alta complexidade para o determinado processo em análise.

Outras técnicas importantes nesse campo são: análises de componentes principais, que são métodos estatísticos que buscam, em um determinado conjunto de dados, as características mais importantes para um certo padrão; classificadores de Bayes, método probabilístico de classificação, usado neste campo para distinguir entre fases de operação da planta ou tipos de falhas; auto regressão vetorial (*do inglês, vector autoregression, VAR*), modelo de regressão entre conjuntos de séries temporais usado para achar padrões entre os dados.

2.1.2 Área Biológica

O campo das ciências médicas e biológicas vem acelerando rapidamente devido ao grande número de dados gerados e compartilhados dentro da comunidade científica. O Diálogo para Avaliações e Métodos de Engenharia Reversa (*Dialogue for Reverse Engineering Assessments and Methods, DREAM*) é um projeto da comunidade que, por meio de desafios anuais, visa o avanço do conhecimento de sistemas complexos biológicos pela análise de conjuntos de dados compartilhados pela plataforma do

synpase.org.

Durante sua terceira conferência anual, que ficou conhecida como DREAM3, um dos desafios foi a busca de um sistema capaz de entender a dinâmica entre a expressão genética de alguns genes de *E. Coli* e leveduras. O método testado por Tank et al. (2018) propunha o uso de redes neurais para calcular a causalidade de Granger não linear entre as séries do sistema.

Outra técnica comum na área biológica é o uso de mapas de Kohonen, conhecidos também como mapas auto-organizáveis (*self-organized maps, SOM*). Esse método faz o agrupamento dos dados conforme suas similaridades, reduzindo conjuntos multidimensional em um mapa bidimensional (KOHONEN, 2008).

Um exemplo da utilização de mapas auto-organizáveis é na atividade muscular monitorada pela eletromiografia, técnica que monitora a atividade elétrica de células musculares (Tucker, 1999). Com o uso deste modelo é possível classificar possíveis semelhanças entre a ativação de diferentes músculos durante atividades físicas.

2.2 Fundamentação Teórica

Nesta seção, serão apresentados os fundamentos teóricos utilizados ao longo do trabalho. Será revisado o cálculo da correlação e da causalidade entre duas variáveis.

2.2.1 Correlação

A correlação é um método de se mensurar a associação entre duas variáveis, podendo ou não haver causalidade entre elas. Existem diferentes métodos de medir a correlação, sendo um dos mais utilizados o coeficiente de correlação de Pearson que calcula um coeficiente entre -1 e 1, mensurando assim a força de associação e a direção do efeito entre duas variáveis com relação linear.

O coeficiente de Pearson igual a 1 indica uma correlação linear positiva perfeita entre as variáveis. Um exemplo de coeficiente positivo, porém não perfeito, é mostrado

na Figura 2.1 (a). Na Figura 2.1 (b), é mostrada uma relação negativa entre as variáveis, ou seja, com o aumento de X , acontece a diminuição de Y .

Com esse método, não é possível estimar adequadamente as relações não-lineares. Assim, caso os dados fossem similares aos da Figura 2.1 (c), o coeficiente de Pearson iria indicar uma correlação baixa entre as variáveis, mesmo essas apresentando forte relação quadrática.

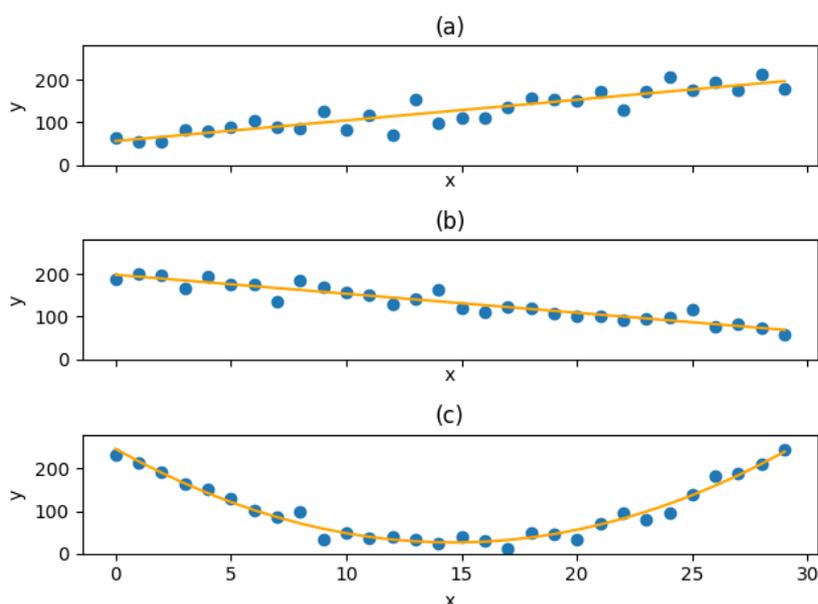


FIGURA 2.1. Exemplo de relações entre variáveis com as linhas de tendências que melhor explicam o tipo de relação. (a) Relação linear positiva entre x e y . (b) relação linear negativa. (c) relação quadrática.

O cálculo para a correlação de Pearson em uma população é dado pela seguinte equação:

$$\rho_{X,Y} = \frac{cov(X, Y)}{\sigma_X \sigma_Y} \quad (2.1)$$

onde $cov(X, Y)$ é a covariância entre X e Y , e σ_X e σ_Y são seus respectivos desvios padrões.

A fórmula do coeficiente de Pearson para uma amostra pode ser obtida substituindo-se a covariância e os desvios padrões da equação 2.1 por suas respecti-

vas correspondentes amostrais, resultando em:

$$r_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2.2)$$

onde n é o tamanho da amostra, x_i, y_i são os pontos amostrais individuais e \bar{x}, \bar{y} são as médias das amostras.

O coeficiente de Pearson r não é proporcional. Assim, um coeficiente de 0,5 não expressa uma correlação duas vezes mais forte que um coeficiente de 0,25.

Para se obter um valor mais interpretável, é comum o uso do coeficiente de determinação, conhecido também como r^2 . Ao elevar-se o coeficiente de Pearson ao quadrado todos os valores são mapeados no intervalo entre 0 e 1. Deste modo, um valor de r^2 igual a 0,5 apresenta correlação duas vezes mais forte que um valor de 0,25 (PATTEN; NEWHART, 2017). Fazendo essa operação, não é possível mais distinguir entre correlação positiva ou negativa.

2.2.2 Causalidade

A capacidade de determinar relações de causa e efeito entre variáveis é extremamente útil para diversas áreas do conhecimento. Na estatística, a determinação de causalidade entre séries temporais pode ser feita por diversos métodos, cada qual com diferentes vantagens e desvantagens (EICHLER, 2013).

As principais propriedades que devem ser empregadas na determinação da relação de causalidade é que toda causa deve preceder seus efeitos e qualquer variação na causa irá gerar uma variação no efeito. Porém, correlação não implica em causalidade. Caso valores passados de uma série X apresentem coeficiente de correlação de Pearson igual a 1 com a série Y , isso não indica necessariamente que X cause Y .

O método mais popular para a determinação de causalidade é o de Granger (EICHLER, 2013). Ele é um teste de hipótese estatística que determina se uma série temporal é útil para projetar valores futuros de outra série. Deste modo, um resultado

positivo de causalidade de Granger não garante necessariamente a relação de causa e efeito, mas sim mostra uma causalidade preditiva entre as séries. É dito que uma série X causa a série Y no sentido de Granger caso as previsões da série Y baseadas nos valores passados de X e Y em combinação geram melhores resultados que a previsão baseada apenas nos valores passados de Y sozinhos.

Para que duas séries possam ser comparadas pelo teste de Granger, elas devem ser estacionárias. As propriedades de uma série estacionária não variam conforme a progressão no tempo, ou seja, para que uma série possa ser considerada estacionária, ela não pode ter tendências nem sazonalidade. Exemplos de séries não estacionárias e estacionárias podem ser vistos, respectivamente, na Figura 2.2 (a) e (b).

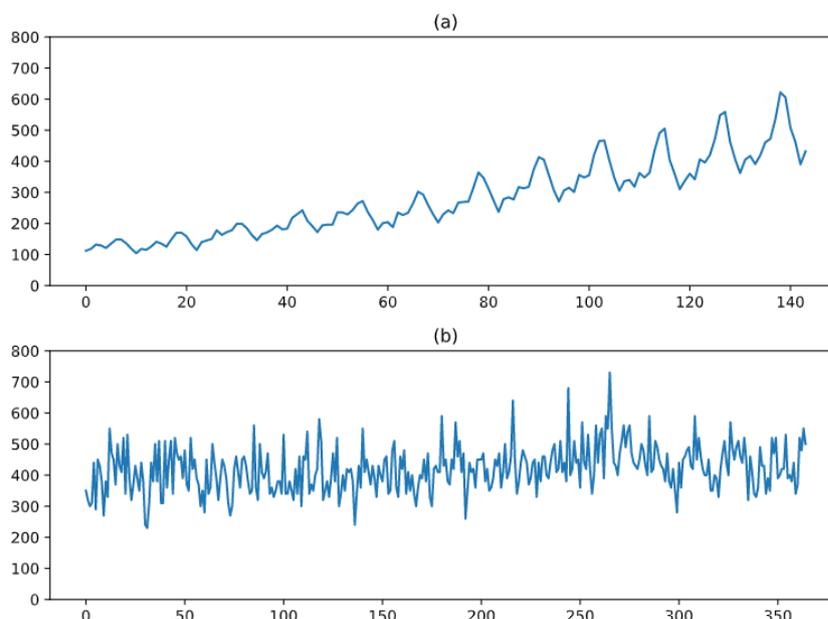


FIGURA 2.2. Exemplo de séries temporais não estacionárias (a) e estacionárias (b).

A maneira mais simples de transformar uma série em estacionária é pela diferenciação, fazendo a variação entre dois pontos adjacentes dos dados. Por exemplo, o preço de uma ação na bolsa de valores pode apresentar uma tendência durante o ano, porém, ao analisar a variação entre o preço do dia em relação ao preço do dia anterior, este é bastante semelhante a um ruído, um processo estocástico.

Às vezes, para tornar uma série estacionária, é necessário mais de uma diferenciação. A cada vez que uma série é diferenciada ela é encurtada em dois pontos e é

dito que foi feita a diferenciação de n ordem, onde n é o número de vezes que a operação foi aplicada. Sendo a variável X uma série com três pontos x_1 , x_2 e x_3 , ao aplicar a primeira diferença o resultado dessa será a série de dois pontos $(x_2 - x_1)$, $(x_3 - x_2)$ (HYNDMAN; ATHANASOPOULOS, 2018).

Séries que apresentam sazonalidade podem não se tornar estacionárias mesmo com várias ordens de diferenciação. Assim, é possível também aplicar a diferenciação sazonal sabendo de antemão o período da sazonalidade. Essa transformação é feita pela seguinte equação:

$$x'_t = x_t - x_{t-m} \quad (2.3)$$

Onde m é o período da sazonalidade e x'_t é o elemento com índice n de x diferenciado sazonalmente.

Os métodos formais para determinar estacionariedade são testes de raiz unitária, no qual o mais conhecido é o Dickey-Fuller Aumentado (*do inglês Augmented Dickey-Fuller, ADF*). Esse teste já aplica automaticamente a diferenciação na série e procura por possíveis raízes unitárias, que, caso encontradas, tornariam a série não estacionária.

Finalmente, depois de se obter um par de séries estacionárias pode-se aplicar o teste de correlação de Granger. Em essência, para descobrir se a série x causa a série y , o teste de Granger primeiro determina o quanto y depende si mesmo. Ou seja, o quão bem é possível projetar o próximo valor y_t utilizando y_{t-n} onde y_{t-n} são possíveis valores anteriores de y . Esse tipo de estrutura é conhecido como o modelo autorregressivo. Obtendo-se os valores passados de y que mais ajudam na projeção dos valores futuros, são então incorporados valores da série x .

Para a série X , o processo é similar, o teste de Granger busca os melhores valores passados da série que ajudam a projetar o valor futuro para a série y , o y_t . Para cada um dos valores de x_0 a x_{t-n} , é feito um teste t para confirmar com certo grau de certeza que este é útil na projeção de y .

Assim, com todos os valores passados úteis de x e y para a identificação de y_t , é feito então um *teste f* que confirma se esse modelo gerado consegue ou não projetar o valor futuro y_t com certo grau de confiança. Caso o modelo final passe o *teste f* e caso neste modelo tenha sido incorporado qualquer valor passado de x é dito então que x causa y no sentido de Granger.

Capítulo 3

Metodologia

Neste capítulo, serão apresentados inicialmente os softwares e pacotes numéricos utilizados para o desenvolvimento deste trabalho. Serão mostrados também as simulações de processo que foram utilizadas para a geração dos dados os quais servirão para a criação do método de análise. A seguir, serão detalhadas e justificadas as etapas empregadas no método proposto. A metodologia consolidada é descrita no final deste capítulo.

3.1 Softwares

As análises deste estudo foram realizadas utilizando a linguagem de programação Python, versão 3.8. Todas estas análises e visualizações foram feitas utilizando bibliotecas usuais dentro da comunidade da ciência e análise de dados.

A manipulação e os cálculos com os dados foram feitos utilizando as bibliotecas pandas e NumPy. Para grande parte das visualizações, foram usadas as bibliotecas matplotlib e seaborn, sendo esta última apenas uma interface mais simples para a geração de gráficos do matplotlib. Outra parte das visualizações foi feita pela biblioteca NetworkX, focada na criação de gráficos de rede.

Para o teste de causalidade de Granger foi utilizada a função *grangercausalitytests* importada da biblioteca statsmodels. Deste módulo também foi utilizada a função *adfuller* para o teste de estacionariedade de Dickey-Fuller Aumentado. Algumas outras bibliotecas úteis para operação matricial e análise de imagens utilizadas foram

scipy e skimage. Para as simulações computacionais, foi empregado o software Matlab (R201b) e o pacote Simulink.

3.2 Dados de processo

As análises deste trabalho foram feitas utilizando-se dados de duas simulações computacionais de processos distintos. A primeira simulação, que será chamada de simulação A, apresenta dois sistemas separados de tanques, como mostrado no fluxograma da Figura 3.1. Com esta simulação foram gerados os dados de processo das válvulas, correntes, tanques e alarmes mostrado pela Tabela 3.1.

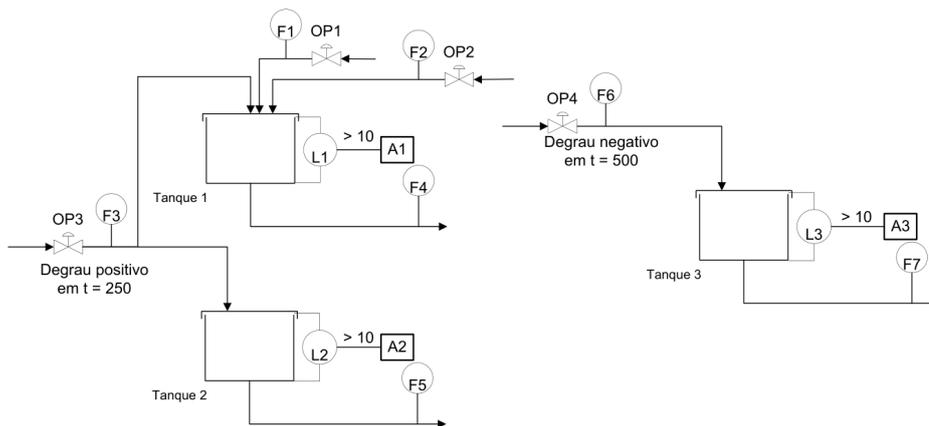


FIGURA 3.1. Fluxograma do processo da simulação A.

	Tanques	Correntes	Válvulas	Alarmes
Quantidade	3	7	4	3
Medida	Nível	Vazão	Abertura	Ativação
Sigla	L	F	OP	A
Unidade de Medida	m	m^3/h	%	Booleano (1 ativo, 0 inativo)

TABELA 3.1. Número de componentes da simulação A.

Os três alarmes dessa simulação, A1, A2 e A3, monitoram os respectivos níveis dos tanques L1, L2 e L3. A corrente F3, controlada pela válvula OP3, alimenta tanto

o tanque 1 quanto o tanque 2. Durante a simulação, feita durante 1000 unidades de tempo, algumas vazões aumentavam devido a abertura de válvulas enquanto outras mantinham-se constantes. Alguns exemplos das séries geradas pela simulação podem ser vistos na Figura 3.2.

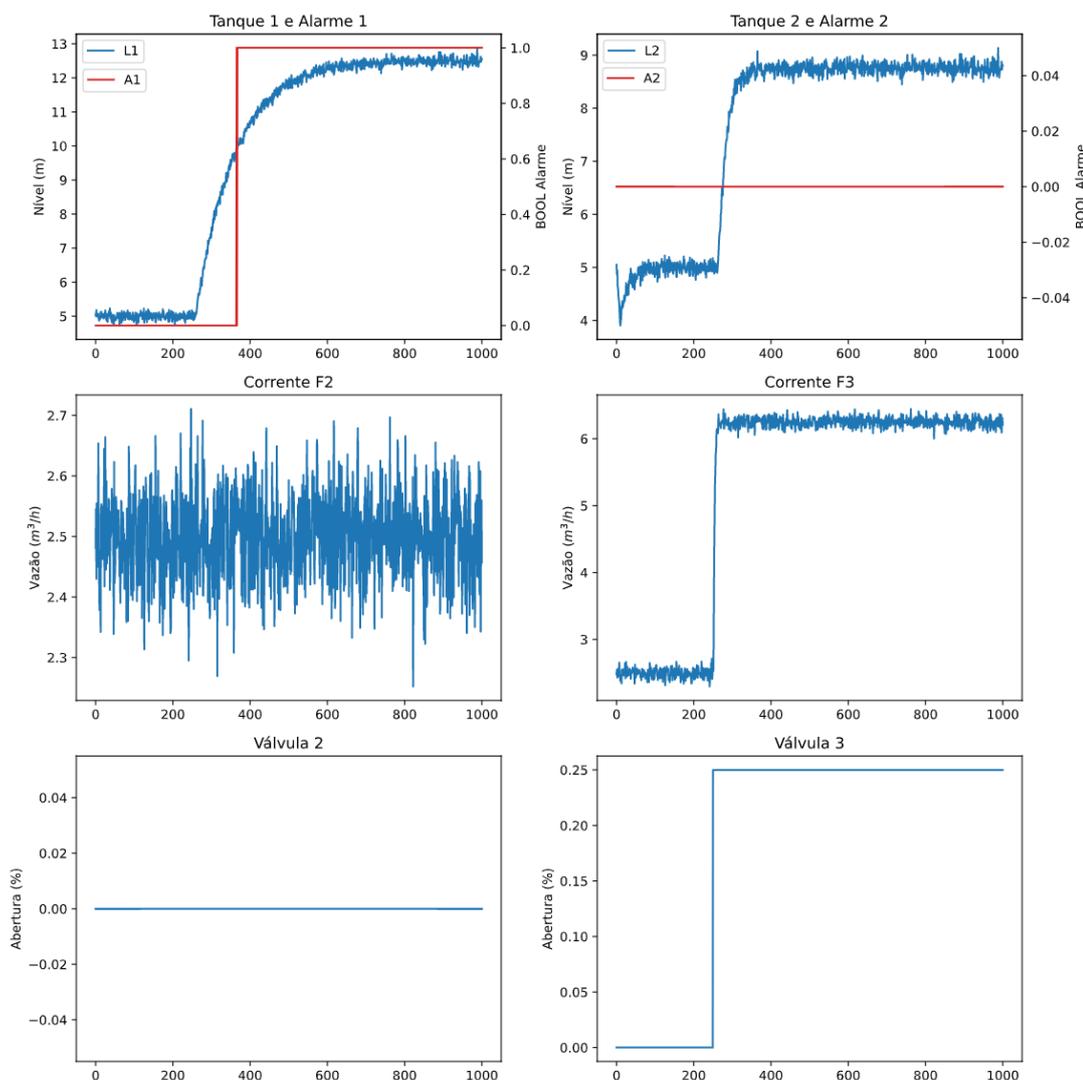


FIGURA 3.2. Progressões de algumas séries de dados da simulação A.

A segunda simulação, chamada de simulação B, continha componentes tais como trocador de calor e reator, e seu fluxograma é trazido na Figura 3.3. Os alarmes monitoram os níveis do tanque 1 e do reator, assim como também a temperatura no trocador de calor. Diferentemente da simulação A, mais de um dos alarmes da simulação B entrava em ativação durante o período simulado, feito em 500 unidades de tempo. Os tipos e quantidades de séries geradas por essa simulação podem ser vistos

na Tabela 3.2.

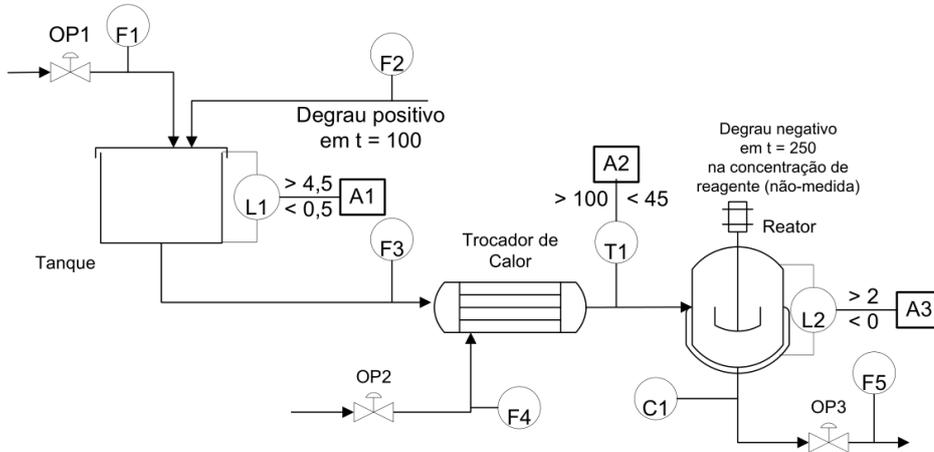


FIGURA 3.3. Fluxograma do processo da simulação B.

	Tanques	Correntes	Válvulas	Temperaturas	Concentrações	Alarmes
Quantidade	2	5	3	1	1	3
Medida	Nível	Vazão	Abertura	Temperatura	Concentração	Ativação
Sigla	L	F	OP	T	C	A
Unidade de medida	m	m^3/h	%	$^{\circ}C$	$kmol/m^3$	Booleano (1 ativo, 0 inativo)

TABELA 3.2. Número de componentes da simulação B.

3.3 Análise dos dados

Nesta seção serão explicados os métodos utilizados para o cálculo da correlação e da causalidade entre as séries. Será também mostrado como foi feita a análise automática dos resultados e a criação dos gráficos de redes.

3.3.1 Correlação

A maneira mais direta de medir a correlação entre um par de séries temporais é fazendo-se o cálculo do coeficiente de Pearson utilizando as séries completas. Fazendo-se isso, a interação das séries como um todo é resumida em um único valor, variando

de -1 a 1. O resultado para um conjunto de séries é uma matriz similar à mostrada na Tabela 3.3.

	F1	F2	OP3	L1	L2
F1	1,00	-0,01	-0,02	0,00	-0,01
F2	-0,01	1,00	0,05	0,05	0,04
OP3	-0,02	0,05	1,00	0,87	0,94
L1	0,00	0,05	0,87	1,00	0,95
L2	-0,01	0,04	0,94	0,95	1,00

TABELA 3.3. Exemplo da correlação de Pearson entre pares de séries.

No entanto, a fim de capturar mais detalhadamente o relacionamento entre duas séries, especialmente a fim de distinguir eventos associados à ativação de alarmes do ruído normal de processo, pode-se fazer o cálculo da correlação entre janelas de tempo. Isto irá gerar uma nova série temporal com o valor do coeficiente de correlação no período de tempo analisado, que pode ser visto num gráfico de tendência como ilustrado na Figura 3.4.

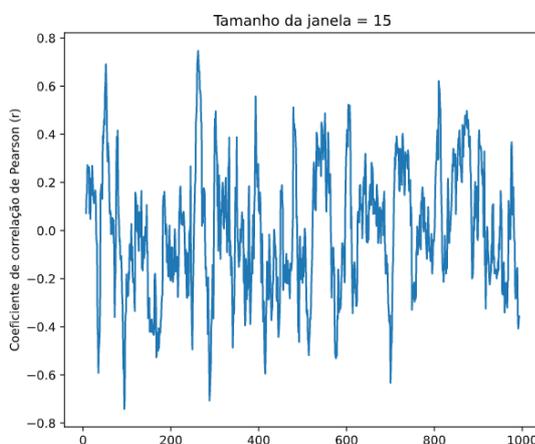


FIGURA 3.4. Gráfico temporal do coeficiente de correlação calculado para janela de tamanho 15 entre um par de séries.

No exemplo da Figura 3.4, foi escolhido um tamanho de janela arbitrário de 15 amostras de cada sequência. Assim, os cálculos da correlação são feitos utilizando apenas segmentos com 15 pontos de cada uma das séries. O avanço para o próximo cálculo neste caso é feito de 1 em 1 unidades de tempo. A fórmula para o cálculo do

coeficiente de correlação de Pearson em janelas de tempo, r^J , entre x e y é:

$$r_{x,y}^J(k) = \frac{\sum_{i=k}^{k+l} (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=k}^{k+l} (x_i - \bar{x})^2} \sqrt{\sum_{i=k}^{k+l} (y_i - \bar{y})^2}}, k = 1, \dots, N - l \quad (3.1)$$

Onde l é o comprimento da janela e N é o comprimento total de x e y .

Uma dificuldade de análise utilizando a Equação 3.1 acontece com o cálculo de correlação quando uma das séries é de alarme ou de abertura de válvulas em malha aberta, caracterizadas como séries de valores constantes por intervalos. Como estas variam pouco durante o intervalo analisado, as chances de que em uma janela todos os valores para um alarme ou abertura de válvula sejam idênticos são altas. Isso faz com que a média da janela seja igual aos próprios valores individuais e impossibilita o cálculo da correlação de Pearson, visto que seu denominador será igual a zero para aquele período.

Para contornar este problema, foi adicionado um ruído com distribuição normal variando entre 0 e 0,0001 à todas as séries de alarmes e válvulas. Este ruído não causava nenhuma alteração dos resultados, porém tornava possível o cálculo da correlação destas séries. Assim, por mais que as séries de válvulas tenham sido utilizadas para as análises de correlação, todos os cálculos seriam baseados na série que o alarme monitorava, e não no alarme em si.

Há outros problemas com esta maneira de calcular a correlação. Um deles é a intensidade do ruído nas séries, a qual terá um efeito maior na estimativa de $r_{x,y}^J$. Isto pode ser resolvido aumentando-se o tamanho da janela, o que faz com que um número maior de dados seja utilizado para calcular cada valor de correlação e assim diminuindo o efeito do ruído. Porém, isto gera um novo problema, que é a necessidade da seleção de um tamanho de janela ideal, suficiente para reduzir o efeito do ruído, porém ao mesmo tempo fornecendo a informação desejada de correlação entre eventos nas séries.

Neste trabalho, observou-se que tamanhos de janela na ordem de 10% a 30% do comprimento total das séries funcionaram bem para os dados de ambas simulações.

Aumentando-se o tamanho de janela dos dados mostrados na Figura 3.4, tem-se o gráfico da Figura 3.5.

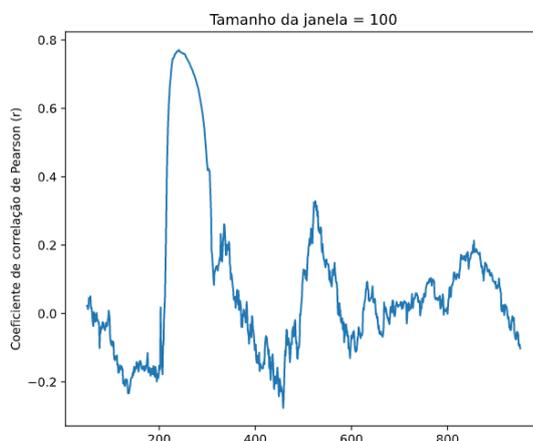


FIGURA 3.5. Gráfico temporal do coeficiente de correlação calculado para janela de tamanho 100 entre um par de séries.

Assim, é possível perceber um pico de correlação em torno do ponto 230 do eixo horizontal. Para melhorar essa análise e facilitar o processo de isolar os pontos de interesse (picos de alta correlação), será empregado o valor do coeficiente de Pearson ao quadrado, transformando-o no coeficiente de determinação r^2 .

Ao fazer essa transformação, todos os valores da sequência tornam-se positivos, o que é de interesse para a proposta deste trabalho, visto que o objetivo é descobrir se séries são correlacionadas, independentemente da direção desta correlação. Outro fator benéfico da transformação é o aumento da separação entre valores com coeficientes mais elevados em relação aos mais próximos de zero. O resultado dessa operação para os dados referente a Figura 3.5 é mostrado na Figura 3.6.

Uma complicação adicional com esse tipo de análise é que não são levadas em conta possíveis defasagens entre as séries. Isso é problemático, já que as mesmas correspondem em princípio a processos sujeitos à dinâmica e a atrasos e o efeito de uma causa pode estar temporalmente deslocado. Para descobrir o impacto da defasagem no coeficiente de correlação, uma possibilidade é o cálculo do valor de Pearson global, igual mostrado na Tabela 3.3, entre um par de séries defasando-se uma delas diversas vezes. Esses valores são então elevados ao quadrado para se obter o coeficiente

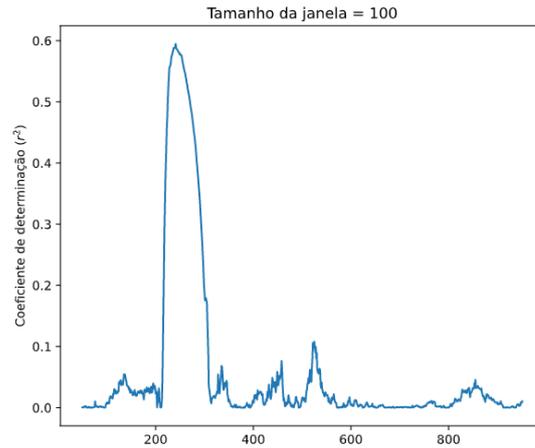


FIGURA 3.6. Gráfico temporal do coeficiente de determinação (r^2) calculado para janela de tamanho 100 entre um par de séries.

de determinação. A fórmula para o cálculo do coeficiente de correlação de Pearson defasado, r^D , entre x e y é:

$$r_{x,y}^D(\delta) = \frac{\sum_{i=0}^N (x_i^\delta - \bar{x}^\delta)(y_i - \bar{y})}{\sqrt{\sum_{i=0}^N (x_i^\delta - \bar{x}^\delta)^2} \sqrt{\sum_{i=0}^N (y_i - \bar{y})^2}}, \delta = -n, \dots, n \quad (3.2)$$

Onde x^δ é a série x defasada até que o elemento de índice δ seja o primeiro da série, N é o comprimento das séries de x e y e n é a quantidade de defasagens que deve ser feita em cada sentido, sendo necessariamente menor que N .

No gráfico da Figura 3.7, é mostrado um exemplo da análise feita para a simulação A. As séries F3 e L1 são comparadas de modo que na linha central do gráfico tem-se o coeficiente de correlação entre as duas séries originais, sem nenhuma defasagem. Para os valores à esquerda da linha central, a série L1 é defasada negativamente. Ou seja, com uma defasagem de -100, o valor de índice 100 na série L1 passa a ser o primeiro valor.

Assim, neste exemplo, o ponto de maior correlação é o de defasagem -70 para a série L1. Isso significa que é necessário atrasar a série L1 em 70 pontos para se obter o maior nível de correlação entre F3 e L1, ou seja, a maior correlação entre as duas variáveis ocorre para valores posteriores de L1 em relação a F3.

Defasar uma série reduz o seu tamanho. Quando uma série é defasada negati-

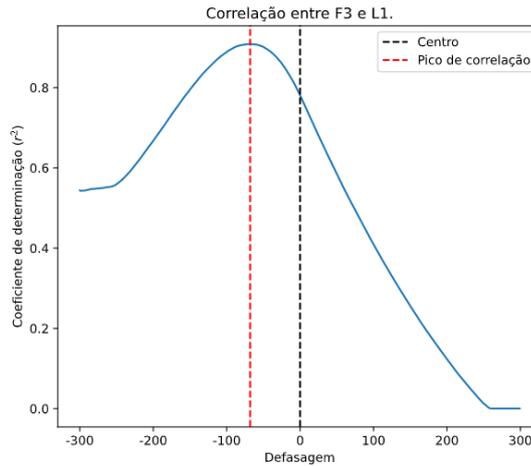


FIGURA 3.7. Exemplo do valor de Pearson calculado para diferentes defasagens entre um par de séries.

vamente de forma que seu último valor passa a ser o penúltimo, não há valores para assumir a última posição dessa nova série, assim, este se torna nulo. O mesmo acontece ao defasar positivamente, porém com o primeiro valor da série.

Como a correlação entre séries com pequeno número de pontos apresenta grande efeito estatístico de ruídos, exemplo demonstrado pela Figura 3.4, é necessário limitar a quantidade de defasagens feitas sobre a série, evitando que correlações sejam calculadas para trechos pequenos de dados. Devido a isso, nas análises envolvendo defasagem, foi sempre removida uma parcela das correlações calculadas com alta defasagem, de modo a tirar essas zonas de elevado ruído do gráfico.

Para que se possa analisar o impacto da defasagem sem precisar reduzir as séries a um único valor de correlação para cada deslocamento, é utilizado um método híbrido entre as análises feitas na Figura 3.6 e 3.7. Este método divide as séries originais em vários segmentos e para cada um dos pedaços é feita a análise da defasagem do coeficiente de determinação. Assim, a fórmula para cálculo do coeficiente de correlação de Pearson calculado para cada defasagem em cada janela, $r^{J,D}$, para x e y é:

$$r_{x,y}^{J,D}(k, \delta) = \frac{\sum_{i=k}^{k+l} (x_i^\delta - \bar{x}^\delta)(y_i - \bar{y})}{\sqrt{\sum_{i=k}^{k+l} (x_i^\delta - \bar{x}^\delta)^2} \sqrt{\sum_{i=k}^{k+l} (y_i - \bar{y})^2}}, k = 1, \dots, N - l, \delta = -n, \dots, n \quad (3.3)$$

O resultado desse método é mostrado no exemplo da Figura 3.8, utilizando uma

visualização de mapa de calor. As séries foram divididas em relação ao seu comprimento, sendo que o tamanho da janela neste exemplo da simulação A foi de 10% do total. Neste gráfico, o eixo vertical apresenta as divisões entre as janelas feitas nas séries e o eixo horizontal apresenta a defasagem entre as séries. O valor de defasagem é sempre referente à segunda série no título do gráfico, neste caso, L1.

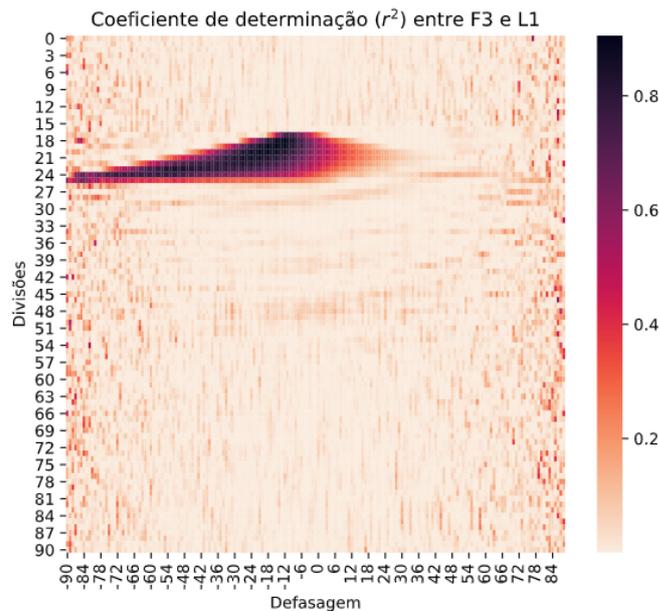


FIGURA 3.8. Análise híbrida do coeficiente de determinação.

Essa análise facilita a descoberta do ponto de interesse de maior correlação, visto que todos os dados ficam contidos numa única matriz. Além disso, a quantidade de informação é superior às outras análises citadas anteriormente, visto que se pode analisar tanto a defasagem quanto a progressão da correlação no decorrer das séries.

3.3.2 Buscas de pontos de interesse

Para isolar as áreas das matrizes resultantes da análise híbrida, foi feito primeiramente a transformação dela em uma matriz binária, ou seja, todos os valores foram convertidos para 0 ou 1. Foi escolhido o valor do coeficiente de determinação de 0,5 para o corte entre o que é considerado como correlação ou não. Este valor foi escolhido pois é metade do máximo de correlação que pode existir entre essas séries, visto que esta propriedade é o diferencial entre a correlação de Pearson e o coeficiente de deter-

minação r^2 . Assim, todos os valores abaixo da nota de corte foram transformados em 0, e todos acima tornaram-se 1.

A partir de uma matriz binária, é possível fazer a busca por "ilhas" de valores unitários. No caso deste trabalho, tais ilhas foram definidas como valores unitários adjacentes, incluindo as diagonais, na matriz e foram identificadas de forma automática por um algoritmo que as enumerava. Um exemplo de uma matriz que contém 5 ilhas, em sua forma binária e em sua forma classificada pelo algoritmo, é mostrada na Figura 3.9.

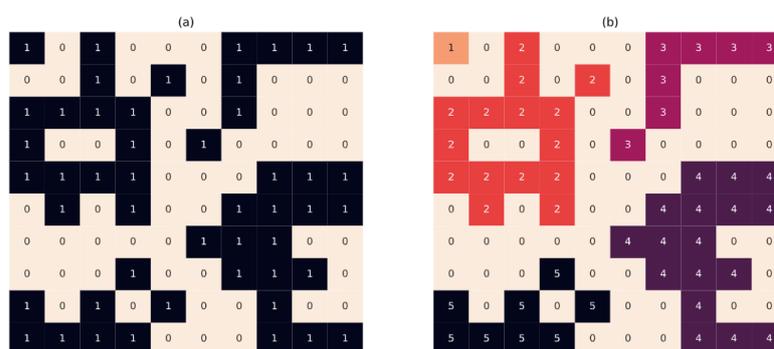


FIGURA 3.9. (a) Matriz binária. (b) Matriz com suas ilhas identificadas e enumeradas.

Visto que as ilhas são enumeradas, a obtenção do "tamanho" de cada uma destas é feita pela contagem de ocorrência dos valores diferentes de zero na matriz. Assim, se o valor 4 ocorre 10 vezes, isso significa que a ilha de número 4 é responsável por 10 elementos na matriz. Escolhe-se então as três maiores ilhas, e a partir dos índices de seus componentes, suas posições (x, y) , cada área de interesse era isolada da matriz de correlação original.

Uma das análises feita em cada área de interesse isolada buscava determinar seu centro de massa, ou seja, procurava pelo índice que melhor definia a distribuição dos coeficientes de determinação, como mostrado na Figura 3.10. Era feita também uma análise de "intensidade" da ilha, somando-se todos os coeficientes de determinação contidos na área de interesse e dividindo pelo valor máximo definido como o próprio tamanho da ilha, isto é, caso todos os coeficientes apresentassem uma correlação perfeita igual a 1.



FIGURA 3.10. Ponto do centro de massa marcado com um x , calculado a partir dos valores dos coeficientes de determinação, em uma ilha isolada.

Com o centro de massa, é possível então saber qual a defasagem média entre os pontos de alta correlação, analisando o eixo horizontal do mapa de calor. E com a intensidade e o tamanho da ilha, é possível julgar numericamente qual ilha deve ter preferência em relação a outra quando busca-se por áreas de interesse que representem alta correlação. Por simplicidade, para evitar casos extremos nos quais ilhas maiores com correlação baixas próximas a 0,5 pudessem ser priorizadas em relação às menores e mais intensas, foi feito um sistema de pontuação, calculada por:

$$P = T(1 + I) \quad (3.4)$$

Onde P é a pontuação, T é o tamanho da ilha e I a intensidade.

3.3.3 Diagramas de Causalidade e Correlação

Para a visualização das correlações entre as séries, é proposto um gráfico de rede, no qual cada nó representa uma série temporal e suas ligações representam a correlação e causalidade entre as séries. O tamanho dos nós e a opacidade das ligações foi estipulado proporcional à pontuação da maior ilha de correlação entre as séries. A causalidade era indicada pelo sentido das setas ligando os nós, como mostrado na

Figura 3.11.

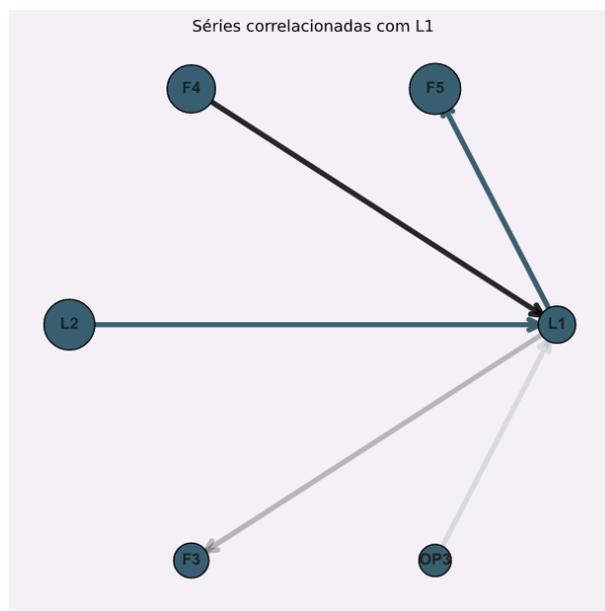


FIGURA 3.11. Exemplo do gráfico de rede gerado automaticamente para a série L1, monitorada pelo alarme A1.

Este gráfico de rede é gerado em relação à série monitorada pelo alarme que foi ativado, sendo X essa série de interesse e Y o conjunto de todas as outras séries, excluindo as de alarmes. Cada série temporal dentro deste conjunto é representada por Y_i , no qual cada valor de i é uma série como OP1, F1, L1, etc...

Assim, a série de interesse X é comparada com todas as outras séries do conjunto Y , de forma que cada uma dessas comparações resulta numa matriz do mapa de calor dos coeficientes de determinação. Desta matriz são obtidas as três ilhas mais evidentes com base nas suas pontuações. Estas são então agrupadas e depois ordenadas decrescentemente por suas pontuações. As cinco séries distintas de Y que apresentam as ilhas de maior pontuação eram escolhidas como possíveis candidatas para a causa de X .

Para gerar a direção das setas no gráfico de rede, é calculada a causalidade de Granger entre X e cada uma das cinco séries de Y mais correlacionadas com X . Para isto, tanto a série X quanto as séries de Y são diferenciadas até se tornarem estacionárias, e então o teste de Granger é feito para descobrir se Y_i causa X . Como o teste de

Granger busca por valores passados de Y_i que ajudem a projetar a série X , foi estipulado neste estudo que seria permitido apenas buscar por valores passados nas últimas 50 unidades de tempo.

O teste de causalidade de Granger retorna o p-valor dos testes f feitos para cada um dos valores passados de Y_i . A hipótese nula é que Y_i não causa X , assim, caso encontrado um p-valor inferior a 0,01 para algum dos valores passados de Y_i é possível rejeitar a hipótese nula e concluir que Y_i causa X no sentido de Granger. A probabilidade de significância de 1% foi utilizada neste trabalho para diminuir o número de falsos positivos quando buscado por relações de causa e efeito.

Tendo uma resposta positiva para essa causalidade, a seta é direcionada de Y_i para X . Caso contrário, o teste de Granger é feito no sentido oposto e, caso X cause Y_i , a seta é direcionada de X para Y . Não havendo causalidade em ambos os sentidos a seta é colorida de preta, de forma a indicar que o sentido desta não tem significado. A opacidade de setas coloridas de preto ainda é referente a pontuação da correlação entre as séries dos nós. O motivo pelo qual a seta é colorida de preto é porque a biblioteca usada para gerar os gráficos de rede não permite que um gráfico direcional apresente ligações sem orientação.

Similar à limitação de 50 unidades de tempo estipulada para o teste de Granger, neste estudo não foi considerado séries correlacionadas que apresentassem o centro de massa de suas ilhas deslocadas no eixo de defasagem em mais de 50 unidades de tempo. Este valor de corte foi escolhido sabendo que nas simulações empregadas, todas as causas e efeitos deveriam ocorrer em intervalos mais curtos de tempo.

3.3.4 Metodologia Consolidada

Um resumo da metodologia consolidada para gerar o gráfico de rede com as correlações e direções de causalidade entre as séries é mostrado a seguir em forma de pseudocódigo. Esse pseudocódigo gera um único gráfico de rede, assumindo que já se tem de antemão a série de interesse X monitorada pelo alarme que ativou e que as séries de dados de alarme já foram removidos de Y .

Seja X a serie de interesse

Seja Y um conjunto de series temporais

para cada serie Y_i em Y :

para cada segmento de janela em X e Y_i :

para cada defasagem no segmento de Y_i :

calcula da correlacao de Pearson entre os segmentos de serie

para cada matriz de correlacao entre series:

busca das tres maiores ilhas

isola cada uma das ilhas

calcula centro de massa da ilha

calcula intensidade da ilha

calcula pontuacao da ilha

ordena todas ilhas por sua pontuacao

descobre as 5 series Y_i responsaveis pelas ilhas com maior pontuacao

para cada serie Y_i nas 5 series separadas anteriormente:

diferencia Y_i e X ate estacionariedade

testa se Y_i causa X

caso sim:

sentido da flecha no diagrama final vai de Y_i a X

caso nao:

testa se X causa Y_i :

caso sim:

sentido da flecha de X a Y_i

caso nao:

flecha colorida de preto, sentido nao relevante

Capítulo 4

Resultados e Discussão

Nesta seção serão mostrados os resultados do uso da análise de correlação e causalidade para dados das variáveis das simulações. Primeiramente, será discutida a efetividade das técnicas em termos gerais, analisando o processo de cálculo da correlação entre as séries e evidenciando os problemas encontrados ao aplicar estas técnicas aos dados das simulações. Posteriormente, serão apresentados e discutidos os gráficos de rede das simulações A e B, comparando-os com as causas reais das simulações.

4.1 Resultados Gerais

A análise de correlação pelo método híbrido, combinando os cálculos por janela com os de defasagem em uma única matriz, detectou a correlação entre séries de forma satisfatória em ambas as simulações, mesmo que a relação entre as séries apresentasse defasagem. Analisando-se visualmente os mapas de calor, é fácil perceber a diferença entre séries obviamente correlacionadas, Figura 4.1 (a), e séries não correlacionadas, Figura 4.1 (b).

Um desafio dessa técnica é a escolha do tamanho de janela e do tamanho do passo, que é a quantidade de unidades de tempo avançada entre cada janela, anteriormente utilizado como 1. De preferência, quanto maior for o tamanho do passo, menos cálculos serão necessários, porém isso vem ao custo da redução na resolução do mapa de calor, o que torna mais incerta a busca por ilhas.

O tamanho de janela é importante por alguns fatores: primeiramente, ele garante que os cálculos da correlação sejam feitos com um número suficiente de dados, de forma a serem mais robustos aos ruídos; entretanto, janelas muito grandes causam a correlação a ser calculada sobre segmentos muito grandes das séries, fazendo com que eventos curtos como a abertura súbita de válvulas sejam mascarados por outros eventos durante o intervalo de tempo correspondente à janela. Além disso, o tamanho de janela é limitante na defasagem que pode ser aplicada sobre as séries, assim, com janelas muito pequenas, algumas correlações mais longas não serão observadas.

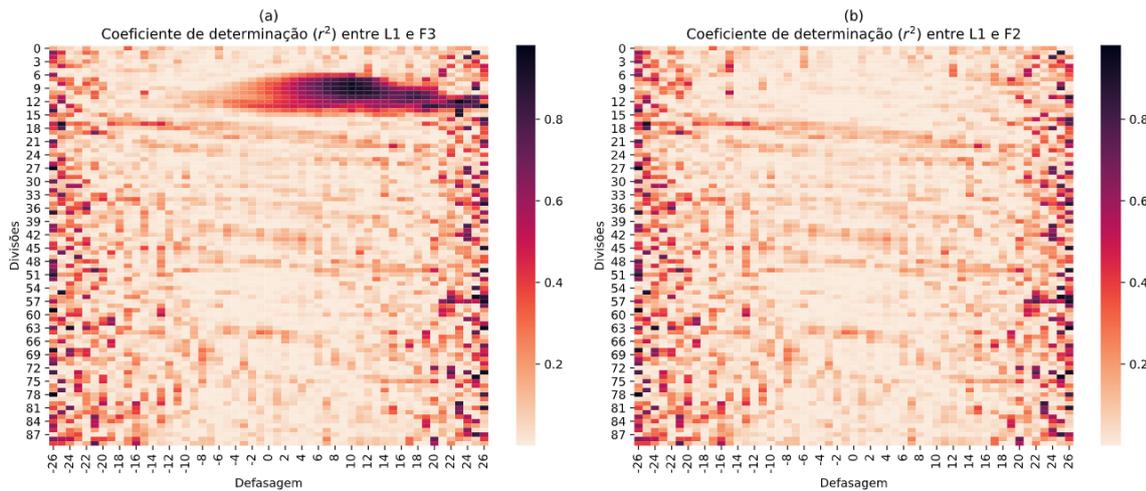


FIGURA 4.1. Exemplo típico de mapas de calor entre séries que apresentam correlação (a) e séries que não apresentam correlação (b).

Em geral, a escolha de todos os parâmetros vai depender do processo sendo analisado, o que faz com que sempre seja necessário um ajuste deste método quando for aplicado a um conjunto novo de dados. O tamanho de janela e do passo precisam estar de acordo com a quantidade de dados sendo analisada, para que todas as correlações sejam detectadas de forma adequada. Assim, os tamanhos de janela e de passo que funcionaram bem para este estudo foram, respectivamente, de 10% e 1% do comprimento total da série.

4.2 Resultados da simulação A

Durante a simulação A somente o alarme A1, alarme de nível alto do Tanque 1 (L1), é ativado. O gráfico de rede das cinco séries mais correlacionadas com L1, junto com suas relações de causalidade é mostrado na figura 4.2.

Esta análise indica que L2 e OP3 causam L1 e que F5 é causado por L1. E por mais que exista correlação de L1 com F4 e F3, essas duas séries não apresentam relação de causa e efeito, indicado pela cor preta da seta.

Para comparar este resultado, é necessário considerar a causa real do evento de alarme da simulação A. Nesta, uma abertura súbita na válvula OP3 ocasiona um aumento na vazão F3, a qual acarreta um aumento do nível L1 e L2, os quais estão portanto correlacionados, mas não guardam relação de causa-efeito. Assim, as vazões F4 e F5, que saem dos tanques 1 e 2, aumentam proporcionalmente.

Pela análise do gráfico de rede é possível concluir que:

1. É correto L1 apresentar correlação com F5, visto que ambas séries aumen-

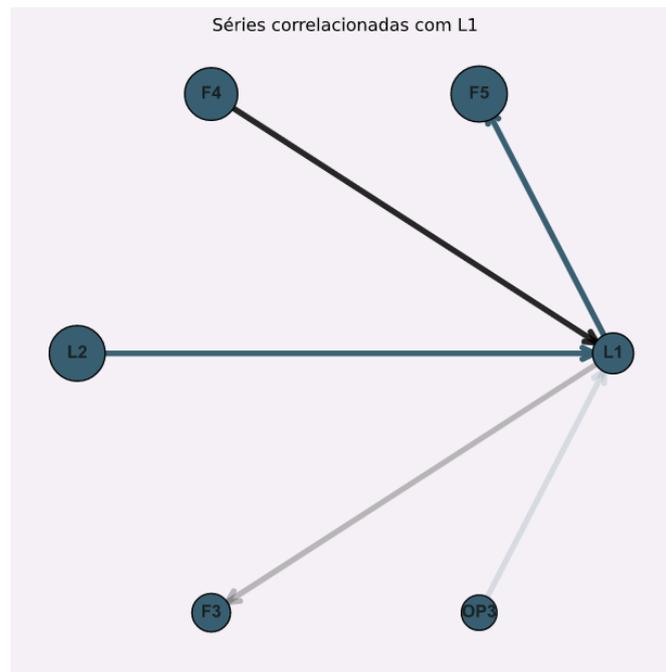


FIGURA 4.2. Gráfico de rede gerado para a análise de correlação e causalidade da simulação A.

tam após a abertura súbita da válvula OP3. Porém, L1 não causa F5.

2. É correto L1 apresentar correlação com F4. Ambas dependem da abertura de OP3, assim, faz sentido não haver causalidade, já que sua variação ocorre de forma simultânea.
3. É correto L1 apresentar correlação com L2 visto que ambos os níveis aumentam pela abertura de OP3. Não deveriam apresentar causalidade.
4. É correto L1 apresentar correlação com F3. Ambas dependem da abertura de OP3, assim, também é correto não haver causalidade.
5. É correto L1 apresentar correlação e ser causado por OP3.

4.3 Resultados da simulação B

A simulação B tem a ativação dos três alarmes A1, A2 e A3. Nesta, um aumento súbito no valor da corrente de vazão F2 causa um aumento do nível L1 até que o alarme A1 seja disparado. A corrente de vazão F3, que é a saída do tanque 1 e entrada do trocador T1, aumenta proporcionalmente, isso causa a redução na temperatura do trocador e ativação do alarme A2 por temperatura baixa. Este mesmo distúrbio leva ainda ao aumento do nível L2 do reator, causando a ativação de A3. Há, por último, um distúrbio não medido pelos sensores de concentração de reagente que afeta a concentração C1 do reator.

Em termos das correlações, este conjunto de dados apresenta um baixo número de componentes, todos interligados, o que faz com que exista correlação entre todas as séries medidas por sensores que apresentem alguma variação durante a simulação. Assim, esta simulação é utilizada para testar em um sistema mais complexo a efetividade do teste de causalidade de Granger.

Gerando-se os gráficos de rede com as relações entre as séries para L1, T1 e L2, séries monitoradas pelos alarmes A1, A2 e A3, respectivamente, tem-se o resultado da Figura 4.3. Nesta análise, é possível perceber que a corrente F2, que foi a origem de todas as ativações, apareceu como causa de todos os alarmes, porém com pontuações menores de ilha em comparação às outras séries, indicado pelo tamanho dos nós e opacidade das linhas.

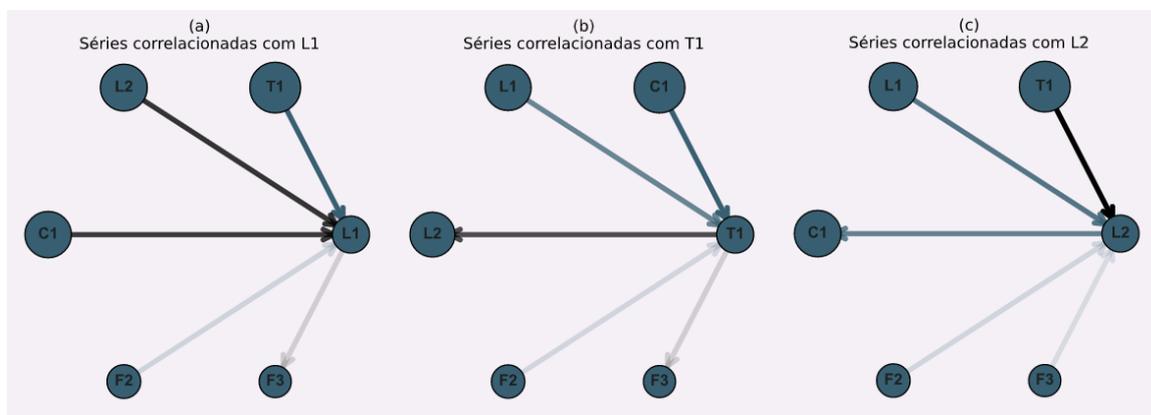


FIGURA 4.3. Gráficos de rede gerados para cada série monitorada por alarmes na simulação B. Em (a) o resultado da ativação do alarme A1, o qual monitorava L1. Em (b) para o alarme A2, monitorando T1. Em (c) para alarme A3, o qual monitorava L2.

Para a série monitorada L1, na Figura 4.3 (a), foi detectada erroneamente a série T1 como uma das causas da ativação do alarme. Na Figura 4.3 (b), para a temperatura no trocador de calor, as séries C1 e L1 foram incorretamente detectadas como causas do evento. A análise do gráfico de L2, na Figura 4.3 (c), apresentou o maior número de erros, detectando tanto L1 e F3 como causa do aumento de nível em L2 e esse como causa da concentração C1 do reator.

Foi percebido, durante a análises dos mapas de calor, que há um padrão incomum na correlação de C1 com as outras séries, apresentando zonas de alta correlação "cortadas" por zonas de baixa correlação, como mostrado na Figura 4.4 (a). É possível que o motivo desse comportamento incomum seja devido às relações não lineares que a concentração do reator tem com as outras variáveis. Em contraste, na Figura 4.4 (b) é mostrada a correlação entre o nível do tanque 1 e a vazão de saída dele, séries que são afetadas linearmente pelo aumento súbito em forma de degrau em F2.

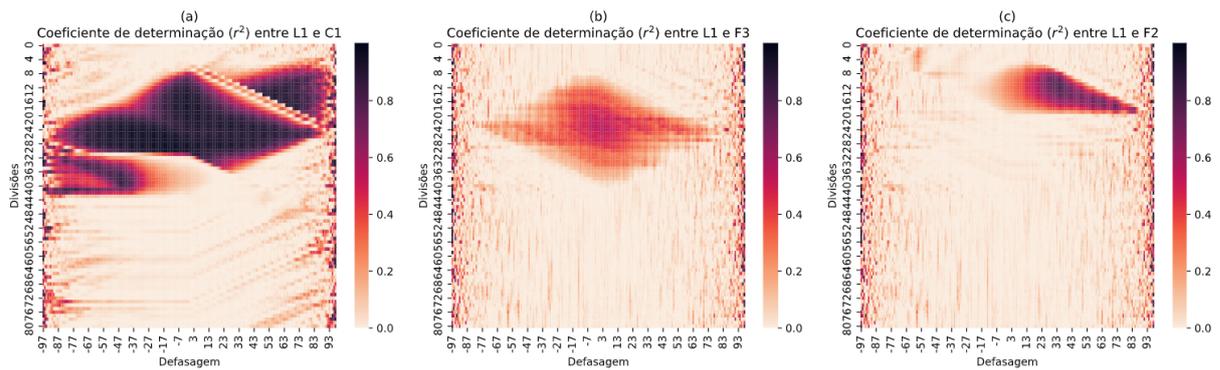


FIGURA 4.4. (a) Exemplo do comportamento incomum das correlações envolvendo a série C1, que apresenta relações não lineares com outras variáveis. (b) Comportamento típico de séries que são afetadas por um mesmo evento. (c) Correlação entre séries na qual uma delas sofre uma variação em forma de degrau.

Foi notado, durante este estudo, alguns padrões típicos nos mapas de calor das correlações entre as variáveis. Por exemplo, zonas de alta correlação centralizadas na área de defasagem 0, como mostrado na Figura 4.4 (b), são comuns para séries afetadas por um mesmo distúrbio, evidenciado também pelos mapas de calor vistos na simulação A. Ainda, foi visto, em ambas simulações, um padrão para séries afetadas por aumentos súbitos em forma de degrau, mostrado na Figura 4.4 (c), no qual as zonas de alta correlações são afastadas do eixo central e distorcidas no eixo horizontal, de defasagem.

Capítulo 5

Conclusões e Trabalhos Futuros

Neste capítulo serão apresentadas as conclusões sobre os resultados das técnicas de cálculo automático de correlação e causalidade aplicadas aos dados das simulações. Será também concluído sobre a escolha do tipo de visualização escolhida neste estudo e, por último, será sugerido possíveis abordagens para trabalhos futuros sobre o mesmo tópico deste trabalho.

5.1 Conclusão sobre o cálculo da correlação

Os objetivos referentes aos cálculos de correlação estipulados neste trabalho foram alcançados. Estes buscavam obter uma maneira robusta de calcular a correlação entre um par de séries, de modo que fosse considerada a progressão da correlação durante o processo e também a correlação das séries defasadas. Ainda, era necessário que o resultado deste método pudesse ser analisado automaticamente com certa facilidade.

A análise híbrida, utilizando o cálculo do coeficiente de correlação de Pearson por janela e defasado, serviu bem este propósito, apresentando resultados com diferenças óbvias entre séries correlacionadas e não correlacionadas. Como essa distinção é bastante aparente, o método automático de busca de ilhas apresentou bons resultados em todos os casos estudados, determinando as áreas de interesse das matrizes sem identificar que ruídos fossem indicativos de correlação entre as séries. Isso também fez com que os cálculos do tamanho das áreas, centro de massa e intensidade fossem confiáveis em todos os testes.

5.2 Conclusão sobre o cálculo da causalidade

A obtenção das relações de causalidade entre as séries monitoradas nas simulações foi inconsistente. Por mais que tenha sido possível obter corretamente as causas

originais dos eventos de alarmes em ambas simulações, ocorreram muitos erros ao inferir as relações de causa e efeito.

Como o teste de causalidade de Granger não busca pela causa real de um acontecimento e sim por valores de uma série que sejam úteis na predição de outra, é aceitável que, em alguns casos, seja obtida uma sequência de correlações. Por exemplo, na simulação A a abertura súbita da válvula OP3 causa o aumento de F3, que, em sequência, causa o aumento do nível L1 além do limite permitido. Assim, seria admissível para o objetivo deste trabalho detectar tanto OP3 quanto F3 como causa de L1, visto que esses efeitos precedem o aumento do nível no tanque.

Porém, nos resultados das duas simulações, foram detectadas várias relações de causa e efeito entre séries que não fazem sentido pela descrição original do processo simulado, como o caso de F5 na simulação A ser causado por L1. É chegado então à conclusão de que o uso do teste de Granger não funciona para estes dados de simulação.

5.3 Conclusão sobre o uso dos gráficos de rede

O uso de gráficos de rede para representar as relações de correlação e causalidade entre séries foi uma escolha boa visto que é fácil de automatizar a geração destas visualizações. Porém, a biblioteca escolhida neste trabalho não apresentou toda as funcionalidades necessárias para gerar estes gráficos da melhor maneira possível, visto que é essencial a criação de nós ligados por setas não direcionadas, para representar correlações entre séries sem causalidade.

5.4 Trabalhos Futuros

Trabalhos futuros que venham a estudar esse mesmo tópico podem começar pelos cálculos das correlações entre séries, utilizando o método híbrido, para dados de sensores em processos reais. Sabendo que é possível lidar com os ruídos e descobrir automaticamente as áreas de alta correlações entre séries em dados reais, pode-se, então, partir para as melhorias da busca das relações de causalidade.

Como o teste de causalidade de Granger não apresentou bons resultados para exemplos simples das simulações feitas neste trabalho, pode-se fazer testes de descoberta de relações de causa e efeito analisando as matrizes oriundas dos cálculos de correlação. Os padrões percebidos nos mapas de calor, mostrado na Figura 4.4, podem servir como base para um modelo de aprendizagem de máquina que consiga fazer a classificação entre séries correlacionadas e séries que apresentem relação de causa e efeito.

Referências Bibliográficas

- BECRAFT, W.; LEE, P. An integrated neural network/expert system approach for fault diagnosis. *Computers & Chemical Engineering*, v. 17, p. 1001–1014, 10 1993.
- BROWN, N. Alarm management/the eemua guidelines in practice. *Measurement and Control*, v. 36, n. 4, p. 114–119, 2003. Disponível em: <<https://doi.org/10.1177/002029400303600403>>.
- EICHLER, M. Causal inference with multiple time series: Principles and problems. *Philosophical transactions. Series A, Mathematical, physical, and engineering sciences*, v. 371, p. 20110613, 07 2013.
- HYNDMAN, R.; ATHANASOPOULOS, G. *Forecasting: Principles and Practice*. 2nd. ed. Australia: OTexts, 2018.
- KOHONEN, T. Data management by self-organizing maps. In: . [S.l.: s.n.], 2008. v. 5050, p. 309–332. ISBN 978-3-540-68858-7.
- PATTEN, M.; NEWHART, M. *Understanding Research Methods: An Overview of the Essentials*. Routledge, 2017. 231-234 p. ISBN 9780415790529. Disponível em: <<https://books.google.com.br/books?id=joxEnQAACAAJ>>.
- PINTO, L. D.; FARINHA, L. A. Sistema de gerenciamento de alarmes em uma indústria petroquímica. In: ISA Show 2007, 2007.
- PRILL, R.; MARBACH, D.; SAEZ-RODRIGUEZ, J.; SORGER, P.; ALEXOPOULOS, L.; XUE, X.; CLARKE, N.; ALTAN-BONNET, G.; STOLOVITZKY, G. Towards a rigorous assessment of systems biology models: The dream3 challenges. *PloS one*, v. 5, p. e9202, 02 2010.
- TANK, A.; COVERT, I.; FOTI, N.; SHOJAIE, A.; FOX, E. Neural granger causality for nonlinear time series. 02 2018.
- Tucker, C. A. Self-organizing maps for time series analysis of electromyographic data. In: *IJCNN'99. International Joint Conference on Neural Networks. Proceedings (Cat. No.99CH36339)*. [S.l.: s.n.], 1999. v. 5, p. 3577–3580 vol.5.
- VENKATASUBRAMANIAN, V. A review of process fault detection and diagnosis part i: Quantitative model-based methods. *Computers & Chemical Engineering*, v. 27, p. 293 – 311, 01 2003.

- VENKATASUBRAMANIAN, V.; RENGASWAMY, R.; KAVURI, S. A review of process fault detection and diagnosis part ii: Qualitative models and search strategies. *Computers & Chemical Engineering*, v. 27, p. 313–326, 03 2003.
- VENKATASUBRAMANIAN, V.; RENGASWAMY, R.; KAVURI, S.; YIN, K. A review of process fault detection and diagnosis part iii: Process history based methods. *Computers & Chemical Engineering*, v. 27, p. 327–346, 03 2003.
- YANG, F.; SHAH, S.; XIAO, D. Correlation analysis of alarm data and alarm limit design for industrial processes. In: . [S.l.: s.n.], 2010. p. 5850 – 5855.