

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

MÁRCIO JOSÉ DA SILVA

**MODELO ONTOLÓGICO
PROBABILÍSTICO BASEADO EM
DADOS DE ALARMES E EVENTOS NO
CONTEXTO DA INDÚSTRIA 4.0**

Porto Alegre
2022

MÁRCIO JOSÉ DA SILVA

**MODELO ONTOLÓGICO
PROBABILÍSTICO BASEADO EM
DADOS DE ALARMES E EVENTOS NO
CONTEXTO DA INDÚSTRIA 4.0**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica.

Área de concentração: Controle e Automação

ORIENTADOR: Prof. Dr. Carlos Eduardo Pereira

Porto Alegre
2022

MÁRCIO JOSÉ DA SILVA

**MODELO ONTOLÓGICO
PROBABILÍSTICO BASEADO EM
DADOS DE ALARMES E EVENTOS NO
CONTEXTO DA INDÚSTRIA 4.0**

Esta tese foi julgada adequada para a obtenção do título de Doutor em Engenharia Elétrica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: _____

Prof. Dr. Carlos Eduardo Pereira, UFRGS

Doutor pela (Universidade de Stuttgart, Stuttgart, Alemanha)

Banca Examinadora:

Prof. Dr. Luiz Affonso Henderson Guedes de Oliveira, Departamento de Engenharia de Computação e Automação - UFRN
Doutor pela Faculdade de Engenharia Elétrica e de Computação da Unicamp - Campinas, Brasil

Prof. Dr. Angelo Perkusich, Departamento de Engenharia Elétrica - UFCG
Doutor pela Engenharia Elétrica pela Universidade Federal da Paraíba - Paraíba, Brasil

Prof. Dr. Edison Pignaton de Freitas, Departamento de Engenharia Elétrica - UFRGS
Doutor pela Universidade de Halmstad – Halmstad, Suécia

Coordenador do PPGEE: _____

Prof. Dr. Sérgio Luis Haffner

Porto Alegre, abril de 2022.

DEDICATÓRIA

Dedico este trabalho, a Deus, que me deu forças para superar os desafios do dia a dia. Ao meu pai José (*in memoriam*), pelo apoio para alcançar meus objetivos e infelizmente não pode estar presente neste momento da minha vida. A minha mãe, Neide, que dedicou parte de sua vida dando condições para que eu estudasse.

AGRADECIMENTOS

Ao Programa de Pós-Graduação em Engenharia Elétrica, PPGEE, pela oportunidade de realização de trabalhos em minha área de pesquisa, a todos os colegas e amigos, em especial a Miriam Rosek, pelo suporte e assistência.

Agradeço o apoio e confiança do Professor Carlos Eduardo Pereira, pelos ensinamentos, orientações e oportunidades dadas a mim durante a realização do doutorado.

Aos colegas e amigos do PPGEE, da Universidade Feevale e do Senai, pelos ensinamentos, pelo auxílio nas tarefas desenvolvidas durante o curso e pelo apoio neste trabalho. Também agradeço a todos do grupo de pesquisas em MetaMaintain pelas contribuições e publicações realizadas em conjunto.

À CAPES pela provisão de apoio nas publicações.

SUMÁRIO

LISTA DE ILUSTRAÇÕES	7
LISTA DE TABELAS	9
LISTA DE ABREVIATURAS	10
RESUMO	11
ABSTRACT	12
1 INTRODUÇÃO	13
1.1 Evoluções Históricas	13
1.2 Motivação	16
1.3 Caracterização do Problema	17
1.4 Objetivos	18
1.4.1 Objetivo Geral	18
1.4.2 Objetivos Específicos	19
1.4.3 Principais Contribuições	19
1.5 Organização da Tese	19
2 FUNDAMENTAÇÃO TEÓRICA	21
2.1 Visão Geral do Capítulo	21
2.2 Indústria 4.0	21
2.3 Mineração de Dados	22
2.4 Inteligência Artificial	23
2.5 Redes Neurais Artificiais	25
2.5.1 Redes de Hopfield	26
2.5.2 Máquina de Boltzmann	26
2.5.3 Máquina de Boltzmann Restrita	26
2.5.4 Rede Neural Recorrente com Camadas LSTM	29
2.6 Modelos de Grafos Acíclicos Dirigidos	31
2.6.1 Processo de Inferência	31
2.6.2 Redes Bayesianas	31
2.6.3 Inferência Probabilística	32
2.7 Entropia	33
2.8 Árvore de Decisão	34
2.9 Ontologias	34
2.9.1 Definições	34
2.9.2 Modelagem de Contexto	35

2.9.3	Modelagem Probabilística	36
3	ANÁLISE DO ESTADO DA ARTE	37
3.1	Visão Geral do Capítulo	37
3.2	Metodologia de Pesquisa	37
3.3	Trabalhos Relacionados	39
3.3.1	Dimensão de Informação e Modelos Semânticos	39
3.3.2	Inferência e Aprendizagem de Máquina	47
4	ABORDAGEM PROPOSTA	58
4.1	Visão Geral do Capítulo	58
4.2	Introdução	58
4.3	Etapas do desenvolvimento da proposta	58
4.3.1	Caracterização semântica	59
4.3.2	Definição de Contexto	66
4.3.3	Modelo Híbrido de Inferência Preditiva	68
4.3.4	Raciocínio Probabilístico	70
4.3.5	Representação das Situações	74
4.4	Considerações Finais	77
5	IMPLEMENTAÇÃO	79
5.1	Introdução	79
5.1.1	Análise dos dados em termos de suas relações	79
5.1.2	Extração de informações a partir da aprendizagem	81
5.2	Implementação do Modelo	82
5.2.1	Abordagem Clássica	82
5.2.2	Abordagem Bayesiana	83
5.3	Considerações Finais	90
6	ESTUDOS DE CASO	91
6.1	Estudo de Caso 1: Trens Urbanos	91
6.1.1	Descrição da aplicação	91
6.1.2	Uso da Abordagem Clássica	93
6.1.3	Uso da Abordagem Bayesiana	102
6.1.4	Comparação dos Resultados	105
6.1.5	Considerações Finais	107
6.2	Estudo de Caso 2: Tennessee Eastman Process	108
6.2.1	Descrição da aplicação	108
6.2.2	Pré-processamento de Dados	109
6.2.3	Construindo a RNN	111
6.2.4	Uso da abordagem com RNN-LSTM	111
6.2.5	Considerações Finais	114
7	CONCLUSÃO, CONTRIBUIÇÕES E TRABALHOS FUTUROS	115
7.1	Principais Contribuições	116
7.2	Trabalhos Futuros	117
	REFERÊNCIAS	118

LISTA DE ILUSTRAÇÕES

Figura 1 –	evolução das Tecnologias de HMIs: a) Sistema supervisorio da década de 70; b) HMI avançada com base em tecnologias de realidade aumentada e realidade virtual; c) Tecnologia Digital Twin.	15
Figura 2 –	exemplo da necessidade de identificação de situações anormais de operação em processos industriais.	18
Figura 3 –	representação dos conceitos envolvidos no caminho para indústria 4.0.	22
Figura 4 –	metodologia KDD.	23
Figura 5 –	metodologia CRISP-DM.	24
Figura 6 –	modelo de um neurônio artificial.	25
Figura 7 –	representação da rede neural RBM.	28
Figura 8 –	representação do amostrador de Gibbs.	29
Figura 9 –	estrutura da célula RNN-LSTM.	30
Figura 10 –	representação da função de energia.	33
Figura 11 –	busca por termos <i>Industrial and Alarm and Systems</i>	38
Figura 12 –	busca por termos <i>Industrial and Alarm and Systems and Ontology</i>	38
Figura 13 –	ontologia modelada para processos industriais.	40
Figura 14 –	ciclo da modelagem probabilística.	41
Figura 15 –	rede Bayesiana de situação específica (SSBN) para o fragmento <i>Judgment History</i>	42
Figura 16 –	metodologia CHARM.	44
Figura 17 –	seletor de contexto.	44
Figura 18 –	ontologia para CPPS.	45
Figura 19 –	sistema de gerenciamento e manutenção do processo.	47
Figura 20 –	distinção entre arquiteturas para diagnóstico de falhas: a) centralizada; b) descentralizada e c) distribuída.	48
Figura 21 –	distinção entre topologias para análise causal: a) serial; b) paralelo.	49
Figura 22 –	diagrama esquemático de um estado normal com isolamento de falsos alarmes.	49
Figura 23 –	metodologia aplicada na análise de dados.	50
Figura 24 –	metodologia aplicada na análise de dados.	51
Figura 25 –	<i>flowchart</i> da metodologia desenvolvida aplicando redes neurais.	52
Figura 26 –	<i>flowchart</i> da metodologia desenvolvida aplicando processamento em nuvem.	53
Figura 27 –	<i>flowchart</i> da metodologia desenvolvida aplicando redes neurais.	55
Figura 28 –	representação da abordagem do conhecimento em relação aos eventos.	56
Figura 29 –	representação da proposta desenvolvida.	59
Figura 30 –	etapas do desenvolvimento da proposta.	60

Figura 31 – etapas do desenvolvimento da ontologia probabilística.	61
Figura 32 – processo industrial hipotético.	62
Figura 33 – visão sumarizada do modelo ontológico para um exemplo hipotético.	63
Figura 34 – construção do modelo conceitual probabilístico para um exemplo hipotético.	65
Figura 35 – etapas do desenvolvimento da proposta.	67
Figura 36 – etapas do desenvolvimento da proposta.	71
Figura 37 – etapas do desenvolvimento da proposta.	72
Figura 38 – ssbn gerada para um exemplo hipotético.	74
Figura 39 – ssbn gerada para um exemplo hipotético.	75
Figura 40 – alarmes gerados para um exemplo hipotético.	75
Figura 41 – representação do PR-OWL.	76
Figura 42 – representação das Situações.	77
Figura 43 – visão parcial da avaliação dos registros, com destaque para o padrão gerado pelo modelo apriori em relação às variáveis de interesse.	80
Figura 44 – painel para edição do UMP-ST.	84
Figura 45 – modelo semântico implementado utilizando Protégé OWL. A) definição das classes, b) definição das propriedades de objeto.	85
Figura 46 – modelo conceitual probabilístico	87
Figura 47 – modelo conceitual probabilístico.	88
Figura 48 – representação da MFrag Situation implementada nesta tese a partir do plugin MEBN no UnBBayes.	89
Figura 49 – ssbn gerada pelo plugin UnBBayes.	89
Figura 50 – representação do motor de tração.	91
Figura 51 – rotas Trensurb.	92
Figura 52 – a) transmissão de tração e a adesão entre rodas e trilhos ferroviários, b) gráfico do coeficiente de adesão em relação ao movimento das rodas.	93
Figura 53 – ocorrências registradas nas diferentes Rotas presentes no domínio em relação ao Ponto (<i>Gear Box</i>).	94
Figura 54 – rotas onde ocorreram falhas em relação à velocidade em Km/h.	95
Figura 55 – registro de falhas.	96
Figura 56 – ocorrências em relação às rotas.	97
Figura 57 – carta multi-variável para PoF.	101
Figura 58 – carta multi-variável para entropia.	101
Figura 59 – rede Bayesiana gerada para uma situação reativa. Análise implementada com plugin UnBBayes (HABERLIN, 2013).	106
Figura 60 – processo Tennessee Eastman.	109
Figura 61 – variável XMEAS 24 em comportamento normal.	112
Figura 62 – variável XMEAS 24 em comportamento de falha.	112
Figura 63 – análise preditiva da variável de processo XMEAS 24 em comportamento de falha.	113
Figura 64 – resultado da análise preditiva da pressão no reator.	114

LISTA DE TABELAS

Tabela 1 –	análise dos trabalhos relacionados a dimensão de informação e modelos semânticos.	46
Tabela 2 –	análise dos trabalhos relacionados a Inferência e ML.	57
Tabela 3 –	parâmetros do projeto de experimentos.	97
Tabela 4 –	Variáveis do processo TEP.	110

LISTA DE ABREVIATURAS

CPPS	Cyber-Physical Production Systems
CSV	Comma-Separated Value
EEMUA	Engineering Equipment and Materials Users Association
GCAR	Grupo de Controle, Automação e Robótica
HMI	Human Machine Interface
HSE	Health and Safety Executive
ISA	International Society of Automation
IIoT	Industrial Internet of Things
JESS	Java Expert System Shell
KDD	Knowledge Discovery in Databases
LSTM	Long Short-Term Memory
MEBN	Multi-Entity Bayesian Network
ML	Machine Learning
MRF	Markov Random Field
OWL	Ontology Web Language
OWL-DL	Ontology Web Language Description Language
PPGEE	Programa de Pós-Graduação em Engenharia Elétrica
PR-OWL	Probabilistic OWL
RNN	Recurrent Neural Networks
RBM	Restricted Boltzmann Machine
SCADA	Supervisory Control and Data Acquisition
SDCD	Sistema digital de controle distribuído
SSBN	Situation Specific Bayesian Network
SWRL	Semantic Web Rule Language
TEP	Tennessee Eastman Process
UFRGS	Universidade Federal do Rio Grande do Sul

RESUMO

Os avanços das tecnologias de automação, informação e de comunicação apresentam novas perspectivas para diversas áreas, incluindo os sistemas de alarmes de processos industriais. Sistemas inteligentes de alarme industrial são capazes de auxiliar os operadores por meio de alertas, permitindo realizar os ajustes necessários nas variáveis operacionais. Ao mesmo tempo que as modernas tecnologias permitem a monitoração de um número crescente de variáveis e informações dos processos industriais, aumenta a carga cognitiva. Portanto, contribui-se com uma abordagem que beneficia os sistemas industriais para gerenciamento de alarmes de processos com a capacidade de prever situações para facilitação de ações operacionais, particularmente quando uma quantidade de eventos acima da capacidade humana de gerenciamento ocorre. Nesse sentido, é concebido um modelo semântico probabilístico voltado para predição e inferência de situações anormais de operação. A partir disso, é realizada uma integração de definições de contexto em um conjunto de dados, a partir de um modelo ontológico probabilístico, aplicando técnicas de aprendizado de máquina.

Palavras-chave: Ontologia, mineração de dados, automação e controle, inferência preditiva, rede Bayesiana, modelo probabilístico.

ABSTRACT

The advent of automation, communication, and information technology has been shaping new realities for many fields, including industrial alarm systems. Intelligent industrial alarm systems are able to give advice to the operators being alerts to make necessary adjustments in operating variables. At the same time, that modern technologies allow the monitoring of an increasing number of variables and information from industrial processes, the cognitive load increases. In this direction, this thesis proposes an integration of context definitions in a dataset from a probabilistic and ontological model using machine learning techniques.

Keywords: ontology, data mining, automation and control, predictive inference, Bayesian Network, probabilistic model.

1 INTRODUÇÃO

1.1 Evoluções Históricas

As últimas décadas foram marcadas por novas demandas no ambiente industrial e uma crescente mudança no nível de inovação e em sistemas de automação, com o surgimento de conceitos como IIoT (*Industrial Internet of Things*) (MALIK *et al.*, 2020), (SISINNI *et al.*, 2018), (ATZORI; LERA; MORABITO, 2010) e do crescente número de dispositivos conectados (ZHOU *et al.*, 2018). Na chamada quarta revolução industrial (Indústria 4.0) (BLOEM *et al.*, 2014), é possível uma melhoria no nível de abstração ao traduzir os dados de campo para o ambiente corporativo, como, por exemplo, os dados de alarmes e eventos, e começar a antecipar o enredo diante de determinadas situações, refletindo sobre as informações do domínio, ou seja, analisando a probabilidade de determinados eventos ocorrerem, possibilitando que o resultado do aprendizado seja válido em novas situações a serem encontradas.

A indústria 4.0 depende de conhecimento para análise e tomada de decisão a partir de dados, como por exemplo *Artificial Intelligence* (AI), *Machine Learning* (ML), *Deep Learning* (DL), bem como, *Big Data*, *Data Analytics*, *Cyber-Physical Production Systems* (CPPS), *Machine to Machine* (M2M), *Cloud Computing* e *Web Semântica* (WS). A heterogeneidade destas áreas torna o uso de métodos preditivos, baseados no contexto e na análise de dependência entre conceitos e variáveis, uma ferramenta que pode ser aplicada no processo de tomada de decisão, permitindo avaliar a informação que temos sobre uma hipótese numa amostra de dados. Ao longo do processo de inferência probabilística podemos avaliar as evidências para uma determinada hipótese ser verdadeira ou a probabilidade de uma hipótese ser verdadeira a partir de evidências (PEARL, 1988). Contudo, é necessária uma sistemática e um aprimoramento de técnicas, como, por exemplo, a aplicação de ML, que dependem de diversos fatores para extrair a informação retida em dados históricos, aprendendo e apresentando um conhecimento. Assim, é possível tratar os eventos que ocorrerão diante de uma determinada situação como uma distribuição de probabilidade. O resultado do aprendizado sobre os eventos possibilita construir um padrão para que a predição seja possível. O modelo resultante combina evidências

que, durante um processo de raciocínio probabilístico, envolve o aprendizado de padrões implícitos nos dados, permitindo auxiliar na tomada de decisão a partir de uma resposta quantitativa sobre uma variável de interesse. Segundo (BERNERS-LEE; HENDLER; LASSILA, 2001), uma ontologia possui como base uma taxonomia que define classes de objetos e suas relações, além de um conjunto de regras de inferência que possibilita o raciocínio.

Um evento expressa, de forma geral, ocorrências durante a operação do processo e consiste em qualquer acontecimento relevante dentro do escopo operacional de um sistema técnico automatizado, do inglês ATS (*Automated Technical System*) e está presente em uma situação, gerando alerta e provocando ações e reações, como, por exemplo, um desarme de um dispositivo previamente configurado no sistema de automação para uma situação reativa. Os alarmes, por sua vez, são meios audíveis ou visíveis utilizados para indicar uma falha, o mau funcionamento de um equipamento ou processo, desvios nas variáveis do processo ou condições anormais, que necessitam uma ação humana, automatizada ou ambas (ISA, 2016), (BEZERRA *et al.*, 2019).

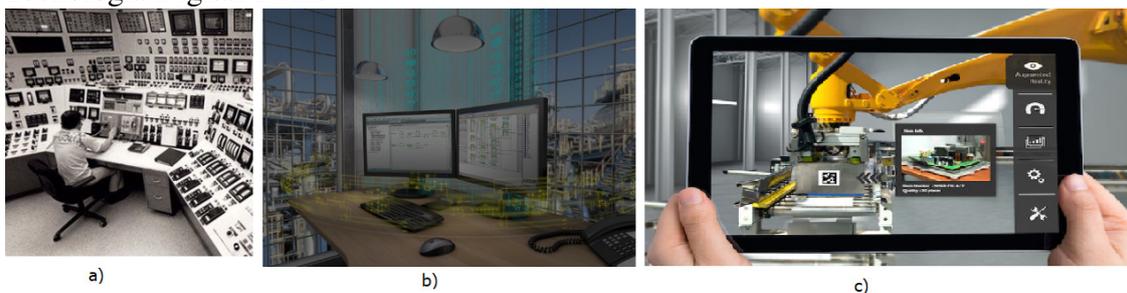
O controle e o monitoramento dos processos, nos ambientes indústrias, mudaram após o advento do SDCD e a implementação de sistemas de gerenciamento de alarmes (ISA, 2016). Um alarme gerado por uma falha pode ser disparado quando uma variável do processo excede o seu limite de controle correspondente. Quando um dispositivo indica uma falha o sistema de automação recebe este sinal da planta e gera um certo volume de dados. Os operadores realizam as ações necessárias durante o funcionamento do processo a partir do recebimento destes dados de campo e, em geral, o tempo para tomada de decisão tende a ser limitado para uma intervenção manual, em relação a dinâmica da planta e ao volume de dados apresentados, por exemplo, pela interface do sistema de gerenciamento de alarmes tradicional. Contudo, existem também ações automatizadas pré-configuradas no sistema de automação que possibilitam intertravamentos de emergência (*Trip*) em um estado de desarme (*Shutdown*) (GOEL; DATTA; MANNAN, 2017). O processo de tomada de decisão considera um valor resultante produzido por um modelo. Este modelo, previamente gerado pelo aprendizado, passa a ser a resultante de interesse que possibilita executar ações a partir de um limite crítico, permitindo agir sobre a predição.

Uma falha registrada durante um processo compõe uma base que permite iniciar a implementação de um modelo preditivo. Contudo, as falhas que ocorrem no processo e que são registradas pelos dispositivos de campo também podem representar discrepâncias entre o valor medido e o valor real de uma variável (BLANKE *et al.*, 2000). Uma falha em um dispositivo atuador, por exemplo, representa uma discrepância entre o comando de entrada e o seu real valor de saída (ZAYTOON; LAFORTUNE, 2013). Considere o sistema de alarmes que pode ser projetado para manusear os eventos oriundos de um determinado processo. Uma falha pode gerar um sinal de alerta, como um alarme, e produzir um volume de dados discretos (ROTHENBERG, 2009). Todos estes dados são, em geral,

armazenados em uma base de dados do processo (MANNANI; IZADI; GHADIRI, 2019).

Alarmes podem ser configurados para informar determinados eventos. A configuração, segundo a norma ANSI/ISA-18.2, deve seguir uma priorização e ser realizada por meio de racionalização (ISA, 2016). Isso está relacionado a taxa de alerta que pode exceder os níveis que podem ser gerenciados pelos operadores. Esses registros estão vinculados ao monitoramento da operação da planta e comumente direcionam a atenção dos operadores, sendo apresentados no monitoramento online por meio de painéis, interfaces ou HMIs (*Human-Machine Interfaces*), conforme apresentado na Figura 1. Além disso, as salas de controle de processos industriais se transformaram ao longo do tempo e o acesso aos dados por meio destas interfaces permitiu melhorar ainda mais o ambiente de trabalho operacional.

Figura 1 – evolução das Tecnologias de HMIs: a) Sistema supervisorio da década de 70; b) HMI avançada com base em tecnologias de realidade aumentada e realidade virtual; c) Tecnologia Digital Twin.



Fonte: adaptado de computerworld¹ e Siemens.²

Segundo a EEMUA 191 (*Engineering Equipment and Materials Users Association*), o propósito de um sistema de alarmes é direcionar a atenção dos operadores para condições da planta que requerem uma resposta rápida por meio de ações (EEMUA, 2007). Sistemas digitais de controle distribuídos (SDCDs) foram propostos no início da década de 1970 e permitem o registro de dados das variáveis do processo, auxiliando seus usuários a lidar com as diferentes situações da planta. Contudo, segundo (HABIBI; HOLLIFIELD, 2006), a indicação de condições anormais e as formas de acesso as informações nestes sistemas não são ideias. Uma falha pode causar uma avalanche de alarmes (ROTHENBERG, 2009), que são apresentados como mensagens e que representam, em geral, uma informação discreta (BLANKE *et al.*, 2006). Esse volume de dados pode ser utilizado para uma análise de padrões de eventos num modelo preditivo, que auxilie no controle e monitoramento do ATS.

Falhas podem causar uma grande quantidade de sinalizações a partir do ponto onde ultrapassam um limite de controle, e isso ocorre durante situações presentes nos processos industriais (LEITÃO; GUEDES; ARAÚJO, 2012). Contudo, segundo (FRANK; BLANK, 2007), uma diagnóstico completo de falhas pode ser impraticável. Além disso,

nos processos de maior risco, com por exemplo plantas petroquímicas que processam e armazenam produtos inflamáveis, as consequências de uma falha podem ser desastrosas.

1.2 Motivação

A necessidade de se priorizar alarmes se tornou mais relevante com a chegada dos sistemas digitais. Embora possa existir uma ordem para que os eventos mais importantes que ocorrerem sejam apresentados para os operadores, existem situações onde a informação apresentada pode ser confusa, insuficiente ou numa taxa acima da capacidade humana de processamento. Num processo podem haver centenas de milhares de variáveis a serem monitoradas (VENKATASUBRAMANIAN *et al.*, 2003), sendo que, em geral, grande parte dos pontos de medição de um processo possuem um alarme associado, podendo haver inclusive uma variação de tipos de alarmes para cada um destes pontos, fazendo com que a quantidade de informações geradas seja ainda maior. Assim, considerando o grande número de alarmes e eventos que podem ser gerados durante o funcionamento de um processo, percebe-se o valor de uma análise de contexto relacionada ao conhecimento gerado por modelos preditivos a partir da integração com dados, alinhada com o paradigma da Web Semântica, que permite uma especificação formal dos dados de contexto, de forma que uma ontologia é implementada para representar o domínio do conhecimento, considerando o contexto como fonte de informação na caracterização de uma situação e, com isso, permitindo gerar uma recomendação.

As atividades operacionais podem ser expostas em determinadas situações a uma sobrecarga cognitiva quando suportadas por ATS (SILVA; PEREIRA; GÖTZ, 2018). Destaca-se que esses sistemas apresentam uma lacuna em relação a modelos semânticos, voltados para predição e inferência, a partir de dados do domínio. Essa tese aborda a modelagem e implementação de ontologias para a representação do conhecimento sobre situações anormais de operação. Isso torna o estudo de ontologias um tema de pesquisa relevante, principalmente no contexto da indústria 4.0, pois envolve um processo de percepção e tomada de decisão.

A partir da identificação de informações de interesse que possibilitem a formalização do conceito de situação, é proposto o uso de inferência probabilística para determinação da situação e a avaliação dos padrões comportamentais dos eventos registrados durante o processo, através de uma representação quantitativa com uso de evidências e utilizando os registros presentes numa base de dados do ATS. A situação de interesse é a informação que se deseja obter a partir dos dados e análise de padrões obtidos numa etapa de definição de contexto. O contexto de interesse envolve as informações necessárias para apoiar uma tarefa e um conjunto de estados do ambiente que caracterizam a situação.

Um olhar mais atento para a segurança e efetividade dos sistemas de alarmes de processo somente ocorreu após acidentes marcantes, como o ocorrido na refinaria de Milford

Haven da Texaco em 1994, onde se constatou que 87% dos 2040 alarmes que foram registrados antes da explosão da refinaria possuíam prioridade 1 (um), especificada com sendo a prioridade máxima do sistema (BRANSBY; JENKINSON, 1998).

Em março de 2001, um acidente na plataforma de petróleo P-36 da Petrobras® ocorreu durante um vazamento de fluidos voláteis que provocou o rompimento de um tanque utilizado para dreno de emergência. Isso desencadeou uma incontrolável cadeia de eventos provocando o afundamento da plataforma. Uma avalanche de 1723 alarmes foram registrados em um período de 17 minutos, sem que houvesse um método de priorização de alarmes (NASA, 2008). Este cenário pode causar uma sobrecarga cognitiva que envolve os operadores, podendo ocorrer até mesmo nos processos onde existem sistemas de gerenciamento de alarmes implementados (SILVA; PEREIRA; GÖTZ, 2018).

Em agosto de 2008, um acidente na planta do processo de produção pesticidas da Bayer® foi desencadeado a partir de uma reação química que provocou uma variação de pressão, conforme apresentado na Figura 2, provocando uma grave explosão. Segundo registros, inicialmente os operadores tentaram acionar sem sucesso o desarme de emergência do tanque onde foi identificada a falha. Neste mesmo momento, desencadeou-se uma variação repentina de pressão que provocou a explosão, causando danos irreparáveis e tirando vidas daqueles que estavam no local. Inúmeros alarmes foram disparados em poucos minutos após a primeira indicação do alarme de alta pressão. Entretanto, nos processos identificados como perigosos e com potencial risco para as pessoas, equipamentos e meio ambiente, um desligamento controlado torna-se necessário em um SIS (*Safety Instrumented Systems*) (ISA, 2016), (CBS, 2011).

1.3 Caracterização do Problema

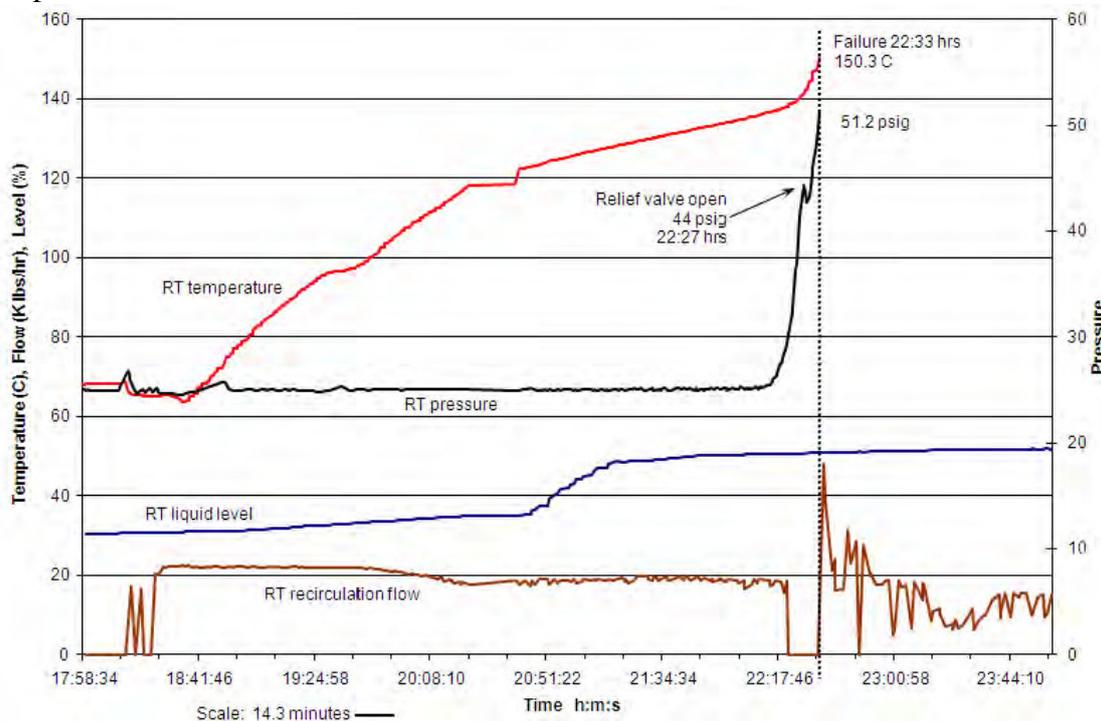
Sendo o sistema de gerenciamento de alarmes de processos a estratégia frequentemente adotada para o monitoramento de alarmes de processos presentes na indústria, este pode ser complementado a partir de metodologias que permitam uma recomendação aos seus usuários, frente às situações específicas que ocorrem na planta.

Desta forma, a questão de pesquisa relevante e que motiva este estudo é: como um sistema técnico automatizado pode se beneficiar por um modelo suportado por Inteligência Artificial e tecnologias da Web Semântica?

As seguintes hipóteses de pesquisa são investigadas no presente trabalho:

- é possível o estudo e o desenvolvimento de uma metodologia que combine semântica e dados, possibilitando modelar formalmente uma situação em um Sistema Técnico Automatizado.
- é possível o tratamento de hipóteses para identificar a probabilidade de ocorrência de uma situação relacionada aos alarmes e eventos, gerando um modelo para

Figura 2 – exemplo da necessidade de identificação de situações anormais de operação em processos industriais.



Fonte: (CBS, 2011).

inferência preditiva.

Com o intuito de apresentar uma metodologia que permita compor um modelo híbrido, envolvendo dados e semântica, possibilitando um processo de inferência preditiva e considerando um ATS, o presente estudo foca na identificação de situações preditivas e que evoluem um conjunto de características do domínio, definidas em um nível semântico, tendo em vista os elementos contextuais possíveis de serem obtidos de forma manual e automática.

1.4 Objetivos

1.4.1 Objetivo Geral

O objetivo principal é propor uma metodologia que permita combinar semântica, dados e informações do domínio, tais como evidências, permitindo suportar a capacidade de reconhecimento e tratamento de situações presentes num ATS. Essa modelagem deve ser abrangente podendo conter situações de interesse, e permitindo o reuso em outras aplicações.

1.4.2 Objetivos Específicos

Este problema engloba direta ou indiretamente questões que são atualmente foco de pesquisas em áreas relacionadas à indústria 4.0, tais como: (i) A análise de dados relacionados a alarmes e eventos; (ii) As formas de obtenção e tratamento de dados relativos ao contexto; (iii) As aplicações do conhecimento resultante desta análise.

Ao final, espera-se fornecer uma abordagem metodológica que contribua na análise destes conceitos, propondo soluções que possam ser aplicadas ao processo de percepção e tomada de decisão, voltada às necessidades operacionais a partir da modelagem probabilística.

As etapas a serem cumpridas para atingir o objetivo descrito são as seguintes:

- aplicar a metodologia de descoberta de conhecimento a partir de dados de alarmes e eventos de processo.
- análise de como explorar o conhecimento das situações presentes no ambiente e apoiar no processo de tomada de decisão.
- propor uma metodologia de modelagem para formalizar conhecimento específico, servindo como base para inferências, aprendizado, previsões e que permita o reuso.

1.4.3 Principais Contribuições

As principais contribuições desta tese são identificadas abaixo e detalhadas no último capítulo, apresentando as publicações realizadas e o trabalho desenvolvido nesta tese:

- estudo teórico e definição dos conceitos relacionados ao tema Indústria 4.0, assim como dos elementos que envolvem sistemas inteligentes, com base nos conceitos e visão orientada a semântica apresentados por (ATZORI; LERA; MORABITO, 2010).
- manipulação da incerteza com técnicas de Aprendizagem de Máquina e Web Semântica em modelos de contexto.
- avaliar a abordagem através de um projeto de experimentos suportado pelas metodologias *Knowledge Discovery in Database* (KDD) e *Cross Industry Standard Process for Data Mining* (CRISP-DM).
- implementação de um modelo ontológico probabilístico para análise de situações de forma reusável para outros domínios.

1.5 Organização da Tese

O restante do texto está estruturado como segue:

- os conceitos relacionados ao contexto em que este trabalho se insere estão descritos no Capítulo 2.
- o estado da arte relacionado a esta tese é apresentado no Capítulo 3.
- o modelo estruturado e uma discussão sobre como implementar o modelo e aplicá-lo em diferentes domínios é apresentado no Capítulo 4. O capítulo traz a pesquisa realizada nesta tese, apresentando a visão almejada a respeito de predição de situações.
- uma sistematização onde são descritas as tarefas desde a mineração de dados e o processo de implementação desenvolvido aplicando ontologias, até a etapa de aprendizado de máquina e aplicações com redes neurais artificiais é apresentada no Capítulo 5.
- os estudos de caso com as aplicações práticas são descritos no Capítulo 6.
- as considerações finais e apresenta os resultados das contribuições e inovações apresentadas nas publicações que foram originadas a partir desta tese são apresentadas o Capítulo 7.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Visão Geral do Capítulo

Os principais conceitos utilizados nesta tese são descritos neste capítulo. Uma base para o leitor sobre a indústria 4.0 é apresentada na segunda seção. As metodologias de mineração de dados são apresentadas na terceira seção. O conceito de inteligência artificial é apresentado em uma breve descrição na quarta seção. Em seguida, são apresentados conceitos sobre redes neurais artificiais na quinta seção. Nesta seção é abordado o tema aprendizagem de máquina, pois representa conceitos centrais a esta pesquisa. Em função disso, essa seção está subdividida, incluindo uma abordagem do tema máquina de Boltzmann e os conceitos de uma rede neural recorrente. Os modelos de grafos probabilísticos que serão abordados nesta tese são apresentados na sexta seção. O conceito de entropia é abordado na sétima seção. Conceitos de árvore de decisão são descritos na oitava seção. As definições de ontologia de domínio e modelagem de contexto são apresentadas na nona seção. É importante ressaltar que muitos termos foram mantidos em inglês (no seu original) devido ao melhor entendimento do mesmo do ponto de vista técnico e científico.

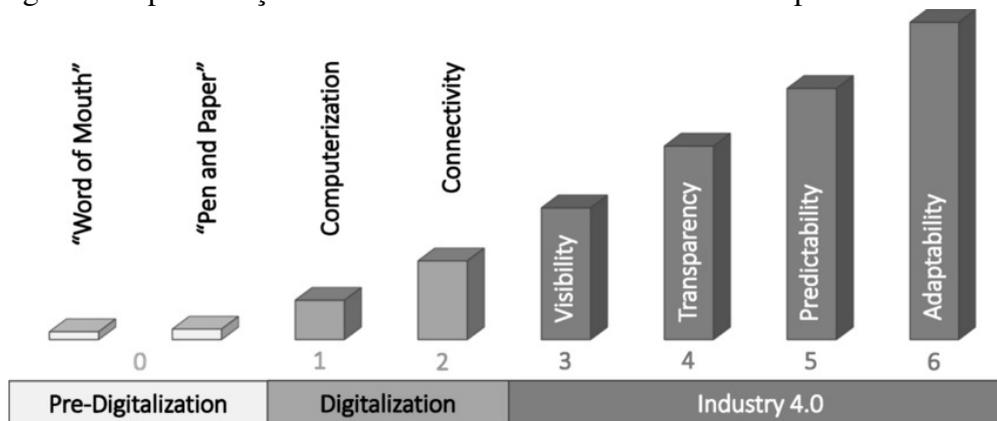
2.2 Indústria 4.0

A introdução da eletricidade, da mecanização e de tecnologias da informação caracterizaram as primeiras 3 fases da revolução industrial (BLOEM *et al.*, 2014). Em seguida, com a adoção de tecnologias digitais de forma integrada nas empresas, foi possível chegar a aquisição e o processamento de dados em tempo real. Em relação à percepção do ambiente monitorado, observa-se um aumento significativo do número de sensores e consequentemente de variáveis relevantes, as quais estão provocando mudanças também na área operacional, à medida que geram dados sobre este ambiente. Assim, a análise resultante de dados históricos permite embasar o processo de tomada de decisão operacional.

A quarta revolução industrial inicia-se com a era da internet, sendo inserida no ambiente fabril e adaptada para as características da planta, integrando a chamada fábrica inteligente (*Smart Factory*) (ROMEIO *et al.*, 2020). Para lidar com essa evolução, é necessário desenvolver modelos conceituais voltados para predição, atendendo a essas características

representadas na Figura 3.

Figura 3: representação dos conceitos envolvidos no caminho para indústria 4.0.



Fonte: (LI; FAST-BERGLUND; PAULIN, 2019)

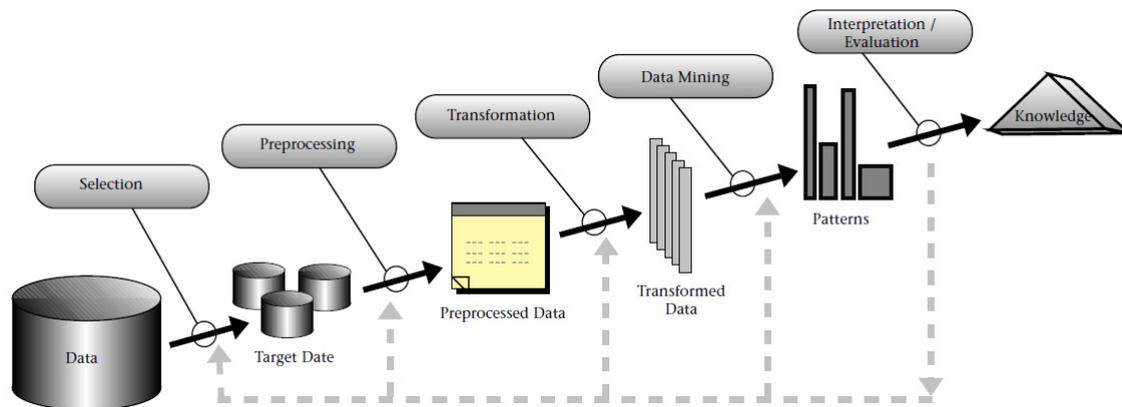
O uso de dados gerados nos processos industriais tornam-se matéria-prima até então pouco utilizada na tomada de decisão. Neste sentido, destaca-se a prevenção de falhas em equipamentos antes da linha de produção parar e melhorias nos níveis de conhecimento operacional dos respectivos processos (BLOEM *et al.*, 2014). Dessa forma, inferência preditiva, que representa projetar uma situação num futuro próximo, envolve uma abordagem conceitual que permite uma nova forma de perceber o ambiente, de modo que a indústria 4.0 possui um papel essencial, dada as necessidades em propor abordagens voltadas para a tecnologia semântica (PLOENNIGS, 2017).

2.3 Mineração de Dados

O processo de descoberta de conhecimento em base de dados (KDD), tem particularidades conforme representado na Figura 4 (FAYYAD; PIATETSKY; SMYTH, 1996). Em um sentido amplo, a mineração de dados é conhecida como a tarefa de descoberta de conhecimento e que possui inúmeras aplicações (HU; CHEN; SHAH, 2018). Segundo (MANNANI; IZADI; GHADIRI, 2019), uma implementação prática deste processo passa por várias etapas até que seja possível gerar um conhecimento.

Armazenar e analisar dados, em geral, não apresenta tantas restrições de processamento quanto nas décadas passadas. Dentre as ferramentas que permitem implementar as etapas de mineração de dados apresentadas por Fayyad et al. (FAYYAD; PIATETSKY; SMYTH, 1996), uma das mais conhecidas atualmente é chamada de Weka (MARK *et al.*, 2009), que possui um conjunto de algoritmos de aprendizado de máquina para tarefas de pré-processamento, classificação, regressão, clusterização e visualização. Além dessa, existem outras ferramentas que são específicas, como, por exemplo, o software Disco® (FLUXICON, 2019) e o ProM (VERBECK, 2010).

Figura 4: metodologia KDD.



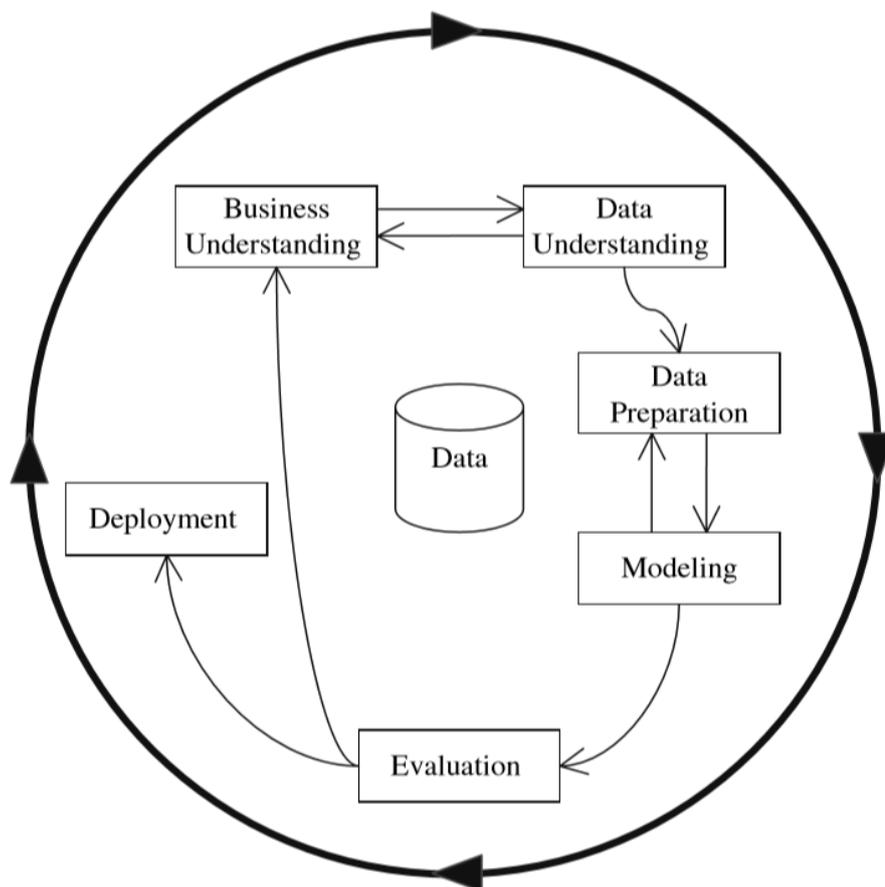
Fonte: (FAYYAD; PIATETSKY; SMYTH, 1996).

Como definido na introdução, CRISP-DM é uma metodologia voltada para mineração de dados que implementa um plano completo para a condução de um projeto. Nela é descrito o ciclo de vida de um projeto de mineração de dados em seis etapas. A primeira delas, conforme apresentado na Figura 5 é o entendimento dos objetivos do projeto (*Business Understanding*) (HAYKIN, 2003). Em seguida ocorre a compreensão dos dados (*Data Understanding*), a fim de identificar a qualidade destes dados, além da coleta e exploração inicial. Na fase seguinte ocorre a preparação dos dados (*Data Preparation*) para que os algoritmos de mineração possam ser aplicados, possibilitando a análise de características destes dados. Em seguida ocorre a etapa conhecida por modelagem (*Modeling*), onde são selecionadas e aplicadas as técnicas de modelagem de dados, como, por exemplo, uma árvore de decisão ou um modelo de regressão. Concluída a etapa de modelagem, ocorre a avaliação (*Evaluation*), que permite testar o modelo e verificar se os objetivos iniciais foram alcançados. A última fase prevista é a implementação (*Deployment*) (WIRTH; HIPPE, 2000).

2.4 Inteligência Artificial

A inteligência artificial, do inglês AI (*Artificial Intelligence*), presente desde a década de 50 (RUSSELL; NORVIG, 2003), possibilita tarefas cognitivas e experimentais de representação, raciocínio e aprendizagem (HAYKIN, 1998). Embora a teoria da aprendizagem tenha surgido muito próximo do advento da AI, sabe-se que foi somente na década de 90 que surgiram os algoritmos mais conhecidos de aprendizagem (CARRAZZA, 2018). Entre os algoritmos existentes, o processo de aprendizagem a partir de métodos baseados no gradiente consiste em minimizar uma função custo, que no caso de aprendizagem de máquina supervisionada, significa minimizar o erro a partir de um conjunto de treino (AGGARWALL, 2018). Contudo, um estudo mais aprofundado dessas teorias e algoritmos não faz parte do escopo desta tese.

Figura 5: metodologia CRISP-DM.



Fonte: (WIRTH; HIPPI, 2000).

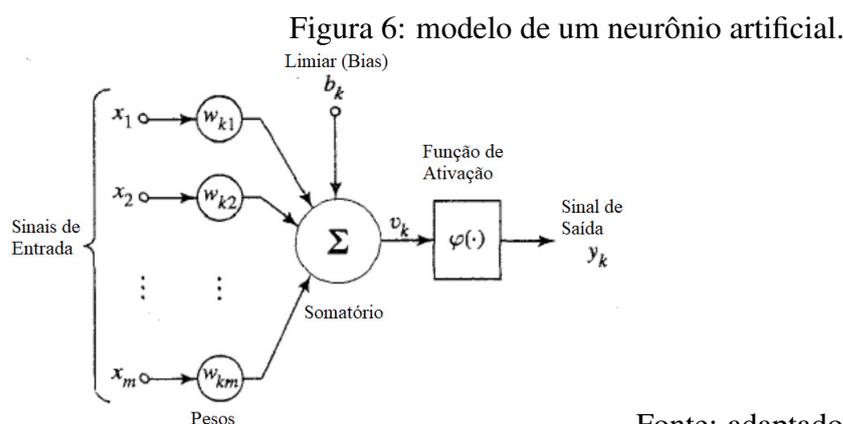
Existem diferentes paradigmas relacionados ao aprendizado de máquina que são geralmente utilizados dependendo de quais dados de entrada e saída estão disponíveis ou que estejam sendo tratados. A aprendizagem supervisionada caracteriza-se por possuir uma rede na qual a saída atual é comparada com a saída desejada, a partir dos padrões de entrada, mostrando a direção de ajuste dos pesos da rede neural, a fim de garantir o menor erro entre a saída resultante da rede e a saída desejada. Na aprendizagem não supervisionada, os padrões de entrada são apresentados continuamente e a regularidade entre esses dados permite o aprendizado necessário para uma aplicação posterior. No entanto, o rótulo de dados não é conhecido neste processo. Essa capacidade de aprendizado das redes de ANNs nos permite perceber padrões de dados sem a necessidade de conhecer as equações ou modelos que deram origem a esses dados (HAYKIN, 1998). A aprendizagem semi-supervisionada caracteriza-se quando apenas uma pequena quantidade das entradas possui uma saída correspondente. Por fim, o aprendizado por reforço ocorre quando nenhuma entrada ou saída histórica está disponível para tratamento. Assim, o aprendizado do parâmetro é então baseado em um sistema de recompensa e de tentativa e erro (RUSSELL; NORVIG, 2003).

De todo modo, é necessário possuir um conhecimento do contexto no qual é aplicado uma abordagem baseada em modelos preditivos implementados a partir de redes neurais. Entre as hipóteses de trabalho, o conhecimento do contexto permite uma melhoria na performance de muitos dos algoritmos de AI, conforme apresentados por (GRAVES; SCHIMIDHUBER, 2005).

2.5 Redes Neurais Artificiais

As Redes Neurais Artificiais, do inglês ANNs (*Artificial Neural Networks*), formadas por um conjunto de neurônios e suas interconexões implementadas, em geral, para classificação ou regressão (GRAVES; SCHIMIDHUBER, 2005), são responsáveis pelo processamento da informação (JIA *et al.*, 2016). ANNs compreendem o paradigma de AI, que busca a solução de problemas através da simulação computacional dos mecanismos e estruturas do cérebro humano. Uma ANN consiste basicamente na interconexão de neurônios artificiais, formando uma rede composta por inúmeros sinais que possibilitam processamentos unitários. A estrutura da ANN adotada implica no algoritmo de aprendizado a ser utilizado. É através deste algoritmo de aprendizagem que a ANN obtém o conhecimento necessário para resolver um problema (HAYKIN, 1998).

O modelo de um neurônio, proposto inicialmente por McCulloch e Pitts (MCCULLOCH; PITTS, 1943), possui um elemento central que é responsável por fazer os cálculos entre pesos w_k existentes para cada uma das ligações que se conectam com a entrada, e um peso extra apresentado como um limiar b_k (bias), conforme apresentado na Figura 6 (HAYKIN, 1998) e que é ajustado durante o treinamento da ANN.



Fonte: adaptado de (HAYKIN, 1998).

A função de ativação apresentada na Figura 6 recebe como entrada um potencial de ativação v_k referente ao resultado do cálculo descrito acima. Com isso, o sinal de saída y_k que será enviado para os outros neurônios, depende da transferência definida em uma função específica $\phi(\cdot)$ que mantém esse valor de saída dentro de um estado. O sinal v_k é processado, permitindo limitar o domínio deste sinal e indicar se houve uma resposta ao

estímulo apresentado na entrada x . A topologia da rede, incluindo o número de camadas, é que irá definir como este sinal será propagado.

2.5.1 Redes de Hopfield

O aprendizado de máquina permite diferentes métodos computacionais relacionados à tarefa de descoberta do conhecimento. Um paradigma da AI são as *Recurrent Neural Networks* (RNNs) formadas por um conjunto de neurônios e suas interconexões, responsáveis pelo processamento de informações e aprendizagem de parâmetros (HOPFIELD, 1982). Uma das características da rede de Hopfield é que a saída dos neurônios é associada a um valor escalar, caracterizado por sua magnitude, descrito como um valor de energia e, mesmo que esse valor seja contínuo, permite apresentar uma característica primitiva discreta que remete a origem da estrutura neural artificial apresentada pelo autor.

2.5.2 Máquina de Boltzmann

A Máquina de Boltzmann, do inglês *Boltzmann Machine (BM)*, utiliza a estrutura da rede de Hopfield para a tarefa de interpretação, que requer aprendizagem, dos dados que são apresentados na entrada da rede (HINTON; SEJNOWSKI; ACKLEY, 1984). Inspirada na estatística, os estados da rede neural são representados como uma distribuição de Boltzmann que possui um valor de energia associado a um estado físico termodinâmico. O treino da rede envolve um processo de otimização que depende, basicamente, dos dados de entrada e do conjunto de pesos presentes no cálculo. BM é apresentada na literatura como uma versão da rede de Hopfield. Embora essa estrutura seja capaz de aprender um padrão de dados a partir de uma informação local, o processo estatístico de atualização de pesos envolve uma estrutura que possui uma dependência temporal, melhorada com o surgimento de novas abordagens que serão apresentadas a seguir.

2.5.3 Máquina de Boltzmann Restrita

Existem diferentes paradigmas de ML que podem ser implementadas e que dependem de quais dados de entrada e saída estão disponíveis (RUSSELL; NORVIG, 2003). Um exemplo é a máquina de Boltzmann restrita, do inglês RBM (*Restricted Boltzmann Machine*), a qual possui ampla aplicação (FISCHER; IGEL, 2012), (LIAO; JIN; PAVEL, 2016).

Segundo (LIAO; JIN; PAVEL, 2016), existem diversas tecnologias para análise de dados aplicáveis para processos industriais. Considerando um ambiente fabril, quando um operador necessita tomar uma decisão a partir dos dados disponíveis, é possível aplicar um modelo preditivo que identifique uma determinada situação, auxiliando nesta tarefa. Contudo, os modelos baseados em dados precisam ser treinados ao longo do tempo antes de poderem contribuir neste sentido. Esses objetivos podem ser alcançados por um modelo de estimativa de probabilidade com uma estrutura de um grafo bidirecional repre-

sentado como uma RBM, sendo que seus parâmetros podem ser aprendidos efetivamente a partir dos dados. A formulação a partir de uma máquina de Boltzmann leva a um algoritmo de aprendizado independente de domínio e que modifica os pontos fortes da rede neural, para que toda a rede desenvolva um modelo que manipule as probabilidades das diferentes situações, a partir de um processo de modificação dos pesos da rede (HINTON; SEJNOWSKI; ACKLEY, 1984), (HINTON; SEJNOWSKI, 1986).

2.5.3.1 *Arquitetura da RBM*

Existem diversas aplicações para análise de dados, conforme apresentado em (LIAO; JIN; PAVEL, 2016). A grande quantidade de dados armazenada nos processos pode ser utilizada para um modelo preditivo e de aprendizado sobre diferentes situações. Um modelo probabilístico com uma estrutura de um grafo bipartido representada como uma RBM pode ser implementado para esta aprendizagem. A máquina de Boltzmann representa uma distribuição de probabilidade e é implementada a partir de um algoritmo de aprendizagem independente de domínio, que modifica os pesos relacionados à força da conexão dentro do modelo da máquina. Dessa forma, toda a rede desenvolve um modelo que permite manipular as probabilidades dos vários estados (HINTON; SEJNOWSKI, 1986).

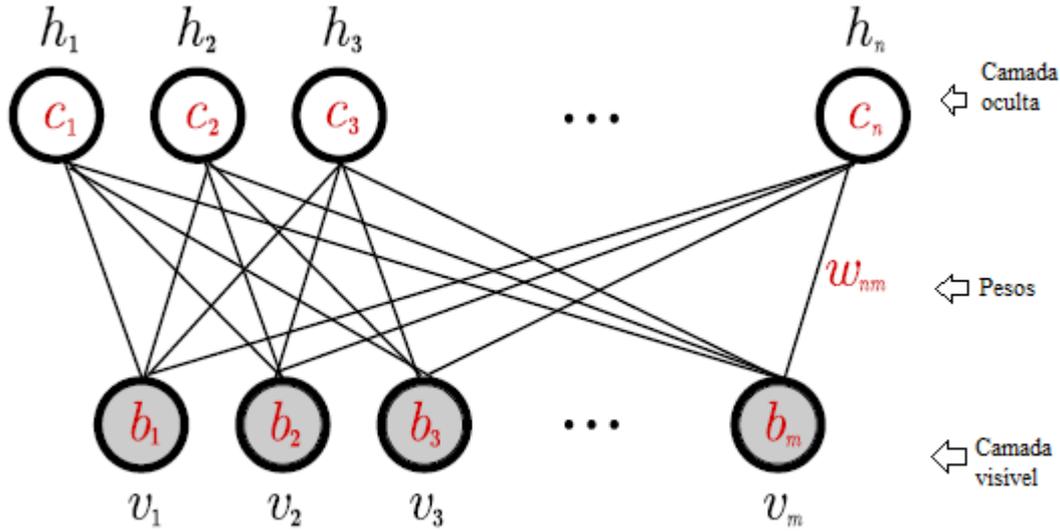
A máquina de Boltzmann restrita (RBM) é um modelo não supervisionado de aprendizado estocástico generativo, que pode modelar uma distribuição de probabilidade em um grafo não direcionado. A RBM consiste em duas camadas conectadas entre um nó visível onde os dados são coletados e um nó oculto que irá aprender as características da camada visível, com o objetivo de representar uma distribuição probabilística destes dados (HAYKIN, 2003). A probabilidade de uma configuração conjunta entre nós visíveis e ocultos corresponde aos neurônios e as respectivas conexões sinápticas da rede neural artificial. Além disso, uma função de energia fornece uma compreensão de como o modelo funciona (HAYKIN, 2003), (LECUN; CHOPRA S. HADSELL; RANZATO, 2006).

Cada camada de uma rede neural pode ser considerada um nível de energia, abrindo a possibilidade de suporte analítico avançado para a tomada de decisão utilizando dados de campo disponíveis em arquiteturas de alto nível para prover melhorias na operação dos processos. Com estes dados é possível analisar a situação corrente e calcular o posicionamento que está associado à maior probabilidade de uma situação de interesse.

2.5.3.2 *Aprendizado da RBM*

Em uma RBM todos os nós são iguais e funcionam como um sistema. Estes estados gerados pelo sistema compreendem a camada visível v com m unidades e uma camada oculta h com n unidades binárias, conforme representado na Figura 7. O processo de aprendizagem é realizado utilizando a minimização da energia do sistema (LECUN; CHOPRA S. HADSELL; RANZATO, 2006), (FISCHER; IGEL, 2012).

Figura 7: representação da rede neural RBM.



Fonte: adaptado de (FISCHER; IGEL, 2012).

Como pode ser observado na Equação (1), a probabilidade pode ser medida como o inverso da energia. Se a energia escalar entre os estados dos k neurônios é dada por ΔE_k e a temperatura artificial T é um parâmetro que representa a temperatura em um sistema, temos o valor de probabilidade p calculado para os diferentes estados em relação ao valor de energia.

$$p_i = \frac{e^{-\epsilon_i/kT}}{\sum_{j=1}^M e^{-\epsilon_j/kT}} \quad (1)$$

O processo de aprendizado envolve a minimização da energia do sistema (FISCHER; IGEL, 2012):

$$E(v,h) = -\left(\sum_{i=1}^n \sum_{j=1}^m W_{ij} h_i v_j + \sum_{j=1}^m b_j v_j + \sum_{i=1}^n c_i h_i\right). \quad (2)$$

Minimizar uma função é a direção adotada para fazer previsões com RBMs. O procedimento de treino envolve estimar a derivada da função de partição logarítmica observada na Equação (4) inicializando os nós ocultos e visíveis em um estado que pode ser aleatório. RBM é difícil de treinar porque a função de partição (constante Z observada na Equação (3)) possui muitos termos e que aumentam exponencialmente. Contudo, a aprendizagem não supervisionada significa uma aprendizagem com base em uma amostra de dados, possibilitando o processo de aprendizado (FISCHER; IGEL, 2012).

$$P(v,h) = \frac{1}{Z} e^{-E(v,h)} \quad (3)$$

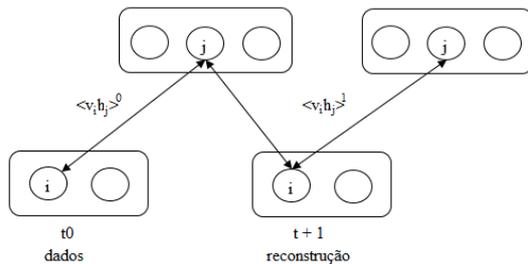
Aprender em uma RBM consiste em minimizar a parte negativa da *log-likelihood*:

$$\begin{aligned} \epsilon \frac{\partial \log p(v^0)}{\partial w_{ij}} &= \langle h_j^0(v_i^0 - v_i^1) \rangle + \langle v_i^1(h_j^0 - h_j^1) \rangle + \langle h_j^1(v_i^1 - v_i^2) \rangle + \dots \\ &= \epsilon \langle v_i^0 h_j^0 \rangle - \langle v_i^\infty h_j^\infty \rangle \approx \epsilon \langle v_i^0 h_j^0 \rangle - \langle v_i^1 h_j^1 \rangle \quad (4) \end{aligned}$$

A taxa de aprendizado ϵ descrita na Equação (4) é utilizada para representar os valores esperados dos dados. As expectativas do modelo são substituídas por uma estimativa usando a amostragem de Gibbs (GEMAN; GEMAN, 1984), conforme representado na Figura 8, com um número limitado de iterações, usando o algoritmo de *Contrastive Divergence* (CD-k) (FISCHER; IGEL, 2012). De acordo com (MNIH; LAROCHELLE; HINTON, 2012), essa arquitetura foi um avanço no procedimento de aprendizagem durante o treinamento em grandes conjuntos de dados.

Em (FISCHER; IGEL, 2012), é apresentado que o número de passos de treino se resume a amostrar um estado para a camada oculta h a partir da probabilidade $p(h|v)$ e, em seguida, amostrar um estado para a camada visível v a partir da probabilidade $p(v|h)$. Esse processo é chamado de *Contrastive Divergence* - CD- k , de forma que as etapas descritas acima podem ocorrer somente uma vez, ou seja, quando é considerado $k = 1$. Em (HINTON, 2002), o algoritmo CD possui um conjunto de parâmetros relacionados ao treino, sendo a taxa de aprendizagem, *momentum* e o fator de decaimento α . Durante o processo de otimização, ocorre o ajuste dos valores dos pesos presentes na rede, permitindo encontrar a probabilidade local de um estado deste sistema. Com isso, esse problema de aprendizagem é considerado convexo (LECUN; CHOPRA S. HADSELL; RANZATO, 2006), de modo que os dados observados especificam um estado binário para os nós presentes na RBM.

Figura 8: representação do amostrador de Gibbs.



Fonte: adaptado de (FISCHER; IGEL, 2012).

2.5.4 Rede Neural Recorrente com Camadas LSTM

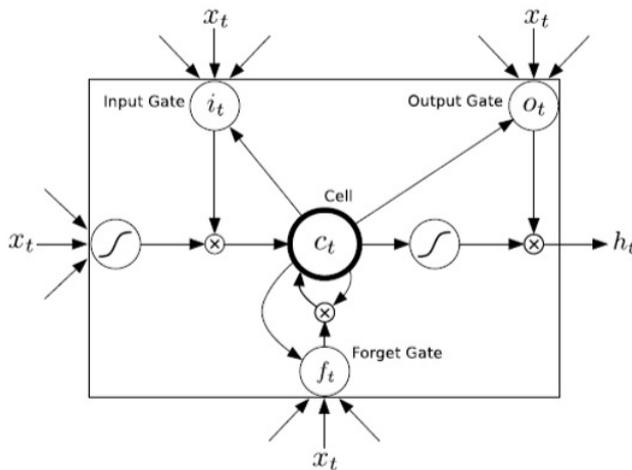
A detecção de falhas em sistemas industriais está intimamente ligada às relações temporais que ocorrem no processo. O uso da AI é aplicado no comportamento preditivo

relacionado à falhas, aplicando uma janela de dados (SALFNER; MALEK, 2007) que especifica o número de eventos presentes em uma situação. RNN com camadas *Long Short-Term Memory* (LSTM) (YANG *et al.*, 2019), (TIAN *et al.*, 2018) representa um modelo utilizado para análise de séries temporais aplicando um processo de aprendizagem supervisionado, após a definição de uma janela deslizante (*Sliding Window*). Segundo (GREFF *et al.*, 2015) a ideia central que suporta a arquitetura de uma rede LSTM é a célula de memória, que permite manter seu estado ao longo do tempo, e unidades não lineares, que regulam o fluxo de informações para dentro e para fora de cada célula.

As RNNs são designadas para capturar uma dependência temporal em dados sequenciais. Estes modelos se tornaram ainda mais conhecidos após a introdução de RNNs juntamente com unidades LSTM, propostas para superar as dificuldades de lidar com a dependência de longo prazo (*long-term*) e o problema relacionado ao gradiente conhecido como decaimento do gradiente (*vanishing gradient*) (SEPP; JÜRGEN, 1997).

A RNN com camadas LSTM é estruturada e os resultados são comparados com uma função de ativação distinta, onde cada unidade visível tem uma multiplicação escalar na entrada da função de ativação, representado na Figura 9. Uma representação da célula com as respectivas funções de ativação pode ser observada na Figura 9.

Figura 9: estrutura da célula RNN-LSTM.



Fonte: (SEPP; JÜRGEN, 1997).

A função de ativação pode ser expressa como ((SU; LIAU; CARIN, 2017), (RAVANBAKSH *et al.*, 2018), (MARTENS *et al.*, 2013)):

$$\text{Sigmoid} = \frac{1}{(1 + e^{-x})} \quad (5)$$

$$\text{tanh} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

A célula LSTM, que é apresentada na Figura 9, é aplicada para capturar uma relação entre os dados de uma série temporal. O cálculo pode ser definido da seguinte

forma (YANG *et al.*, 2019):

$$f_t = \text{Sigmoid}(W^f h_{t-1} + b^f) \quad (7)$$

$$i_t = \text{Sigmoid}(W^i h_{t-1} + b^i) \quad (8)$$

$$c_t = \text{tanh}(W^c h_{t-1} + b^c) \quad (9)$$

$$m_t = f_t \odot m_{t-1} + i_t \odot c_t \quad (10)$$

$$o_t = \text{Sigmoid}(W^o h_{t-1} + b^o) \quad (11)$$

$$h_t = \text{tanh}(o_t \odot m_t) \quad (12)$$

onde:

W^i, W^f, W^o, W^c são pesos da multiplicação vetorial por (h_{t-1}) , e b^i, b^f, b^o, b^c são o bias, e $o_t \odot m_t, f_t \odot m_{t-1} + i_t \odot c_t$ são operações (*element-wise*) de Hadamard (STYAN, 1973).

2.6 Modelos de Grafos Acíclicos Dirigidos

Por se tratar de um grafo dirigido acíclico, a rede Bayesiana (*Bayesian Network* - BN) difere em algumas características do modelo de grafo não direcionado da RBM, apresentado na seção anterior. Segundo (PEARL, 1988), os *Directed Acyclic Graphs* (DAGs) permitem capturar dependências causais probabilísticas que os tornam mais flexíveis em relação aos grafos não direcionados.

2.6.1 Processo de Inferência

A etapa de inferência baseada em modelo permite características relacionadas ao domínio e que é base para a troca de informações. Entre as arquiteturas encontradas na literatura, destacam-se a abordagem diagnóstica *bottom-up* "baixo para cima" e causal *top-down* "cima-para-baixo". Além disso, uma outra abordagem encontrada na literatura que combina as estratégias *top-down* e *bottom-up* é conhecida como intercausal *explaining away* (LEE; HONG, 2017), (WELLMAN; HENRION, 1993).

2.6.2 Redes Bayesianas

A aplicação de estatística Bayesiana que teve origem no trabalho do reverendo Thomas Bayes (1763) superou os entraves relacionados ao processo inferencial, a partir de procedimentos computacionais conhecidos por Monte Carlo via Cadeias de Markov, do inglês MCMC (*Markov Chain Monte Carlo*).

A estrutura de uma BN é representada por um grafo acíclico que consiste em nós, que representam variáveis identificáveis com uma informação sobre o domínio, especificada por uma distribuição de probabilidade, e arcos direcionados entre esses nós. Se houver um arco do nó A para o nó B, então A é considerado um nó pai e B é um nó filho. As probabilidades de cada nó são condicionadas apenas ao seu nó pai, e isso gera uma propriedade importante chamada independência condicional. Todos os nós são condicionalmente independentes de seus nós descendentes, dados seus pais (MILLÁN; LOBODA; PERÉZ-DE-LA-CRUZ, 2010). Uma BN permite inserir evidências de qualquer número de variáveis em parte do modelo.

Quanto às características da rede, cada nó é identificado com informações que correspondem a uma variável aleatória, especificadas a partir de distribuições condicionais que quantificam os efeitos dos pais sobre o nó filho. O valor da probabilidade quantitativa resume um conjunto de circunstâncias e também a incerteza associada a esses vínculos presentes na rede (CARVALHO, 2011).

Em uma BN, tabelas de probabilidade condicional CPT (*Conditional Probability Table*) são utilizadas para avaliar a relação entre A e B, a partir da distribuição de probabilidade. Contudo, existem limitações de aplicação para que uma BN seja utilizada em situações que envolvem uma estrutura repetida dos nós sobre o tempo (WRIGHT *et al.*, 2002).

2.6.3 Inferência Probabilística

Causalidade é a relação consciente humana sobre um evento ocorrido e os parâmetros envolvidos (PEARL, 1988). No momento em que é modelada a influência de determinados parâmetros em relação a um evento, é possível atualizar um conhecimento. Neste processo, tendo em vista a presença da incerteza, é adotado o cálculo da probabilidade. Seja no sentido de diagnóstico ou de prognóstico, existem parâmetros intangíveis que determinam a ocorrência de um evento. Assim, um processo de inferência permite representar a estrutura do raciocínio a partir de evidências, executada por um processo de propagação de probabilidades locais (LEE; HONG, 2017), (PEARL, 1988).

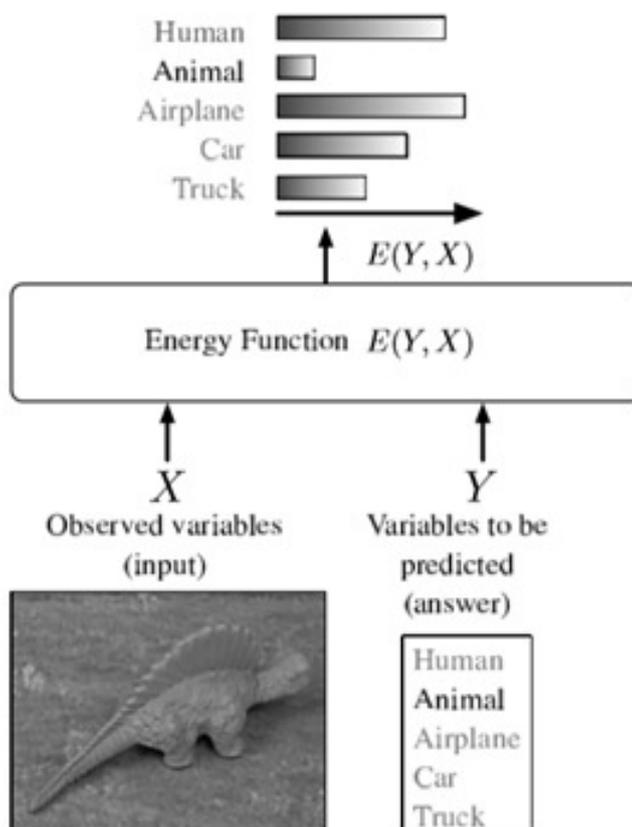
A análise probabilística sobre um conhecimento avaliado a partir de variáveis em um contexto, juntamente com as evidências que são apresentadas, ocorre através de uma representação, que no caso da BN, trata-se de um grafo (MCELREATH, 2020). Em relação à inferência resultante de uma consulta que relaciona em duplo sentido, causa e efeito, temos uma atualização das crenças, presente a partir de novas evidências. Tais evidências participam do cálculo *a posteriori*. Assim, a equação elaborada por Bayes relaciona valores *a priori* com os registrados na *Local Probability Distribution* (LPD), mantendo coerente as relações de um modelo adaptativo (RUSSELL; NORVIG, 2003).

2.7 Entropia

Entropia é uma informação sobre os eventos de um sistema que surgem em diferentes estados e está relacionada a incerteza. A relação existente entre a entropia e a temperatura T , apresentada na Equação 1, está associada a questão de um maior valor de temperatura representar uma maior quantidade de energia distribuída entre os elementos deste sistema, concentrando um maior número de estados possíveis (WALKER; DAVIES; ELLIS, 2017), (JAYNES, 2003).

Existe uma relação entre entropia e uma distribuição exponencial (MCELREATH, 2020). O valor analisado da entropia representa uma distribuição de probabilidade que está associada a uma relação causal (RUSSELL; NORVIG, 2003; MCELREATH, 2020; QUINLAN, 1986). Em redes Bayesianas, este valor representa que as hipóteses são verdadeiras (JAYNES, 2003). Segundo (LECUN; CHOPRA S. HADSELL; RANZATO, 2006), a entropia e a probabilidade estão relacionadas num processo que envolve minimizar a energia escalar entre variáveis. O processo de aprendizagem consiste em encontrar um padrão que associe um menor valor de energia ao valor correto da variável de resposta, conforme representado na Figura 10.

Figura 10: representação da função de energia.



Fonte: (LECUN; CHOPRA S. HADSELL; RANZATO, 2006).

2.8 Árvore de Decisão

Aprendizagem de máquina possui paradigmas que permitem implementar um modelo exploratório a partir de um conjunto de dados. A estrutura de uma árvore de decisão, do inglês DT (*Decision Tree*), possibilita essa modelagem a partir de um processo de classificação ou regressão, numa visão orientada para descoberta. Numa visão orientada para verificação, árvores de decisão são aplicadas para testar hipóteses predefinidas (ROKACH; MAIMON, 2014).

Uma árvore de decisão é um modelo que pode ser aplicado para problemas de classificação (BREIMAN *et al.*, 1984), como, por exemplo, para classificar falhas que ocorrem em um processo. DT pode ser construída para avaliar dados históricos em um processo de mineração de dados. Sua estrutura consiste de vértices e arestas que formam um árvore.

O valor correspondente de entropia em uma árvore de decisão, sendo uma distribuição de probabilidade discreta, é dado por (JAYNES, 2003), (QUINLAN, 1986), (SHANNON, 1949):

$$H(Y) = -E.\log_2 pi = -\sum_i pi.\log_2 pi \quad (13)$$

onde Y é a entropia da variável Y . Cada evento "E" possui probabilidade pi .

No processo de análise de dados, este modelo desempenha importante contribuição ao prover informações úteis para análises subsequentes (HANDLEY *et al.*, 2019), (DANGETI, 2017), (HINO; MURATA, 2014).

2.9 Ontologias

Ontologias agrupam conceitos de um domínio de conhecimento. Seu desenvolvimento, segundo (NOY; MCGUINNES, 2001), envolve a definição de um conjunto de elementos como entidade, classe, propriedade, restrição, predicados, funções e pode ser escrita em uma linguagem formal que permite a descrição do conhecimento, sendo utilizada para realizar inferência sobre os objetos do domínio.

2.9.1 Definições

Segundo (GRUBER, 1993), em uma ontologia os conceitos e restrições de uso são explicitamente definidos, podendo ser entendida por máquina, permite capturar um conhecimento e se refere a um modelo abstrato do mundo real. Conforme o autor, uma ontologia pode ser descrita como um conjunto de termos de uma representação, existindo a associação entre classes, funções e objetos.

O consórcio *World Wide Web Consortium* (W3C) definiu a *Web Ontology Language* (OWL) como uma linguagem semântica utilizada para construção de ontologias que representam um conhecimento. OWL pode ser entendida como uma linguagem baseada

em lógica, cujo conhecimento pode ser entendido por máquina e implementado a partir de ferramentas de desenvolvimento que permitem a aplicação de motores de inferência. A linguagem OWL foi construída sobre recomendações pré existentes da W3C, como *Resource Description Framework* (RDF), *eXtensible Markup Language* (XML), etc.

A linguagem OWL-DL possui como extensão uma lógica descritiva, que faz parte da lógica de primeira ordem (*First Logic Order* - FOL) (LASKEY, 2008). Segundo (MCGUINNESS; VAN HAMERLEN, 2004), três sublinguagens definem o nível de expressividade, sendo OWL-Lite a que fornece o menor grau de expressividade. Em seguida, temos o OWL-DL (*Web Ontology Language Description Language*) que permite que todas as conclusões sejam computáveis em um tempo finito, com algumas restrições, por exemplo a relação entre instâncias e classes. Por fim, OWL-Full que apresenta maior expressividade.

A OWL-DL permite a utilização de motores de inferência, a fim de validar o modelo desenvolvido, descobrir novos conhecimentos e inferir relacionamentos existentes entre as diferentes classes. Além disso, uma ontologia implementada em OWL-DL permite um processo de inferência com base na informação de contexto e permite compartilhar um conhecimento (MAKRIS; SKOUTAS; SKIANIS, 2013). Para inferências de relações de conhecimento do domínio, existem ferramentas de *Reasoning* que apresentam maior expressividade em lógica descritiva (SIRIN *et al.*, 2007).

2.9.2 Modelagem de Contexto

A metodologia para construção da ontologia definida por (NOY; MCGUINNES, 2001) define regras que facilitam a tomada de decisão em um projeto, sendo: (1) não há uma maneira correta de modelar um domínio, mas sim alternativas viáveis, sendo que a melhor opção muitas vezes depende da aplicação que se deseja construir; (2) o desenvolvimento de ontologias é necessariamente um processo iterativo; (3) conceitos em ontologia devem ser próximos a objetos (físicos ou lógicos) e relacionamentos no domínio de interesse. Estes podem ser substantivos (objetos) ou verbos (relacionamentos) em sentenças que descrevem o domínio.

O método 101 (NOY; MCGUINNES, 2001) possui como apoio uma estrutura de ações que define etapas para as atividades durante a construção da ontologia. Entre os passos presentes nesse método, são analisados questionamentos como, por exemplo, qual é o domínio em questão? No passo seguinte, verifica-se a possibilidade de reutilização, que é útil para possibilitar a comunicação com outras aplicações, para o aperfeiçoamento e manutenção do formalismo. Em seguida são listados termos que auxiliam na declaração e nos relacionamentos. Por fim, são definidas as classes e hierarquias, que ajudam a definir de que tipo são as instâncias. Além disso, as propriedades das classes são definidas para permitir a implementação da ontologia de domínio. Essa definição de propriedades é necessária, pois elas podem possuir diferentes facetas que definem o tipo de valor, valores

permitidos, cardinalidade de valores, entre outras características que a propriedade pode assumir.

2.9.3 Modelagem Probabilística

As Redes Bayesianas, do inglês BNs (*Bayesian Networks*) são um tipo de modelo de grafo probabilístico. Para a concepção de um modelo probabilístico utilizando ontologia é necessário a implementação de uma ontologia de base que permita a utilização de um motor de inferência. A partir de (MCGUINNESS; VAN HAMERLEN, 2004), que recomenda OWL para o desenvolvimento de ontologias e com base nos dados disponíveis, são definidos os conceitos relacionados ao domínio de interesse. Em seguida, é possível determinar a probabilidade através da implementação de ontologias probabilísticas PR-OWL (*Probabilistic OWL*), de uma situação acontecer no futuro por meio de MEBN (*Multi-Entity Bayesian Network*) (LASKEY, 2008).

Os sistemas reativos consideram que o ambiente monitorado depende de ações, diante de uma ocorrência anormal detectada (O'BREIN, 2009). Objetivando prever tal situação, é considerada a mudança no contexto a partir de um modelo ontológico de inferência no qual é necessário considerar os eventos que irão participar da situação em questão. A definição do contexto reúne as informações sobre o domínio, e irá permitir o raciocínio probabilístico (HERVÁS; BRAVO; FONTECHA, 2010).

Ontologias oferecem um vocabulário com definições e restrições que estabelecem um modelo conceitual. Esse modelo representa o conhecimento sobre o domínio, descrevendo classes, atributos e relacionamentos. As classes representam conceitos do domínio, enquanto que os relacionamentos indicam como esses conceitos interagem entre si. Os atributos são características que os conceitos devem possuir. Assim, são estabelecidas relações que são verificadas por meio de motores de inferência, tendo como base, evidências ou axiomas. Em relação a ontologia probabilística, essa acrescenta regularidades estatísticas que caracterizam o domínio e considera a incerteza sobre as formas de conhecimento. De acordo com (BETTINI *et al.*, 2010), é possível inferir a partir de um ambiente modelado informações de mais alto nível. Em (CARVALHO; LASKEY; COSTA, 2016), são descritos os passos e as principais características que um modelo conceitual probabilístico deve apresentar.

3 ANÁLISE DO ESTADO DA ARTE

3.1 Visão Geral do Capítulo

A análise do estado da arte é apresentada neste capítulo. Foram analisados os trabalhos relacionados ao formalismo semântico e a dimensão de informação, preferivelmente trabalhos que consideram processos industriais. Além desses, outros artigos foram estudados, considerando a modelagem probabilística como um requisito para a problemática apresentada. Em seguida, são apresentados trabalhos relacionados ao uso de técnicas de mineração de dados e de aprendizagem de máquina.

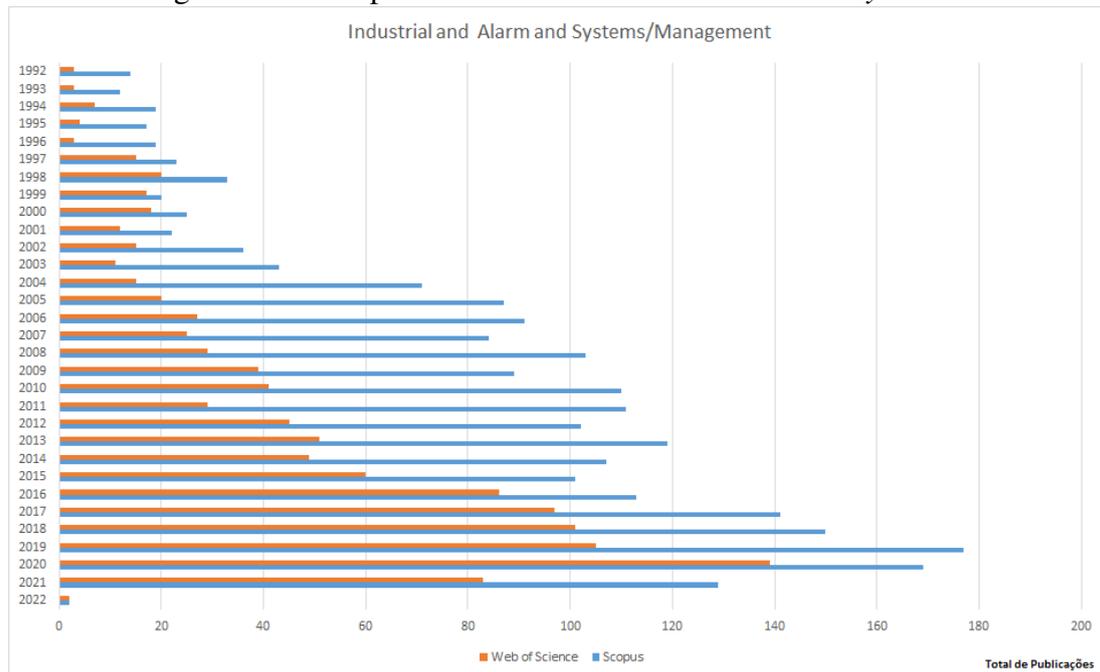
3.2 Metodologia de Pesquisa

A metodologia de pesquisa adotada nesta tese foi uma análise na literatura sobre sistemas de alarmes industriais e ontologia. A pesquisa se concentrou nas bases de dados Web of Science e Scopus. Foram realizadas duas buscas. Na primeira busca foram incluídos os termos "*Industrial and Alarm and Systems*" no título, resumo ou palavra-chave, sendo o inglês o idioma considerado nesta busca. Como resultado, foram listados 1173 trabalhos na base Web of Science e 2570 na base Scopus. Conforme apresentado na Figura 11, esses números representam uma busca crescente por soluções na área de pesquisa desta tese.

Na segunda busca foram incluídos os termos "*Industrial and Alarm and Systems and Ontology*" no título, resumo ou palavra-chave, sendo o inglês o idioma considerado nesta busca. Como resultado, foram listados 7 trabalhos na base Web of Science e 17 na base Scopus. Conforme apresentado na Figura 12, existe uma lacuna inerente na área de pesquisa que inclui modelos semânticos, e também sobre o processo de modelagem de contexto.

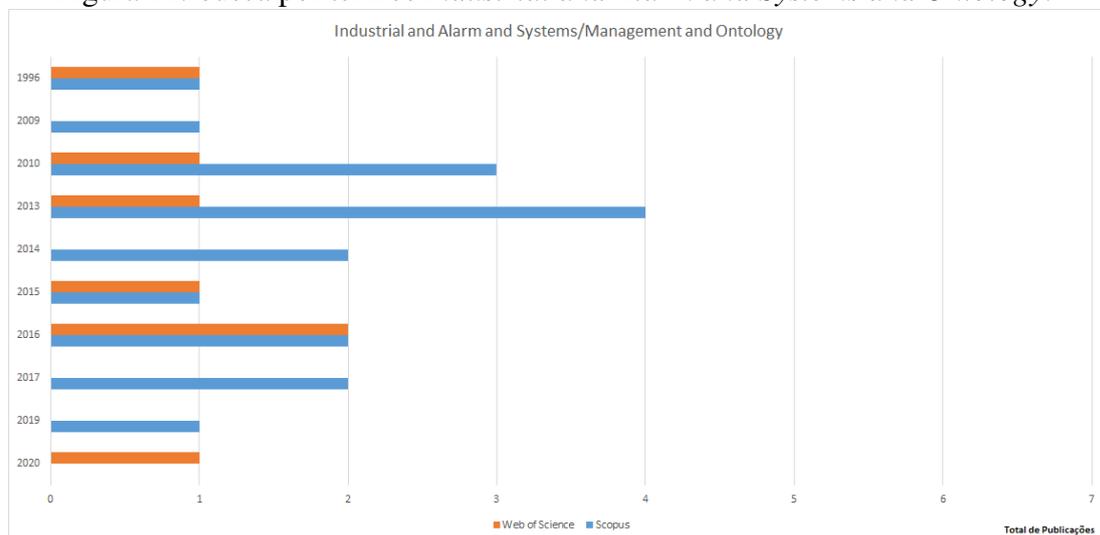
Nesta seção, a análise do estado da arte é apresentada em duas Tabelas. Na primeira delas foram analisados os trabalhos relacionados ao formalismo semântico e à dimensão de informação. Com isso foi gerada a Tabela 1, que compara as publicações mais relevantes, onde cada linha representa as publicações relacionadas a esta tese, conforme destaque apresentado nas Figuras referentes a busca nas bases Scopus e Web of Science,

Figura 11: busca por termos *Industrial and Alarm and Systems*.



Fonte: autor.

Figura 12: busca por termos *Industrial and Alarm and Systems and Ontology*.



Fonte: autor.

onde a maior parte dos trabalhos relacionados a este tema compreende a este período. Em seguida, iniciou-se a análise de trabalhos relacionados ao uso de técnicas de mineração de dados, inferência probabilística e o uso de redes neurais artificiais. A partir disso, elaborou-se a Tabela 2, que representa os diferentes tópicos de estudo repassados durante esta tese e destacado nas contribuições que serão apresentadas no final deste texto.

3.3 Trabalhos Relacionados

3.3.1 Dimensão de Informação e Modelos Semânticos

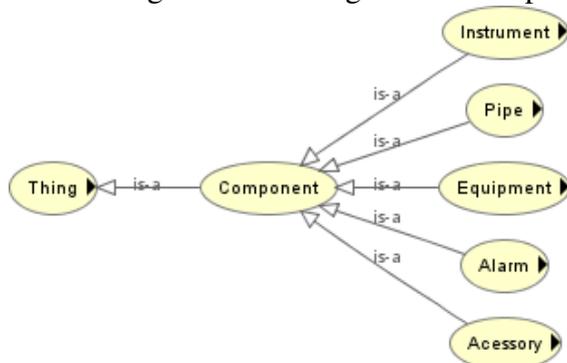
Com os avanços nas tecnologias de automação e o crescente volume de dados gerados pelos processos, surgem demandas relacionadas ao conhecimento operacional e à capacidade de atuação diante de determinadas situações. Em um processo industrial típico, tais decisões são, em geral, amparadas por sistemas de gerenciamento de alarmes. Contudo, existem lacunas relacionadas ao entendimento do domínio quando são adotados os padrões tradicionais, por exemplo, como manter uma média de um alarme a cada 10 minutos ou 144 alarmes por dia e que são apresentados aos operadores. Todavia, a possibilidade de integrar uma abordagem semântica nas fases iniciais do processo de descoberta de conhecimento e a predição de situações também são tarefas desafiadoras.

Uma abordagem preditiva é tratada em (VARGA; SZEIFERT; ABONYI, 2010), onde é apresentado um modelo baseado na detecção de uma situação específica. A metodologia envolve a simulação do efeito de ajustes em variáveis em um processo químico realizado pelo operador, e o cálculo de um tempo em que cada ação deve ser executada para evitar um distúrbio na planta. Segundo os autores, há um último ponto de operação controlável em cada manipulação sobre o processo, antes que este se torne instável. Um modelo baseado em previsão para detectar certas situações em um processo químico industrial é apresentado neste artigo. Os autores destacam que algumas técnicas para análise de processos, como, por exemplo, uma árvore de eventos ET (*Event Tree*) ou uma árvore de falhas FT (*Fault Tree*), exigem um conhecimento adicional a fim de permitir uma ação efetiva em determinados contextos. O trabalho aborda as questões relacionadas ao funcionamento de um processo químico e os eventos ocorridos no reator presente nestes processos, relacionando com os acidentes em Bophal na Índia e em Seveso na Itália. O trabalho aplica um *benchmark* industrial para exemplificar o comportamento das variáveis do processo em situações normal e em falha, e busca definir as possíveis regiões de operação seguras durante o funcionamento do processo.

O trabalho de (LIMA *et al.*, 2013a), propõe uma ontologia modelada para processos industriais. Segundo os autores, nos sistemas SCADA (*Supervisory Control and Data Acquisition*) (BOYER; SHAOYUAN; BO, 2004), a qualidade das informações de processo, relacionadas aos alarmes e eventos presentes neste ambiente pode dificultar o trabalho dos operadores. Neste trabalho é utilizado OWL para modelagem ontológica conforme apresentado na Figura 13. Segundo os autores, uma ontologia permite modelar o domínio da planta e dar suporte a aplicações de automação industrial. Em razão da quantidade de alarmes e eventos que podem estar presentes em um processo industrial e dos possíveis erros de configuração destes alarmes, ferramentas de avaliação permitem implementar desde uma racionalização prevista na literatura até a extração de conhecimento. O trabalho é baseado em alarmes gerados no processo de tratamento de dietano-

lamina (DEA), que envolve um processamento de gases voláteis, e que foram associados ao acidente ocorrido na plataforma da Petrobras® em 2001 (NASA, 2008). Os autores destacam a importância na inclusão de aspectos semânticos na análise dos alarmes, que melhoram os procedimentos diagnósticos de falhas no processo.

Figura 13: ontologia modelada para processos industriais.



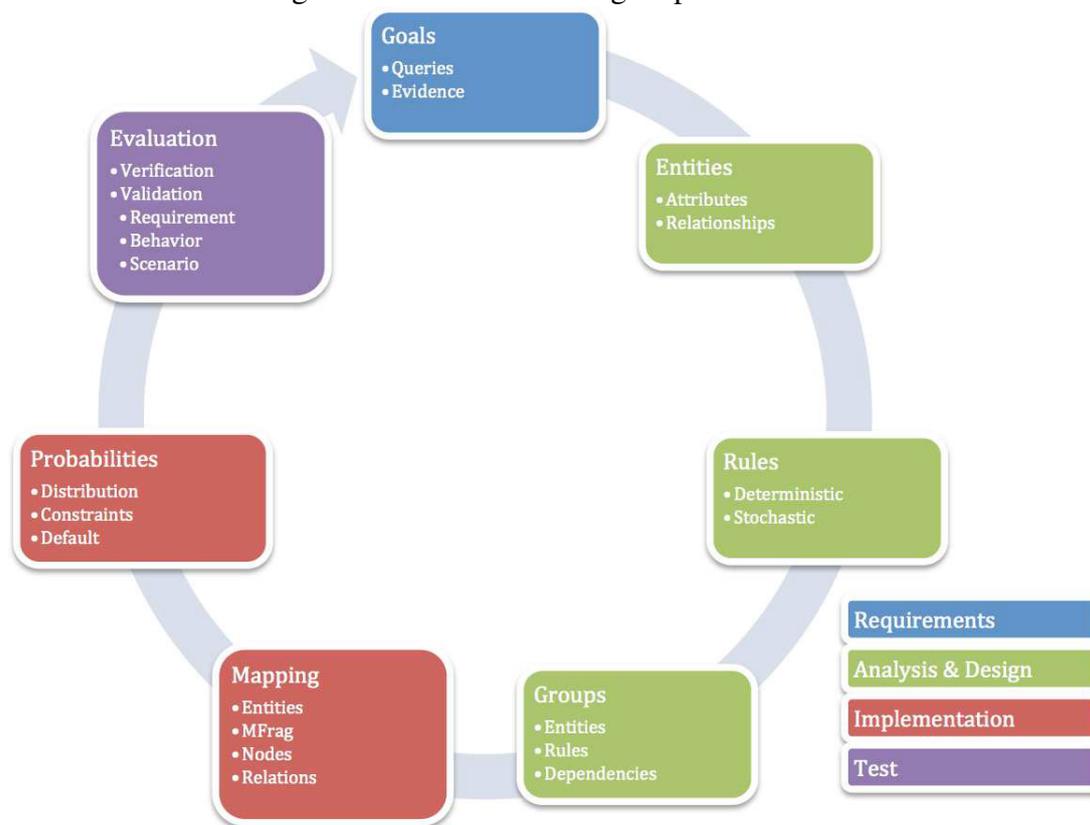
Fonte: (LIMA *et al.*, 2013a).

No trabalho de (JIANFENG *et al.*, 2016), os autores apresentam um modelo probabilístico que utiliza dados de alarmes armazenados em uma base de dados de um SDCD para realizar uma previsão. Os autores apresentam uma discussão sobre o aumento na quantidade de alarmes monitorados pelos operadores, dada a facilidade na configuração e inclusão de novos alarmes nos sistemas de automação atuais. Isso impacta diretamente na quantidade de alarmes que são apresentados, mesmo considerando documentos que norteiam essa questão, como, por exemplo, a norma ISA 18.2 (ISA, 2016) e a EEMUA 191 (EEMUA, 2007). A abordagem apresentada pelos autores busca prever a probabilidade de ocorrência de um alarme específico a partir de um modelo de Markov. O modelo apresentado busca, a partir da estimativa de parâmetros utilizando o método da máxima *likelihood*, prever a ocorrência de alarmes em uma planta petroquímica. A abordagem apresenta um modelo de classificação de alarmes de temperatura preditos.

No trabalho apresentado por (CARVALHO; LASKEY; COSTA, 2016), uma representação probabilística ocorre a partir da modelagem de um domínio, definindo classes e relacionamentos, conforme apresentado na Figura 14. O modelo probabilístico utiliza linguagem de primeira ordem MEBN (*Multi-Entity Bayesian Network*), na qual os fragmentos (MFragments) expressam a incerteza no relacionamento entre as entidades. Esses fragmentos fazem parte de uma MEBN *theory* (MTheory) (DA COSTA, 2005) que expressa a distribuição de probabilidade das situações que envolvem as entidades do domínio (GUIZZARDI, 2005). Segundo os autores, é necessário construir uma representação que determine todos os aspectos relacionados a um domínio e a incerteza ligada a estes aspectos.

O modelo apresentado por (CARVALHO; LASKEY; COSTA, 2016) busca avaliar a incerteza a partir de uma análise ontológica probabilística. Um motor de inferência

Figura 14: ciclo da modelagem probabilística.

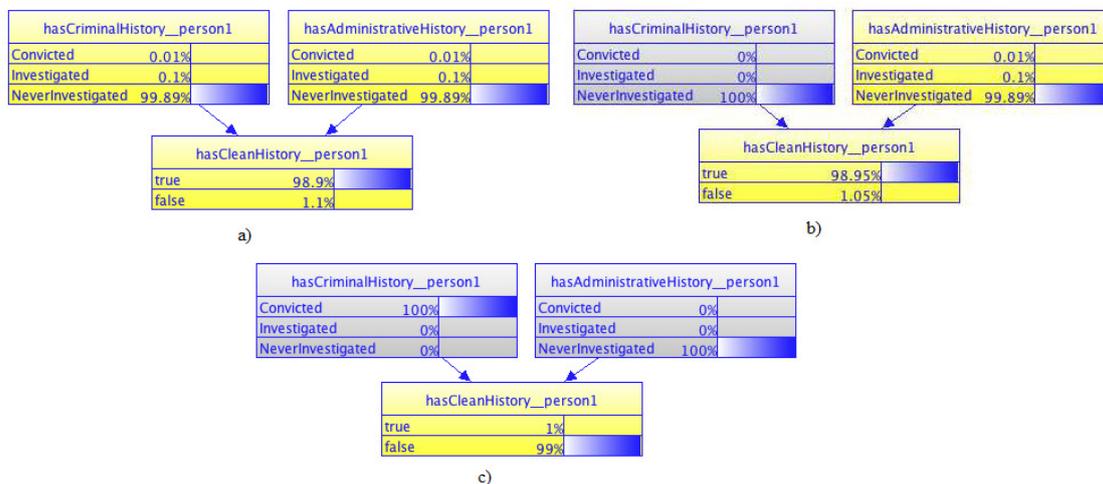


Fonte: (CARVALHO; LASKEY; COSTA, 2016).

é utilizado após uma consulta sobre uma situação específica. Para tal, este trabalho é estruturado a partir do ciclo de modelagem semântica, com o objetivo de detectar fraudes em processos licitatórios, considerando a lei federal número 8.666 de 1993. Os autores destacam que a atribuição de valores de distribuição de probabilidade para um atributo incerto pode ser declarada como um nó residente na rede (fragmento) chamado MFrag. Cada MFrag define uma distribuição de probabilidade local (LPD) e que está presente em um contexto. O modelo permite avaliar o comportamento de uma variável de interesse a partir de evidências apresentadas, conforme observado na Figura 15. Neste exemplo, é avaliado o histórico de uma pessoa envolvida num processo de licitação. Observa-se que, um histórico criminal é fator decisivo, conforme apresentado na Figura 15c. Caso não haja evidências ou, considerando que as evidências sejam favoráveis à pessoa, os resultados do processo de inferência mudam, conforme apresentado na Figura 15a, com 98.9% de probabilidade *a priori* de que a pessoa possui um histórico positivo, tendo em vista de que não há nenhuma evidência disponível. Na Figura 15b, cujo valor de probabilidade é de 98.95%, temos o caso onde existe um conhecimento sobre a pessoa1 que é *NeverInvestigated*, causando um aumento na certeza de que a referida pessoa possui histórico positivo em relação ao envolvimento em questões criminais, representado neste

exemplo da BN.

Figura 15 – rede Bayesiana de situação específica (SSBN) para o fragmento *Judgment History*.



Fonte: (CARVALHO; LASKEY; COSTA, 2016).

Segundo (SOARES *et al.*, 2016), em um monitoramento de processos industriais, existe uma correlação entre variáveis durante uma situação anormal e isso pode afetar outras variáveis simultaneamente. Neste trabalho, foi proposta uma priorização de alarmes aplicado a uma planta de processamento de gás natural. Os autores sugerem que a correlação entre variáveis em um processo é a causa para uma série de alarmes. Como proposta, os autores apresentam uma métrica (*Explained Variance*) que indica quanta variância ou informação é expressa por um PC (*Principal Component*) e assim, é possível encontrar os componentes mais representativos para alarmes e que sejam suficientes para uma determinada parte da planta. Desta forma, torna-se essencial a investigação de novas metodologias que auxiliem no processo de tomada de decisão. Neste trabalho é enfatizado que uma análise estatística de alarmes como parte da rotina operacional é aceita pelos guias e normas ISA 18.2 (ISA, 2016) e EEMUA 191 (EEMUA, 2007).

Um método para detectar segmentos de dados anormais é apresentado no trabalho de (YU *et al.*, 2017), aplicado em amostras de dados históricos e observando as direções de correlação entre variáveis de processo. Neste trabalho, um método de estimação é apresentado, considerando uma correlação de variáveis no processo. Os autores propuseram, entre os exemplos de aplicação do método, a seleção de 4 variáveis de um processo de geração térmica de energia elétrica a partir da queima de carvão, a fim de detectar padrões de anomalias deste processo em dados históricos. Além disso, os autores destacam que um pré-requisito para implementação de um método como este é a existência de um conjunto de dados de treino. Os autores definem hipóteses estatísticas para avaliar o nível de significância das correlações entre as variáveis avaliadas, identificando condições de

baixa eficiência de operação da planta em uma condição anormal, permitindo indicar para os operadores que uma determinada ocorrência necessita de atenção.

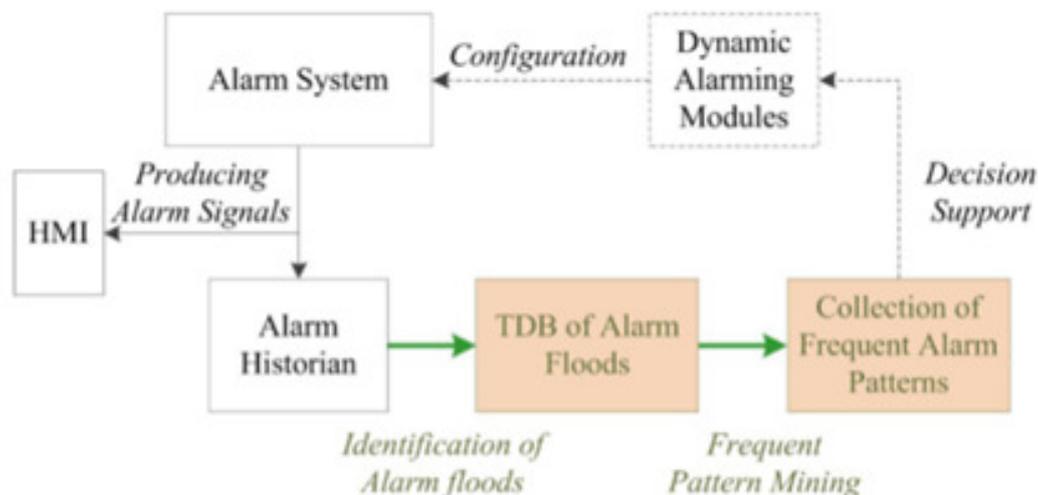
No trabalho de (BEZERRA *et al.*, 2018), os autores apresentam uma contextualização sobre o *Big Data* industrial e a importância em aplicar uma análise exploratória de dados, a partir de uma infraestrutura computacional específica, capaz de suportar as situações existentes no contexto da planta. Neste processo de análise exploratória dos dados, os autores aplicam diferentes métodos de visualização de dados, sendo um deles um diagrama aluvial, que permite identificar uma relação entre variáveis do processo. Em alguns estudos na literatura este gráfico também pode ser apresentado como gráfico de Sankey (SOUNDARARAJAN; HO; SU, 2014), (RIEHMANN; HANFLER; FROELICH, 2005). É importante destacar que os autores não aplicam um modelo semântico, tratando apenas da descoberta de conhecimento em dados.

Os dados do ATS, que tem como origem diversos dispositivos, como por exemplo sensores em um ambiente industrial, são complexos. Muitos dos trabalhos relacionados que estão citados nesta tese enfrentam esse desafio e destacam o esforço necessário para extrair informações úteis de dados oriundos de um processo e então realizar a previsão de um comportamento de falha a partir de um processo de ML. A massa de dados gerada em uma planta industrial a partir do comportamento de variáveis de processo, e que são detectadas por dispositivos de campo, inclui outros tipos de dados que também são gerados durante o funcionamento da planta e em grande quantidade, que são os registros de alarmes e eventos.

No trabalho de (HU; CHEN; SHAH, 2018), é apresentada uma abordagem a partir de técnicas para reduzir inundações de alarmes, usando uma metodologia denominada CHARM (*Closed Association Rule Mining*). Uma análise de padrões de alarmes é apresentada neste trabalho, que destaca que a presença de inundações de alarmes, em determinados casos, é provocada pela propagação de falhas no processo. O método apresentado é baseado em mineração de dados a partir de um histórico de alarmes de processo, conforme apresentado na Figura 16. O processo de análise apresentado pelos autores neste estudo é importante na definição de uma metodologia, pois destaca-se a etapa de mineração de dados com o objetivo de avaliar padrões de dados, bem como os momentos onde ocorrem as chamadas inundações ou avalanches de alarmes. Neste estudo os autores identificaram 180 avalanches de alarmes.

De acordo com (SARNOVSKY *et al.*, 2018), modelos preditivos podem oferecer ganhos efetivos quando aplicados à otimização de processos produtivos. Neste sentido, é importante salientar que o volume de dados gerados nos ATS também são registros de alarmes e eventos, que são uma fonte potencial de conhecimento e que pode ser melhor explorada. Nesta pesquisa é proposta uma arquitetura aplicada em dois processos industriais distintos. O trabalho não discute problemas específicos ou apresenta um modelo semântico, apresentando apenas uma representação que inclui alguns conceitos e propri-

Figura 16: metodologia CHARM.

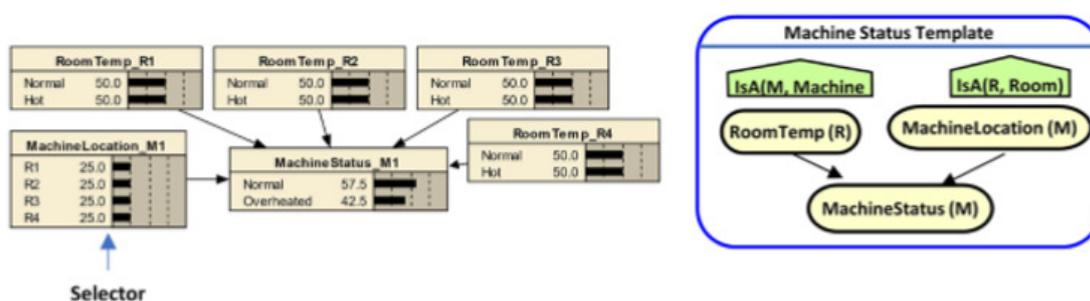


Fonte: (HU; CHEN; SHAH, 2018).

idades relacionadas à visão de informação, trabalhando em aspectos genéricos.

O trabalho de (LOCHER; LASKEY; COSTA, 2020) descreve procedimentos para análise probabilística utilizando a ferramenta Netica®. Seletores de contexto são apresentados na Figura 17, voltados para variáveis de interesse e busca destacar uma dependência de contexto nos diferentes cenários apresentados. O modelo probabilístico apresentado utiliza MEBN (*Multi-Entity Bayesian Network*) e PR-OWL (*Probabilistic OWL*).

Figura 17: seletor de contexto.

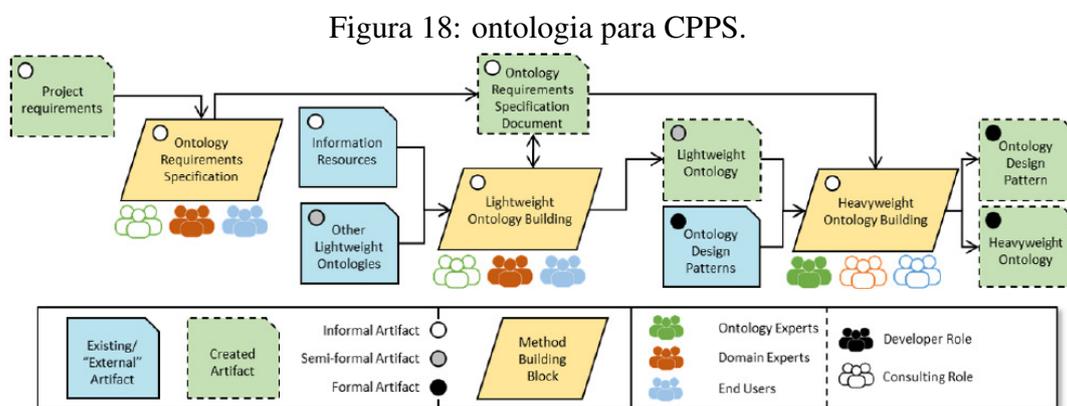


Fonte: (LOCHER; LASKEY; COSTA, 2020).

Os autores destacam a aplicação de lógica de primeira ordem em um modelo probabilístico, que possui basicamente três abordagens: descrição da lógica probabilística que está associada a representação do conhecimento, programação de lógica probabilística que envolve a incerteza, e um modelo de grafo probabilístico dividido em redes de Markov e redes Bayesianas. Neste estudo, uma característica chave apresentada pelos autores é que a capacidade de expressividade da lógica de primeira ordem permite modelar um

problema do domínio onde existe uma combinação de parâmetros que pode ser expressa numa rede Bayesiana (BN). Os autores destacam nessa pesquisa que a tabela de probabilidade local (LPD) presente na BN, e que define uma distribuição de probabilidade para as variáveis, passa a ser definida como sendo uma tabela de probabilidade condicional (CPT). Neste sentido, a LPD possui uma forma funcional que define uma distribuição de probabilidade condicional (LOCHER; LASKEY; COSTA, 2020).

Em (HILDEBRANDT *et al.*, 2020) é proposto uma classificação de ontologias em peso leve LWO (*Lightweight Ontology*) que modelam propriedades e seus relacionamentos, enquanto que as peso pesado HWO (*Heavy Weight*) possuem maior expressividade, conforme apresentado na Figura 18, envolvendo a representação de regras. O artigo utiliza como estudo de caso uma comparação entre duas normas da indústria como informação para formalização de conceitos.



Fonte: (HILDEBRANDT *et al.*, 2020).

No trabalho de (BENATIA; LOUIS; BAUDRY, 2020), os autores identificam a necessidade de extrair e categorizar os eventos que causam interrupção na produção, conforme apresentado na Figura 19. O trabalho busca fazer um agrupamento de itens frequentes, envolvendo alarmes que representam falhas ocorridas, com base no local específico definidos por regras a partir de um algoritmo Apriori, considerando um suporte mínimo.

No trabalho de (NOUIOUA *et al.*, 2021), uma abordagem aplicada em redes de telecomunicações para gerenciamento de falhas é apresentada. Os autores destacam que falhas podem causar uma série de eventos, que é uma mudança discreta de um estado do sistema, podendo gerar notificações, que são enviadas para os usuário destes sistemas como um alarme.

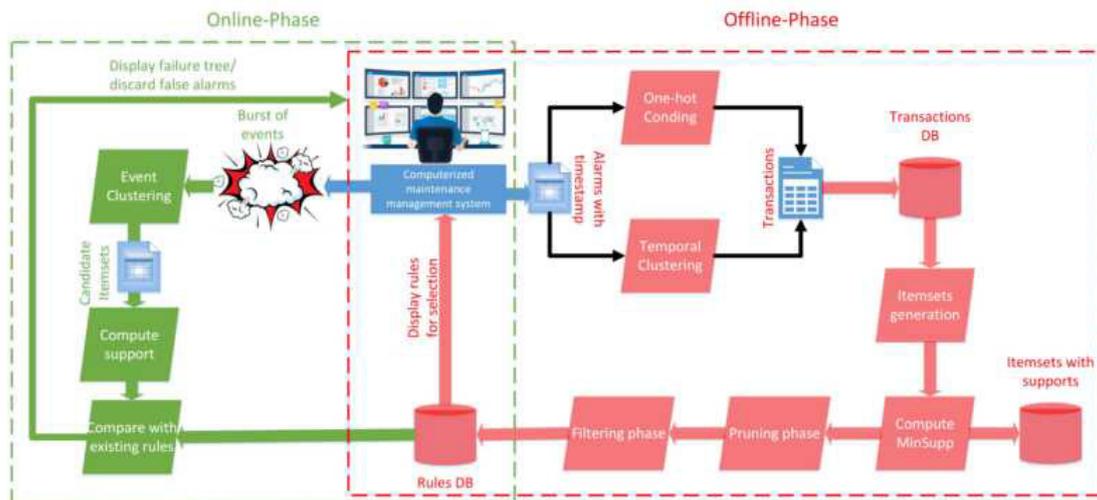
3.3.1.1 Considerações Finais

Os trabalhos apresentados nesta etapa e listados na Tabela 1 representam uma visão geral das publicações anteriores e que propõem em alguns casos, modelos baseados em cenários fictícios e não a um exemplo real de aplicação. Além disso, em sua maioria, os

Tabela 1: análise dos trabalhos relacionados a dimensão de informação e modelos semânticos.

Grupo →	Dimensão de Informação				Formalismo Semântico			Ambiente Modelado		Processo	
	Evento	Situação	Estado	Ação	OWL	SWRL	PR-OWL	Industrial	Outros	online	offline
Categoria											
Artigos											
	✓	✓	✓	✓	x	x	x	✓	x	x	x
(VARGA; SZEIFERT; ABONYI, 2010)	✓	✓	✓	x	✓	x	x	✓	x	x	✓
(LIMA <i>et al.</i> , 2013a)	✓	✓	✓	✓	✓	x	x	✓	x	✓	NA
(JIANFENG <i>et al.</i> , 2016)	✓	✓	✓	✓	x	x	x	✓	x	✓	NA
(CARVALHO; LASKEY; COSTA, 2016)	✓	✓	✓	✓	x	x	x	✓	x	x	✓
(SOARES <i>et al.</i> , 2016)	✓	✓	✓	✓	x	x	x	✓	x	✓	x
(EMANUEL <i>et al.</i> , 2017)	x	✓	✓	✓	x	x	x	✓	x	✓	✓
(YU <i>et al.</i> , 2017)	✓	✓	✓	✓	x	x	x	✓	x	x	✓
(HU; CHEN; SHAH, 2018)	✓	✓	✓	x	x	x	x	✓	x	✓	x
(SARNOVSKY <i>et al.</i> , 2018)	✓	✓	✓	✓	✓	x	x	✓	x	✓	NA
(LOCHER; LASKEY; COSTA, 2020)	✓	✓	✓	✓	✓	x	x	✓	x	✓	x
(HILDEBRANDT <i>et al.</i> , 2020)	✓	✓	✓	✓	✓	x	x	✓	x	✓	✓
(BENATIA; LOUIS; BAUDRY, 2020)	✓	✓	✓	✓	x	x	x	x	✓	x	✓
(NOUIOUA <i>et al.</i> , 2021)	✓	✓	✓	✓	x	x	x	x	✓	x	x

Figura 19: sistema de gerenciamento e manutenção do processo.



Fonte: (BENATIA; LOUIS; BAUDRY, 2020).

trabalhos mais recentes envolvendo semântica não objetivam a aplicação industrial. Alguns descrevem contextos para ambientes educacionais ou relacionado ao comportamento do usuário e não de um processo. Alguns trabalhos apresentam modelos de contexto baseados em ontologias, porém não buscam o uso de técnicas de mineração de dados ou de processos para identificação de padrões de eventos para serem avaliados.

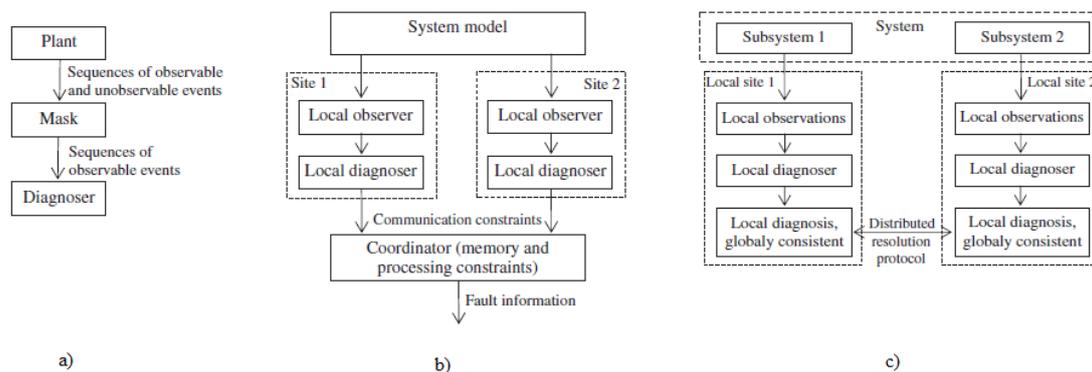
3.3.2 Inferência e Aprendizagem de Máquina

Durante a revisão bibliográfica, optou-se por dividir em duas tabelas os diferentes conceitos abordados nesta pesquisa. Com isso, a fim de chegar a algumas considerações, foram definidos os tópicos: tipo de inferência, que pode ser um teste de hipóteses ou uma estimativa; o método de inferência, que pode ser determinístico ou estocástico; o formalismo de grafo, que pode ser um DAG ou um modelo de Markov; uso de inteligência artificial, que representa o tipo de aprendizagem introduzido na Seção 2.6. Com relação a este último tópico, relacionado a AI, foram escolhidos os termos relacionados as técnicas de classificação ou de regressão (ZHIQIANG *et al.*, 2017).

No trabalho de (YIN *et al.*, 2012) um estudo de métodos, como PCA (*Principal Component Analysis*) ou ICA (*Independent Component Analysis*) é apresentado numa abordagem orientada a dados, no qual são utilizadas medidas estatísticas com limiares definidos manualmente. Essa implementação pode dificultar a utilização em larga escala, uma vez que é necessária uma análise individual para cada classe de falha. Destaca-se o uso do *benchmark* TEP (*Tennessee Eastman Process*) para gerar uma base de dados do processo simulado. Com base nos dados simulados a partir do TEP, este trabalho aplica uma técnica não paramétrica para estimativa da função densidade de probabilidade PDF (*Probability Density Function*).

No trabalho de (ZAYTOON; LAFORTUNE, 2013) uma visão geral sobre diferentes métodos aplicáveis para diagnóstico de falhas a partir de eventos discretos é apresentada. O artigo destaca que métodos diagnósticos para análise de falhas em processos tem avançado no sentido de construir modelos probabilísticos que forneçam uma distribuição de probabilidade. Nesta pesquisa é proposta uma análise do estado da arte sobre diagnóstico de falhas a partir de eventos discretos. Uma classificação dos métodos de diagnóstico em relação à arquitetura de decisão é apresentada dividida conforme a Figura 20. Observa-se que as arquiteturas, embora possuam capacidades distintas, todas consideram um modelo de inferência em comum, que são os conjuntos de eventos observáveis e não observáveis. Segundo os autores, o principal problema de uma arquitetura descentralizada apresentada na Figura 20b, é que os blocos que representam o *site1* e o *site2* podem descobrir simultaneamente a ocorrência de uma falha. Além disso, existe uma incerteza associada as informações disponíveis, que podem ser ambíguas, incompletas, apresentarem atraso e possivelmente apresentar erros.

Figura 20 – distinção entre arquiteturas para diagnóstico de falhas: a) centralizada; b) descentralizada e c) distribuída.



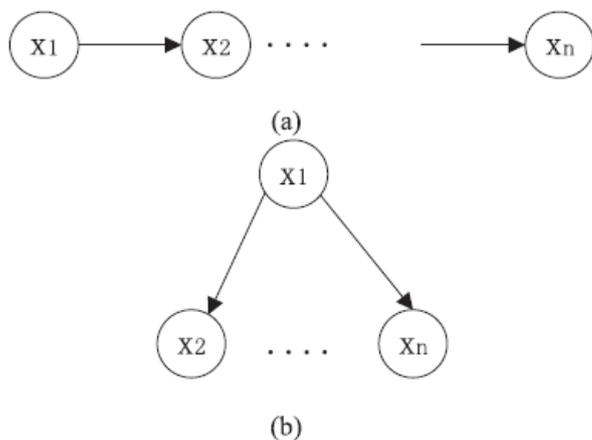
Fonte: (ZAYTOON; LAFORTUNE, 2013).

No trabalho de (CHEN; PETER; YAO, 2014) os autores utilizam uma janela deslizante para a técnica de detecção de falhas. O trabalho é centrado num modelo determinístico que busca diagnosticar as falhas do processo TEP sem possuir um conhecimento *a priori*, no qual uma rede neural é utilizada na classificação. Os autores apresentam os resultados do modelo de aprendizado supervisionado e, ao mesmo tempo, destacam que a principal contribuição do trabalho é o fato de não possuir um conhecimento *a priori* do número de falhas e tipos.

Em (WANG *et al.*, 2015), é apresentado um estudo que apresentou como objetivo a elaboração de um modelo hierárquico, a fim de determinar a causalidade de alarmes, conforme apresentado na Figura 21, ressaltando uma análise causal baseada em entropia. Os autores apresentam um *framework* conceitual e destacam a utilização de um cálculo da diferença entre *p-value* e uma distribuição *F-statistic* (MONTGOMERY, 2005) para definir

se existe ou não causalidade entre os dados de alarmes. Essa abordagem é implementada a partir de dados de uma processo químico de *Dimethylformamide* (DMF), reduzindo a média de alarmes apresentados por dia.

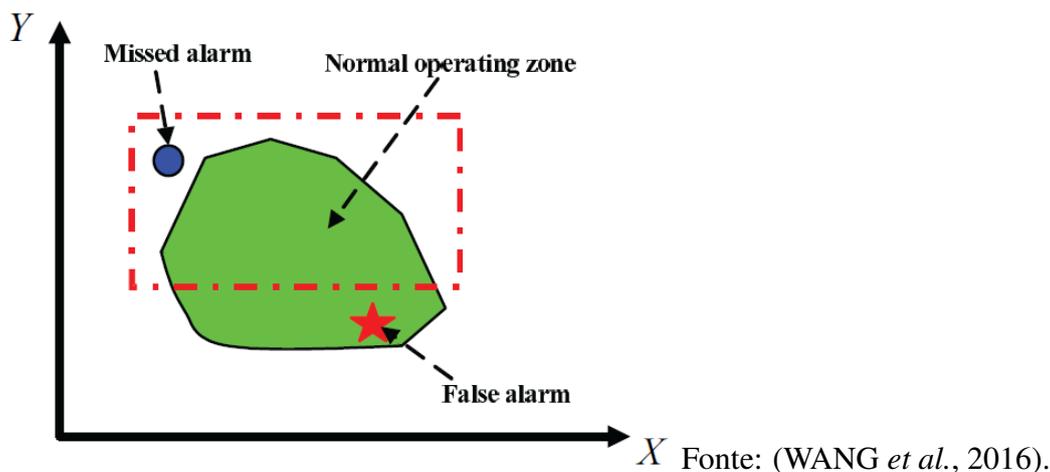
Figura 21: distinção entre topologias para análise causal: a) serial; b) paralelo.



Fonte: (WANG *et al.*, 2015).

No trabalho de (WANG *et al.*, 2016) uma visão geral dos sistemas de alarme industriais é apresentada, com destaque para as principais causas de sobrecarga de alarmes e a forma mais comum de detecção de um estado de alarme entre variáveis de processo relacionadas. O trabalho dos autores contribui com uma representação de uma zona operacional normal de duas variáveis correlacionadas configuradas como alarmes. Se os pontos de disparo de um alarme forem projetados de forma isolada, então uma área retangular é formulada, sendo inconsistente com a zona de operação normal. Como resultado, falsos alarmes podem estar presentes, conforme demonstrado como uma estrela na Figura 22.

Figura 22: diagrama esquemático de um estado normal com isolamento de falsos alarmes.

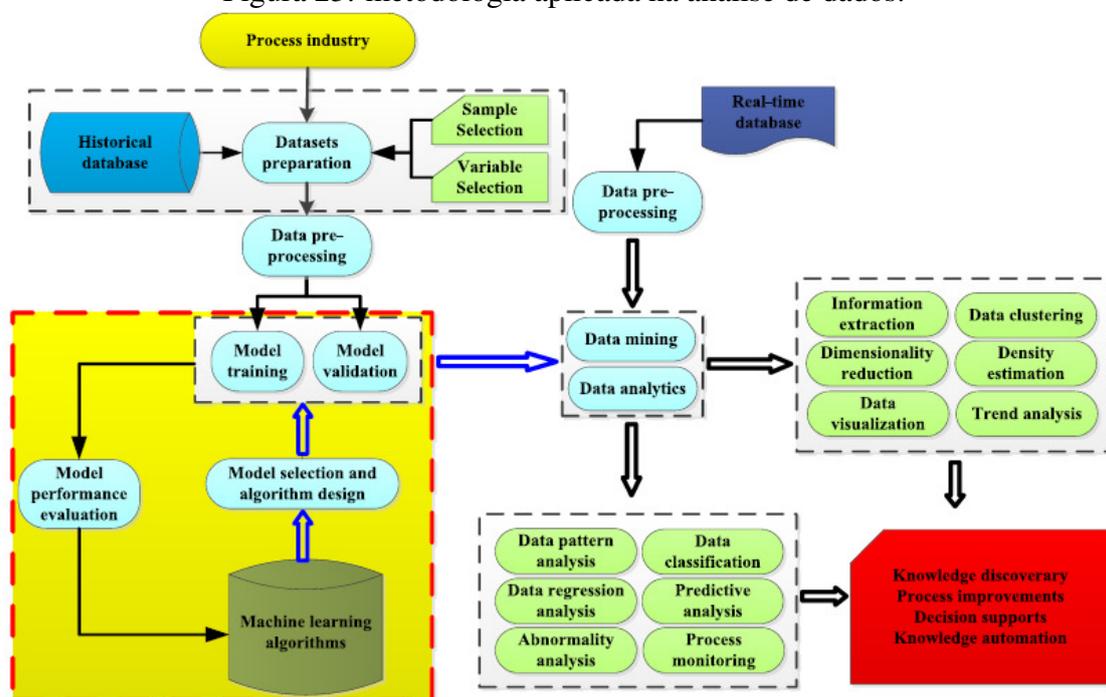


Fonte: (WANG *et al.*, 2016).

Segundo (ZHIQIANG *et al.*, 2017), sobre o ponto de vista da automação industrial, mineração de dados e ML surgem como ferramentas promissoras voltadas para atender ao

dinamismo existente neste domínio. Conforme demonstrado na Figura 23, *Data Mining* e *Data Analytics* são utilizados numa abordagem que permite avaliar se um padrão ou uma falha ocorreu a partir de dados detectados, e permite fornecer subsídios para os responsáveis pelos processos entender a condição operacional e estabelecer uma estratégia de ação ou até mesmo de manutenção adequada em um tempo hábil. Os autores apresentam que os métodos de aprendizagem de máquina supervisionado e não supervisionado correspondem o maior número de aplicações em processos industriais. Contudo, os autores não destacaram a existência de métodos de aprendizagem aplicando redes neurais para gerar uma recomendação a partir de evidências.

Figura 23: metodologia aplicada na análise de dados.

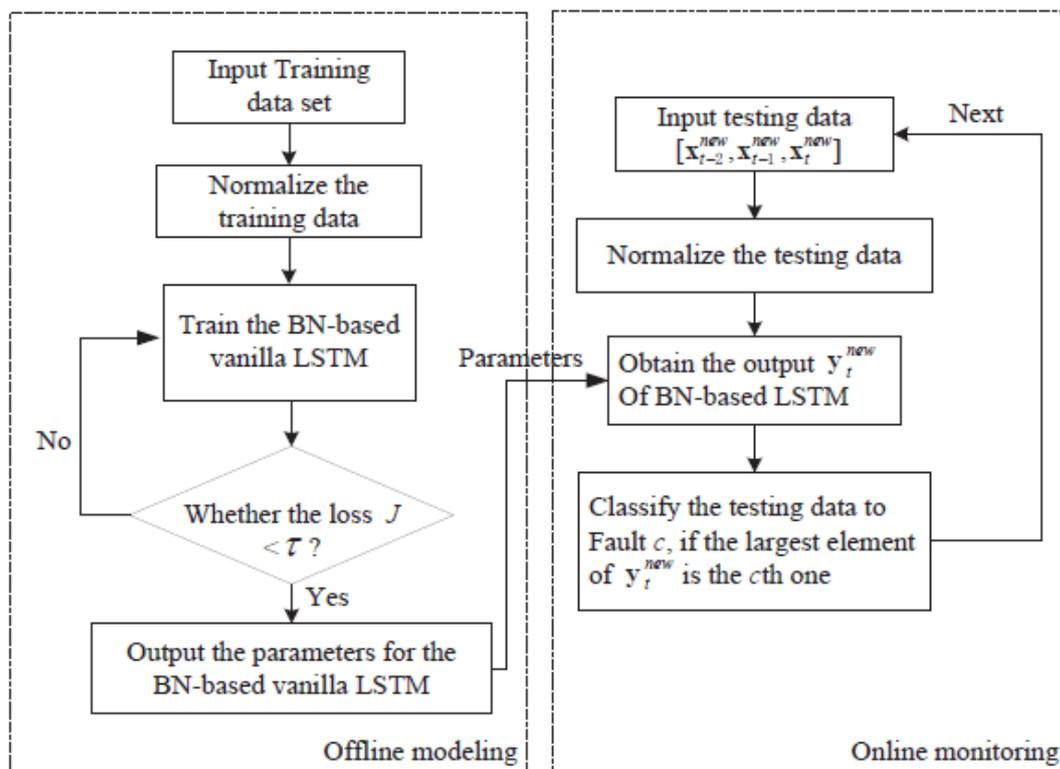


Fonte: (ZHIQIANG *et al.*, 2017).

No trabalho de (HAITAO; SHAOYUAN; BO, 2018) os autores propõem um método de diagnóstico de falhas baseado em LSTM avaliado pelo *benchmark* TEP com uma abordagem de classificação e uma normalização de lote para melhorar a convergência. As etapas online e offline apresentadas na Figura 24, segundo os autores, dependem de um número predefinido de iterações. Foi sugerido para antes do treino da rede um processo de normalização em lotes de dados permitindo um processo de convergência mais atrativo, segundo os autores, em comparação com a LSTM tradicional. Contudo, os autores apresentam na conclusão uma capacidade do modelo em treinar com dados brutos e classificar as falhas simultaneamente.

No trabalho em (ZHANG *et al.*, 2018) uma revisão sobre RBM que considera variações no algoritmo para evitar o sobreajuste ao atualizar os pesos da rede neural é apresen-

Figura 24: metodologia aplicada na análise de dados.



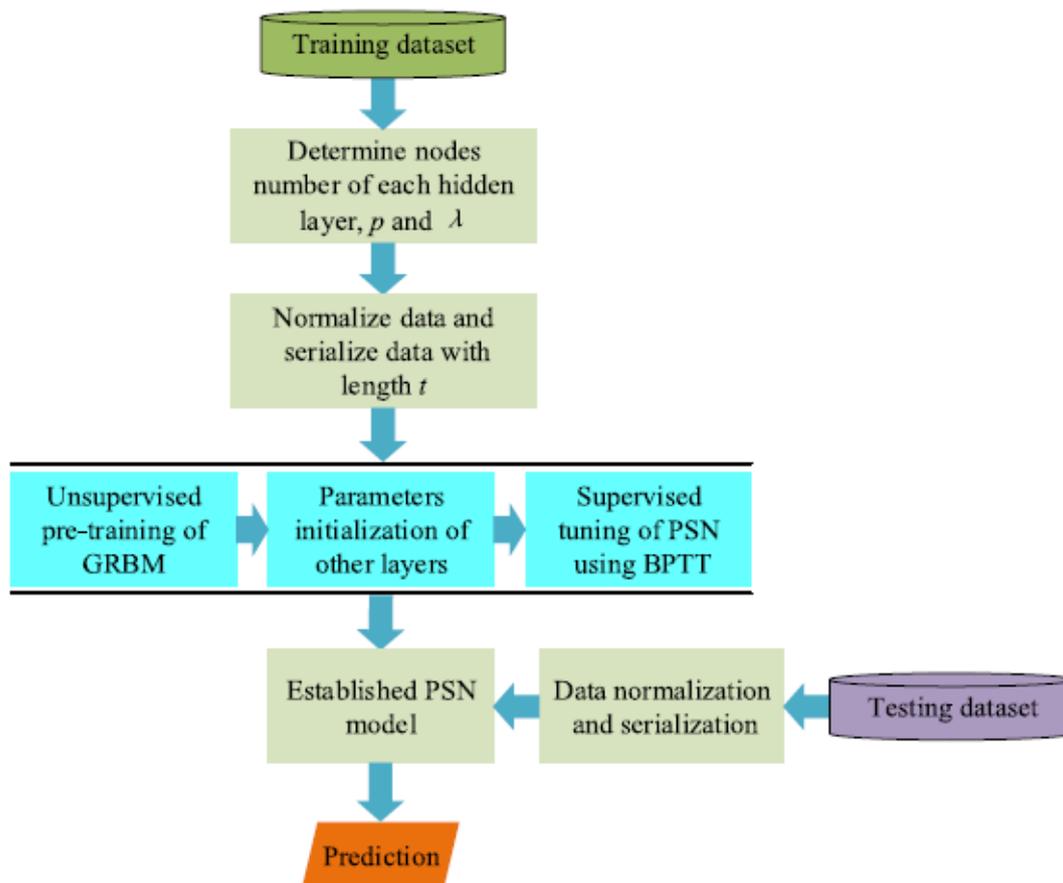
Fonte: (HAITAO; SHAOYUAN; BO, 2018).

tada. Além disso, a implementação com tensores permite o reduzir o número de parâmetros no modelo. Esses tensores são matrizes simples que contêm elementos de um único tipo de dado (ABADI *et al.*, 2016). No entanto, este é um artigo teórico que aborda sobre a dependência nos dados, possibilitando a construção de um modelo preditivo.

No trabalho de (QINGQIANG; ZHIQIANG, 2019), os autores apresentam uma abordagem probabilística utilizando GRBM (*Gaussian-Bernoulli restricted Boltzmann machine*) e RNN (*Recurrent Neural Network*). Este artigo propõe uma abordagem denominada rede probabilística sequencial, na qual uma rede LSTM recebe parâmetros de uma RBM num processo de maximização da *log-likelihood*. Um *Flowchart* da arquitetura apresentada pelos autores é apresentado na Figura 25. O artigo contribui com uma representação do sentido da aprendizagem não supervisionada para supervisionada, utilizando o algoritmo CD (*Contrastive Divergence*) no processo de aprendizagem da RBM Gaussiana (GRBM). Na proposta apresentada pelos autores, dados de um processo industrial químico são utilizados para treino, sendo aplicada uma janela deslizante. Os autores sugerem que a metodologia apresentada permite que se tenha uma menor proporção de dados reservados para treino.

No trabalho de (AZIZ *et al.*, 2019), os autores aplicam um modelo a partir de um algoritmo de inferência Bayesiana para prever situações de risco e realizar uma análise

Figura 25: *flowchart* da metodologia desenvolvida aplicando redes neurais.



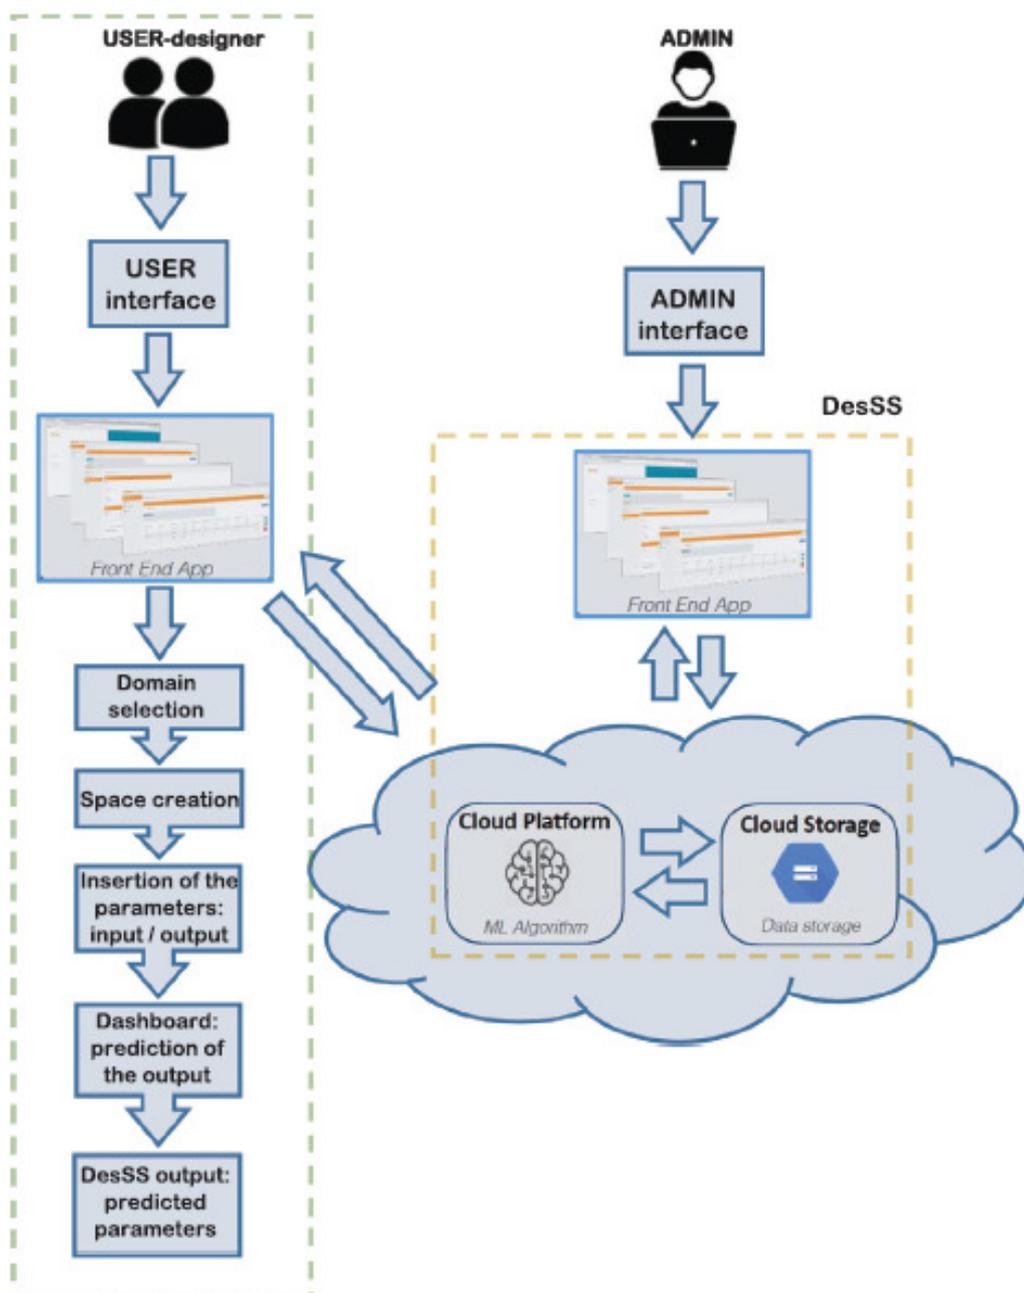
Fonte: (QINGQIANG; ZHIQIANG, 2019).

probabilística. Os autores apresentam um conjunto de evidências para investigação de acidentes ocorridos em processos químicos. No entanto, este estudo inclui uma base de conhecimento desenvolvida exclusivamente com a opinião de um especialista. Além disso, o modelo proposto pelos autores não é voltado para situações preditivas avaliadas em um tempo específico, apresentando apenas características de uma abordagem Bayesiana típica que, embora permita a atualização do modelo a partir de novos conhecimentos, não explora aspectos temporais em relação aos dados, que é uma das vantagens da aplicação da MEBN, onde redes Bayesianas são apresentadas como situações específicas.

No trabalho de (ROMEO *et al.*, 2020), os autores apresentam uma abordagem com aplicação de árvore de decisão aplicada para classificação, cuja intenção é entender por que um determinado elemento foi atribuído a uma determinada classe. O *framework* da abordagem a partir de algoritmos que foram encapsulados em uma plataforma na nuvem, que representa o núcleo principal da arquitetura implementada é apresentado na Figura 26. O processo de aprendizagem de máquina proposto pelos autores se concentra na abordagem de uma árvore de decisão, aplicando um o valor de *Gini index* para avaliar a melhor divisão nas ramificações e a pureza dos nós. Na abordagem KNN (*k-Nearest*

Neighbors), os autores sugerem que uma motivação para escolha dessa abordagem é um menor esforço computacional na fase de treino. Contudo, não foi mencionado no artigo que no processo de inferência, os dados são classificados a partir de um processo de associação com base na frequência de ocorrência dos vizinhos mais próximos, de forma que o algoritmo encontra o número de clusters que se deseja, mesmo que para isso sejam considerados atributos irrelevantes.

Figura 26: *flowchart* da metodologia desenvolvida aplicando processamento em nuvem.



Fonte: (ROMEO *et al.*, 2020).

No trabalho de (ASRES *et al.*, 2021), é apresentada uma abordagem de gerenciamento

de alarmes voltada para sistemas de telecomunicações. Os autores aplicam ML no paradigma de aprendizagem supervisionado para classificar dados de alarmes de uma rede móvel ocorridos num período de 6 meses, sendo que foram aplicados dados de 4 meses para treino e de 2 meses para testes. O problema de classificação de dados envolve o processamento de fluxos de eventos, os quais indicam padrões e regularidades. O classificador é baseado em árvore de decisão, o qual permite extrair características dos alarmes. Contudo, a proposta não considera gerar recomendações frente às demandas do operador e necessita do rótulo de classificação e ser retreinada para aprender novos alarmes. Dessa forma, tal proposta não aborda o aprendizado não supervisionado no que diz respeito a capacidade de extrair características a fim de suprir a limitação destacada pelos os autores.

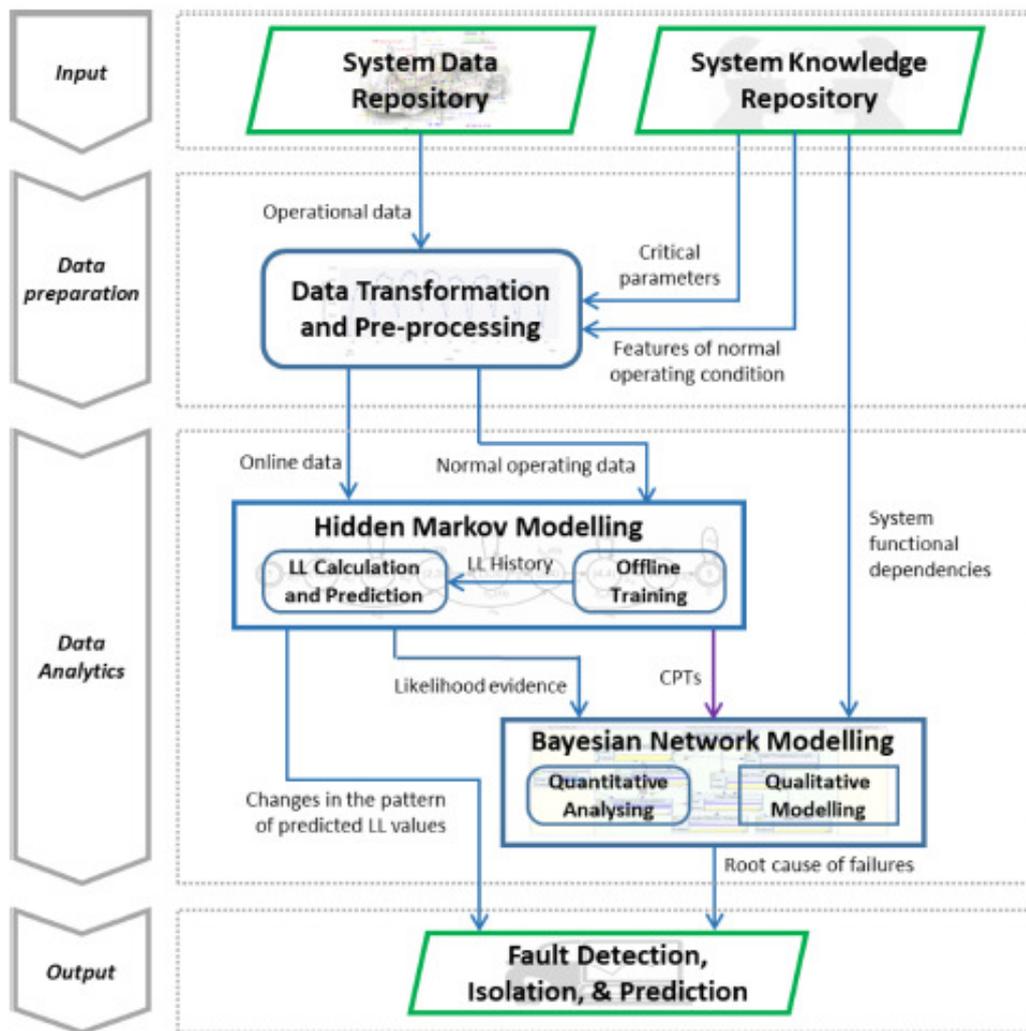
No trabalho de (SOLEIMANI; CAMPEAN; NEAGU, 2021), os autores apresentam uma abordagem probabilística utilizando um modelo de Markov e uma BN. Um fluxo do processo de detecção, isolamento e predição de falhas, utilizando uma tabela de probabilidade condicional, cujos parâmetros são invariantes no tempo é apresentado na Figura 27. Uma estrutura que concentra o processo de aprendizagem em uma etapa descrita como *Data Analytics*, logo após a etapa de preparação dos dados operacionais é apresentada neste trabalho. Um sistema automotivo é apresentado como estudo de caso pelos autores, sendo que os dados avaliados são oriundos da ECU (*Electronic Control Unit*). Os autores destacam que, diferentemente de um processo TEP, os mecanismos de falha e os aspectos relacionados aos estados normal e em falha nem sempre são conhecidos ou estão disponíveis. Além disso, é proposta uma metodologia que busca reduzir a incerteza na predição a partir da avaliação de padrões de dados. Essa proposta tem características relacionadas a abordagem Bayesiana.

No trabalho de (YANG *et al.*, 2021), os autores propõem um método de BN baseado em dados capaz de lidar com evidências observáveis consideradas para prever variáveis de risco. Este trabalho busca evitar grandes tabelas de probabilidade condicional (CPTs) e, com isso, reduzir o trabalho de cálculo para as variáveis de risco de nível intermediário.

No trabalho de (MAO *et al.*, 2021), os autores apresentam uma abordagem probabilística utilizando RNN (*Recurrent Neural Network*). Técnicas para avaliar sob cada domínio, os diferentes padrões presentes em um modelo de previsão de eventos, combinando diferentes tipos de eventos são apresentadas neste artigo. Regras de causalidade que envolvem eventos causais específicos, conforme representado na Figura 28 são apresentadas neste trabalho.

No trabalho de (TERZIYAN; VITKO, 2022), uma abordagem que permite gerar regras semânticas por meio de árvore de decisão, aplicando um plugin denominado XAI (*Explainable AI*) é apresentada. Uma análise de regras de decisão aplicadas para um cenário industrial é apresentada. A ideia principal do trabalho apresentado pelos autores é um modelo aplicado para classificação aplicando regras de decisão. Contudo, a proposta não deixa claro se foi implementada uma ontologia ou se foram reutilizadas classes

Figura 27: *flowchart* da metodologia desenvolvida aplicando redes neurais.



Fonte: (SOLEIMANI; CAMPEAN; NEAGU, 2021).

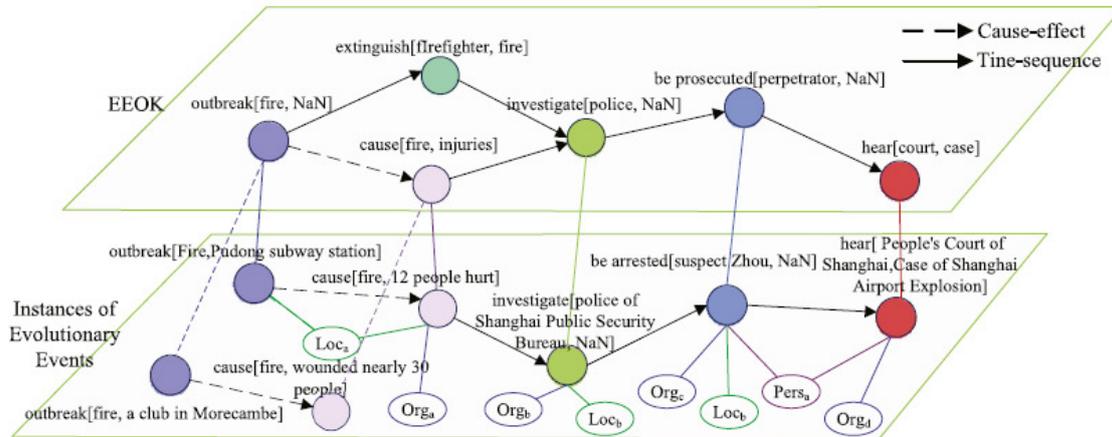
e propriedades de outras ontologias de domínio e, com isso, permitindo a aplicação de *Semantic Web Rule Language* - SWRL, que permite a identificação de uma situação que está ocorrendo no presente. Sendo assim, tal projeto é diferente do trabalho apresentado nesta tese, o qual visa o tratamento da incerteza existente diante das situações de interesse e que envolve os eventos que ocorrem no ATS.

3.3.2.1 Considerações Finais

A maioria das pesquisas que aplica inferência no processo de raciocínio busca utilizar estimativas. Além disso, um processo de definição de regras não é uma tarefa simples, que envolve, em geral, atividades que nem mesmo o operador consegue descrever com detalhes o que está fazendo, levando inclusive a um esforço ainda maior quando é necessário um processo de mudança no domínio.

MEBN fornece uma maneira flexível para tratar essa questão envolvendo variáveis e

Figura 28: representação da abordagem do conhecimento em relação aos eventos.



Fonte: (MAO *et al.*, 2021).

CPTs, a partir de LPDs apresentadas na Seção 2.6.3. Observa-se que existe uma lacuna com relação à inclusão de um modelo de contexto que defina um conjunto de estados do ambiente e os modelos apresentados nos trabalhos relacionados, que permita inferir situações a partir da análise de contexto e esta lacuna será explorada nesta tese.

Tabela 2: análise dos trabalhos relacionados a Inferência e ML.

Grupo →	Tipo de Inferência		Método de Inferência		Modelo Gráfico		Inteligência Artificial			
	Estimação	Outros	Determinístico	Estocástico	Outros	DAG	Cadeia de Markov	Outros	Classificação	Regressão
Categoria	Teste de Hipóteses									
Artigos										
(YIN <i>et al.</i> , 2012)	x	✓	✓	x	x	x	x	x	✓	x
(ZAYTOON; LAFORTUNE, 2013)	x	✓	✓	✓	x	x	✓	x	x	x
(CHEN; PETER; YAO, 2014)	x	✓	✓	x	x	x	x	x	✓	x
(WANG <i>et al.</i> , 2015)	x	✓	✓	x	x	x	✓	x	x	✓
(WANG <i>et al.</i> , 2016)	✓	x	x	✓	x	x	x	✓	✓	x
(ZHANG <i>et al.</i> , 2018)	x	✓	x	✓	x	x	✓	x	✓	x
(HAITAO; SHAOYUAN; BO, 2018)	x	✓	x	✓	x	x	x	✓	✓	x
(QINGQIANG; ZHIQIANG, 2019)	x	✓	x	✓	x	✓	x	x	x	✓
(AZIZ <i>et al.</i> , 2019)	x	✓	✓	x	x	✓	x	x	x	x
(ROMEO <i>et al.</i> , 2020)	x	✓	x	x	✓	x	x	✓	✓	x
(ASRES <i>et al.</i> , 2021)	x	✓	✓	x	x	x	x	x	✓	x
(SOLEIMANI; CAMPEAN; NEAGU, 2021)	x	x	x	✓	x	✓	x	x	✓	x
(YANG <i>et al.</i> , 2021)	x	✓	✓	x	x	✓	x	x	x	x
(MAO <i>et al.</i> , 2021)	x	✓	x	x	x	x	x	✓	x	✓
(TERZIYAN; VITKO, 2022)	x	✓	✓	x	x	x	x	✓	✓	x

4 ABORDAGEM PROPOSTA

4.1 Visão Geral do Capítulo

O detalhamento da pesquisa com a especificação do modelo elaborado na presente Tese de Doutorado será apresentado neste capítulo.

4.2 Introdução

A presente tese aborda etapas principais que tratam as oportunidades de pesquisa avaliadas na literatura. Inicialmente foram estudados os principais autores sobre modelos ontológicos e aprendizagem de máquina, conforme apresentado nos capítulos anteriores. Com isso foi possível alinhar o objetivo deste estudo para as abordagens que apresentavam aspectos não abordados nos trabalhos relacionados, diante do problema identificado.

A abordagem desta tese permite a elaboração de um modelo preditivo que possibilita inferir sobre os eventos presentes em uma situação. Um modelo de apoio orientado à predição necessita de um mecanismo de inferência, que possa proceder um raciocínio probabilístico e gerar recomendações, a partir da especificação de uma base de conhecimento. Para arquitetura deste modelo, é proposta uma abordagem aplicável em um Sistema Técnico Automatizado, do inglês ATS (*Automated Technical System*).

Uma metodologia que explora modelos probabilísticos é apresentada nesta tese. A Figura 29 apresenta uma visão geral da proposta desenvolvida. Os componentes relacionados ao processo offline presentes na arquitetura fazem parte da metodologia proposta nesta tese, com base nos resultados e propostas interessantes dos trabalhos relacionados trazidos dos capítulos anteriores.

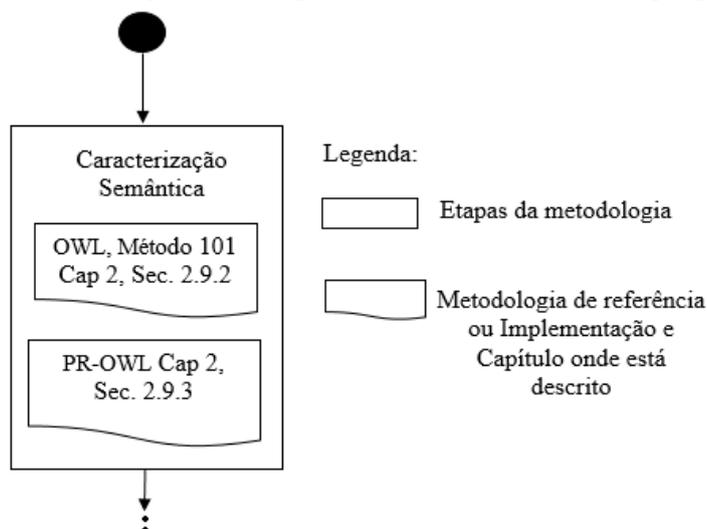
4.3 Etapas do desenvolvimento da proposta

O modelo proposto especifica uma metodologia mais abrangente, que inicia-se a partir da caracterização semântica e que envolve o entendimento do domínio. Assim, entende-se que os requisitos de engenharia, bem como a definição de um problema e um plano preliminar para atingir os objetivos podem ser implementados a partir de um modelo

ção teórica, nesta tese é desenvolvida uma ontologia LWO para ATS. Uma modelagem que aplica ontologias envolve conceitos, e estes possuem aspectos que nem sempre são expressos de forma suficiente. De todo modo, é possível incluir algumas regras e axiomas em uma LWO. Na comparação direta com (HU; CHEN; SHAH, 2018) e (BEZERRA *et al.*, 2018), observou-se que os trabalhos relacionados não fornecem subsídios semânticos comparados ao modelo apresentado nesta tese.

A etapa de caracterização semântica, conforme representado na Figura 30, leva em consideração a elaboração de uma ontologia de domínio (OWL) seguida de uma ontologia probabilística (PR-OWL). Neste estudo, softwares *open source* são aplicados para ambas as modelagens. Uma ontologia é apresentada nesta tese como sendo uma representação das entidades pertencentes ao domínio e seus relacionamentos.

Figura 30: etapas do desenvolvimento da proposta.



Fonte: autor.

Conforme demonstrado na Tabela 1, existe uma lacuna a ser explorada em relação a modelos ontológicos probabilísticos identificados nesta tese como relevantes para ATS, pois uma ontologia de domínio permite a especialização de conceitos classificados em outros níveis de conceituação. Diante das oportunidades de melhoria, em relação à dimensão de informação, foram considerados os trabalhos de (HILDEBRANDT *et al.*, 2020) na definição da ontologia LWO, (LOCHER; LASKEY; COSTA, 2020) e (CARVALHO; LASKEY; COSTA, 2016) na determinação do formalismo semântico. Nas subseções a seguir, são apresentadas as diferentes etapas e as justificativas que levaram à esta proposta de tese.

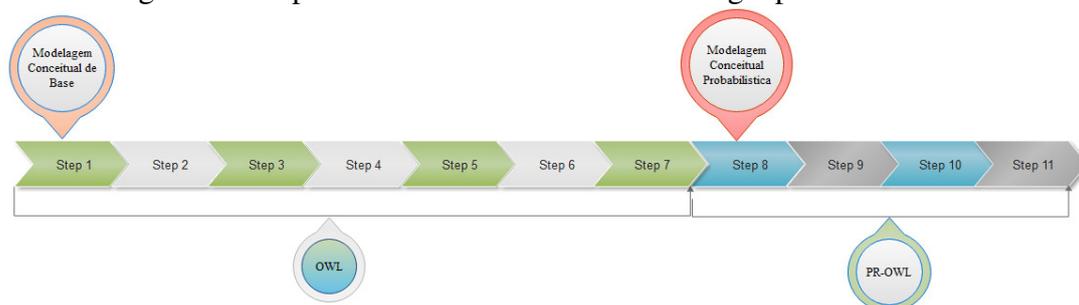
Na etapa de modelagem, que antecede a implementação aplicando uma linguagem da Web Semântica, são delineados os elementos contextuais que irão permitir que a informação obtida do domínio seja identificada em uma situação. Em seguida, foram utilizadas as linguagens OWL-DL e PR-OWL, que permitem executar um conjunto de estruturas de modelagem e representação do conhecimento. Para inferências de relações definidas na

estrutura do modelo, e que é baseada na identificação de informações de interesse, um modelo ontológico de contexto foi escolhido, pois permite uma especificação dos dados presentes em um contexto e das hipóteses avaliadas. Essas hipóteses estão relacionadas ao contexto e a forma como este contexto envolve as situações presentes em um domínio.

Situações envolvem eventos, que podem alterar os estados de um ATS e, com isso, resultar em novas situações. Assim, a ontologia delimita o escopo à medida que define quais os eventos participam de uma determinada situação.

Os passos na elaboração de uma ontologia seguem o método 101 apresentado na Seção 2.9.2, representados na Figura 31, e permitem estabelecer um entendimento sobre o domínio a partir da especificação de um modelo conceitual. A etapa seguinte é a modelagem probabilística, que tem como base o estudo apresentado por (CARVALHO; LASKEY; COSTA, 2016), definida em quatro etapas, sendo a análise de requisitos, a elaboração de um modelo conceitual probabilístico, a implementação deste modelo e os testes. Essas etapas representam um processo de modelagem de ontologias probabilísticas, cuja implementação é apresentada no próximo capítulo.

Figura 31: etapas do desenvolvimento da ontologia probabilística.



Fonte: autor.

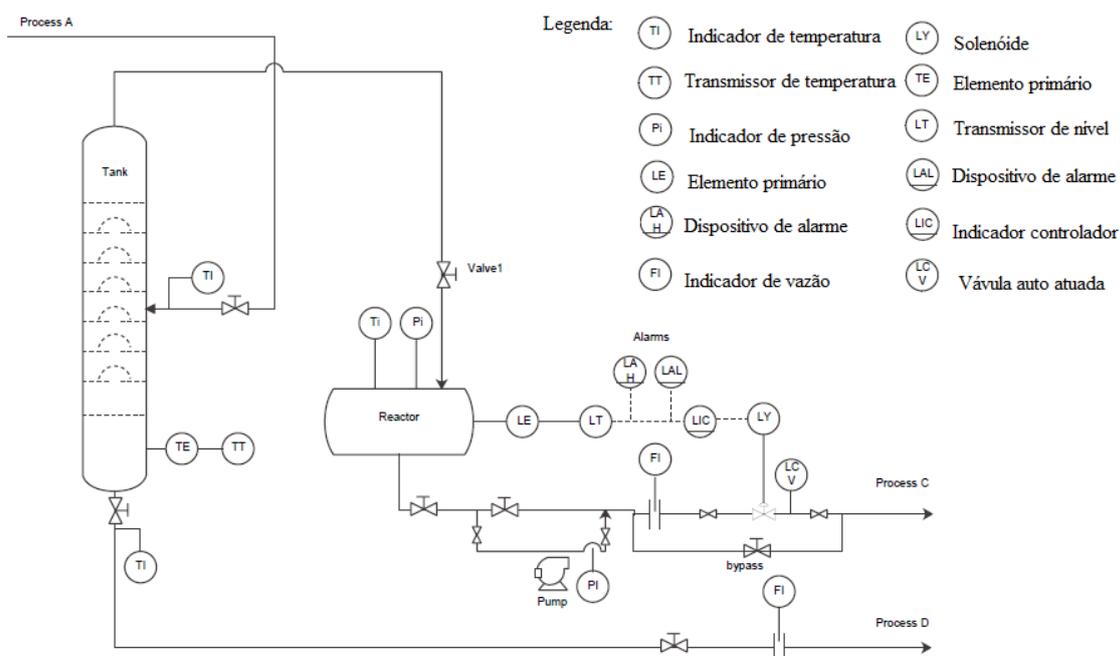
No processo de modelagem e implementação ontológico, seguindo conforme representado na Figura 31, inicia-se com uma questão sobre qual o domínio está sendo tratado. Em seguida é considerado o reuso de ontologias existentes, sendo possível remodelar para o domínio em questão. Um requisito importante nesse passo é que, caso exista uma ontologia com a qual o sistema deva interagir, por exemplo se esse modelo proposto interage com outros sistemas que já utilizam uma ontologia, essa deve ser considerada no modelo. Para o passo seguinte, é importante implementar uma descrição em um vocabulário, que pode ser feita por exemplo por um especialista no domínio, descrevendo os termos que compõe a ontologia. Essa etapa possibilita manter uma documentação sobre o modelo, sendo possível adotar os recursos das ferramentas que serão apresentadas ao longo desta tese, que apresentam inclusive campos e diagramas que auxiliam na visualização durante a construção do modelo. No passo quatro é prevista a definição das classes, e que segue para o passo cinco, que é etapa onde é feita a definição das propriedades que permi-

tem representar um relacionamento entre instâncias das diferentes classes. Ainda sobre a definição das classes, nesse passo é utilizado o vocabulário com os respectivos termos definidos no passo três. No passo seis, são definidas características para as propriedades. O último passo da modelagem conceitual de base é usado para a criação de instâncias individuais para as classes.

A linguagem OWL-DL possui como extensão a lógica descritiva FOL, apresentada na Seção 2.9. Isso permite construir sentenças que possuem um significado no domínio. Contudo, as interpretações sobre os axiomas presentes em um domínio são afetadas pelas relações entre conceitos, e isso está associado a presença da incerteza. Na figura Figura 31 é representada uma sequência de etapas descritas no parágrafo anterior, destinadas a um propósito voltado para construção de um modelo ontológico probabilístico para predição de situações que estão presentes em um domínio. Uma rede Bayesiana pode ser usada para tratar a questão que a FOL possui em relação a incerteza presente em abordagens preditivas. Para isso, a construção de um modelo ocorre a partir das informações do domínio e combina a representação dos tipos de entidades que fazem parte deste domínio, descritos em OWL-DL, com o tratamento de incerteza coberto por um raciocínio aplicando PR-OWL.

Para descrever a modelagem de uma ontologia probabilística, é apresentado um exemplo hipotético para um processo industrial, conforme apresentado na Figura 32.

Figura 32: processo industrial hipotético.

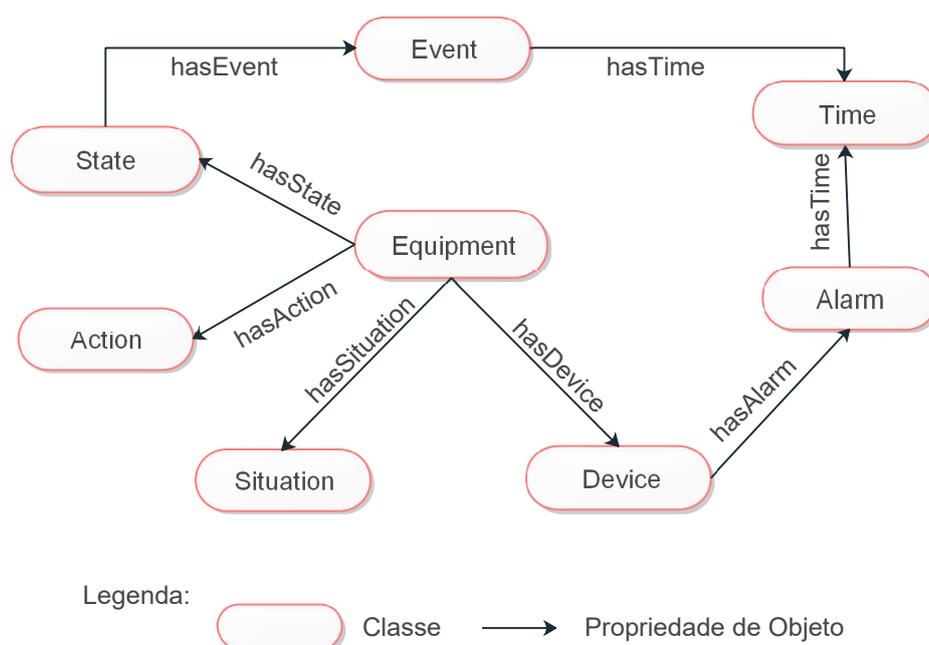


Fonte: autor.

A ontologia apresentada na Figura 33, descreve os conceitos que representam em

OWL a semântica de contexto para um domínio específico, implementada para o auxílio em um processo de tomada de decisão para o exemplo em questão. Com relação às ontologias existentes para sistemas de manufatura e/ou para controle de processos, destaca-se que nesta tese é proposta uma ontologia de domínio, a partir das referências listadas na Tabela 1, entre elas (LIMA *et al.*, 2013a), (LIMA *et al.*, 2013b) e (LIMA, 2014), com diferentes conceitos que foram observados durante a construção deste exemplo, mas eventualmente outras ontologias poderiam ser utilizadas. Após criadas as classes da ontologia, são criadas as propriedades conforme representado na imagem. As propriedades de objeto são atributos comuns aos membros de uma determinada classe. Essas propriedades são nós residentes em PR-OWL e, com isso, permitem estabelecer uma distribuição de probabilidade local (LPD) para os respectivos nós.

Figura 33: visão sumarizada do modelo ontológico para um exemplo hipotético.



Fonte: autor.

Os conceitos e as instâncias presentes neste exemplo são:

1. *equipment*: usado para descrever os equipamentos presentes nos processos. Neste exemplo são incluídas as instâncias de equipamento para o processo *B* como sendo: *reactor*, *tank* e *pump*;
2. *state*: usado para descrever os estados do ATS. Neste exemplo são incluídas as instâncias de estado como sendo: *normal*, *shutdown* e *upset*;

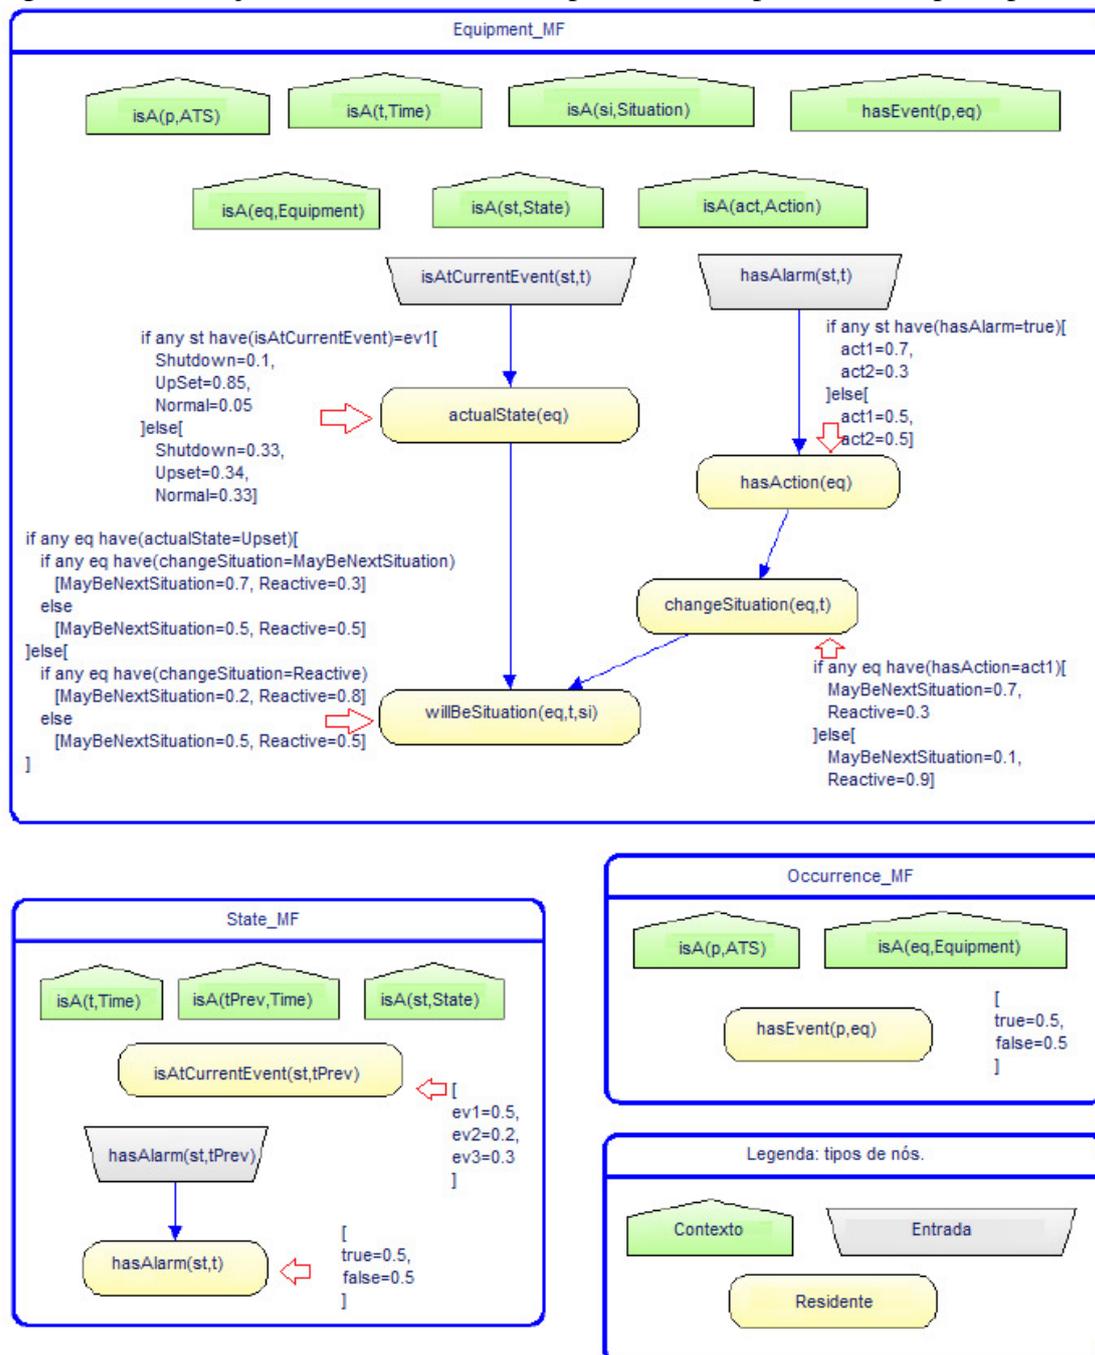
3. *alarm*: usado para descrever os alarmes. Neste exemplo são incluídas as instâncias de alarme como sendo: *alarm1*, *alarm2* e *alarm3*;
4. *event*: usado para descrever os eventos. Neste exemplo são incluídas as instâncias de evento como sendo: *ev1*, *ev2* e *ev3*;
5. *action*: usado para descrever as ações. Neste exemplo são incluídas as instâncias de ação como sendo: *act1* e *act2*;
6. *situation*: usado para descrever as situações. Neste exemplo é incluída a instância de situação como sendo: *reactive* e *maybeNextSituation* ;
7. *device*: usado para descrever os dispositivos. Neste exemplo são incluídas as instâncias de dispositivo como sendo: *sensor1*, *sensor2* e *sensor3*;
8. *time*: usado para descrever unidades de tempo discreto. Neste exemplo são incluídas duas instâncias de tempo como sendo: *t0* e *t1*;

Na etapa seguinte, temos a modelagem conceitual probabilística, apresentada na Subseção 2.9.3. A partir das informações do domínio, o modelo especifica os tipos de entidades que o compõe, que são os eventos que ocorrem nesse domínio e a incerteza. Para isso, são gerados fragmentos (*MFragments*) em uma PR-OWL. Existem 3 tipos de nós em um fragmento. Neste trabalho é apresentado que o nó Residente classifica variáveis aleatórias e possui uma distribuição de probabilidade local definida na LPD. Nó de Entrada, é uma variável que pode influenciar a distribuição de probabilidade de um nó Residente, enquanto que o nó de Contexto, define restrições que permitem validar as MFragments, podendo assumir valores booleanos.

Esses nós representam o conhecimento que vincula as propriedades, por exemplo, *hasEvent* de um equipamento e *hasAlarm*. Durante a modelagem, a propriedade *hasAlarm* recebe um argumento *st* que se refere ao estado da planta. Assim, o nó recebe como argumento uma variável. Em seguida são inseridos os estados, que podem ser valores booleanos. O passo seguinte é a definição de uma distribuição local para *hasAlarm*, na qual é inserido um valor de probabilidade *a priori* sobre um estado, com a indicação de presença de um evento nesse estado em um momento no tempo. A *MTheory* completa para esse exemplo é apresentada na Figura 34, sendo que as distribuições de probabilidade locais (LPDs) estão indicadas por setas para os respectivos nós.

Neste exemplo, o processo denominado *B* representado na Figura 32 recebe como entrada um produto vindo do processo *A*, e apresenta duas saídas a partir do tanque, sendo uma passando pelo reator em direção ao processo *C*, e a outra que segue para o processo *D*. Na configuração dos alarmes consta o monitoramento de nível e a vazão no reator. Estes são apresentados em um painel para os operadores, sendo definido o *Alarm1* para o sinal de vazão *ev3* representado na direção do processo *C*, e que está relacionado

Figura 34: construção do modelo conceitual probabilístico para um exemplo hipotético.



Fonte: autor.

ao nível do reator *Alarm2*, a partir do *ev1* (Sensor1) que é apresentado como evidência, e ao funcionamento da bomba.

Em relação ao funcionamento do processo, é possível controlar a vazão através do *setpoint* da bomba. Também é possível controlar a partir da válvula moduladora, instalada na tubulação em questão, cujo procedimento é denominado *act1*. Neste cenário hipotético, foi estabelecido um procedimento para o final da produção que envolve o fe-

chamento da válvula presente na entrada do reator, sendo esse procedimento denominado *act2*.

4.3.2 Definição de Contexto

A análise de dados e a extração de conhecimento têm sido uma abordagem frequente em diversas pesquisas, conforme apresentado nos capítulos anteriores. Optou-se neste âmbito pelas metodologias existentes KDD e CRISP-DM, sendo usadas de forma combinada, para análise das sequências de eventos de interesse, permitindo identificar por exemplo uma avalanche de alarmes em um ATS (SILVA; PEREIRA; GÖTZ, 2018). Uma das áreas que se beneficia da aplicação destas metodologias é o Aprendizado de Máquina (ou Machine Learning - ML). Neste sentido, é necessário estabelecer um processo de mineração de dados antes de implementar um processo de aprendizagem de máquina. As etapas desta abordagem seguem conforme representado na Figura 35.

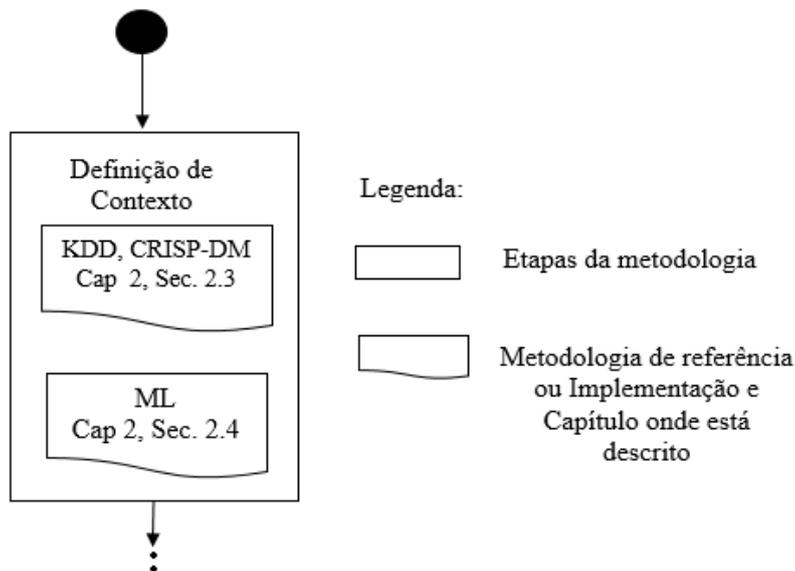
O processo de KDD envolve a elaboração de um perfil (*profile*) dos dados através de estatísticas para saber, por exemplo, quantas instâncias estão presentes num conjunto de dados. Pacotes específicos para aplicações em software *open source* permitem avaliar um sumário, que apresenta todas as estatísticas relacionadas ao conjunto de dados avaliado. A metodologia CRISP-DM aplicada para mineração de dados, considera dados do processo consolidados em um arquivo. Esses são processados por ferramentas de software citadas acima e/ou em linguagens de programação de código aberto. As manipulações de dados que combinam KDD e CRISP-DM nas etapas de avaliação dos dados, pré-processamento e visualização apresentadas neste estudo, utilizam as linguagens e ferramentas destacadas nos trabalhos relacionados. A opção por essas linguagens ocorreu em função do uso de pacotes de computação e geração de gráficos observados nos trabalhos relacionados, e que serão apresentados nos estudos de caso.

Durante o processo de descoberta de conhecimento temos a análise de características presentes no conjunto de dados oriundos do processo, conforme apresentado na metodologia KDD (Capítulos 1 e 2). Essa etapa é feita neste estudo por meio de diagramas, por exemplo um diagrama aluvial, que permite identificar relações proporcionais entre diferentes variáveis categóricas simultaneamente.

A descoberta de conhecimento em dados tradicionalmente apresenta a ideia da utilização de uma metodologia para o planejamento e desenvolvimento de aplicações. Um dos objetivos desta tese é que as propostas aqui presentes sejam flexíveis e que permitam reuso. Desta forma, as características encontradas na literatura serviram como base para a definição dos principais paradigmas adotados.

Essa proposta faz uso de redes neurais, tanto com aprendizagem supervisionada quanto não supervisionada. Baseando-se nos conceitos apresentados nos capítulos anteriores, chegou-se a uma proposta que avalia o comportamento de variáveis de processo, utilizando sequências multi-temporais de sinais de entrada e que foram posteriormente apli-

Figura 35: etapas do desenvolvimento da proposta.



Fonte: autor.

cadadas como entradas nas camadas LSTM. Nesta tese foram treinadas duas redes neurais, sendo uma RNN, que envolve um processo de aprendizagem supervisionado (Seção 2.4), aplicada para séries temporais a partir de dados contínuos gerados pelo processo TEP. Contudo, destaca-se que essa parte do estudo não utiliza a estrutura completa do modelo proposto, ou seja, não aplica a etapa de caracterização semântica. É apresentado nessa proposta uma abordagem que contempla dados contínuos, com foco no problema apresentado no Capítulo 1, mais especificamente no acidente ocorrido na planta de pesticidas da Bayer®. Os resultados dessa implementação serão apresentados no estudo de caso 2. Para o estudo de caso 1, foi implementado uma máquina de Boltzmann restrita, do inglês RBM (*Restricted Boltzmann Machine*), que é uma rede neural que envolve um processo de aprendizado não supervisionado, que recebe na camada de entrada (visível) dados do domínio. A camada escondida da rede neural, conforme representado na Figura 7, captura as características principais dos dados de entrada. Assim, os valores pré-processados presentes na entrada da RBM são apresentados com uma informação sobre o domínio em relação aos eventos no ATS.

O treino da rede ocorre a partir de valores de pesos entre os nós existentes na RBM, sendo que estes valores de pesos do treino são utilizados novamente para reconstruir as entradas. Embora sejam aplicados os mesmos pesos, o valor reconstruído na entrada não é o mesmo valor que foi apresentado durante o treino. Um dos motivos para essa questão é que não existe uma interconexão entre nós da mesma camada. Cada nó presente na camada escondida h da RBM recebe a informação de todos os nós da camada visível v . Uma descrição para a RBM foi apresentada na Seção 2.5.3.

Um pré-processamento dos dados é necessário para a etapa de treino da rede neural

e envolve mineração de dados. A parte específica neste ponto é apresentar na entrada da RBM dados resultantes de pré-processamento, o que significa preparar os dados para o processo de aprendizado. Nesse processo de mineração de dados é necessário executar uma série de etapas, que envolvem por exemplo a análise de dados faltantes, a extração de atributos para o treino a partir de estatísticas sobre uma determinada variável e que pode ser analisado por meio de diagramas, sendo possível aplicar diagramas do tipo aluvial (Sankey), e que foram adotados nesta tese.

A escolha pela RBM foi no sentido de aprender uma distribuição de probabilidade não conhecida a partir de dados do domínio. O treino ocorre a partir de uma amostra dessa distribuição, devido ao problema gerado pela constante Z , apresentada na equação (3), e que representa uma soma de todos os valores de todos os estados possíveis do sistema. O modelo de aprendizagem que foi implementado nessa abordagem permite realizar uma amostragem, considerando a distribuição de probabilidade inferida a partir dos dados do domínio e, com isso, compreender por meio dos padrões de dados o comportamento do processo, extraindo informações de características do domínio.

Outra vantagem ao implementar essa rede neural artificial é a opção de fixar uma determinada unidade visível e buscar uma estimativa para, por exemplo, um dado faltante. Isso é importante na medida em que são observados os dados oriundos de um processo e é um dos pontos destacados na literatura.

O modelo de grafo probabilístico da RBM busca encontrar novas estruturas, a fim de generalizar o modelo, aplicando funções parametrizadas que maximizam um valor de probabilidade, conforme apresentado no Capítulo 2. Com relação ao processo de amostragem de Gibbs, este utiliza o método de aproximação numérica, considerando o gradiente da *log-likelihood*. Essa técnica de treino da RBM é inspirada na física estatística, e está relacionada a uma distribuição de Boltzmann que permite treinar o modelo com um número reduzido de passos. Assim, o estado de todas as variáveis presentes em uma camada da RBM passa por um processo de amostragem, que gera uma distribuição de probabilidade a partir de um amostrador de Gibbs, que tem como base o MCMC, apresentado na Seção 2.6.2.

4.3.3 Modelo Híbrido de Inferência Preditiva

As abordagens da literatura relacionadas a sistemas de alarmes industriais não tratam de uma modelagem e implementação semântica probabilística, que considere dados históricos e evidências, apresentado nesta tese como um modelo híbrido, e que é o foco deste trabalho. A presente abordagem incorpora preceitos de Inteligência Artificial e da Web Semântica voltada para inferência preditiva, procurando avaliar padrões em dados que permitam estabelecer regras que possam ser processadas pelo raciocínio probabilístico. A modelagem de hipóteses em relação à probabilidade de falhas (PoF) é facilitada por meio da RBM na qual ocorre uma redução da dimensionalidade no espaço de características

dos dados a partir da camada escondida da rede, sendo que cada uma destas características presentes na camada oculta extrai informações que são de interesse. Essa abordagem permite entender o padrão de dados que é apresentado na entrada da rede neural, ou seja, obtemos um significado para esses dados por meio de uma representação probabilística. A PoF expressa um conhecimento sobre o domínio, de modo que uma distribuição de probabilidade inferida a partir dos dados do domínio é aplicada no entendimento do comportamento do domínio em questão. Assim, o resultado obtido é um conhecimento com um determinado grau de certeza sobre as hipóteses investigadas, contribuindo no processo de tomada de decisão.

A aplicação de regras juntamente com ontologias, envolve a semântica dos conceitos, relacionamentos e atributos definidos na ontologia. Em relação à ontologia probabilística, essa acrescenta regularidades estatísticas que caracterizam o domínio e considera a incerteza sobre as formas de conhecimento. Assim, é possível determinar a probabilidade através de PR-OWL (*Probabilistic OWL*), tendo como base a linguagem OWL apresentada na Seção 2.9.1, de uma situação acontecer no futuro próximo por meio de MEBN (*Multi-Entity Bayesian Network*).

Nessa tese o foco é a identificação de situações preditivas que envolvem o conjunto de características do domínio definidas em um nível semântico, através de um fragmento (MFrag), e que não mudam num intervalo de tempo, permitindo identificar a situação. Os atributos necessários para implementação das regras presentes nos nós residentes, e que são definidos nos fragmentos, são extraídos a partir de dados do domínio. Assim, o processamento a partir de PR-OWL permite inferir a situação gerando uma rede Bayesiana de situação específica, do inglês SSBN (*Situation Specific Bayesian Network*).

As SSBNs são geradas a partir dos *templates* (MFrags), criados para modelar a incerteza em relação as características que descrevem as entidades e seus relacionamentos. Uma entidade é descrita por predicados de contexto, forma a base de conhecimento, inclui elementos do domínio que participam da interação entre o especialista ou operador e o ATS e definem as dependências das variáveis aleatórias. Examinando as características que descrevem as entidades, definidas na ontologia como propriedades de tipos de dados, são encontrados os padrões que definem a distribuição de probabilidade local. Nós de contexto são criados para os tipos de entidades que são variáveis ordinárias e que são as condições que deverão ser atendidas para tornar válido o fragmento.

Neste exemplo, as relações semânticas que estão vinculadas a instâncias de *Event*, *Situation*, *State* e *Action* é que permitem gerar a SSBN. As regras que são detectadas a partir dos nós residentes presentes nos fragmentos da MEBN, seguem o formato que envolve uma condição e uma ação. A partir dos registros do domínio são avaliados os padrões de eventos que envolvem as variáveis deste domínio num padrão representado pelas LPDs da Figura 34. Este exemplo simplificado modela o conhecimento sobre um determinado estado da planta, que depende dos eventos que ocorrem a partir do nó de

entrada $isAtCurrentEvent(st,t)$.

Os fragmentos modelam o conhecimento do domínio e consideram uma distribuição de probabilidade dos eventos que fazem parte de uma situação. Os valores de probabilidade são definidos em uma LPD (*Local Probability Distribution*) presente no nó residente, podendo ser definida pelo especialista no domínio. As crenças sobre o domínio, que são os valores *a priori*, são atualizadas a partir de evidências. A geração das regras tem com base o modelo de contexto, de forma que as relações semânticas recebem essas variáveis. Por exemplo, no fragmento *Equipment-MF*, temos o nó residente *actualState* conectado com o nó $isAtCurrentEvent$, presente no fragmento *State-MF*, por meio do nó de entrada $isAtCurrentEvent(st,t)$ envolvendo a condição *ev1*. Neste caso, a LPD identifica qual o atributo da variável equipamento participa da situação específica. Os valores dos atributos funcionam como uma restrição, gerando um recurso interessante para o modelo, restringindo as escolhas para os outros nós de contexto associados a essa LPD. Dessa forma, as ações indicadas são representadas pelos diferentes estados do processo. Quando uma situação anormal de operação definida pelos eventos presentes no fragmento (*State-MF*) for detectada, a rede é gerada de acordo com o conjunto de templates que formam a teoria (*MTheory*).

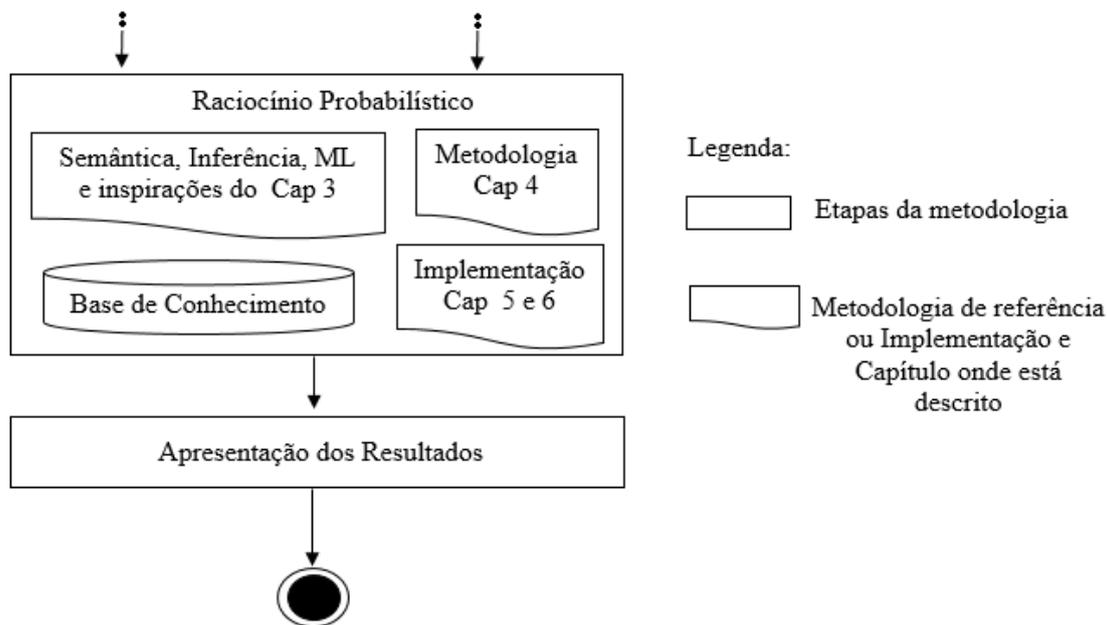
4.3.4 Raciocínio Probabilístico

A definição de contexto reúne as informações sobre o ambiente e permite avaliar as situações que ocorrem no ATS. Além disso, permite reunir evidências para implementação de um teste de hipóteses. Essas informações são capturadas por meio de resultados fornecidos pela mineração de dados, resultando nas hipóteses. Em (ZHIQIANG *et al.*, 2017), é destacado que a aprendizagem de máquina supervisionada e não-supervisionada representam o maior percentual de aplicações presentes nas indústrias, pois possibilitam o compartilhamento de capacidade computacional. Isso foi decisivo na escolha dessas duas abordagens para essa tese, na perspectiva de um modelo voltado para a indústria. Contudo, verificou-se que o modelo apresentado nesta tese possui funcionalidades que podem ser aplicadas por outros domínios, conforme apresentado no estudo de caso 1.

Conforme representado na Figura 36, essa etapa possui duas entradas, que são das etapas de caracterização semântica e da definição de contexto. Em (BETTINI *et al.*, 2010), é apresentado que a modelagem de informações de contexto reduz a complexidade das aplicações e, nesse sentido, é proposto para essa etapa uma abordagem aplicando inferência, que permite raciocinar sobre o contexto. Uma abordagem parcial aplicando somente a etapa da definição de contexto, ou seja, sem a caracterização semântica também foi prevista e será apresentada nos estudos de caso presentes no Capítulo 6.

Uma rede Bayesiana é um modelo descrito na forma de grafo e que representa dependências probabilísticas entre variáveis. Essa rede separa os parâmetros que especificam a distribuição de probabilidade e a base de conhecimento. Assim, é possível avaliar uma

Figura 36: etapas do desenvolvimento da proposta.



Fonte: autor.

hipótese apresentando evidências. Contudo, antes da apresentação de uma evidência, a probabilidade para uma determinada hipótese é considerada um valor *a priori*. Além disso, a aprendizagem dos parâmetros da rede envolve uma distribuição de probabilidade. Por exemplo, em (AZIZ *et al.*, 2019), é destacado que o uso de redes Bayesianas facilita a atualização do modelo usando novas informações, sendo que as informações são baseadas no conhecimento do especialista.

Nesta tese, a base de conhecimento presente na arquitetura recebe como entrada o contexto identificado oriundo da definição de contexto e o modelo semântico de contexto, de forma que a distribuição de probabilidade local recebe informações aprendidas sobre os dados gerados pelo ATS. De maneira geral, a inteligência artificial também representa o mecanismo de inferência, constituindo a parte lógica do sistema, e os dados são informações que definem o contexto identificado, permitindo uma etapa de inferência que é uma etapa de raciocínio presente na metodologia.

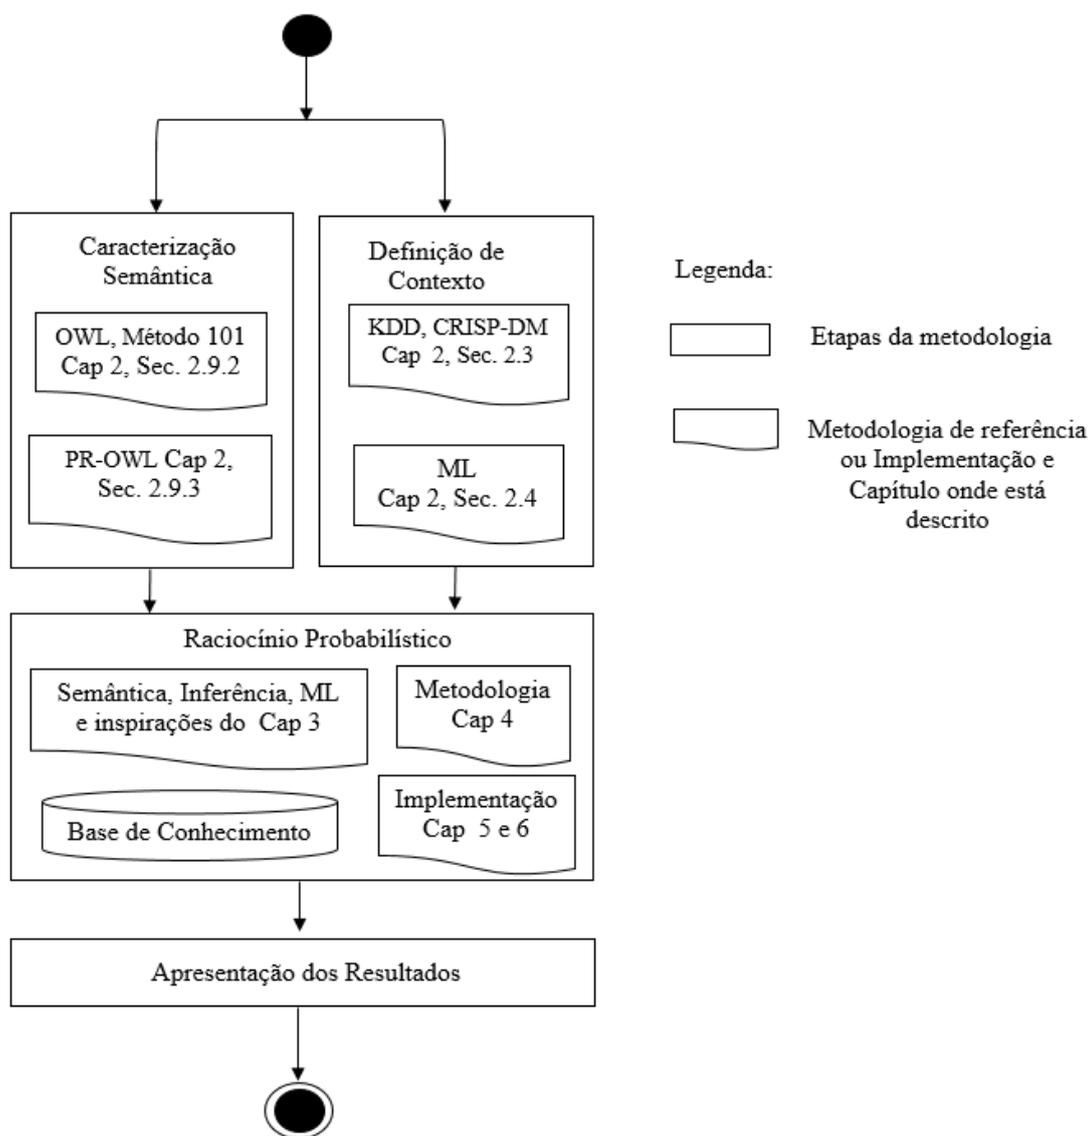
4.3.4.1 Aprendizagem paramétrica

A rede neural treinada é utilizada para verificar a probabilidade de falha como variável alvo. Para construir esse modelo de grafo probabilístico, é necessário conectar a rede ao conjunto de dados e executar o treinamento sobre a amostra binária uniforme. Para isso, utiliza-se cadeia de Markov com um exemplo de treinamento, de forma que a cadeia esteja perto de convergir para uma distribuição final. Assim, amostras são obtidas logo após um processo de amostragem de *Gibbs*, sendo que a distribuição das camadas da

rede é derivada de uma função de energia. A aplicação deste método é possível, dado que o tamanho da camada visível corresponde a dimensão dos dados (DAHL; ADAMS; LAROCHELLE, 2012).

O processo de raciocínio necessita da etapa de mineração de dados, conforme representado na Figura 37, que possibilita conhecer quais atributos das variáveis carregam uma informação de interesse e estimar um valor desconhecido. Assim, o modelo se adapta aos dados a partir do aprendizado dos parâmetros num processo de aprendizagem de máquina.

Figura 37: etapas do desenvolvimento da proposta.



Fonte: autor.

Entre as principais características de funcionamento de um ATS e os elementos do processo que requerem interação humana, existe um conjunto de variáveis que contém as informações necessárias para um processo de aprendizagem, permitindo a geração de modelos preditivos. O contexto do ATS é representado por um conjunto destas variá-

veis, e pode ser tratado como uma situação que se mantém por um período de tempo. Neste sentido, o funcionamento de um ATS envolve a ocorrência de eventos. Nesta tese, evidências e hipóteses são parâmetros de uma distribuição probabilística que geram um modelo referente ao domínio de interesse. As hipóteses correspondem aos parâmetros do modelo e que representam uma crença sobre o domínio. Para isso, hipóteses estatísticas são avaliadas em um determinado nível de confiança.

Este trabalho propõe a análise de situações de processo presentes em um ambiente que depende da atuação operacional. Desta forma, a pesquisa está focada em abordagens que permitam uma integração através da análise computacional e de métodos como os de regressão, permitindo prever o comportamento da variável monitorada no processo. Esta é uma questão crítica, especialmente porque as falhas exigem uma ação ou análise em um momento específico e possuem um significado para os operadores.

4.3.4.2 Inferência usando BNs

A crença que possuímos sobre uma situação é representada por uma descrição probabilística e que é atualizada. A estratégia encontrada a partir desta metodologia articula as condições nas quais uma abordagem é relevante para outra, ou seja, os valores das distribuições de probabilidade que alimentam as LPDs também são gerados a partir do processo de aprendizagem não supervisionada. O valor do aprendizado gerado a partir do módulo de definição de contexto, presente nesta metodologia, é aplicado como um valor *a priori*. Assim, um valor de propriedade da abordagem frequentista é usado na abordagem Bayesiana permitindo gerar uma estimativa *a posteriori*.

O raciocínio implementado nesta tese tem como base o formalismo de um ontologia probabilística, que permite inferir sobre os eventos que fazem parte de uma situação. Assim, a situação e os eventos estão inseridos em um contexto modelado a partir da caracterização semântica.

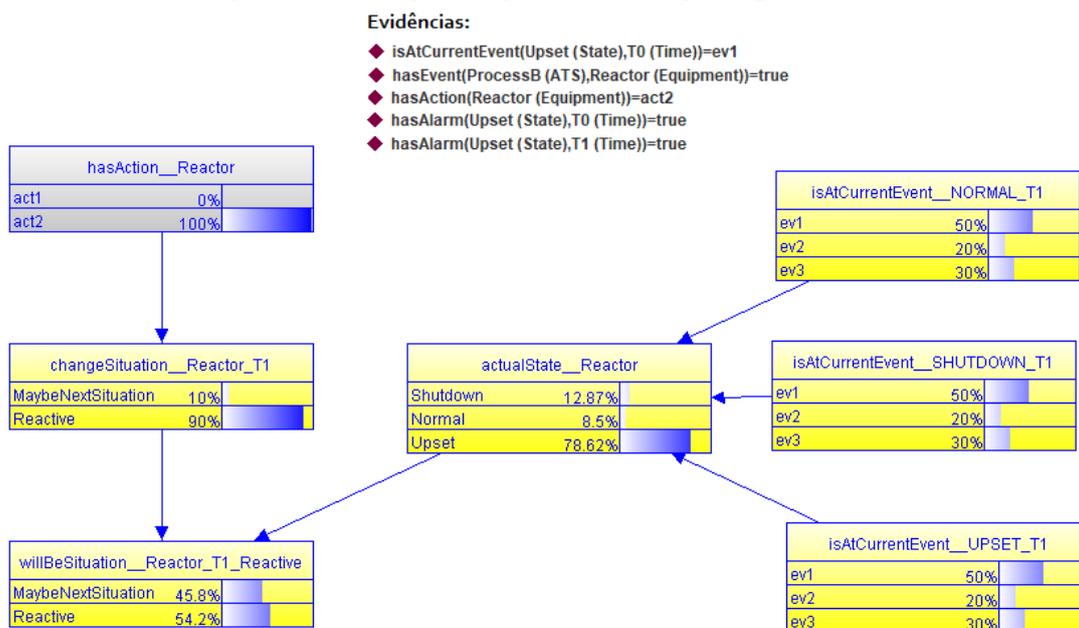
Entender as situações sobre o processo pode melhorar significativamente a capacidade de gerenciamento destes ambientes. O núcleo de situações anormais permite identificar as causas principais, ou seja, os dados são usados para dar sentido as situações que, em geral, também são complexas. Conforme o surgimento de novas situações ao longo do tempo, representado na Figura 42, a metodologia deverá considerar momentos em que ocorrem as situações de interesse onde, por exemplo, um comportamento reativo é inevitável.

Existe uma ilustração apresentada inicialmente por (OGDEN; RICHARDS, 1923) que representa os artifícios humanos utilizados para melhor compreender e se comunicar, buscando a partir de uma organização mental, comunicar para outros indivíduos as situações de um domínio, para representar simbolicamente um domínio a fim de auxiliar a sua compreensão e facilitar tal comunicação. Neste trabalho, coloca-se como principal questão de pesquisa a necessidade de um modelo que expresse um domínio a partir da conceituação compartilhada, conforme apresentado em (GUIZZARDI, 2005), que aproxime os concei-

tos existentes entre homem e máquina na interpretação de determinadas situações.

Seguindo no exemplo iniciado na etapa de caracterização semântica, digamos que durante a produção ocorra um alarme de nível baixo do reator. Uma premissa para inclusão de alarmes em um processo é que este alarme deve possuir relação com uma ação operacional, de modo que corrija a anormalidade no processo. Para observar a influência de uma ação torna-se necessário observar uma relação de causalidade entre os eventos. Neste exemplo, digamos que o operador não saiba exatamente o que fazer, tomando a decisão de fechar a válvula (*valve1*) da entrada do reator, executando assim a ação *act2*. Uma vez que esteja definida a situação através de um modelo semântico, é possível inferir a probabilidade para uma situação específica diante desta ação, conforme apresentado na Figura 38. Caso seja adotada a ação *act1*, o resultado pode ser acompanhado conforme apresentado na Figura 39.

Figura 38: ssbn gerada para um exemplo hipotético.



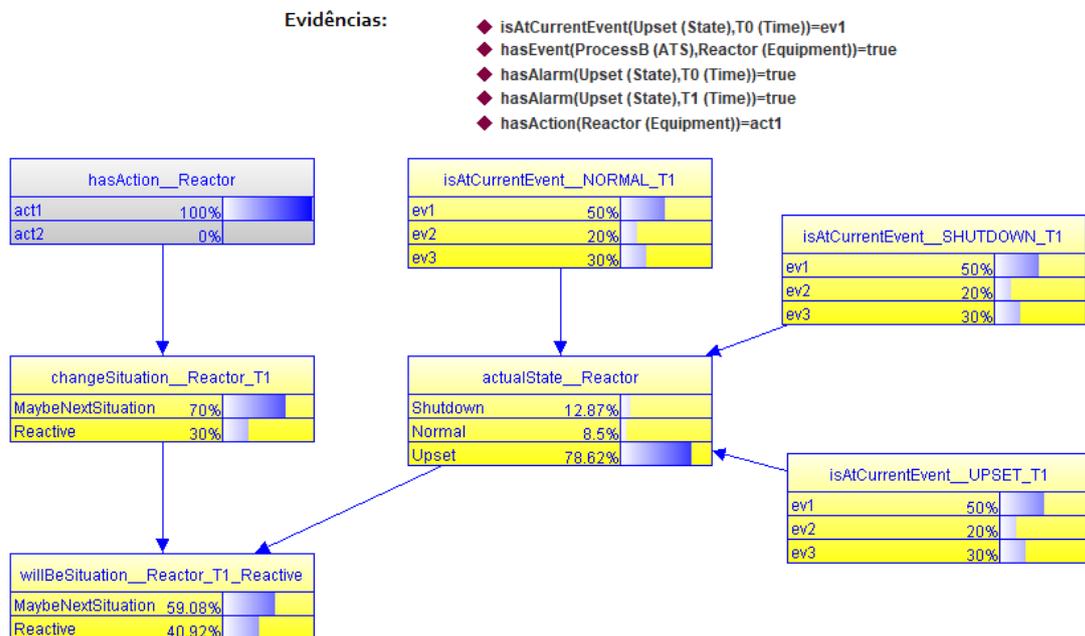
Fonte: autor.

Na Figura 40, são apresentados os alarmes que são gerados neste exemplo. É possível observar que, logo após a ocorrência do alarme 2 (nível baixo no reator) ocorre o alarme 1 (vazão). Esses alarmes foram apresentados para destacar que o processo pode gerar outros alarmes na sequência do alarme inicial, resultando em questões apresentadas no início deste texto, incluindo a interrupção dos processos.

4.3.5 Representação das Situações

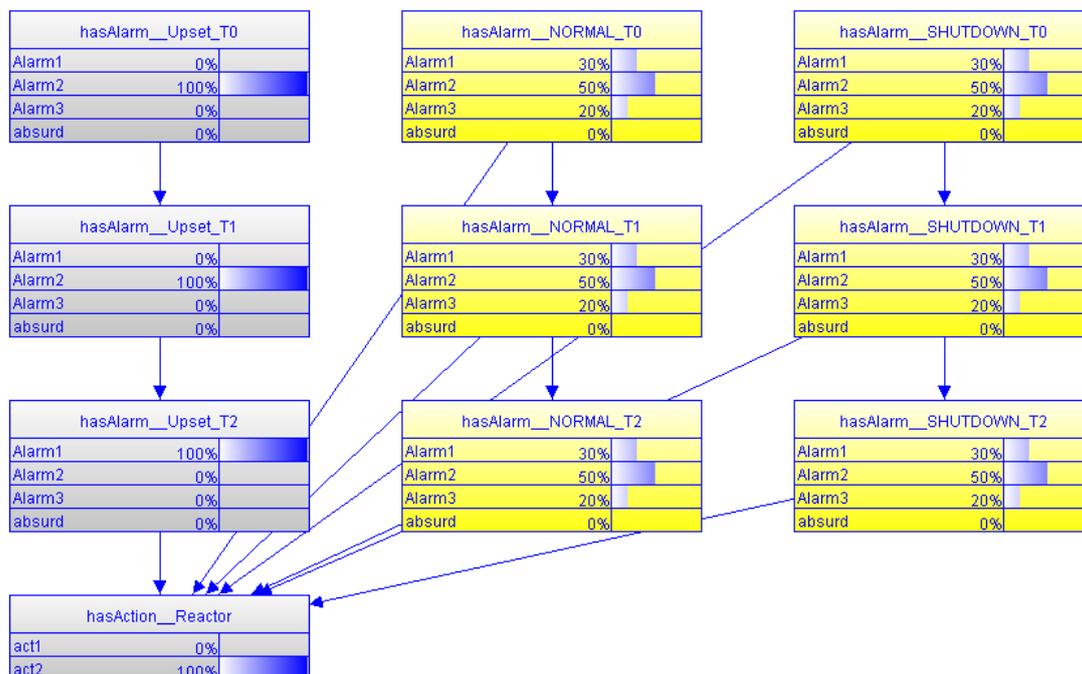
Os eventos presentes em uma BN são tratados como variáveis aleatórias. Considerando que os nós da BN são representados por variáveis do tipo *boolean*, estas variáveis

Figura 39: ssbn gerada para um exemplo hipotético.



Fonte: autor.

Figura 40: alarmes gerados para um exemplo hipotético.



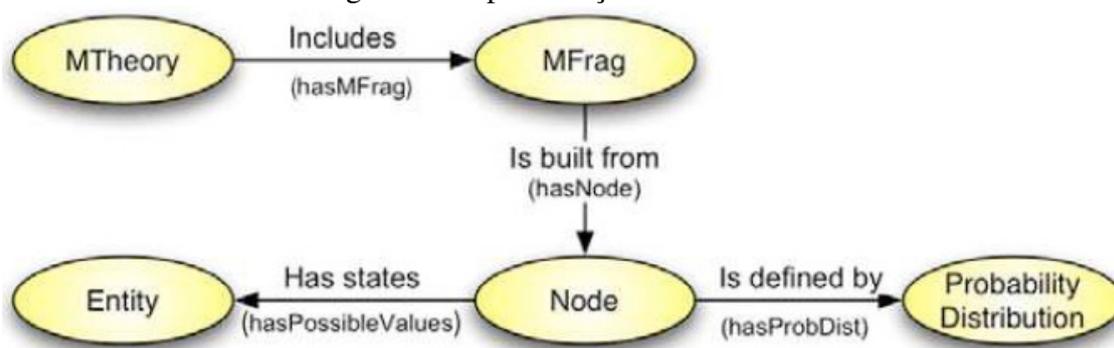
Fonte: autor.

passam a ser representadas em uma LPD, que pode ser preenchida com informações apresentadas por um especialista no domínio e/ou, com os valores gerados através de ML, que nessa tese é permitido pelo processo de aprendizagem não supervisionado, descrito na

Seção 4.3.2 deste capítulo, permitindo um processo semi-automatizado para implementação das LPDs. Na comparação direta com (AZIZ *et al.*, 2019) e (SOLEIMANI; CAMPEAN; NEAGU, 2021), observou-se que os trabalhos relacionados apresentam apenas a aplicação das informações geradas pelo especialista, quando comparados a metodologia apresentada nesta tese.

Nesta tese, a escolha pelo PR-OWL permite, por meio de uma MTheory, conforme apresentado na Figura 41, a implementação de uma MEBN. A abordagem proposta nesta tese visa gerar recomendações aos usuários de um ATS sobre situações preditivas, a partir de um modelo definido semanticamente para permitir um processo de inferência probabilística diante de um contexto. Contudo, não se pode deixar de lado a questão da incerteza. Para isso, propõe-se a análise da entropia. A partir dessa abordagem, são definidas relações entre entidades do domínio, de forma que a situação corrente é representada como um comportamento em um intervalo de tempo, onde eventos dão significado para uma situação.

Figura 41: representação do PR-OWL.

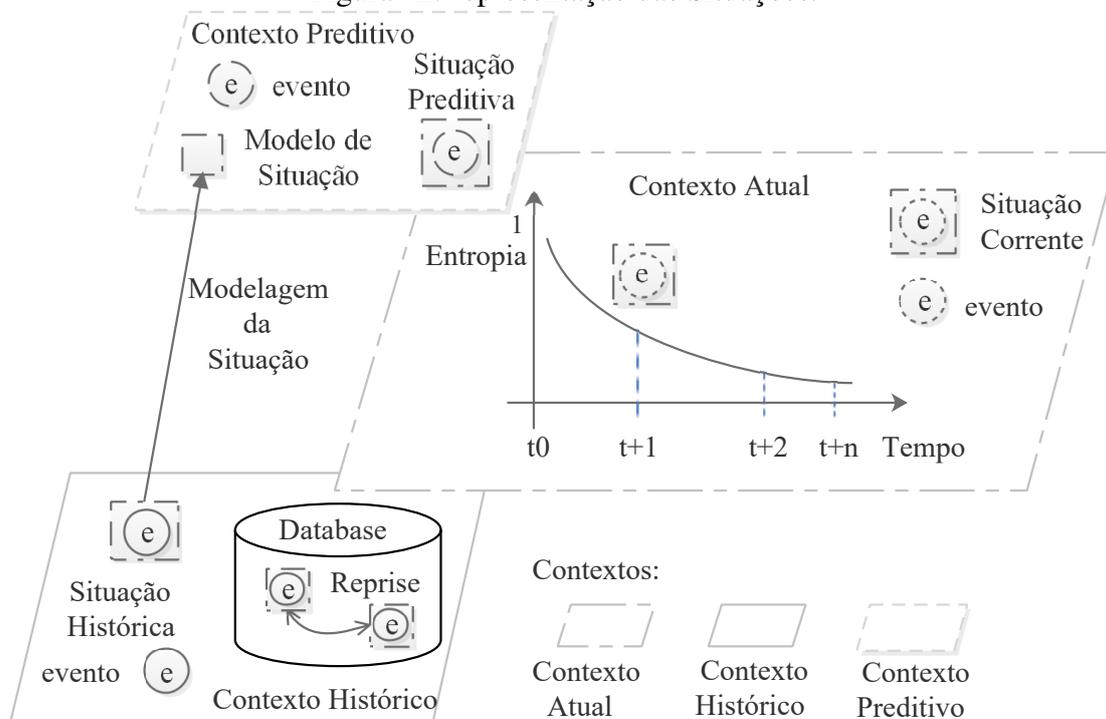


Fonte: (DA COSTA, 2005)

Conforme apresentado na Figura 42, foram definidos 3 contextos. O contexto atual envolve uma situação corrente, que é avaliada durante uma unidade de tempo discreto implementado no PR-OWL. O contexto histórico envolve uma situação que pode ser reprisada a partir da ocorrência dos eventos no domínio. Por fim, o contexto preditivo envolve uma situação preditiva. Nesta proposta, são apresentadas evidências que resultam em um valor de probabilidade para uma determinada situação preditiva a partir de uma consulta que gera a SSBN. Contudo, as ocorrências no processo presentes no contexto atual também podem ser avaliadas por meio de regras semânticas (SILVA; PEREIRA; GÖTZ, 2018). Por fim, o contexto histórico resgata os eventos que ocorreram em determinadas situações passadas. Assim, aplicando a metodologia proposta neste capítulo, é possível extrair um conhecimento a partir de um conjunto de dados, que irá permitir modelar uma situação e, com isso, gerar recomendações que auxiliam no processo de tomada de decisão, tornado mensurável o que é importante, que são as situações, ao invés de apresentar

alertas para todos os eventos individuais que são gerados durante um processo e apresentados, por exemplo, pelos sistemas de gerenciamento de alarmes tradicionais, conforme apresentado nos capítulos anteriores.

Figura 42: representação das Situações.



Fonte: autor.

4.4 Considerações Finais

A partir da metodologia desenvolvida para prever o comportamento, por exemplo de uma falha no processo relacionado, será possível demonstrar que ela permite derivar em novos métodos inteligentes com o intuito de auxiliar a operação do processo, permitindo conter o avanço da propagação de falhas, permitindo estimar o efeito de uma propagação de falha lógica de controle onde múltiplos alarmes podem ser disparados. Esta seção apresentou o método desenvolvido para ATS que explora modelos probabilísticos, a fim de determinar a probabilidade de uma situação a partir de um modelo contextual da definição da situação.

Um projeto experimental para teste de hipóteses incluído na abordagem clássica é apresentado nesta tese. Nesta abordagem, o modelo da RBM, que é uma máquina estocástica, na qual o processo de aprendizagem ocorre a partir de uma função de otimização da distribuição de probabilidade é apresentado.

O aprendizado sobre os eventos auxilia na construção de uma LPD para que um processo de inferência preditiva por meio de uma BN seja possível. Além disso, o modelo resultante combina evidências que, durante um processo de raciocínio probabilístico, en-

volve o aprendizado de padrões implícitos nos dados, permitindo auxiliar na tomada de decisão a partir de uma resposta quantitativa sobre uma variável de interesse.

Por fim, um modelo de aprendizagem é desenvolvido, e busca analisar o comportamento de variáveis de processo, utilizando sequências multi-temporais de sinais de entrada e que serão posteriormente aplicadas como entradas nas camadas LSTM.

5 IMPLEMENTAÇÃO

5.1 Introdução

A implementação feita para validar os resultados obtidos é apresentada neste capítulo. A metodologia possui uma estrutura na qual destacam-se a abordagem híbrida descrita na Seção 4.3.3 e os métodos estatísticos e de aprendizado de máquina aplicados a base de dados gerados por meio de simulação e a partir de um ambiente real.

As metodologias de mineração de dados permitem estabelecer um modelo de predição sobre situações. Além disso, possibilitam uma manutenção prescritiva que envolve prognóstico e tomada de decisões induzidas pelo conhecimento gerado pelas abordagens estatísticas e algoritmos de aprendizado de máquina implementados.

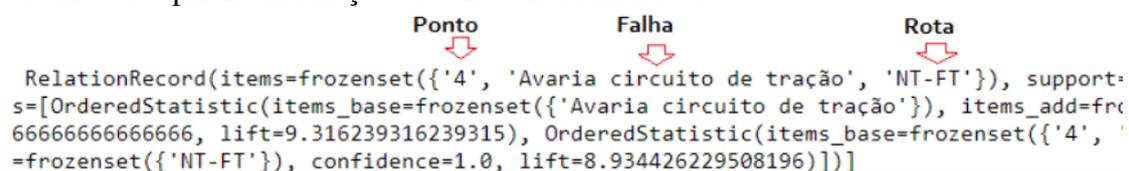
A etapa de definição de contexto inicia-se pelas metodologias de KDD e CRISP-DM, envolvendo várias decisões que são humanas e iterativas, não triviais e que passam pela preparação dos dados. Os trabalhos relacionados destacam que essa etapa de preparação de dados em especial, consome a maior parcela do tempo de projeto, podendo ser superior a soma de todas as outras etapas juntas. A iniciativa de desenvolvimento da metodologia CRISP-DM surgiu com a motivação de estabelecer um modelo independente de plataforma, apresentando uma documentação que define o projeto em termos de um problema de análise de dados. Assim, o problema que antes era gerar um conhecimento necessário para o domínio avaliado, passa a ser um problema de mineração de dados. Na etapa de compreensão dos dados, busca-se assegurar a qualidade dos dados obtidos, sendo que nessa etapa também são aplicados métodos estatísticos, por exemplo para uma análise quantitativa.

5.1.1 Análise dos dados em termos de suas relações

A implementação de um modelo para análise de variáveis de processo a partir de dados permite encontrar padrões interessantes, que são os primeiros achados e que compõem as hipóteses. Durante a preparação dos dados, foi observado um grande número de dados faltantes em relação as variáveis escolhidas, e sabe-se que a presença de dados apropriados é vital para o resultado desta etapa. Como a metodologia CRISP-DM possui

uma interação entre as etapas de preparação dos dados e a modelagem, optou-se por um algoritmo geralmente aplicado nessa etapa, e que fosse compatível com o objetivo do processo. Assim, foi escolhido o algoritmo Apriori (TAN; STEINBACH; KUMAR, 2009), implementado em Python para encontrar itens frequentes a partir dos registros operacionais disponíveis. O algoritmo realiza múltiplos passos sobre os dados considerando um suporte mínimo. Nesta etapa foram definidos filtros para reduzir o total e regras geradas pelo algoritmo a partir de valores de suporte, do *Lift* e o valor de confiança mínima. A Figura 43 representa a primeira etapa envolvendo a preparação e modelagem dos dados, na busca por padrões.

Figura 43 – visão parcial da avaliação dos registros, com destaque para o padrão gerado pelo modelo apriori em relação às variáveis de interesse.



The image shows a Python object of type `RelationRecord` with the following attributes: `items=frozenset({'4', 'Avaria circuito de tração', 'NT-FT'})`, `support_s=[OrderedStatistic(items_base=frozenset({'Avaria circuito de tração'}), items_add=frozenset({'4', 'NT-FT'}), lift=9.316239316239315), OrderedStatistic(items_base=frozenset({'4', 'NT-FT'}), items_add=frozenset({'Avaria circuito de tração'}), lift=8.934426229508196)]`. Three red arrows point from the labels 'Ponto', 'Falha', and 'Rota' above to the corresponding parts of the object's structure.

Fonte: autor.

A tarefa de selecionar os dados relevantes para o problema de mineração, em seguida aplicar as transformações necessárias, extrair regras de associação, testar com múltiplos parâmetros, interpretar e avaliar os resultados, depende da qualidade dos dados. Quando existem dados incompletos ou faltantes, é necessário adotar uma estratégia, como por exemplo, eliminar registros incompletos ou completar segundo heurísticas que não são padronizadas. Ambas as tarefas não são triviais. A primeira implica na perda de registros associados aos dados faltantes. A técnica aplicada nesse processo, chamada *listwise deletion*, permite remover as linhas da tabela que possuem dados faltantes. Por exemplo, em um registro podem haver dados de algumas das variáveis enquanto que para outras, podem estar incompletos, com registros incorretos ou mesmo ausentes. A segunda também requer avaliação dos dados, sendo possível em alguns casos, completar com um valor da média ou da mediana da variável em questão. Contudo, isso impacta na distribuição dos dados. Além disso, para dados de determinadas variáveis, como por exemplo o Ponto (*Gear Box*), essa estratégia não se aplica, sendo necessário adotar outras técnicas, como por exemplo a aplicação da RBM. No caso de variáveis categóricas, além das técnicas relatadas, foi aplicada uma análise com um mapa de palavras, a fim de encontrar informações a partir do relatório operacional, que pudessem ser utilizadas para identificar um registro faltante, por exemplo de uma rota. As variáveis categóricas foram mapeadas para permitir algumas visualizações, bem como o processo de aprendizagem. Nos estudos de caso, essas variáveis estão representadas por um prefixo correspondente. Assim, os registros mapeados permitem identificar posteriormente as variáveis de origem.

5.1.2 Extração de informações a partir da aprendizagem

O raciocínio probabilístico envolve a incerteza presente em um domínio específico e sua estrutura de dados. Um evento possui características que são consideradas variáveis aleatórias e que possuem várias dimensões. Na abordagem de um processo inferencial é possível avaliar situações preditivas, que envolvem esse processo de raciocínio. Dessa forma, a sintaxe consiste em declarações sobre situações e melhor representa o conhecimento do ATS, e que será apresentado no estudo de caso 1 do próximo capítulo. Considerando duas abordagens distintas com relação à interpretação dos dados, observa-se que durante uma análise determinística é necessário observar as características dos eventos como séries de valores de n variáveis. Neste sentido, foi implementado uma RNN com camadas LSTM, e que será apresentada num estudo de caso 2.

Nesta tese, é proposto o uso de aprendizagem de máquina não supervisionado a partir do treino de uma RBM, aplicada para aprender uma distribuição de probabilidade não conhecida sobre dados gerados no ATS. A linguagem de programação utilizada para implementação e treino dessa rede neural artificial foi o Python. Existem várias linguagens de programação que permitem essa implementação. Por exemplo, em Matlab® é possível utilizar caixas de ferramentas específicas para o processamento de dados e aprendizagem. Contudo, optou-se pelo Python por ser amplamente utilizado na indústria. Para auxiliar nessa implementação, com relação à análise exploratória de dados, importação e visualização, foram instaladas as caixas de ferramentas pandas, seaborn e matplotlib. Para implementar a rede neural, foi instalada a caixa de ferramentas TensorFlow (ABADI *et al.*, 2016). Em seguida, para a manipulação dos pesos da rede neural, foi instalada a caixa de ferramentas numpy. O conjunto de dados resultante da etapa de mineração dos dados é armazenado em um arquivo no formato CSV (*Comma-Separated Values*), sendo que as colunas representam variáveis relacionadas ao processo, enquanto que as linhas correspondem aos registros de ocorrências no ATS.

A análise probabilística sobre um conhecimento avaliado a partir de variáveis do domínio apresentada nesta teste, trata de um processo de aprendizagem que não possui um valor ou conceito alvo associado, baseado na otimização que leva em consideração o cálculo do gradiente, a fim de maximizar a *log-likelihood*. Em resumo, são pequenos ajustes que vão aproximando o gradiente do menor valor de energia, ou seja, otimizando os pesos que são coeficientes de uma função linear e, com isso, atualizando a rede neural na direção do menor erro. Esses pesos presentes na rede são inicializados em um tensor, associados a todos os parâmetros da camada visível, dada a camada oculta. Assim, é possível inicializar o valor dos pesos com uma distribuição normal. Também é necessário inicializar um valor de *bias* para a probabilidade do nó visível dado o nó oculto, e para a probabilidade do nó oculto dado o nó visível. Contudo, o cálculo do gradiente é substituído por um processo de amostragem dos nós ocultos de acordo com a probabilidade $p(h|v)$, que é a probabilidade da camada oculta dada a camada visível, que considera a

função de ativação, que possibilita a aproximação do gradiente por meio do processo de amostragem de Gibbs.

O modelo de Gibbs permite amostrar k vezes os nós ocultos e visíveis da rede neural artificial. Os dados de entrada são apresentados e, baseado na probabilidade $p(h|v)$, é realizado um processo de amostragem para o conjunto de nós ocultos. Em seguida, esses nós ocultos são amostrados para a entrada, sendo as características detectadas a partir da camada de entrada. Assim, define-se o conjunto de características que se deseja observar através do modelo, e que irá resultar no número de nós ocultos presentes na rede. A RBM é treinada a partir de um número definido de passos, e que é superior aos realizados durante os testes com dados não observados. Para treinar o modelo, é necessário definir o número de lotes e de épocas. Com isso, o treino inicia-se com um lote de observação com os dados da entrada. Contudo, é necessário transformar os dados categóricos, permitindo que o modelo aprenda correlações de valores que estarão codificados.

A RBM recebe como entrada os dados do ATS. O algoritmo implementado é o CD (*Contrastive Divergence*) disponível em (FISCHER; IGEL, 2012), que busca aproximar a *log-likelihood*, para uma função de energia dependente dos pesos da rede. O processo de otimização dos pesos resulta na minimização a energia. Isso permite maximizar a *log-likelihood* do conjunto de treinamento. Para minimizar a energia ou maximizar a *log-likelihood*, é realizado um cálculo do gradiente. As aproximações deste gradiente ocorrem em ajustes na direção do menor valor de energia. Uma etapa de normalização é necessária para usar na função de ativação no processo de aprendizado de máquina. É necessário definir uma faixa entre zero e um, pois todos os novos valores pré-processados estão nesta faixa. Depois disso, é necessário criar uma nova estrutura de dados para aplicar essas normalizações como uma nova variável que contém o conjunto de dados do processo, normalizados entre zero e um.

5.2 Implementação do Modelo

5.2.1 Abordagem Clássica

Uma característica da abordagem clássica é que as causas podem ser inferidas a partir da repetição de experimentos. Um experimento é um teste que pode ser aplicado para identificar quais variáveis apresentam maior influência em uma variável de resposta (MONTGOMERY, 2005). O projeto de experimentos estuda o planejamento e a execução, reduzindo a influência de variáveis não controláveis e, portanto, com maior precisão. O planejamento fatorial permite estudar os efeitos de certos fatores em uma variável de resposta. Os resultados obtidos e os testes experimentais são analisados por meio de métodos estatísticos. Além disso, a análise da entropia permite prover uma formalização da informação de probabilidade predita.

Um teste de hipóteses é um procedimento que utiliza dados no processo, de forma

que considera fixos os parâmetros enquanto que os dados, que são conhecidos a partir do domínio, são variados. Nesta tese, os testes de hipóteses são realizados a partir de uma árvore de decisão. Para implementação da árvore de decisão em Python, foi instalada a caixa de ferramenta *sklearn*. Essa biblioteca também foi utilizada na fase de mineração de dados para codificar os dados categóricos das variáveis, como por exemplo as diferentes rotas presentes neste domínio.

5.2.2 Abordagem Bayesiana

5.2.2.1 Modelo usando *UnBBayes*

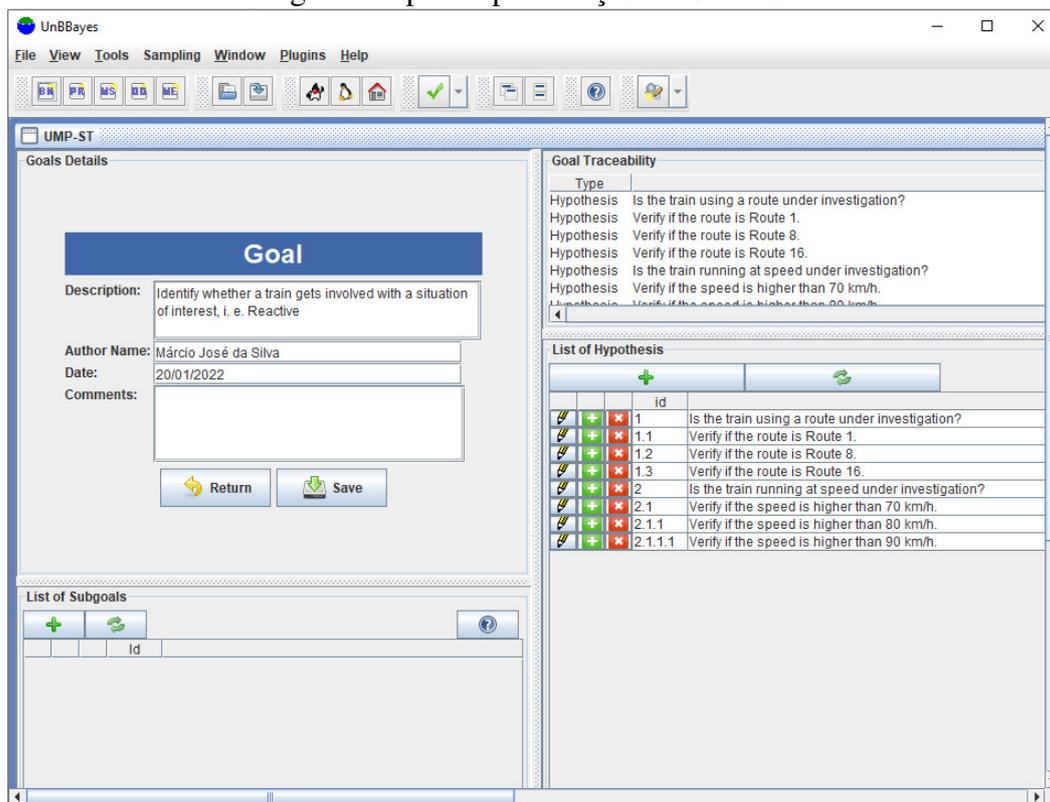
Em um cenário de aplicação de engenharia, uma motivação comum incluída na etapa de entendimento do negócio (domínio) orienta um grupo de especialistas de diferentes áreas do negócio, para agregar e investigar dados com base na experiência do grupo, para resolver um problema e/ou explorar oportunidades. Esse objetivo é então transformado em um problema específico de mineração de dados. Durante a fase de compreensão dos dados, as hipóteses para o problema são formadas com base em premissas qualificadas. Variáveis são coletadas, bem como a geração de recursos com relação ao objetivo da mineração de dados. Depois disso, a fase em que um modelo de estimativa de probabilidade e LPDs são construídos. Na fase subsequente, o modelo é testado e os resultados são avaliados de acordo com as evidências.

As etapas de implementação que suportam a metodologia proposta são resultado da incorporação das tecnologias que foram adotadas. Nesta etapa de caracterização semântica, foi realizada uma especificação inicial de grupos, entidades, objetivos e hipóteses, conforme demonstrado na Figura 44. Tais definições são feitas no *UnBBayes*, utilizando por exemplo o plug-in UMP-ST (HABERLIN, 2013), que permite uma documentação durante a implementação do modelo. Para outras especificações, como por exemplo a definição das distribuições de probabilidade, é aplicado o plug-in MEBN/PR-OWL também disponível no *UnBBayes*, e que será apresentado ao longo deste capítulo.

O processo de raciocínio sobre as situações, conforme exemplo apresentado no capítulo anterior, permite incorporar o contexto na estrutura do modelo. Com isso, é possível avaliar situações específicas a partir de consultas (*Query*) que geram, a partir de relações semânticas definidas no modelo conceitual probabilístico, as SSBNs. O processo de aprendizagem usando BN leva em consideração as relações causais existentes na estrutura da rede e de seus parâmetros. Na arquitetura apresentada nesta tese, são consideradas as técnicas de inferência, tendo em vista um processo de atualização de crenças.

A definição da situação futura envolve a incerteza. Para isso, uma rede Bayesiana é um modelo de grafo flexível para expressar uma distribuição de probabilidade conjunta em hipóteses interrelacionadas. Assim, permite a representação da incerteza de forma semântica. Um modelo ontológico probabilístico apresenta o conhecimento sobre um domínio e a incerteza associada a esse conhecimento. Para isso, optou-se pelas linguagens

Figura 44: painel para edição do UMP-ST.



Fonte: autor.

probabilísticas de primeira ordem Multi-Entity Bayesian Networks (MEBNs) (LASKEY, 2008).

O modelo desta abordagem considera uma distribuição de probabilidade relacionada aos parâmetros de interesse. Além disso, considera-se o grau de incerteza presente na informação e que envolve um conhecimento denominado como *a priori*. Uma vez que os dados são observados, assumimos que estes foram gerados num processo randomizado e, desta forma, temos uma distribuição paramétrica, ou seja, possuímos uma crença *a priori* sobre um determinado parâmetro.

A abordagem Bayesiana permite a aquisição, representação e utilização do conhecimento. Além disso, é possível realizar um processo de atualização de crenças, dadas evidências. O processo de inferência ocorre a partir de uma distribuição calculada *a posteriori*, combinando as informações *a priori* e as evidências. Assim, a inferência Bayesiana envolve uma atualização de valores, onde o valor da probabilidade de uma variável do domínio está presente em uma tabela que representa uma distribuição de probabilidade.

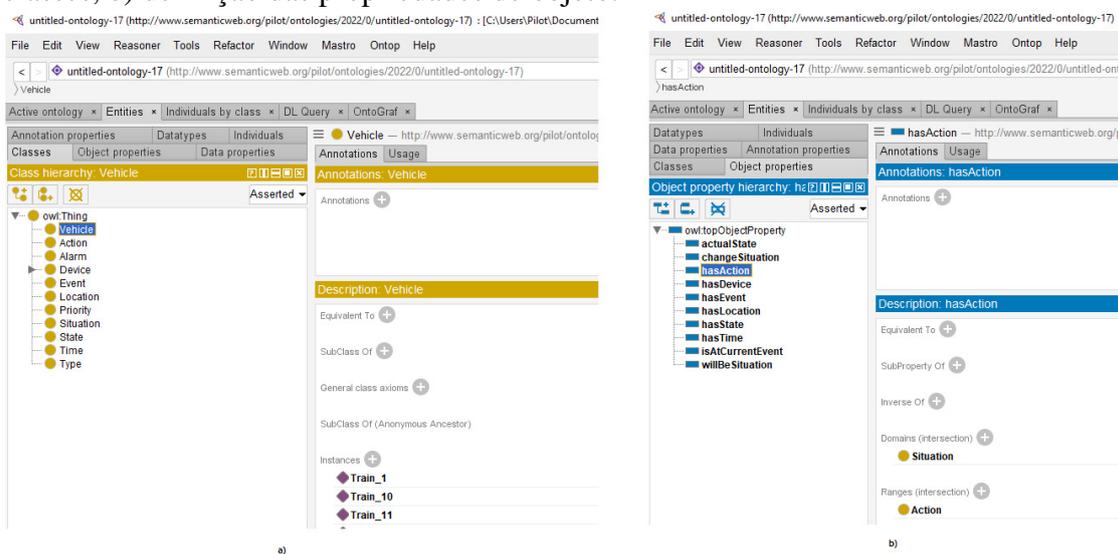
5.2.2.2 Ontologia Probabilística

Um modelo de apoio orientado ao conhecimento necessita de um mecanismo de inferência para gerar recomendações a partir da especificação de uma base de conhecimento. Para arquitetura deste modelo, é proposta uma metodologia aplicável em sistemas técni-

cos automatizados (ATS). A implementação de métodos para raciocinar sobre o domínio envolve as entidades de contexto a partir da base onde os dados são pré-processados. A partir desta metodologia, relações semânticas são definidas, incluindo evidências observáveis permitindo construir uma BN que possui um conjunto de valores numéricos presentes na LPD.

Para a representação de ontologias foi utilizado como ferramenta o Protégé (STANFORD, 2019), que permite vários formatos de representação, executando um conjunto de estruturas de modelagem de conhecimento. Na Figura 45, são apresentadas etapas na implementação do modelo semântico em OWL.

Figura 45 – modelo semântico implementado utilizando Protégé OWL. A) definição das classes, b) definição das propriedades de objeto.



Fonte: autor.

A primeira etapa da implementação do modelo conceitual de base para a ontologia de domínio faz uso do Protégé. Essa ferramenta permite construir a ontologia utilizando a tecnologia da Web Semântica. Para isso são definidos os conceitos e os relacionamentos que representarão o domínio. Classes tem por objetivo representar elementos que possuem um significado no domínio e são especializadas a partir de uma classe padrão *owl:Thing*. Para inferências de relações de conhecimento baseada em conhecimentos pré-existentes utilizou-se ferramentas de *Reasoning*. Uma justificativa para a aplicação de tecnologias semânticas é a consistência na representação dos conceitos. Uma vez relacionados através de propriedades que contém uma informação específica sobre o domínio, isso resulta em um novo conhecimento, possibilitando um processo de atualização do conhecimento.

A ontologia representa um conhecimento sobre o domínio e permite definir quais as características fazem parte de uma situação, conforme apresentado no exemplo da Figura 38. As condições semânticas que definem uma situação corrente envolvem as infor-

mações presentes em um contexto atual. Essas informações são definidas por eventos que ocorrem numa situação e, em geral, são geradas a partir das ações que podem ser manuais ou automatizadas. Com relação a situação preditiva, essa toma por base uma ação que já ocorreu, e que está presente em uma situação histórica.

Um processo de modelagem da situação é possível a partir de um modelo ontológico probabilístico. Para a etapa de modelagem seguinte utilizou-se UnBBayes (CARVALHO; LASKEY; COSTA, 2016), que permitiu o aprendizado e raciocínio sobre as redes probabilísticas. A capacidade computacional atualmente disponível, aliada ao conhecimento expresso por meio de modelos semânticos, ontologias, pode ser usado tanto para modelagem quanto para raciocínio sobre contexto. O uso de motores de inferência permite o raciocínio a partir de regras e ontologias sendo programas que inferem consequências lógicas, com base em fatos ou axiomas.

Em ontologias probabilísticas, ao descrever o conhecimento sobre um domínio e uma incerteza associada a esse conhecimento de forma fundamentada, não há necessidade de que todas as relações de uma ontologia sejam probabilísticas, conforme apresentado na literatura. A representação funcional básica da ontologia probabilística implementada é apresentada na Figura 46. Além disso, as partes modeladas com a extensão do PR-OWL devem formar uma teoria MEBN válida e as condições que devem ser satisfeitas são representadas pelos nós de contexto apresentados na Figura 47.

A MEBN expressa um conhecimento a partir de regularidades estatísticas presentes em cada fragmento (MFrag), e que formam uma base de conhecimento. Nesta tese, os resultados obtidos do processo de aprendizagem são aplicados na especificação das tabelas de probabilidade condicionais que alimentam uma distribuição sobre as entidades que caracterizam um contexto.

Para o cálculo da distribuição de probabilidade, é possível calcular a distribuição de probabilidade conjunta a partir das probabilidades condicionais locais. Dessa forma é possível uma análise da probabilidade de um trem estar envolvido em uma situação de interesse (*Reactive*).

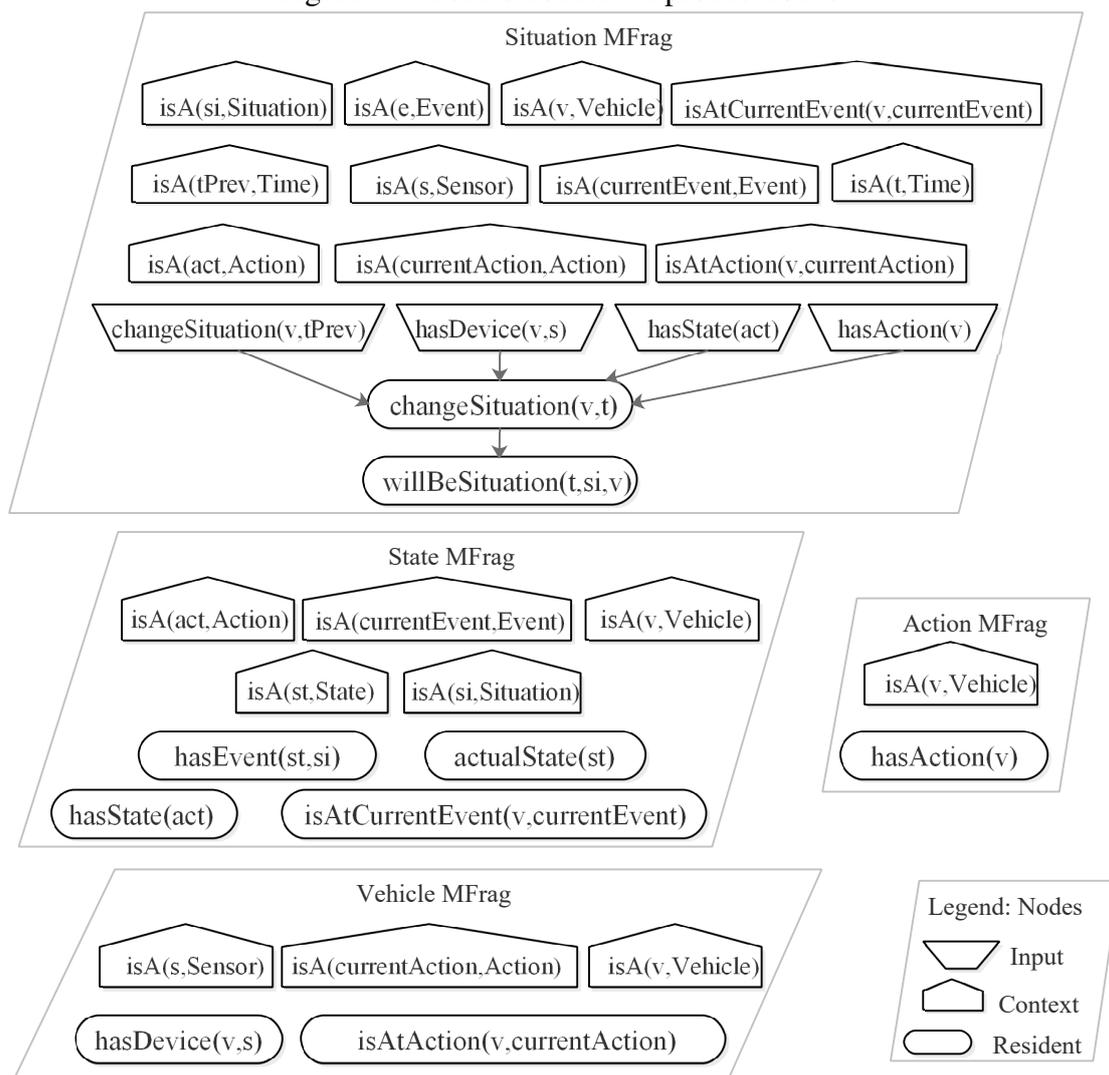
5.2.2.3 Rede Bayesiana Multi-Entidade - MEBN

Ontologias probabilísticas permitem descrever o conhecimento sobre um domínio e uma incerteza associada com esse conhecimento. O modelo probabilístico utiliza linguagem de primeira ordem MEBN, na qual os fragmentos (MFrag) expressam a incerteza no relacionamento entre as entidades. Esses fragmentos fazem parte de uma MEBN *theory* (MTheory) que expressa a distribuição de probabilidade das situações que envolvem as entidades do domínio, conforme apresentado na Figura 47.

Os fragmentos (*MFrag*s) são expressos por uma tupla (LASKEY, 2008):

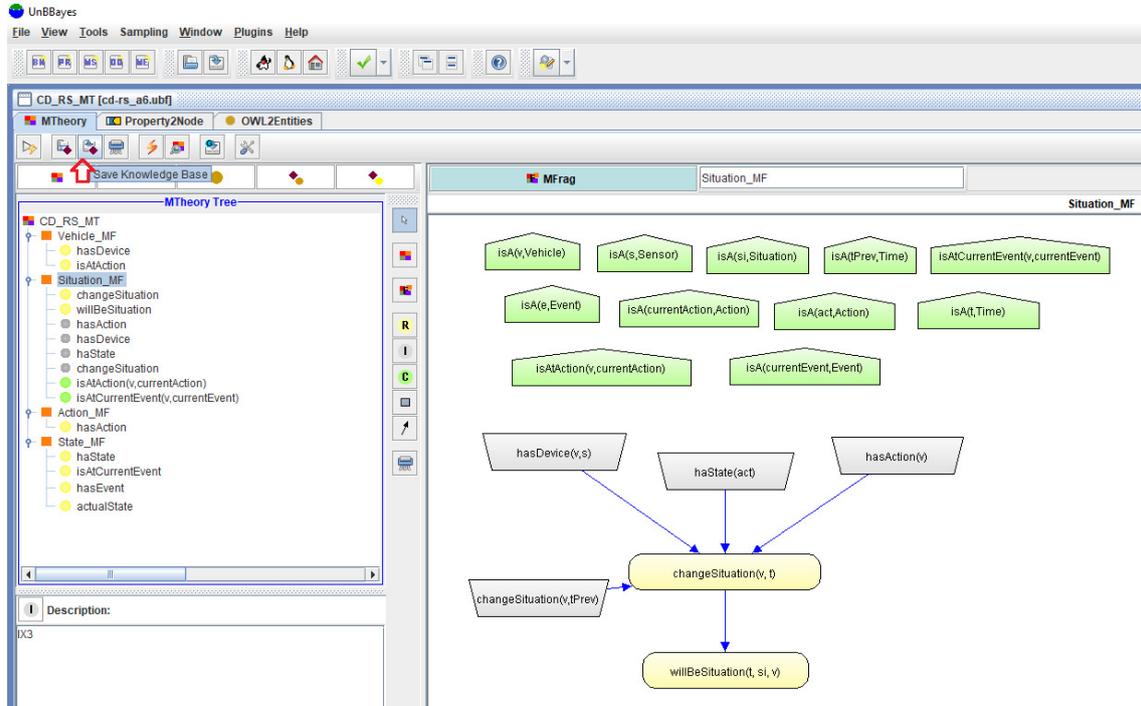
$$F = (C, I, R, G, D) \quad (14)$$

Figura 47: modelo conceitual probabilístico.



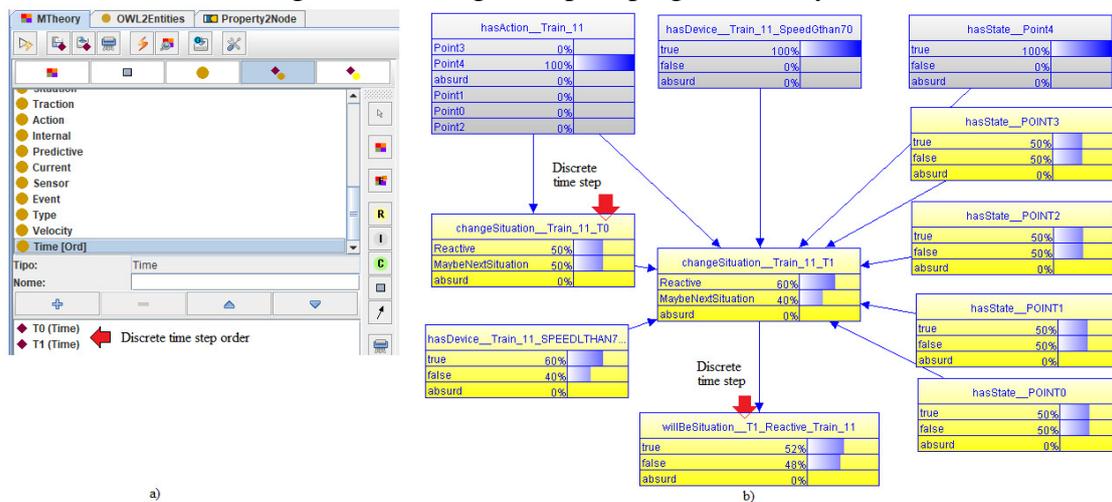
Fonte: autor.

Figura 48 – representação da MFrag Situation implementada nesta tese a partir do plugin MEBN no UnBBayes.



Fonte: autor.

Figura 49: ssbn gerada pelo plugin UnBBayes.



Fonte: autor.

condição de falha desempenha um papel fundamental para a ferrovia que será apresentada no estudo de caso, permitindo analisar a situação atual e calcular a maior probabilidade de uma situação de interesse ocorrer. Nesse contexto, os sistemas recomendação surgem como uma opção para ATS. Assim, o modelo estrutura um contexto altamente relevante, de consciência de situação.

5.3 Considerações Finais

Uma abordagem, voltada para a questão semântica de contexto, permitindo identificar uma situação a partir de padrões de eventos é apresentada neste trabalho. A partir do reconhecimento de uma situação em um determinado contexto ontológico, uma abordagem baseada no conhecimento parece ser mais eficaz para essa tarefa. O uso da ontologia foi adequado para formalizar esse conhecimento probabilístico, a partir de uma Rede Bayesiana. A inferência em BN está relacionada a atualização de crenças que ocorre por meio da apresentação de evidências.

Uma das principais motivações desta pesquisa é a análise de informações de contexto que fornecem subsídios para uma recomendação, necessária para auxiliar a operação, através de procedimentos de projeto baseados no processo de descoberta de conhecimento em dados.

6 ESTUDOS DE CASO

6.1 Estudo de Caso 1: Trens Urbanos

Para mostrar como a abordagem proposta nesta tese pode ser utilizada num estudo de caso real, este trabalho focou no desenvolvimento de uma arquitetura para um problema especializado, a fim de facilitar o processo de percepção e tomada de decisão a partir de dados históricos e relacionamentos semânticos, que definem uma abordagem híbrida de inferência preditiva.

6.1.1 Descrição da aplicação

O estudo de caso apresentado demonstra a aplicação deste modelo em um cenário real. São avaliados os registros relacionados às caixas de transmissão e engrenagens (*gear boxes*) e os motores elétricos de tração (motores de indução e inversores de tensão), conforme representado na Figura 50. São considerados os registros de 25 trens durante o período de 10 anos, mais especificamente relacionado a dois grupos de motores chamados MA e MB, com quatro motores cada grupo. Neste estudo será apresentada uma comparação entre a abordagem clássica e o uso de ontologia probabilística, a fim de mostrar as vantagens da metodologia proposta nesta tese.

Figura 50: representação do motor de tração.



Fonte: adaptado de (MOAVENI; FATHABADI; MOLAVI, 2020).

6.1.1.1 Visão geral

No estudo foram avaliados dados de 25 trens metropolitanos da empresa Trensurb (TREN SURB, 2022), que fazem a ligação metropolitana entre as cidades de Porto Alegre e Novo Hamburgo, passando por diversas cidades da região metropolitana de Porto Alegre, conforme representado na Figura 51. São trens elétricos da primeira aquisição de trens da Trensurb na década de 80 e foram fabricados por um consórcio de empresas Japonesas: Nippon Sharyo Seizo Kaisha, Hitachi e Kawasaki Heavy Ind.

As rotas podem estar relacionadas as cidades em destaque na Figura 51. Também podem ser consideradas rotas os trechos entre estações. Com base nestes trechos, foram investigados os registros operacionais referentes às falhas ocorridas nos 8 motores de tração identificados nos registros históricos. Além disso, considerou-se como rota o trecho entre estações para objeto de estudo, bem como as variáveis velocidade e Ponto, que são governadas pelos requerimentos operacionais específicos da rota.



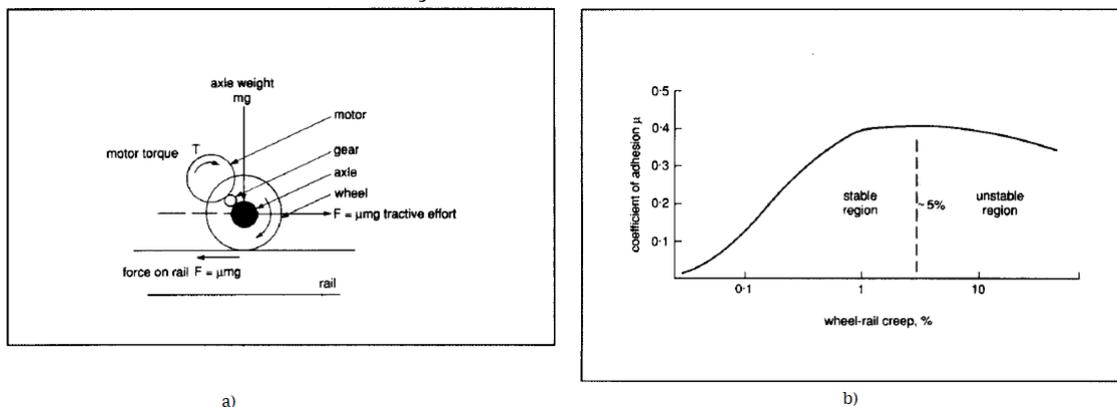
Fonte: (TREN SURB, 2022).

6.1.1.2 Falhas em motores de tração

Todos os trens avaliados neste estudo são movidos por motores de indução, controlados por inversor de tensão e conectados à caixa de transmissão (*Gear Box*). A operação requer a confiabilidade do motor para garantir que ele funcione sem falhas. São avaliadas informações relevantes a fim de facilitar o treinamento dos algoritmos de aprendizado para as situações de interesse (MOAVENI; FATHABADI; MOLAVI, 2020).

Existe uma variedade de falhas relacionadas ao sistema de tração responsável pelo movimento dos trens, e que fazem com que o sistema de proteção atue, como por exemplo sensores, motores elétricos, dispositivos eletrônicos de potência, etc (GARRAMIOLA *et al.*, 2018). Além disso, existem características específicas que estão relacionadas ao movimento dos trens e que possuem uma relação com as falhas relatadas. Conforme destacado na Figura 52a, a caixa de transmissão está conectada entre o motor elétrico e o eixo. Na Figura 52b, é apresentado um coeficiente de adesão que está relacionado ao movimento entre rodas e trilhos (HILL, 1994). Neste sentido, observa-se que as variáveis velocidade e Ponto (*Gear Box*) estão intimamente ligadas às falhas neste processo.

Figura 52 – a) transmissão de tração e a adesão entre rodas e trilhos ferroviários, b) gráfico do coeficiente de adesão em relação ao movimento das rodas.



Fonte: adaptado de (HILL, 1994).

6.1.2 Uso da Abordagem Clássica

A abordagem frequentista necessita que as probabilidades representem os relacionamentos dos eventos que ocorrem em uma determinada frequência, avaliadas em uma amostra. Assim, o padrão que é gerado, por exemplo, a partir de uma repetição das medições, possui uma distribuição de probabilidade amostral.

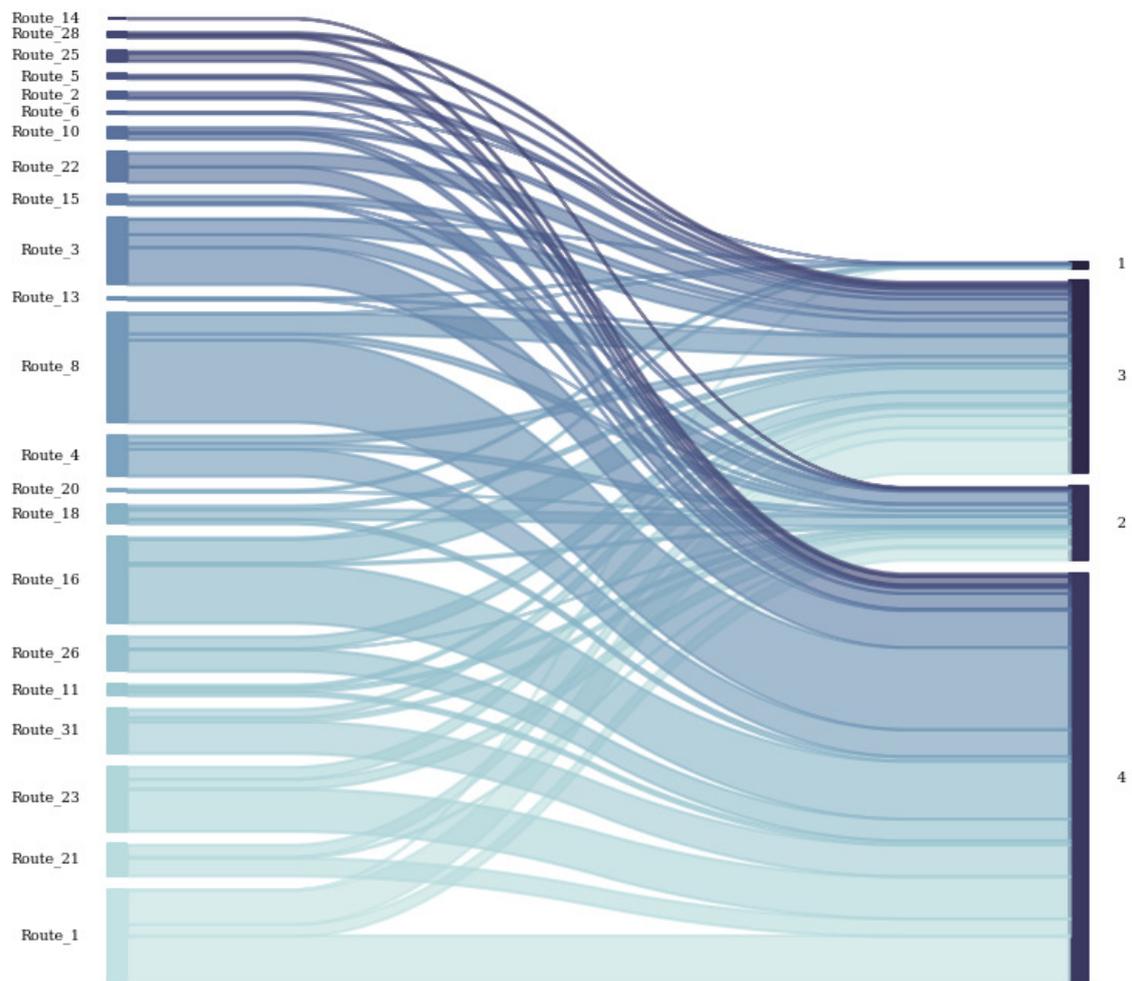
A abordagem dessa seção envolve estatística inferencial preditiva. O propósito da análise é inferir a probabilidade de falha (PoF) nos motores de tração dos trens. A análise estatística permite uma caracterização sobre o valor da PoF, que é inferida a partir das observações condicionadas aos padrões de eventos que ocorrem no domínio. Para isso, são utilizados dados históricos a fim de conhecer a PoF, permitindo tomar decisões relacionadas a esse parâmetro, estimando um evento de falha futura, na qual a distribuição irá depender do valor da PoF.

Um número significativo de falhas ocorreu nos Pontos 3 e 4 (*Gear Box*), conforme demonstrado à direita na Figura 53 do gráfico de Sankey. Apesar dessas falhas estarem relacionadas com a velocidade superior a 70 km/h, conforme demonstrado na Figura 54, quando relacionadas a um Ponto específico melhoram o processo de avaliação, conforme demonstrado na Figura 55. Assim, os dados de entrada do modelo estão relacionados às falhas ocorridas neste ambiente.

Para este estudo, a forma de avaliar o desempenho do modelo ocorre por meio da métrica chamada erro médio quadrático RMSE (*Root Mean Squared Error*) (KOFI; LUO; QUIN, 2013), (SALAKHUTDINOV; MNIH; HINTON, 2007). A arquitetura offline apresentada neste modelo permitiu gerar uma base de conhecimento para recomendações que contemplem os requisitos para um processo online.

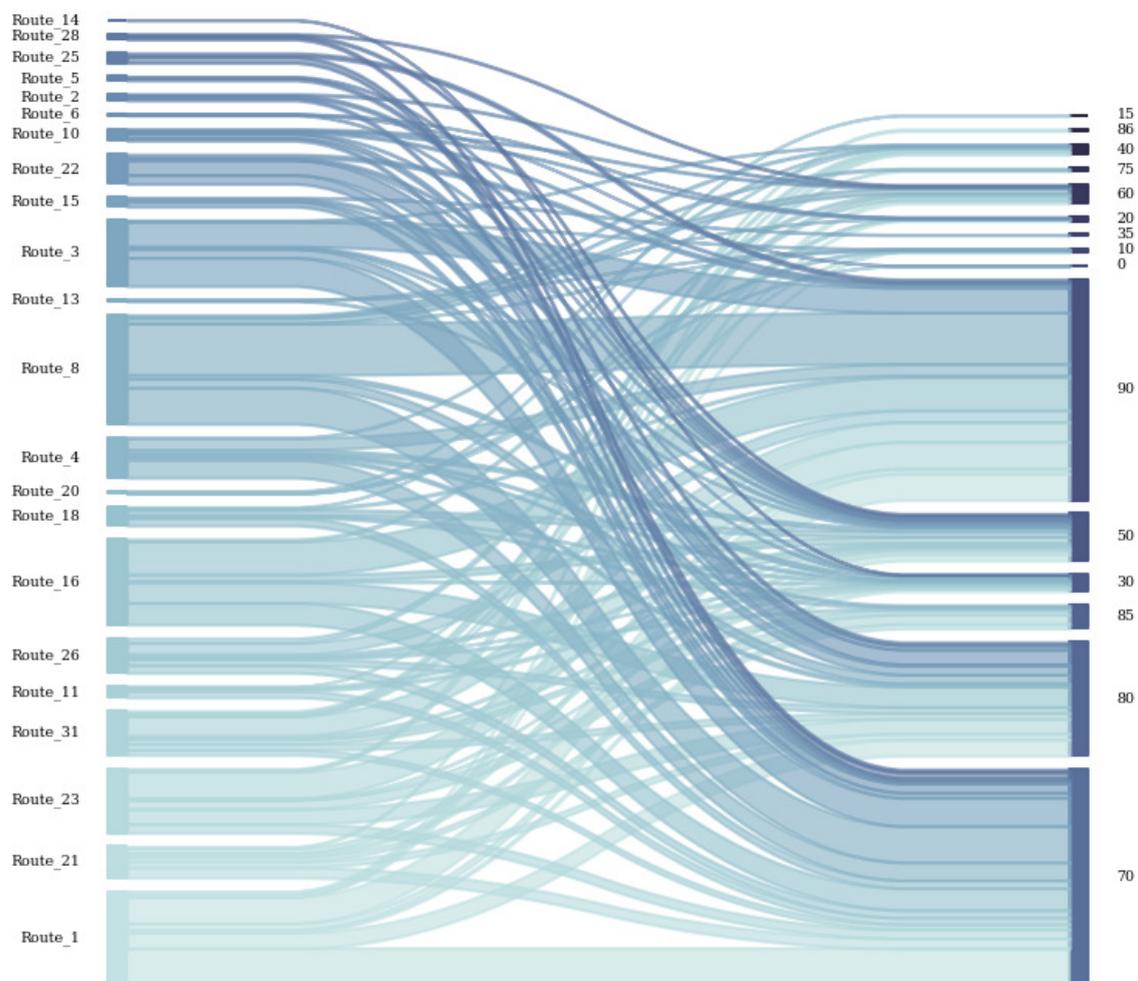
A RBM é implementada para aprendizagem de situações presentes, por exemplo, em um comportamento anormal no processo, minimizando o *log-likelihood* apresentada no

Figura 53 – ocorrências registradas nas diferentes Rotas presentes no domínio em relação ao Ponto (*Gear Box*).



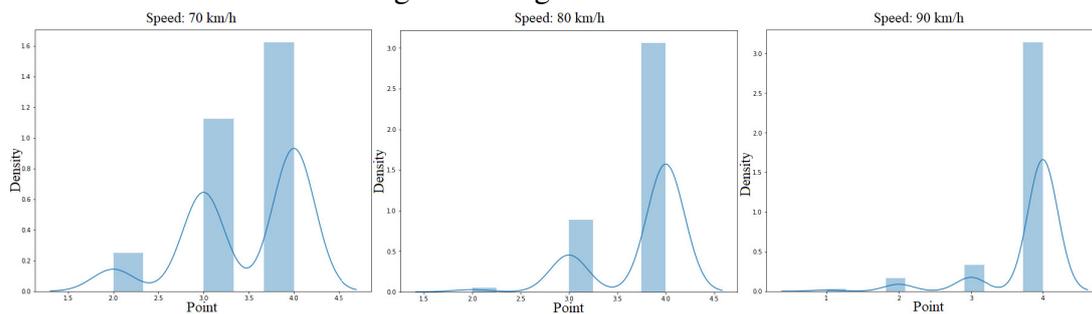
Fonte: autor.

Figura 54: rotas onde ocorreram falhas em relação à velocidade em Km/h.



Fonte: autor.

Figura 55: registro de falhas.



Fonte: autor.

Capítulo 2, Equação (4). Para atingir o objetivo de teste de contexto, este modelo estende as melhorias apresentadas inicialmente em (YU; MAIRESSE; YOUNG, 2011), ou seja, a abordagem de arquitetura adaptativa de contexto. O trabalho atual combina a abordagem proposta com um mecanismo de raciocínio. Como esta tese propõe uma nova arquitetura que leva em consideração o contexto, que são conceitos clássicos, referências relevantes para essas áreas de estudo podem ser encontradas em, (HINO; MURATA, 2014), (QUINLAN, 1986), e (YU; MAIRESSE; YOUNG, 2011).

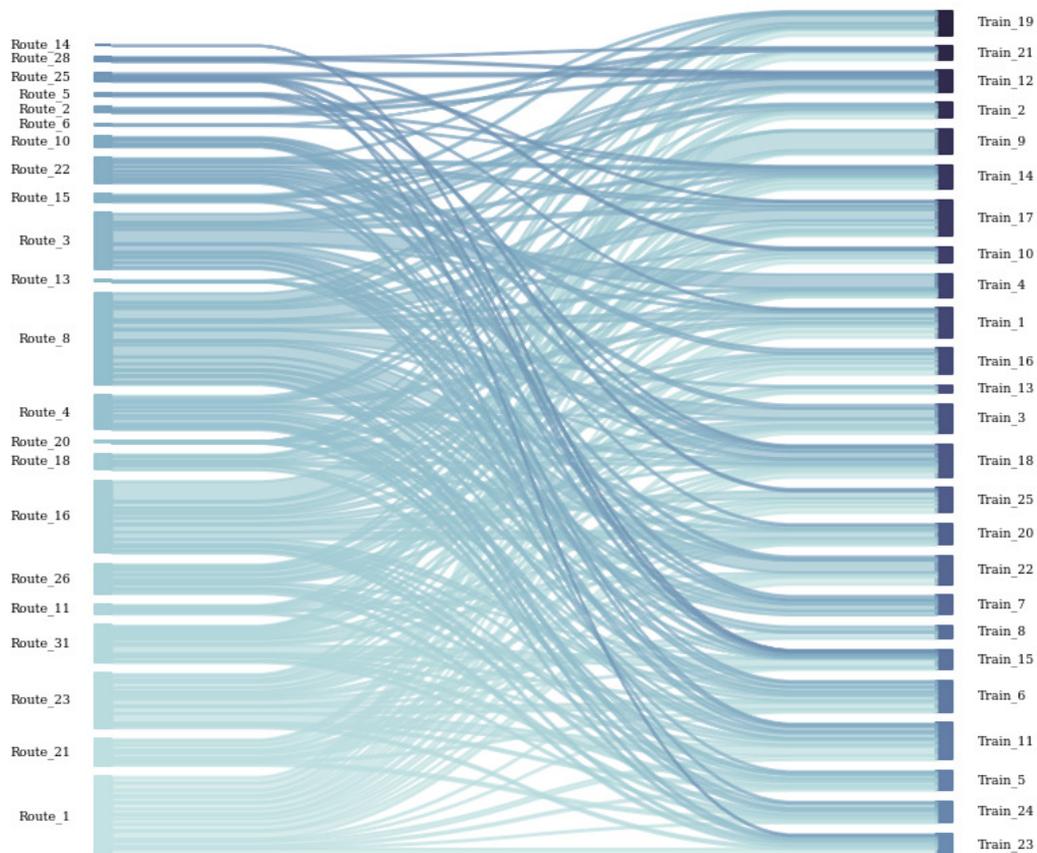
Este estudo foi dedicado a inferências que dependem de evidências, aborda dados gerados em um ambiente operacional real, e buscou adquirir mais informações a partir um motor de raciocínio guiado por *likelihood*. Contudo, os trabalhos relacionados são gerais para essas questões, principalmente em relação aos aspectos operacionais diante de determinadas situações. Os experimentos conduzidos investigaram os efeitos de falhas, considerando o uso de cenários de teste randomizados. Assim, esta abordagem permite rejeitar ao nível de significância de 95% a hipótese de que os fatores apresentados não influenciam na probabilidade de falha. A partir da mineração de dados é possível identificar os principais eventos relacionados a um determinado ambiente. Conforme observado na Figura 56, existem dezenas de rotas neste ambiente relacionadas a este histórico de falhas. Este diagrama facilita a observação do relacionamento entre as variáveis no gráfico. Uma análise utilizando estes resumos gráficos permitem verificar a relação entre as variáveis e seguir relatando os resultados das análises.

A situação analisada por meio do modelo, a partir de uma sequência de eventos, valida a situação de interesse e permite apresentar a probabilidade desse evento ocorrer. Para atender a essa demanda, este modelo avaliou dados registrados durante o período de 10 anos.

6.1.2.1 Setup dos Experimentos

Para a condução dos experimentos, os parâmetros de simulação envolvidos estão resumidos na Tabela 3. As contribuições deste modelo podem ser apresentadas nas análises práticas e nos *insights* de avaliação. A simulação com diversos cenários foi realizada para

Figura 56: ocorrências em relação às rotas.



Fonte: autor.

avaliar o impacto das falhas em motores de tração na ferrovia considerada.

Tabela 3: parâmetros do projeto de experimentos.

Código do Fator	Rota	Velocidade	Ponto
A1	Rota-1	-	-
A2	Rota-8	-	-
A3	Rota-16	-	-
B1	-	70	-
B2	-	80	-
B3	-	90	-
C1	-	-	3
C2	-	-	4

O cenário de teste avaliou três rotas, três valores de velocidade e dois Pontos diferentes. O objetivo é analisar como a variável relacionada afeta a operação do trem. Para isso, aplicou-se um planejamento fatorial para o experimento (MONTGOMERY, 2005), a fim de identificar os fatores que influenciam as falhas em motores de tração. Esses testes avaliam a influência dos fatores e suas interações na variável de resposta. O teste usado para avaliar os resultados foi o teste estatístico tipo F .

As seguintes hipóteses foram definidas para este estudo de caso:

1. influência do fator A (Rota) na probabilidade de falha.
 $H_0: \tau_i = 0$ - Fator A não tem efeito sobre a variável de resposta.
 $H_1: \tau_i \neq 0$ - Fator A tem efeito sobre a variável de resposta.
2. influência do fator B (Velocidade) na probabilidade de falha.
 $H_0: \beta_j = 0$ - Fator B não tem efeito sobre a variável de resposta.
 $H_1: \beta_j \neq 0$ - Fator B tem efeito sobre a variável de resposta.
3. influência do fator C (Ponto) na probabilidade de falha.
 $H_0: \phi_k = 0$ - Fator C não tem efeito sobre a variável de resposta.
 $H_1: \phi_k \neq 0$ - Fator C tem efeito sobre a variável de resposta.
4. influência da interação entre os fatores A.B na probabilidade de falha.
 $H_0: (\tau, \beta)_{i,j} = 0$ - Interação dos fatores A.B não tem efeito sobre a variável de resposta.
 $H_1: (\tau, \beta)_{i,j} \neq 0$ - Interação dos fatores A.B tem efeito sobre a variável de resposta.
5. influência da interação entre os fatores A.C na probabilidade de falha.
 $H_0: (\tau, \phi)_{i,j} = 0$ - Interação dos fatores A.C não tem efeito sobre a variável de resposta.
 $H_1: (\tau, \phi)_{i,j} \neq 0$ - Interação dos fatores A.C tem efeito sobre a variável de resposta.
6. influência da interação entre os fatores B.C na probabilidade de falha.
 $H_0: (\beta, \phi)_{j,k} = 0$ - Interação dos fatores B.C não tem efeito sobre a variável de resposta.
 $H_1: (\beta, \phi)_{j,k} \neq 0$ - Interação dos fatores B.C tem efeito sobre a variável de resposta.
7. influência da interação entre os fatores A.B.C na probabilidade de falha.
 $H_0: (\tau, \beta, \phi)_{i,j,k} = 0$ - Interação dos fatores A.B.C não tem efeito sobre a variável de resposta.
 $H_1: (\tau, \beta, \phi)_{i,j,k} \neq 0$ - Interação dos fatores A.B.C tem efeito sobre a variável de resposta.

Existem fatores controláveis relacionados às falhas em motores de tração, e estes são dispostos em um projeto fatorial. Cada experimento contém todas as combinações de

fatores. Conforme explicado acima, a combinação dos códigos com fatores (A, B e C) define os parâmetros de cada configuração experimental realizada, como o caso A1B1C1 exemplificado com Rota_1, com Velocidade de 70 km/h no Ponto 3. Os resultados da análise podem ser realizados a partir do teste de hipótese (contexto) (MONTGOMERY, 2005).

A Tabela 3 resume os parâmetros de realização de simulações elaboradas no planejamento de experimentos apresentados nesta seção, em que a primeira coluna é a rota com um código de fator controlável para cada valor. A segunda coluna é a velocidade com um código para cada valor em quilômetros por hora.

Neste modelo, a hipótese é rejeitada ou não com um nível de significância de 95%. Este nível exige um experimento com tamanho amostral igual a 18, graus de liberdade com dois e quatro para o fator do numerador e 17 para o fator do denominador, que é expresso por um valor tabulado $F_{0,05,2,17} = 3,59$ e $F_{0,05,4,17} = 2,96$ obtidos em (MONTGOMERY, 2005). Simplificando, a hipótese é rejeitada se seu valor F for maior que o valor crítico apresentado anteriormente.

Como pode ser observado na configuração experimental realizada ajustando os parâmetros como rota, velocidade e Ponto apresentados anteriormente na Tabela 3, seguindo uma randomização das rodadas de simulação. Os procedimentos são repetidos até que todas as observações necessárias sejam obtidas. Após a execução, todos os resultados foram processados e tabulados com software R.

6.1.2.2 *Resultados e Discussão*

Os resultados apresentados nesta seção exploram as hipóteses apresentadas e testadas em um experimento fatorial. Para essa avaliação, os resultados obtidos foram conduzidos pela análise da variância ANOVA (DEVORE, 2009). Os pressupostos da análise de variância dos resíduos são normalmente distribuídos com média zero e desvio padrão constante. As premissas são normalidade, independência e igual variância. O planejamento fatorial se mostrou prático, proporcionando uma análise sólida dos dados coletados durante o experimento (MONTGOMERY, 2005).

Os resultados obtidos nas simulações com os dois Pontos e três rotas avaliados neste estudo de caso e apresentados na Tabela 3, possibilitaram analisar o efeito nas suas aplicações e o impacto imposto pelas falhas. A independência dos dados é garantida por meio da randomização da ordem das rodadas do experimento.

A probabilidade de falha é investigada por meio de um conjunto de testes experimentais. Considerando as premissas relatadas em (MONTGOMERY, 2005), os experimentos apresentados nesta tese exploram os efeitos das falhas conforme apresentados e discutidos nesta seção. Entre as análises realizadas, resíduos vs ajustes indicam a randomização apropriada dos experimentos. A independência dos dados foi garantida através da randomização da ordem das rodadas do experimento.

Os fatores presentes neste ambiente são organizados em um experimento. O modelo linear é

$$y_{ijkl} = \mu + \tau_i + \beta_j + \phi_k + (\tau.\beta)_{i,j} + (\tau.\phi)_{i,k} + (\beta.\phi)_{j,k} + (\tau.\beta.\phi)_{i,j,k} + \epsilon_{ijkl}. \quad (15)$$

onde τ_i é o efeito do fator Rota (A), β_j é o efeito do fator Velocidade (B) e ϕ_k é o efeito do fator Ponto (C). O teste estatístico considera o *Mean Square* (MS) num teste de hipóteses, onde

$$MS' = MS_C + MS_{ABC} = 0.23759 + 0.01140 = 0.24899 \quad (16)$$

e

$$MS'' = MS_{AC} + MS_{BC} = 0.0259 + 0.03040 = 0.0563 \quad (17)$$

O efeito do fator Ponto pode ser calculado a partir de

$$F = \frac{MS'}{MS''} = \frac{0.24899}{0.0563} = 4.422 \quad (18)$$

Comparando o valor calculado de $F = 4.422$ com os valores tabelados $F_{0.05,2,17} = 3,59$ e $F_{0.05,4,17} = 2,96$ disponíveis em (MONTGOMERY, 2005), temos que é possível rejeitar a hipótese nula com 95% de significância.

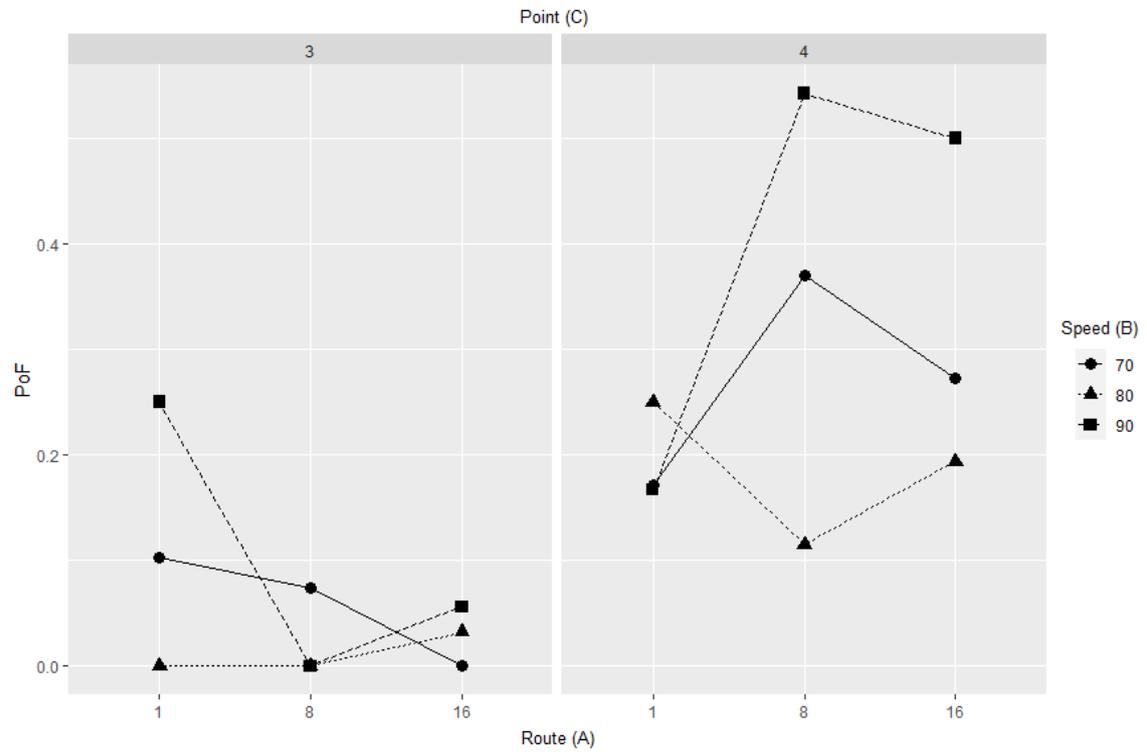
Os experimentos realizados visaram avaliar o comportamento da probabilidade de falha (PoF), sendo possível observar esse comportamento a partir das variáveis rota e velocidade, considerando uma variação da variável Ponto. Analisando a interação com a variável rota (ver Tabela 3), é possível observar na Figura 57 PoF, como o Ponto 4 influencia neste resultado em comparação ao Ponto 3.

Observou-se neste experimento, na Figura 58, um aumento da entropia, que é observado com relação às mudanças na variável Ponto. Além disso, os resultados apresentados indicam que o aumento da PoF, ocorrido entre as rotas 2 e 3, também está relacionado à mudança do Ponto. Por fim, observa-se que com o Ponto 4, relacionado ao fator C2, e todos os valores do fator B (ver Tabela 3), sendo combinações considerando 3 rotas, e com todos os valores de velocidade, ocorre um aumento da PoF, sendo possível observar inclusive pela variação da entropia.

6.1.2.3 Considerações Finais

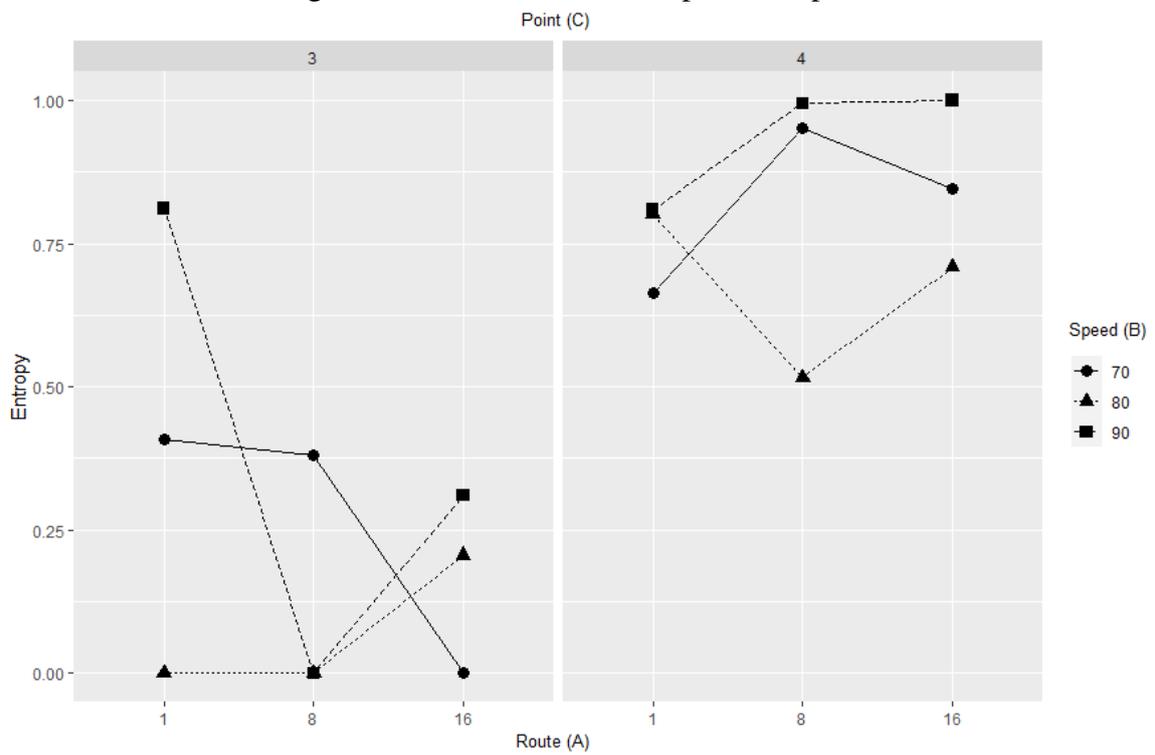
O modelo apresentado neste estudo contempla um projeto de experimentos, sendo que os requisitos foram derivados da literatura. Isso ressalta a importância da abordagem desenvolvida com base nos dados operacionais. Como a RBM é um modelo matemático de um experimento probabilístico, o objetivo do aprendizado da RBM é em função de otimização da distribuição de probabilidade. A informação não está localizada em um

Figura 57: carta multi-variável para PoF.



Fonte: autor.

Figura 58: carta multi-variável para entropia.



Fonte: autor.

único neurônio, e sim na distribuição entre diversos neurônios. Além disso, observa-se que a arquitetura desenvolvida pode beneficiar a operação do Metro, a partir de procedimentos de projeto baseado no processo de descoberta de conhecimento em dados e teste de contexto (hipóteses).

Este modelo demonstra a aplicação da abordagem desenvolvida a partir de um cenário real. Os resultados permitem concluir que, ao considerar o contexto, essa metodologia ajudou a melhorar o modelo baseado em ML. A contribuição dessa abordagem é a capacidade de prever situações para dar suporte aos operadores, considerando a severidade das situações presentes em um ATS, que, em geral resultam em perdas de produção e confiabilidade do processo. Ao aplicar a metodologia desenvolvida, observou-se que as ações operacionais para corrigir as condições do processo, ocorrem diante de incertezas. Isso é um problema sugerido nos trabalhos relacionados, porém não detalhados. Além disso, foi possível analisar este problema levando em consideração a informação da entropia. Essa abordagem contribuiu para implementação da abordagem Bayesiana, que será apresentada a seguir.

6.1.3 Uso da Abordagem Bayesiana

A estatística Bayesiana permite considerar a incerteza presente na informação avaliada do domínio no processo decisório. Dessa forma, os parâmetros e as evidências são tratados como semelhantes, embora sejam percebidos no domínio de forma diferente. Além disso, um conhecimento *a priori* é um valor probabilístico que participa na representação da incerteza e que descreve uma crença em relação às hipóteses. Neste ponto, tradicionalmente considera-se a experiência de um especialista para informar esse valor. Assim, é possível, num processo inferencial, partindo dos eventos, chegar aos parâmetros que representam as causas que geraram esses eventos. Contudo, observa-se que o número de hipóteses muda conforme o contexto. Considerando os valores estimados, resultantes da abordagem clássica, é possível regular os parâmetros para observar o comportamento do modelo, e assim, combinar as abordagens.

Descobrir um conhecimento é identificar, receber informações, computá-las e adicioná-las a um conhecimento prévio (FAYYAD; PIATETSKY; SMYTH, 1996), (WIRTH; HIPPEL, 2000), (MANNANI; IZADI; GHADIRI, 2019). Assim, um processo de descoberta de conhecimento torna-se complexo e, muitas vezes, subjetivo, dependendo do problema a ser resolvido e de como uma situação é percebida pela pessoa, incluindo a forma como os processos, que são em geral operados por pessoas são conduzidos durante uma falha em particular, além de como são tomadas as decisões operacionais.

Para o desenvolvimento apresentado neste estudo, um histórico com registro de eventos pode fornecer dados amplos para a execução da mineração de dados. Em um cenário de aplicação, uma motivação comum incluída nesta etapa envolve um grupo de especialistas de domínio de diferentes áreas do negócio para agregar e investigar dados com base

na experiência do grupo, a fim de resolver o problema em questão ou explorar oportunidades de melhoria no processo. Esse objetivo é então transformado em um problema específico de mineração de dados. Durante a fase de compreensão dos dados, as hipóteses para o problema são formadas com base em premissas qualificadas. Na ciência de dados, as principais variáveis são coletadas e são gerados recursos com relação ao objetivo da mineração de dados. Depois disso, segue-se para a fase em que um modelo de estimativa de probabilidade depende de uma distribuição de probabilidade local (LPD). Na fase subsequente, o modelo é testado e os resultados são avaliados de acordo com as evidências.

Com base nos resultados da mineração de dados é possível identificar os principais eventos relacionados a um determinado processo. A situação analisada a partir de uma sequência de eventos valida a situação de interesse. Os parâmetros de uma BN determinam a força das relações probabilísticas entre seus nós. Cada nó da BN possui um conjunto único de estados com uma distribuição de probabilidade condicional à combinação dos estados de seus nós pais, ou se o nó não tem pai, uma distribuição incondicional. Para variáveis discretas, que são utilizadas nesta tese, a distribuição de probabilidade é observável por meio de uma LPD (LOCHER; LASKEY; COSTA, 2020). Os nós que não possuem pais não apresentam uma LPD. Assim, as LPDs são fixas e determinadas no momento da construção da BN (HABERLIN, 2013).

O modelo probabilístico apresentado utiliza uma linguagem de primeira ordem *Multi-Entity Bayesian Network* (MEBN), na qual os fragmentos (MFrag) expressam a incerteza na relação entre as entidades. Esses fragmentos fazem parte de uma teoria MEBN *MTheory* (LASKEY, 2008), expressando a distribuição de probabilidade das situações que envolvem as entidades do domínio. Um software de código aberto para modelagem, apresentado em (CARVALHO; LASKEY; COSTA, 2016), chamado UnBBayes, permitiu o aprendizado e raciocínio sobre as redes probabilísticas. UnBBayes suporta diferentes categorias de redes probabilísticas, incluindo diagramas de influência.

6.1.3.1 Modelagem Probabilística

No modelo probabilístico, ao descrever o conhecimento sobre um domínio e a incerteza associada a esse conhecimento de forma fundamentada, não há necessidade de todas as relações de uma ontologia serem probabilísticas (LOCHER; LASKEY; COSTA, 2020), (LASKEY, 2008). A representação funcional básica da ontologia probabilística implementada é apresentada na Figura 46.

O contexto é uma fonte real de informações por meio das atividades gerais que ocorrem no ambiente. Neste estudo de caso, uma abordagem para ambientes que exploram o conhecimento semântico por meio de modelos probabilísticos, para determinar a probabilidade de uma situação acontecer no futuro próximo, a partir de um modelo de contexto de definição da situação é apresentada. Os nós implementados neste trabalho são:

1. vehicle-MFrag: representa a probabilidade do veículo estar envolvido em um determinado evento dentro da situação. Este fato é representado pelo nó residente $isAtCurrentEvent(v, currentEvent) = \{true, false\}$;
2. action-MFrag: representa a probabilidade de uma ação ser executada com base na situação. Este fato é representado pelo nó residente $hasAction(v) = \{Actions\}$;
3. state-MFrag: representa a probabilidade de um estado ocorrer com base no histórico do estado, representado pelo nó residente $actualState(st) = \{Level_A, Level_B, Level_C\}$ e o histórico do evento que deu início a situação dentro de um estado, representado pelo nó $hasEvent(st, si) = \{Eventos\}$;
4. situation-MFrag: representa a distribuição de probabilidade local de uma situação preditiva durante um determinado período de tempo, sendo recomendada através do nó $willBeSituation(si, t, v) = \{True, False\}$. A distribuição de probabilidade deste nó é resultante dos MFraags anteriores. Esta distribuição é calculada através do nó residente $changeSituation(v, t) = \{States\}$ conforme demonstrado na Figura 47. As situações do nó residente $changeSituation$ são eventos presentes nos estados. Desta forma, é possível calcular a probabilidade de uma situação específica ocorrer influenciada pelos MFraags anteriores.

O cálculo da distribuição de probabilidade conjunta é realizado a partir das probabilidades condicionais locais (LPDs). Um aspecto relevante é que uma MEBN não fornece um padrão para a LPD (LASKEY, 2008). O processo de raciocínio e inferência da MEBN é realizado por uma questão que implica a geração de uma rede Bayesiana de situação específica, do inglês SSBN (*Situation Specific Bayesian Network*), que representa uma BN e que determina a probabilidade de uma situação específica.

Nesta tese, foram analisadas situações por meio de ontologias probabilísticas. Essa abordagem permite resolver a questão apresentada no final da Seção 2.6.2, onde foi destacado uma limitação na aplicação de BN. Este modelo utilizou linguagens probabilísticas baseadas em MEBN para descrever o conhecimento sobre um domínio e uma incerteza associada a esse conhecimento.

6.1.3.2 Resultados e Discussão

A ideia de definir uma situação preditiva, que pode ocorrer no futuro, envolve a incerteza. Para isso, uma BN é um modelo de grafo flexível para expressar uma distribuição de probabilidade conjunta em hipóteses inter-relacionadas. Assim, permite a representação da incerteza de forma semântica.

A previsão da condição de falha desempenha um papel fundamental para este domínio (RIERA-GUASP; ANTONIO-DAVIU; CAPOLINO, 2014). Para avaliações experi-

mentais deste modelo, foram escolhidos dados reais, a fim de desenvolver a arquitetura MEBN apresentada. Dados são coletados de modo contínuo dos processos técnicos automatizados. Ao processar esses dados seguindo uma metodologia, é possível analisar a situação atual e calcular a probabilidade de uma situação de interesse ocorrer. Nesse contexto, o modelo estrutura um contexto relevante em relação à situação corrente. Além deste estudo descrever os elementos do contexto e seus relacionamentos, a abordagem baseada em ontologia fornece uma especificação formal da semântica dos dados de contexto, que é adequada para o compartilhamento do conhecimento.

As LPDs geram a SSBN para cada situação futura, de acordo com as relações semânticas que estão mapeadas pelas instâncias do domínio. Por exemplo, na SSBN mostrada na Figura 59, temos uma situação reativa na forma de uma SSBN. Assim, a LPD para o nó residente *willBeSituation* (motor, falha, probabilidade: 52%, tempo: t_1) descreve como os outros nós residentes influenciam na inferência da probabilidade desta situação por meio dos eventos, definidos no nível semântico a partir de um padrão, no tempo t_0 , por meio do nó residente *changeSituation*.

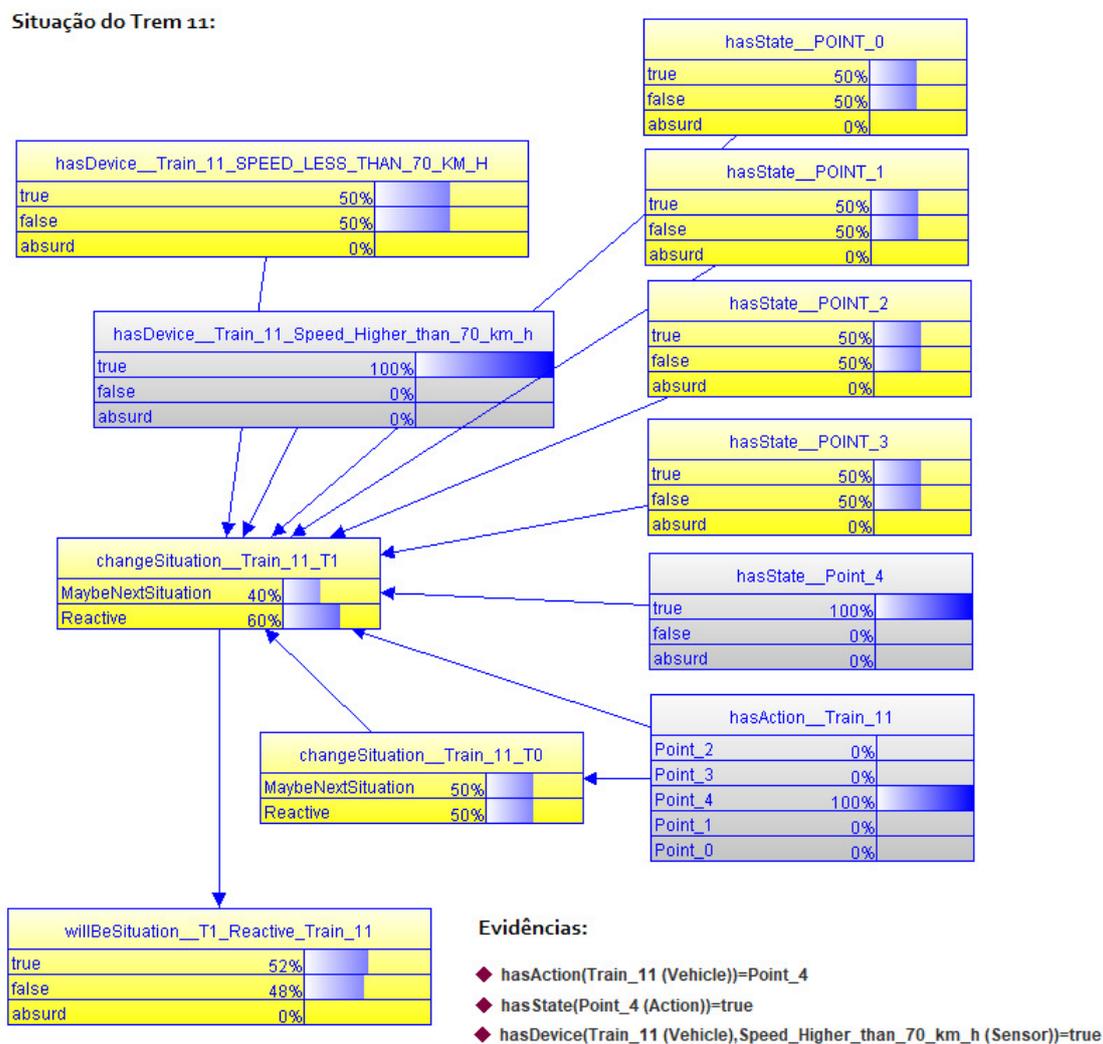
Neste estudo foram descritos os elementos do contexto e seus relacionamentos, além de uma abordagem baseada em ontologia probabilística, implementada a partir do modelo conceitual, permitindo descrever o conhecimento, com base na distribuição de probabilidade presente num padrão de dados avaliados no domínio. O raciocínio probabilístico envolve uma consulta sobre modelo semântico. Com isso, permite avaliar a probabilidade do trem estar em uma situação reativa, dadas as evidências, ou seja, na distribuição de probabilidade local para o nó preditivo, é aplicada a probabilidade no tempo t , permitindo avaliar o contexto no qual a situação *Reactive* é válida. Assim, a inferência probabilística é usada para o tratamento da incerteza presente no domínio, de forma que são tratadas as hipóteses para identificar a probabilidade de ocorrência da situação anormal de operação.

6.1.4 Comparação dos Resultados

Algumas comparações são feitas a partir dos resultados apresentados nesta tese. Ambas abordagens permitem avaliar evidências para uma hipótese usando uma amostra de dados. Isso pode ser comprovado quando avaliado o valor da PoF apresentado na Figura 57 para o Ponto (*Gear Box*) 4 em relação ao valor percentual apresentado pela SSBN da Figura 59, resultante da consulta sobre a probabilidade de o trem estar envolvido em uma situação específica. Contudo, a abordagem Bayesiana está mais próxima da lógica probabilística em relação à abordagem clássica. Isso ocorre, pois à abordagem clássica é baseada em uma regra para avaliar evidências para uma hipótese. Além disso, as conclusões que podem ser feitas são de que as falhas ocorrem com determinados valores de probabilidade.

Este estudo de caso permitiu avaliar a abordagem proposta considerando dados reais que possuem questões relacionadas a incerteza que foram consideradas. Abordagens

Figura 59 – rede Bayesiana gerada para uma situação reativa. Análise implementada com plugin UnBBayes (HABERLIN, 2013).



Fonte: autor.

da literatura exploram parcialmente essa questão e, em geral não detalha como explorar dados estatísticos, ignorando abordagens semânticas.

Na abordagem Bayesiana não são feitos experimentos. O resultado da probabilidade é inferido e dado pela propagação das evidências na rede e expressam uma incerteza. De todo modo, nesta tese, foram investigados os valores de entropia para a abordagem clássica que, para as definições relacionadas a teoria da informação (SHANNON, 1949) também expressa a incerteza.

O estudo da abordagem Bayesiana também deixa evidente que as probabilidades são avaliadas como crenças subjetivas, haja visto que é possível apresentar novas evidências, que são propagadas pela rede e permitem atualizar a crença, permitindo avaliar a incerteza nos valores dos parâmetros depois de observados os dados. Os dados históricos do ATS nos permitem realizar um processo de aprendizado de um valor, que se refere a uma

distribuição de probabilidade dos valores dos parâmetros, e que são entradas em uma LPD.

Uma característica que justifica uma abordagem a partir do modelo proposto nesta tese é que, uma vez investigados os dados do processo, é possível, por exemplo avaliar uma situação de interesse com base em um contexto que, no caso da abordagem clássica não é possível, ou seja, foram definidos o contexto e a situação, enquanto que na abordagem clássica essa definição não é possível. Contudo, os resultados obtidos pela abordagem clássica foram utilizados para preencher os valores das LPDs presentes na abordagem Bayesiana. Isso pode ser considerada uma contribuição importante para este estudo, dado que os trabalhos relacionados não apresentaram uma solução para essa questão, em comparação com os trabalhos de (AZIZ *et al.*, 2019) e (SOLEIMANI; CAMPEAN; NEAGU, 2021). Além disso, trabalhos relacionados que apresentam uma abordagem Bayesiana, não enfrentam a questão nativa da rede, que limita o raciocínio sobre a incerteza, embora seja resolvido a partir da abordagem ontológica probabilística.

6.1.5 Considerações Finais

A aplicação de raciocínio ontológico probabilístico permite inferir novas situações de contexto baseadas em classes e propriedades modeladas e no estado atual do ATS. Os dados de contexto gerados no ATS eventualmente produzem informações imprecisas que podem ser processadas por meio de raciocínio probabilístico. Assim, ontologias probabilísticas permitem descrever o conhecimento sobre um domínio e uma incerteza associada com esse conhecimento.

Nesta tese, são utilizadas linguagens probabilísticas de primeira ordem *Multi-Entity Bayesian Networks* (MEBNs). Conforme apresentado, a representação de incertezas em uma ontologia é possível considerando uma abordagem probabilística. A partir dos padrões considerados, os dados probabilísticos foram gerados para um cenário real e apresentados como evidência no software UnBBayes. A evidência é adicionada na teoria MEBN como axiomas, diretamente nos modelos (MFragments). A partir dos resultados apresentados, depois de conhecer o padrão de eventos validado numa situação atual, é possível a partir deste modelo, determinar a probabilidade de ocorrência de uma situação futura, ou seja, a probabilidade do veículo se encontrar na situação de interesse (*Reactive*), representada através de uma SSBN.

Apesar de sua importância nas aplicações de engenharia, as ontologias probabilísticas baseadas em redes Bayesianas não são um assunto recorrente na pesquisa científica atual e os trabalhos apresentados na literatura estão relacionados aos ambientes educacionais ou domésticos, destacando o diferencial presente nesta tese.

6.2 Estudo de Caso 2: Tennessee Eastman Process

Neste estudo de caso é apresentado o resultado dos testes realizados considerando dados gerados a partir da simulação do sistema de controle industrial TEP (*Tennessee Eastman Process*) (DOWNS; F., 1993). O TEP foi escolhido para este estudo devido ao controle do ambiente que a simulação oferece. O TEP possui dezenas de atributos que representam medidas conforme apresentado na Figura 60. Também possui um conjunto de falhas que podem ser injetadas durante a simulação. Após coletar os dados simulados, inicia-se a etapa que envolve extrair conhecimento útil a partir destes dados, por meio de aprendizado de máquina.

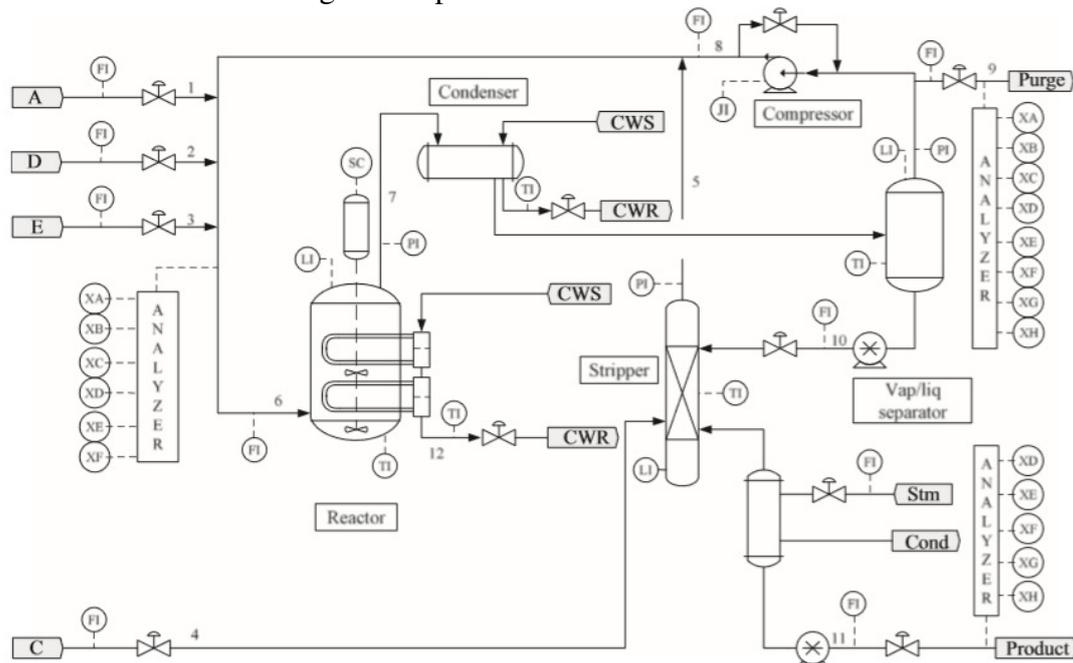
Conforme apresentado na primeira seção desta tese, a sofisticação dos SDCDs ao longo do tempo não possibilitou uma redução de alarmes apresentados para os operadores durante situações anormais da planta. A causa disso é que falhas no chão de fábrica são inevitáveis. Estas falhas provocam uma redução na performance do processo e o acionamento de uma função de segurança não impede que ocorram acidentes. Exemplos de alguns acontecimentos foram apresentados no Capítulo 1.

6.2.1 Descrição da aplicação

A planta TEP permite simular um ambiente industrial. Esta simulação gera dados referentes à operação normal e em falha e, em seguida, estes dados são armazenados. Assim, a implementação da simulação do TEP gera o conjunto de dados usados como entrada para o modelo de regressão. A simulação possibilitou analisar o estado normal de operação e todos os estados de falha. Com isso, foram armazenados os valores de saída num arquivo em formato CSV. Este arquivo possui colunas que representam os recursos do processo, como a temperatura interna do reator ou o controle da mistura dos elementos químicos utilizados na produção. As linhas do arquivo gerado representam observações relacionadas aos recursos do TEP. Uma representação do TEP pode ser observada na Figura 60.

O *benchmark* TEP simula um processo químico com variáveis responsáveis pelas diferentes etapas da produção, listadas na Tabela 4. Este processo possui quatro reagentes, dois produtos e um subproduto (DOWNS; F., 1993). As variáveis de entrada possuem parâmetros, por exemplo o fluxo de reagentes, que impacta diretamente no modo de operação deste processo. A partir dos valores gerados pelos diferentes sinais, nos equipamentos deste processo, os dados gerados são armazenado e posteriormente utilizados neste estudo de caso. A base de dados gerada possui atributos que correspondem às diversas medidas do processo. O TEP possui variáveis responsáveis pelas diferentes etapas de produção. As variáveis de entrada possuem parâmetros como o valor do sensor, e isso impacta diretamente no modo de operação da planta.

Figura 60: processo Tennessee Eastman.



Fonte: (DOWNS; F., 1993).

6.2.2 Pré-processamento de Dados

Após a importação dos dados gerados na simulação, é necessário definir um conjunto de treino, que contém os dados de entrada a serem aplicados na rede neural RNN. Uma etapa de normalização é necessária para utilização da função de ativação sigmoideal, utilizada no processo de aprendizagem. Além disso, é necessário definir um intervalo de valores entre zero e um. Em seguida, é necessário criar uma nova estrutura de dados, a fim de aplicar essa normalização como uma nova variável que contém o conjunto de dados de treino normalizados. Na etapa seguinte ocorre a criação de uma estrutura de dados específica, de modo que a RNN possa ser aplicada para prever novos valores. Para isso é utilizada uma janela de tempo do tipo deslizante, citada na Seção 2.5.4, sendo definidas as etapas de tempo necessárias para esse processamento. Estes intervalos de tempo significam que para cada valor de t a rede RNN irá examinar os valores antes da etapa de tempo definida previamente e, com base nas tendências e correlações durante essas etapas de tempo, irá prever o próximo valor no tempo $t+1$.

Tabela 4: Variáveis do processo TEP.

Variável	Descrição
XMEAS 1	Vazão de alimentação do componente A: XMV 3
XMEAS 2	Vazão de alimentação do componente D: XMV 1
XMEAS 3	Vazão de alimentação do componente E: XMV 2
XMEAS 4	Vazão de alimentação dos componentes A e C: XMV 4
XMEAS 5	Vazão reciclo do compressor
XMEAS 6	Vazão alimentação do reator
XMEAS 7	Pressão do reator
XMEAS 8	Nível do reator
XMEAS 9	Temperatura do reator
XMEAS 10	Vazão de purga
XMEAS 11	Temperatura do separador
XMEAS 12	Nível do separador
XMEAS 13	Pressão do separador
XMEAS 14	Vazão de líquido na saída do separador: XMV 7
XMEAS 15	Nível da retificadora
XMEAS 16	Pressão da retificadora
XMEAS 17	Vazão de líquido na saída da retificadora: XMV 8
XMEAS 18	Temperatura da retificadora
XMEAS 19	Vazão de vapor para retificadora
XMEAS 20	Trabalho do compressor
XMEAS 21	Temperatura de saída da água de resfriamento para o reator
XMEAS 22	Temperatura de saída da água de resfriamento para o condensador
XMEAS 23-28	Medidas das composições A-F de alimentação do reator
XMEAS 29-36	Medidas das composições A-H do gás de purga
XMEAS 37-41	Medidas das composições D-H do produto de fundo da retificadora

Após o treinamento do modelo, ocorre uma reformulação interna na RNN de todos os dados, os quais agregam a dimensionalidade necessária para a construção da estrutura prevista na última etapa, denominada neste estudo como unidade, que representa o número de preditores utilizados para prever o próximo valor correspondente. Deste modo, é necessário adicionar os indicadores que irão permitir prever as tendências ascendentes e descendentes das variáveis. Para adicionar essa nova dimensão na matriz, é necessá-

rio utilizar mais uma função denominada *reshape*, com um tensor 3D de acordo com o número de observações para as etapas de tempo e para os preditores.

6.2.3 Construindo a RNN

A RNN é configurada como um modelo, que permite prever os recursos que fornecem uma representação dos dados em relação ao comportamento do processo. Neste caso, para prever um valor contínuo, optou-se pelo estudo deste modelo no modo de regressão. Em seguida é adicionada na camada LSTM uma etapa de regularização denominada *dropout*.

A rede neural artificial é utilizada para à predição no comportamento das variáveis avaliadas. Este modelo demonstra as possibilidades em explorar um algoritmo de regressão. Após o treinamento do modelo, o processo segue para a fase de validação. Nesta etapa, utiliza-se o otimizador *Adam* (ABADI *et al.*, 2016). Para avaliar o desempenho do modelo, é aplicada a métrica RMSE (*Root Mean Squared Error*) destacada na literatura. Com isso, é possível prever tendências de valores de variáveis contínuas em processos utilizando camadas LSTM. Para concluir esta etapa, é necessário conectar a rede neural ao conjunto de dados de treino e executar este treinamento. Também é necessário definir o número de épocas para convergência e um tamanho de lote, avaliados ao atualizar os pesos da rede neural artificial.

6.2.4 Uso da abordagem com RNN-LSTM

A divisão da base em dados de treino e teste é uma técnica, na qual parte do conjunto de dados é utilizada para treinar os modelos, enquanto que a outra parte é utilizada para validar esses modelos. Tendo em mãos os resultados da validação, é possível trabalhar com os parâmetros, a fim de alcançar um melhor resultado na predição.

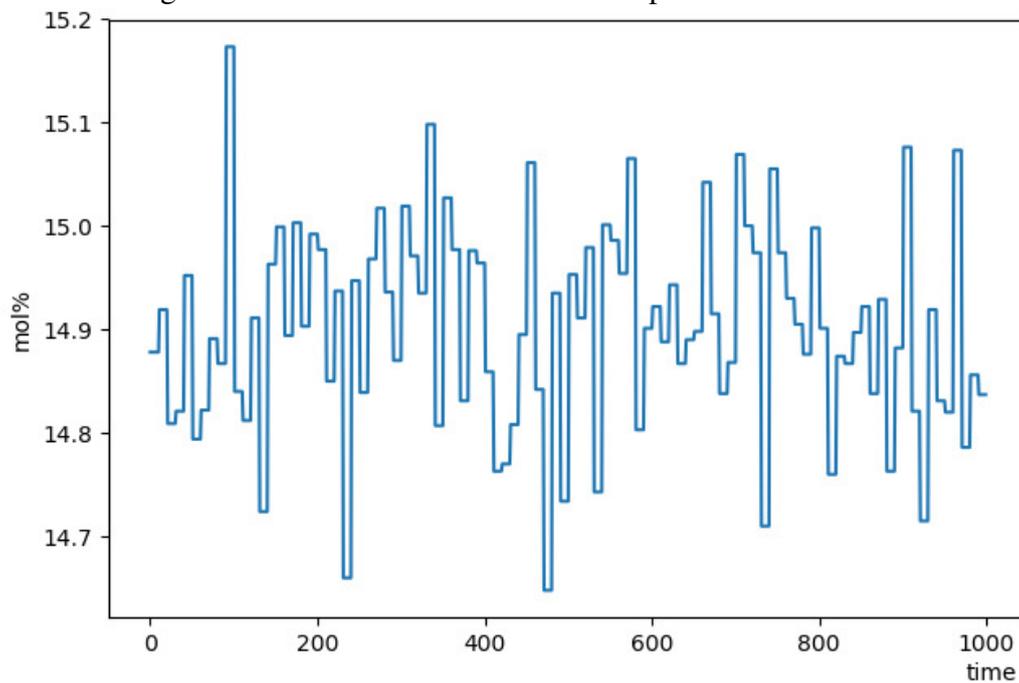
Os testes tiveram como objetivo identificar o comportamento das variáveis contínuas presentes no processo TEP. Os dados utilizados para os testes são originários de uma sequência de variáveis, de modo que esses dados gerados, resultam do processo industrial simulado utilizando o software MATLAB®/Simulink®.

Os dados de processo brutos, que tem como origem diversos sensores em um ambiente industrial, são complexos e incertos. Os trabalhos citados no referencial teórico destacam essa questão e descrevem como um desafio o esforço necessário para extrair informações úteis destes dados, para então realizar uma detecção de um comportamento de falha, retornando com algum tipo de resposta, como por exemplo, uma recomendação.

O comportamento normal do fluxo de entrada de produto no reator, onde é possível observar que o valor é estável em torno do valor de 14.9% da massa total que entra no reator é apresnetado na Figura 61.

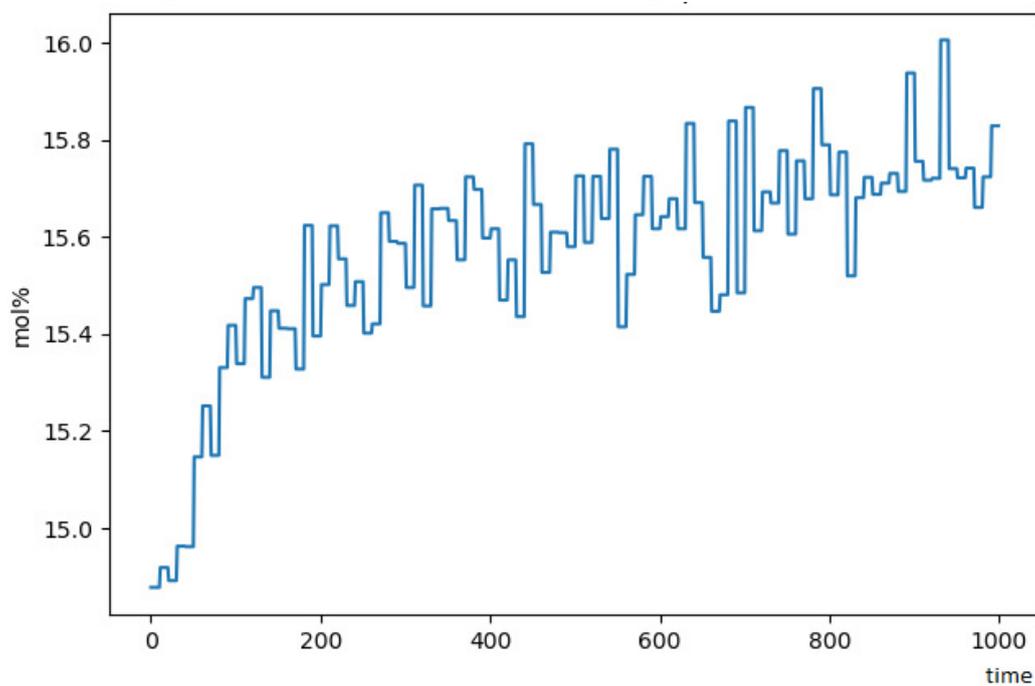
Na Figura 62, é observado o comportamento de falha, de modo que ocorre um aumento na concentração deste produto na entrada do reator, atingindo o valor de aproximadamente 16%. Este é um requisito funcional importante para um sistema de alarme

Figura 61: variável XMEAS 24 em comportamento normal.



Fonte: autor.

Figura 62: variável XMEAS 24 em comportamento de falha.

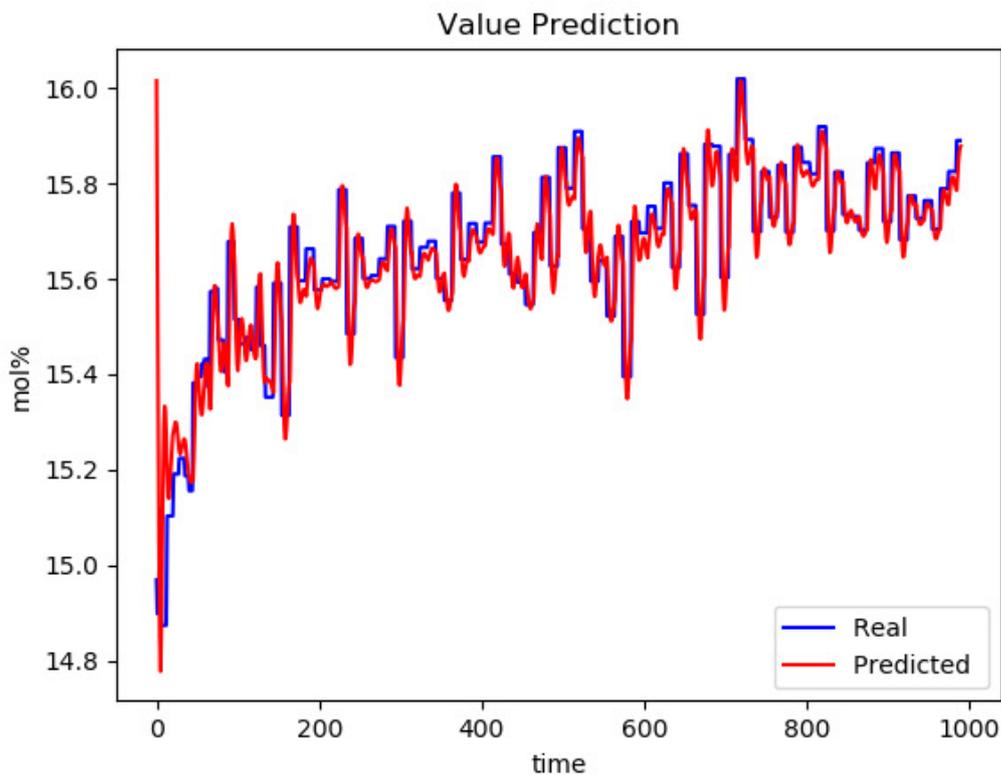


Fonte: autor.

industrial, que deve detectar e avisar o operador sobre as condições anormais de operação que requerem uma atenção. Em geral, devemos confiar em um operador para identificar

rapidamente a situação anormal de operação e atuar, evitando assim que o processo inicie um estado reativo ou, em determinadas situações, uma emergência.

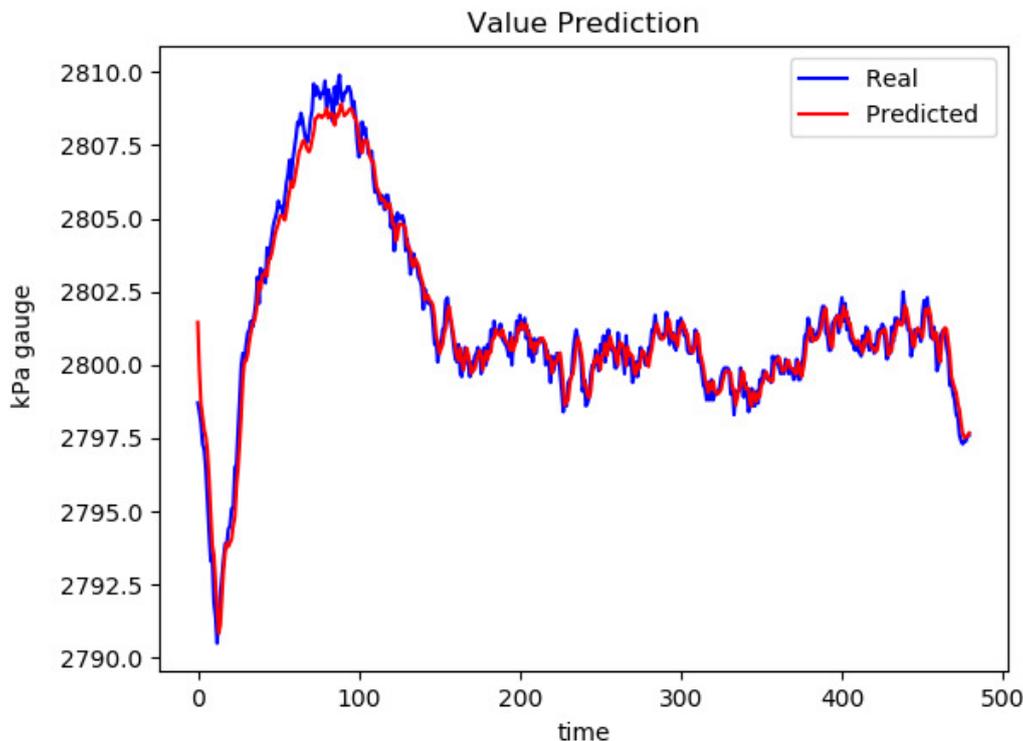
Figura 63 – análise preditiva da variável de processo XMEAS 24 em comportamento de falha.



Fonte: autor.

Os testes experimentais tiveram como objetivo avaliar o comportamento das variáveis do processo contínuo, que pode ser observado na Figura 62. Um valor é previsto para o valor da variável XMEAS 24, diante do comportamento de falha apresentado. Neste modelo, utilizou-se o processo simulado Tennessee Eastman para analisar um ambiente industrial. Esta simulação permitiu gerar os dados referentes a operação da planta. Os experimentos realizados tiveram como objetivo avaliar o comportamento das variáveis deste processo, como por exemplo XMEAS 24 apresentada no comportamento de falha, conforme demonstrado na Figura 63. Observou-se durante o aumento da concentração deste elemento na entrada do reator, uma variação na pressão de operação deste equipamento, conforme demonstrado na Figura 64, sendo que os valores preditos para ambas as variações, podem ser observados nas linhas em vermelho.

Figura 64: resultado da análise preditiva da pressão no reator.



Fonte: autor.

6.2.5 Considerações Finais

A maioria das falhas que provocam a uma situação reativa numa planta ou processo e, conseqüentemente, a interrupção da produção ou um desligamento de emergência em estado de *Shutdown*, são impulsionadas pelo próprio processo, podendo ser previstas e até mesmo controladas.

Este modelo permitiu a previsão do comportamento das variáveis de processo de uma planta industrial simulada. Além disso, os métodos foram baseados no aprendizado da máquina. Para o treinamento do método regressor, os dados utilizados para treino e validação, foram extraídos do conjunto de dados gerados durante as simulações, realizadas seguindo os requisitos descritos em (DOWNS; F., 1993).

A análise computacional mostra que o método de regressão apresentado, a partir deste modelo, permite identificar o comportamento da falha que ocorre durante um processo. Esta é uma questão crítica, especialmente porque as falhas exigem uma ação ou análise em um momento específico pelo operador. Desta forma, é possível avaliar o comportamento dos eventos e prever a situação da planta.

7 CONCLUSÃO, CONTRIBUIÇÕES E TRABALHOS FUTUROS

Com base na questão de pesquisa apresentada nesta tese de como um sistema técnico automatizado pode se beneficiar por um modelo suportado por inteligência artificial e tecnologias da Web Semântica, este trabalho consiste na definição de uma metodologia ontológica probabilística e na análise ampla de contexto.

Diante do impacto operacional causado por sobrecarga de alarmes, os operadores de sistemas técnicos automatizados possuem um tempo limitado para uma tomada de decisão durante um desligamento de emergência em estado de *Shutdown*. Nos casos em que múltiplos alarmes são disparados em um curto intervalo de tempo, ou em casos onde não existam sistemas que apresentem o que é importante a partir de variáveis mensuráveis, os operadores necessitam uma metodologia preditiva que permita tornar mensurável o que é importante, que são as situações que ocorrem durante o funcionamento dos processos.

A contribuição desta tese pode ser observada pela definição e implementação de um modelo preditivo orientado para tecnologias da Web Semântica, aplicado em um Sistema Técnico Automatizado (ou *Automated Technical System - ATS*). Neste contexto, verificou-se que maioria das falhas que levam a uma situação específica, por exemplo, em uma planta e, conseqüentemente, a uma parada são impulsionadas pelo próprio processo e a maioria delas pode ser prevista e até mesmo controlada. Este trabalho apresentou uma metodologia para previsão de situações em uma planta industrial. Além disso, os métodos aplicados foram baseados na aprendizagem da máquina. Contudo, é necessário a existência de dados históricos para que seja possível a implementação desta metodologia.

A presente tese contribui com um modelo conceitual híbrido aplicado em um ATS, considerando dados de alarmes e eventos, modelando este sistema técnico como elemento central. Entre os principais benefícios apresentados a partir deste estudo, destacam-se a base semântica modelada e implementada e a metodologia aplicada que possibilitam a implementação de um modelo preditivo. O estudo resultou no detalhamento de uma abordagem probabilística com destaque para implementação envolvendo Inteligência Artificial e Web Semântica, em um processo de aprendizagem paramétrica.

7.1 Principais Contribuições

Resultados preliminares desta tese foram publicados em diferentes conferências científicas, tais como elencados a seguir. Inicialmente foi realizada uma análise dos conceitos de situação e contexto. Em seguida foram analisadas as ferramentas para mineração de dados de processo e que permitiram analisar além de dados estatísticos, padrões de dados de eventos ocorridos no processo. Na sequência do trabalho, foi desenvolvido o modelo conceitual de contexto. Com a definição da modelagem, o conceito de situação foi formalizado e proposto o uso de inferência para determinação da situação da planta industrial. Durante o desenvolvimento da tese de doutorado diversas publicações científicas foram realizadas, as quais encontram-se listadas abaixo:

- SILVA, M. J.; PEREIRA, C. E.; GÖTZ, M. A Dynamic Approach for Industrial Alarm Systems. 2016 International Conference on Computer, Information and Telecommunications Systems (CITS 2016), Kunming, China, (SILVA; PEREIRA; GÖTZ, 2016a);
- SILVA, M. J.; PEREIRA, C. E.; GÖTZ, M. Knowledge awareness in Alarm Systems Database. 3rd IFAC Workshop on Advanced Maintenance Engineering, Service and Technology (AMEST'16), Biarritz, França, (SILVA; PEREIRA; GÖTZ, 2016b).
- SILVA, M. J.; PEREIRA, C. E.; GÖTZ, M. CEEIAS: Avaliação de Eventos em um Sistema de Alarmes Industrial. XIII Simpósio Brasileiro de Automação Inteligente (SBAi'17), Porto Alegre, Brasil, (SILVA; PEREIRA; GÖTZ, 2017);
- SILVA, M. J.; PEREIRA, C. E.; GÖTZ, M. Context-Aware Recommendation for Industrial Alarm System. 16th IFAC Symposium on Information Control Problems in Manufacturing (INCOM'18), Bergamo, Italia, (SILVA; PEREIRA; GÖTZ, 2018).
- SILVA, M. J.; PEREIRA, C. E.; GÖTZ, M. On the Use of Inductive Biases for Semantic Characterization of Industrial Alarm Systems. IEEE Innovative Smart Grid Technologies conference, Gramado, Brasil, 2019. (SILVA; PEREIRA; GÖTZ, 2019).
- SILVA, M. J.; PEREIRA, C. E. Towards the use of LSTM-based Neural Network for Industrial Alarm Systems. XXIII Congresso Brasileiro de Automática - CBA2020, Porto Alegre, Brasil, (SILVA; PEREIRA, 2020).
- SILVA, M. J.; KÜNZEL, G., PEREIRA, C. E. A Predictive, Context-Dependent Stochastic Model for Engineering Applications. XIV Workshop on Intelligent Manufacturing Systems (IMS 2022), Tel Aviv, Israel, 2022, (SILVA; KÜNZEL; PEREIRA, 2022);

Com relação ao desenvolvimento, experimentação e validação de novos testes com a implementação de uma RBM e uma BN, esta pesquisa conta com um artigo em processo de revisão:

- SILVA, M. J.; KÜNZEL, G., PEREIRA, C. E. Heuristic-based decision support system targeted at the analysis of context for engineering and practice, IEEE Transactions on Automation Science and Engineering, 2021.

7.2 Trabalhos Futuros

Algumas perspectivas de trabalhos futuros que podem ser desenvolvidos a partir dos resultados finais desta tese de doutorado:

- aumentar a abrangência do modelo de contexto apresentado a partir da identificação de novos domínios, como domínio do usuário e tecnológico, mas principalmente aprofundar o domínio do ATS. Com relação ao processo online destacado na proposta, uma análise aprofundada desta parte será foco de trabalhos futuros. Pontos que podem servir de alicerce para essa abordagem seriam conceitos de *Fog Computing* e sistemas de *adaptive hypermedia*;
- explorar os conceitos de redes de ontologia que permitam cobrir diferentes domínios, permitindo analisar novos contextos e situações. Além disso, outra frente de trabalho identificado durante essa pesquisa seria investigar novos processos de recomendação, especialmente modelos semânticos adaptativos;
- avaliar os benefícios da utilização de RNN-LSTM, os quais incluem uma célula de memória a fim de acompanhar o tempo necessário para as ações operacionais. Visa-se que tal abordagem possa enriquecer as informações relevantes utilizadas no processo de recomendação e, por consequência, contribuir no processo de tomada de decisão;
- estudo e implementação de um sistema de recomendação a partir de uma HMI. Sugere-se para tanto investigar as demandas do usuário e prover alertas personalizados conforme o perfil. Para isso, é necessário explorar a viabilidade da integração da metodologia proposta com uma ontologia do domínio do usuário, conforme apontado acima.

REFERÊNCIAS

- ABADI, M. *et al.* Tensorflow: a system for large-scale machine learning. *In: SYMPOSIUM ON OPERATING SYSTEMS DESIGN AND IMPLEMENTATION (OSDI 16)*, 2016, GA. **Proceedings...** USA, 2016. n. 12, p. 2877–2885.
- AGGARWALL, C. C. **Neural Networks and Deep Learning**. New York, USA: Springer, 2018. 497 p.
- ASRES, M. W. *et al.* Supporting Telecommunication Alarm Management System with Trouble Ticket Prediction. **IEEE Transactions on Industrial Informatics**, USA, v. 17, n. 2, p. 1–10, Feb 2021.
- ATZORI, L.; LERA, A.; MORABITO, G. The Internet of Things: a survey. **Computer Networks**, New York, NY, USA, v. 54, n. 15, p. 2787–2805, Oct 2010. ISSN 1389-1286.
- AZIZ, A. *et al.* An ontology-based methodology for hazard identification and causation analysis. **Process Safety and Environmental Protection**, New York, NY, USA, v. 123, p. 87–98, 2019. ISSN 0957-5820.
- BENATIA, M. A.; LOUIS, A.; BAUDRY, D. Alarm correlation to improve industrial fault management. *In: IFAC WORLD CONGRESS*, 2020, New York. **Proceedings...** USA, 2020. v. 53, n. 2, p. 10485–10492. ISSN 2405-8963.
- BERNERS-LEE, T.; HENDLER, J.; LASSILA, O. The Semantic Web: a new form of web content that is meaningful to computers will unleash a revolution of new possibilities. **Scientific American Magazine**, New York, USA, v. 284, n. 5, p. 34–43, 2001.
- BETTINI, C. *et al.* A survey of context modelling and reasoning techniques. **Pervasive and Mobile Computing**, USA, v. 6, n. 2, p. 161–180, 2010. ISSN 1574-1192.
- BEZERRA, A. *et al.* Uma abordagem orientada a dados para a análise de eventos e alarmes na indústria 4.0. *In: XXII CONGRESSO BRASILEIRO DE AUTOMÁTICA (CBA 2018)*, 2018, Campinas, SP. **Proceedings...** Brasil, 2018. v. 1, n. 1, p. 1–7.

BEZERRA, A. *et al.* Extracting Value from Industrial Alarms and Events: a data-driven approach based on exploratory data analysis. **Sensors**, USA, v. 19, n. 12, p. 2772, Jun 2019. ISSN 1424-8220.

BLANKE, M. *et al.* What is Fault-Tolerant Control? *In: IFAC SYMPOSIUM ON FAULT DETECTION, SUPERVISION AND SAFETY FOR TECHNICAL PROCESSES (SAFEPROCESS)*, 2000, Budapest. **Proceedings...** Hungary, 2000. v. 33, n. 4, p. 41–52.

BLANKE, M. *et al.* **Diagnosis and Fault-Tolerant Control**. Berlin, DE: Springer-Verlag, 2006. 43-67 p. n. 2.

BLOEM, J. *et al.* **The fourth industrial revolution things to tighten the link between IT and OT**. USA: Sogeti VINT2014, 2014. 1-40 p.

BOYER, A.; SHAOYUAN, S.; BO, J. **SCADA**:supervisory control and data acquisition. USA: ISA, 2004. 219 p. ISBN:1-55617-877-8.

BRANSBY, M. L.; JENKINSON, J. **The Management of Alarm Systems. A review of current practice in the procurement, design and management of alarm systems in the chemical and power industries**. London, UK: HSE - Health and Safety Executive, 1998. Disponível em: <http://www.hse.gov.uk/>. Acesso em: 20/10/2019.

BREIMAN, L. *et al.* **Classification and Regression Trees**. New York, USA: The Wadsworth Statistics/Probability Series, 1984. 368 p.

CARRAZZA, S. **Lectures on Machine Learning, Lecture 1**: from artificial intelligence to machine learning. Spain: Benasque, 2018. Disponível em: <http://benasque.org/>. Acesso em: 15/04/019.

CARVALHO, R. N. Probabilistic Ontology: representation and modeling methodology. **Tese de Doutorado**, USA, p. 341, 2011.

CARVALHO, R. N.; LASKEY, K. B.; COSTA, P. C. G. Uncertainty modelling process for semantic technology. **PeerJ Computer Science**, USA, v. 2:e77, p. 1–27, Ago 2016.

CBS. Investigation Report: pesticide chemical runaway reaction pressure vessel explosion. report no. 2008-8-i-vw. **Chemical Safety and Hazard Investigation Board**, Washington, DC, USA, 2011. Disponível em: <http://www.csb.gov>. Acesso em: 08/02/2021.

CHEN, H.; PETER, T.; YAO, X. Cognitive fault diagnosis in Tennessee Eastman Process using learning in the model space. **Computers and Chemical Engineering**, New York, v. 67, p. 33–42, Aug 2014. ISSN 0098-1354.

DA COSTA, P. C. G. Bayesian semantics for the semantic web. **Tese de Doutorado**, VA, USA, p. 312, 2005.

DAHL, G. E.; ADAMS, R. P.; LAROCHELLE, H. Training Restricted Boltzmann Machines on Word Observations. *In*: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 2012, Edinburgh. **Proceedings...** Scotland, 2012. n. 29, p. 1–8.

DANGETI, P. *Statistic for Machine Learning. Techniques for exploring supervised, unsupervised, and reinforcement learning models with Python and R*. **Packt Publishing**, USA, p. 438, 2017. ISBN: 978-1-78829-575-8.

DEVORE, J. L. **Probability and Statistic for Engineering and the Sciences**. USA: Cengage, 2009. 739 p. ISBN- 10: 0-495-55744-7.

DOWNS, J.; F., V. E. A plant-wide industrial process control problem. **Computers & chemical engineering**, New York, NY, USA, n. 17, p. 245–255, 1993.

EEMUA. **EEMUA-191**: alarm systems: a guide to design, management and procurement. USA: Engineering Equipment and Material Users Association, 2007.

EMANUEL, T. *et al.* A Flexible Architecture for Data Mining from Heterogeneous Data Sources in Automated Production Systems. *In*: INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY (ICIT), 2017, Toronto. **Proceedings...** Canada, 2017. n. 18, p. 1106–1111.

FAYYAD, U.; PIATETSKY, S.; SMYTH, P. **From data mining to Knowledge from volumes of data**. USA: AI Magazine, 1996. 37-54 p. n. 3.

FISCHER, A.; IGEL, C. An Introduction to Restricted Boltzmann Machines. *In*: PROGRESS IN PATTERN RECOGNITION, IMAGE ANALYSIS, COMPUTER VISION, AND APPLICATIONS. CIARP 2012, 2012, New York. **Proceedings...** USA, 2012. v. 7441, n. 17, p. 14–36.

FLUXICON. *Process Mining for Professionals*. , USA, 2019. Disponível em: <https://fluxicon.com/disco/>.

FRANK, P.; BLANK, M. **Fault Diagnosis and Fault-Tolerant Control**. [S.l.: s.n.], 2007. 308-320 p. v. 16.

GARRAMIOLA, F. *et al.* A Review in Fault Diagnosis and Health Assessment for Railway Traction Drives. **MPDI applied sciences**, USA, p. 1–19, 2018.

GEMAN, S.; GEMAN, D. Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, New York, NY, USA, n. 6, p. 721–741, Nov. 1984.

GOEL, P.; DATTA, A.; MANNAN, M. S. Industrial Alarm Systems: challenges and opportunities. **Journal of Loss Prevention in the Process Industries**, New York, NY, USA, n. 50, p. 26–36, Nov. 2017.

GRAVES, A.; SCHIMIDHUBER, J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures. **Neural Networks**, USA, n. 5-6, p. 602–610, 2005.

GREFF, K. *et al.* LSTM: a search space odyssey. , USA, 2015.

GRUBER, T. R. A translation approach to portable ontology specifications. **Knowledge Acquisition**, London, n. 5, p. 199–220, 1993.

GUIZZARDI, G. Ontological Foundations for Structural Conceptual Models. **Tese de Doutorado**, Enschede, Niederlande, 2005.

HABERLIN, R. UnBBayes PR-OWL 2.0 Tutorial. , USA, 2013. Disponível em: <http://sourceforge.net/projects/unbbayes>. Acesso em: 04/03/2018.

HABIBI, E.; HOLLIFIELD, B. Alarm Systems greatly affect offshore facilities amid high oil process. **World Oil Magazine, Houston, v.**, USA, n. 227, p. 1–4, Set 2006.

HAITAO, Z.; SHAOYUAN, S.; BO, J. Sequential Fault Diagnosis Based on LSTM Neural Network. **IEEE Access: Special Section on Sequential Data Modeling and its Emerging Application**, USA, v. 6, p. 12929 – 12939, Jan 2018.

HANDLEY, W. *et al.* Maximum-Entropy Priors with Derived Parameters in a Specified Distribution. **Entropy**, USA, p. 1–7, 2019.

HAYKIN, S. **Neural Networks: a comprehensive foundation**. New York, USA: Prentice Hall, 1998. 185-190 p.

HAYKIN, S. **Neural Networks and Learning Machines**. Third Edition: Pearson Education, Inc., 2003. 938 p. ISBN: 0-13-147139-2.

HERVÁS, R.; BRAVO, J.; FONTECHA, J. A Context Model Based on Ontological Languages: a proposal for information visualization. **Journal of Computer Science**, Sydney, USA, n. 16, p. 1539–1555, 2010.

HILDEBRANDT, C. *et al.* Ontology Building for Cyber-Physical Systems: application in the manufacturing domain. **IEEE Transactions on Automation Science and Engineering**, USA, n. 17, p. 1266–1282, Jul 2020.

- HILL, R. J. Electric railway traction. Part 1 Electric traction and DC motor drives. **Power Engineering Journal**, USA, p. 47–56, 1994.
- HINO, H.; MURATA, N. A Non-parametric Maximum Entropy Clustering. *In*: INTERNATIONAL CONFERENCE ON ARTIFICIAL NEURAL NETWORKS. ICANN 2014, 2014, USA. **Proceedings...** USA, 2014. v. 8681, n. 22, p. 113–120.
- HINTON, G. E. Training products of experts by minimizing contrastive divergence. **Neural Computation**, USA, p. 1771–1800, 2002.
- HINTON, G. E.; SEJNOWSKI, T. J. Learning and Relearning in Boltzmann Machines. **Parallel Distributed Processing**, USA, n. 1, p. 282–317, 1986.
- HINTON, G. E.; SEJNOWSKI, T. J.; ACKLEY, D. H. Boltzmann machines: constraint satisfaction networks that learn. **Carnegie-Mellon University, Dept. of Computing Science**, USA, p. 42, 1984.
- HOPFIELD, J. J. Neural networks and physical systems with emergent collective properties. **Proc. Nat. Acad. Sci**, USA, n. 79:2554-8, 1982.
- HU, W.; CHEN, T.; SHAH, S. L. Detection of frequent alarm patterns in industrial alarm floods using itemset mining methods. **IEEE Transactions on Industrial Electronics**, USA, n. 65, p. 7290–7300, Sept 2018.
- ISA. **ANSI/ISA-18.2**: management of alarm systems for the process industries. USA: INTERNATIONAL AUTOMATION SOCIETY, 2016.
- JAYNES, E. T. **Probability Theory. The Logic of Science**. USA: Cambridge University Press, 2003.
- JIA, F. *et al.* Deep neural networks: a promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. **Mechanical Systems and Signal Processing**, USA, n. 82, p. 72–73, May 2016.
- JIANFENG, Z. *et al.* Dynamic alarm prediction for critical alarms using a probabilistic model. **Chinese Journal of Chemical Engineering**, USA, n. 24, p. 881–885, 2016.
- KOFI, G. A.; LUO, G.; QUIN, K. Multi-Level Data Pre-Processing for Software Defect Prediction. , USA, p. 170 – 174, November 2013.
- LASKEY, K. B. Mebn: a language for first-order Bayesian knowledge bases. **Artificial Intelligence, Essex**, v., USA, v. 172, p. 140–178, 2008.
- LECUN, Y.; CHOPRA S. HADSELL, R.; RANZATO, M. A. A Tutorial on Energy-Based Learning. **IEEE Transactions on Automation Science and Engineering**, USA, n. 17, p. 29–40, 2006.

- LEE, J.; HONG, Y. S. Bayesian network approach to change propagation analysis. **Springer-Verlag London**, USA, n. 28, p. 437–455, March 2017.
- LEITÃO, G. B. P.; GUEDES, L. A.; ARAÚJO, J. R. S. A Correlation-based Approach to Determining Related Alarms in Industrial Processes. *In: INTERNATIONAL CONFERENCE ON EMERGING TECHNOLOGIES AMP; FACTORY AUTOMATION (ETFA 2012)*, 2012, USA. **Proceedings...** USA, 2012. n. 17, p. 1–7.
- LI, D.; FAST-BERGLUND, A.; PAULIN, A. Current and future Industry 4.0 capabilities for information and knowledge sharing. **The International Journal of Advanced Manufacturing Technology**, USA, p. 3951–3963, 2019.
- LIAO, L.; JIN, W.; PAVEL, R. Enhanced Restricted Boltzmann Machine With Prognosability Regularization for Prognostics and Health Assessment. **Transactions on Industrial Electronics**, USA, n. 63, p. 7076–7083, Nov. 2016.
- LIMA, R. G. F. Modelagem Conceitual de Processos Industriais com Aplicações. **Tese de Doutorado**, RN, Brasil, 2014.
- LIMA, R. G. F. *et al.* Semantic alarm correlation based on ontologies. *In: EMERGING TECHNOLOGIES FACTORY AUTOMATION (ETFA)*, 2013, Cagliari, Italy. **Conference...** Cagliari: IEEE, 2013. n. 18, p. 1–4.
- LIMA, R. G. F. *et al.* Correlação Semântica de Alarmes Utilizando Ontologia. *In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI)*, 2013, Brasil. **Proceedings...** Brasil, 2013. n. 11, p. 1–6.
- LOCHER, M.; LASKEY, K. B.; COSTA, P. C. G. Design patterns for modeling first-order expressive Bayesian networks. **The Knowledge Engineering Review**, USA, n. 35, p. 28, Jun 2020.
- MAKRIS, P.; SKOUTAS, D. N.; SKIANIS, C. A Survey on Context-Aware Mobile and Wireless Networking: on networking and computing environments' integration. **IEEE Communications Surveys Tutorials**, USA, n. 15, p. 362–386, 2013.
- MALIK, P. K. *et al.* Industrial Internet of Things and its Applications in Industry 4.0: state of the art. **Computer Communications**, USA, n. 166, p. 125–139, Jan 2020.
- MANNANI, Z.; IZADI, I.; GHADIRI, N. Preprocessing of Alarm Data for Data Mining. *Ind. Eng. Chem. Res.*, p. 11261–11274, 2019.
- MAO, Q. *et al.* Event prediction based on evolutionary event ontology knowledge. **Future Generation Computer Systems**, USA, n. 115, p. 76–89, Feb. 2021.

MARK, H. *et al.* The WEKA Data Mining Software: an update. , USA, n. 11, p. 10–18, Nov. 2009.

MARTENS, J. *et al.* On the Representational Efficiency of Restricted Boltzmann Machines. *In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS 26 (NIPS 2013)*, 2013, NY. **Proceedings...** USA, 2013. n. 26, p. 1–21.

MCCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, New York, NY, USA, n. 5, p. 115–133, Dec. 1943.

MCELREATH, R. **Statistical Rethinking. A Bayesian Course with Examples in R and Stan**. UK: CRC Press, 2020.

MCGUINNESS, D. L.; VAN HAMERLEN, F. OWL Web Ontology Language Overview. **W3C recommendation**, Cambridge, p. 10, 2004.

MILLÁN, E.; LOBODA, T.; PERÉZ-DE-LA-CRUZ, J. L. Bayesian networks for student model engineering. **Journal of Loss Prevention in the Process Industries**, USA, n. 55, p. 1663–1683, 2010.

MNIH, V.; LAROCHELLE, H.; HINTON, P. F. Conditional Restricted Boltzmann Machines for Structured Output Prediction. **Journal of Machine Learning Research**, USA, n. 17, p. 1–61, 2012.

MOAVENI, B.; FATHABADI, F. R.; MOLAVI, A. Supervisory predictive control for wheel sleep prevention and tracking of desired speed profile in electric trains. **ISA Trans.**, New York, NY, USA, v. 101, 2020.

MONTGOMERY, D. C. **Design and Analysis of Experiments**. 6ed. John Wiley and Sons Inc: United States: WILEY, 2005.

NASA. That Sinking Feeling. System Failure Case Studies. , USA, n. 2, Oct 2008. Disponível em: <http://nsc.nasa.gov/SFCS/SystemFailureCaseStudy/Details/11>.

NOUIOUA, M. *et al.* A Survey of Machine Learning for Network Fault Management. **Machine Learning and Data Mining for Emerging Trend in Cyber Dynamics**, New York, NY, USA, 2021.

NOY, N. F.; MCGUINNES, D. L. Ontology development 101: a guide to creating your first ontology. , USA, p. 234–252, 2001.

OGDEN, C. K.; RICHARDS, I. A. **The Meaning of Meaning. A study of influence of language upon thought and of the science of symbolism**. USA: Mariner Books, 1923. p.363 p.

O'BREIN, P. An Ontology for Mobile Situation Aware Systems. **Australian Journal of Information System**, Geelong, n. 15, p. 1–28, 2009.

PEARL, J. **Probabilistic reasoning in intelligent systems: networks of plausible inference**. USA: Morgan Kaufmann series in representation and reasoning, 1988. 552 p. ISBN.9780080514895.

PLOENNIGS, J. e. a. Guest editorial semantic technologies in automation systems. **IEEE Transactions on Industrial Informatics**, USA, n. 13, p. 3334–3337, Dec 2017.

QINGQIANG, S.; ZHIQIANG, G. Probabilistic Sequential Network for Deep learning of Complex Process Data and Soft Sensor Application. **IEEE Transactions on Industrial Informatics**, USA, n. 15, p. 2700–2709, Sep 2019.

QUINLAN, J. R. Induction of decision trees. **Mach Learn 1.**, USA, p. 81–106, 1986.

RAVANBAKSH, S. *et al.* Stochastic Neural Networks with Monotonic Activation Functions. **19th International Conference on Artificial Intelligence and Statistics - AISTATS**, USA, n. 51, p. 809–818, 2018.

RIEHMANN, P.; HANFLER, M.; FROEHLICH, B. Interactive Sankey Diagrams. **IEEE Symposium on Information Visualization**, USA, p. 233–240, 2005.

RIERA-GUASP, M.; ANTONIO-DAVIU, J. A.; CAPOLINO, G. Advances in Electrical Machine, Power Electronic and Drive Condition Monitoring and Fault Detection: state of art. **Transactions on Industrial Electronics**, USA, v. 62, p. 1746 – 1759, Dec 2014.

ROKACH, L.; MAIMON, O. **Data Mining wit Decision Trees. Theory and Applications**. New Jersey, USA: World Scientific, 2014. 328 p.

ROMEO, L. *et al.* Machine learning-based design support system for the prediction of heterogeneous machine parameters in industry 4.0. **Expert Systems With Applications**, New York, NY, USA, n. 140, p. 1–15, 2020.

ROTHENBERG, D. H. **Alarm Management for Process Control. A best-practice guide for design, implementation and use of industrial alarm system**. 2. ed. New York, USA: Momentum Press, 2009. pp. 610 p. ISBN:978-1-60650-003-3.

RUSSELL, J. S.; NORVIG, P. **Artificial Intelligence A Modern Approach**. New York: Pearson Education, Inc, 2003.

SALAKHUTDINOV, R.; MNIH, A.; HINTON, G. Restricted Boltzmann machines for collaborative filtering. *In: INTERNATIONAL CONFERENCE ON MACHINE LEARNING (ICML '07)*, 2007, Oregon. **Proceedings...** USA, 2007. n. 24, p. 791–798.

SALFNER, F.; MALEK, M. Using Hidden Semi-Markov Models for Effective Online Failure Prediction. *In: IEEE INTERNATIONAL SYMPOSIUM ON RELIABLE DISTRIBUTED SYSTEMS, 2007, Beijing. Proceedings...* China, 2007. n. 26, p. 161–174.

SARNOVSKY, J. *et al.* Big Data Processing and Analytics Platform Architecture for Process Industries Factories. **Big data and cognitive computing**, Manchester, UK, Jan 2018.

SEPP, H.; JÜRGEN, S. Long Short-Term Memory. **Neural Computation**, Bethesda MD, USA, v. 8, p. 1735–1780, 1997.

SHANNON, C. E. **The mathematical theory of communication**. New Jersey, USA: Nokia Bell Labs, 1949.

SILVA, M. J.; KÜNZEL, G.; PEREIRA, C. E. A Predictive, Context-Dependent Stochastic Model for Engineering Applications. *In: XIV WORKSHOP ON INTELLIGENT MANUFACTURING SYSTEMS (IMS 2022), 2022, Tel Aviv. Proceedings...* Israel: Elsevier, 2022. n. 55-2, p. 402–407.

SILVA, M. J.; PEREIRA, C. E. Towards the use of LSTM-based Neural Network for Industrial Alarm System. *In: CONGRESSO BRASILEIRO DE AUTOMÁTICA (CBA 2020), 2020, Porto Alegre, Brasil. Proceedings...* Porto Alegre: SBA, 2020. n. 23, p. 1–6.

SILVA, M. J.; PEREIRA, C. E.; GÖTZ, M. A Dynamic Approach for Industrial Alarm Systems. *In: INTERNETIONAL CONFERENCE ON COMPUTER, INFORMATION AND TELECOMUNICATIONS SYSTEMS (CITS), 2016, Kunming, China. Proceedings...* Kunming: IEEE, 2016. p. 308–320.

SILVA, M. J.; PEREIRA, C. E.; GÖTZ, M. Knowledge awareness in Alarm Systems Database. *In: WORKSHOP ON ADVANCED MAINTENANCE ENGINEERING, SERVICE AND TECHNOLOGY (AMEST'16), 2016, Biarritz, France. Proceedings...* Biarritz: IFAC, 2016. v. 49, n. 28, p. 297–302.

SILVA, M. J.; PEREIRA, C. E.; GÖTZ, M. CEEIAS: avaliação de eventos em um sistema de alarmes industrial. *In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE (SBAI'17), 2017, Porto Alegre, Brasil. Proceedings...* Porto Alegre: SBA, 2017. n. 13, p. 1–6.

SILVA, M. J.; PEREIRA, C. E.; GÖTZ, M. Context-Aware Recommendation for Industrial Alarm System. *In: SYMPOSIUM ON INFORMATION CONTROL PROBLEMS IN MANUFACTURING, 2018, Bergamo, Italy. Proceedings...* Bergamo: IFAC, 2018. v. 51, n. 16, p. 229–234.

SILVA, M. J.; PEREIRA, C. E.; GÖTZ, M. On the Use of Inductive Biases for Semantic Characterization of Industrial Alarm Systems. *In: INNOVATIVE SMART GRID TECHNOLOGIES CONFERENCE (ISGT LATIN AMERICA)*, 2019, Gramado, Brasil. **Proceedings...** Gramado: IEEE, 2019. v. 17, p. 1–6.

SIRIN, E. *et al.* Pellet: a practical owl-dl reasoner. **Journal Web Semantics: Science, Services and Agents on the World Wide Web**, New York, NY, USA, v. 5, n. 2, p. 51–53, 2007.

SISINNI, E. *et al.* Industrial Internet of Things: challenges, opportunities, and directions. **IEEE Transactions on Industrial Informatics**, USA, n. 14, p. 4724–4734, Nov 2018.

SOARES, V. B. *et al.* Alarm management practices in natural gas processing plant. **Control Engineer in Practice**, New York, NY, USA, n. 55, p. 185–196, Oct 2016.

SOLEIMANI, M.; CAMPEAN, F.; NEAGU, D. Integration of Hidden Markov Modelling and Bayesian Network for fault detection and prediction of complex engineered systems. **Reliability Engineering and System Safety**, New York, NY, USA, p. 1–12, 2021.

SOUNDARARAJAN, K.; HO, H. K.; SU, B. Sankey diagram framework for energy and exergy flows. **Applied Energy**, New York, NY, USA, n. 136, p. 1035–1042, Dec. 2014.

STANFORD. Protégé. **Stanford Center for Biomedical Informatics Research (BMIR) at the Stanford University School of Medicine**, CA, USA, 2019. Disponível em: <http://protege.stanford.edu>.

STYAN, G. P. H. Hadamard Products and Multivariate Statistical Analysis. **Linear Algebra and its Applications**, New York, NY, USA, p. 217–240, 1973.

SU, Q.; LIAU, X.; CARIN, L. A Probabilistic Framework for Nonlinearities in Stochastic Neural Networks. **31st Conference on Neural Information Processing System - NIPS 2017**, New York, USA, n. 17, p. 1–10, 2017.

TAN, P. N.; STEINBACH, M.; KUMAR, V. **Introdução ao Data Mining**. Third Edition: Ciência Moderna, 2009. 978 p.

TERZIYAN, V.; VITKO, O. Explainable AI for Industry 4.0: semantic representation of deep learning models. *In: INTERNATIONAL CONFERENCE OF INDUSTRY 4.0 AND SMARTH MANUFACTURING*, 2022, New York. **Proceedings...** USA, 2022. n. 3, p. 216–226.

TIAN, Y. *et al.* LSTM-based traffic flow prediction with missing data. **Neurocomputing**, New York, NY, USA, n. 318, p. 297–305, 2018.

TRENSURB. Empresa de Trens Urbanos de Porto Alegre S.A. , Porto Alegre, Brasil, 2022.

VARGA, T.; SZEIFERT, F.; ABONYI, J. Detection of Safe Operating Regions: a novel dynamic process simulator based predictive alarm management approach. **American Chemical Society**, Washington, DC, USA, v. 49, p. 658–668, 2010.

VENKATASUBRAMANIAN, V. *et al.* A review of process fault detection and diagnosis: part i: quantitative model-based methods. **Computers Chemical Engineering**, New York, NY, USA, n. 27, p. 293–311, 2003.

VERBECK, H. M. e. a. ProM6: the process mining toolkit. *In: INTERNATIONAL CONFERENCE OF BUSINESS PROCESS MANAGEMENT*, 2010, New Jersey. **Proceedings...** USA, 2010. n. 8, p. 34–39.

WALKER, S. I.; DAVIES, P. C.; ELLIS, G. F. R. **From Matter to Life. Information and Causality**. USA: Academic Press, 2017. n. Cambridge.

WANG, J. *et al.* A data similarity based analysis to consequential alarms of industrial processes. **Journal of Loss Prevention in the Process Industries**, New York, NY, USA, n. 35, p. 29–34, 2015.

WANG, J. *et al.* An Overview of Industrial Alarm Systems: main causes for alarm overloading, research status, and open problems. **IEEE Transactions on Automation Science and Engineering**, USA, n. 13, p. 1045–1061, Apr 2016.

WELLMAN, M. P.; HENRION, M. Explaining Explaining Away. **IEEE Transactions on pattern analysis and machine intelligence**, USA, n. 15, 1993.

WIRTH, R.; HIPPEL, J. CRISP-DM: towards a standard process model for data mining. **Proceedings of the 4th international conference on the practical applications of knowledge discovery data mining**, USA, p. 29–39, 2000.

WRIGHT, E. *et al.* Multi-Entity Bayesian Networks for Situation Assessments. **Proceedings of the Fifth International Conference on Information Fusion. FUSION 2002**, Annapolis, MD, USA, p. 804–811, 2002.

YANG, B. *et al.* Traffic flow prediction using LSTM with feature enhancement. **Neurocomputing**, New York, NY, USA, p. 320–327, 2019.

YANG, Z. *et al.* Using Bayesian network-based TOPSIS to aid dynamic port state control detention risk control decision. **Reliability Engineering and System Safety**, USA, v. 213, 2021.

YIN, S. *et al.* A comparison study of basic data-driven fault diagnosis and process monitoring methods on the benchmark Tennessee Eastman process. **Control Engineering Practice**, New York, USA, v. 22, p. 1567–1581, 2012.

YU, K.; MAIRESSE, F.; YOUNG, S. Context Adaptive training with factorized decision tree for HMM-based statistical parametric speech synthesis. **Speech Communication**, Manchester, UK, n. 53, p. 914–923, 2011.

YU, Y. *et al.* Abnormal Data Detection for multivariate alarm system detection based on correlation directions. **Journal of Loss Prevention in the Process Industries**, Manchester, UK, n. 45, p. 43–55, Jan 2017.

ZAYTOON, J.; LAFORTUNE, S. Overview of Fault Diagnosis methods for Discrete Event Systems. **Annual Reviews in Control**, USA, n. 37, p. 308–320, dec 2013.

ZHANG, N. *et al.* An Overview on Restricted Boltzmann Machine. **Neurocomputing**, New York, NY, USA, n. 275, p. 1186–1199, 2018.

ZHIQIANG, G. *et al.* Data Mining and Analytics in the Process Industry: the role of machine learning. **IEEE Access. Data-Driven Monitoring, Fault Diagnosis and Control of Cyber-Physical Systems**, USA, n. 5, p. 20590–20616, 2017.

ZHOU, J. *et al.* Toward New-Generation Intelligent Manufacturing. **Engineering**, New York, NY, USA, n. 4, p. 11–20, 2018.