

UNIVERSIDADE FEDERAL DO PARANÁ

PAULO HENRIQUE AMORIM SANTOS

OS DESAFIOS E BENEFÍCIOS DA IMPLANTAÇÃO DAS TECNOLOGIAS DA  
INDÚSTRIA 4.0 NO SETOR QUÍMICO DE PROCESSO CONTÍNUO

CURITIBA

2019

PAULO HENRIQUE AMORIM SANTOS

OS DESAFIOS E BENEFÍCIOS DA IMPLANTAÇÃO DAS TECNOLOGIAS DA  
INDÚSTRIA 4.0 NO SETOR QUÍMICO DE PROCESSO CONTÍNUO

Dissertação apresentada ao curso de Pós-Graduação em Engenharia de Produção, Setor de Tecnologia, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia de Produção.

Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Izabel Cristina Zattar

CURITIBA

2019

Catálogo na Fonte: Sistema de Bibliotecas, UFPR  
Biblioteca de Ciência e Tecnologia

S237d

Santos, Paulo Henrique Amorim

Os desafios e benefícios da implantação das tecnologias da Indústria 4.0 no setor químico de processo contínuo [recurso eletrônico] / Paulo Henrique Amorim Santos. – Curitiba, 2019.

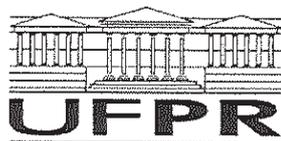
Dissertação - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia de Produção, 2019.

Orientador: Izabel Cristina Zattar .

1. Indústria química. 2. Indústria química – Inovações tecnológicas – Brasil. 3. Controle de processos químicos. 4. Sustentabilidade e meio ambiente. 5. Indústria 4.0. I. Universidade Federal do Paraná. II. Zattar, Izabel Cristina. III. Título.

CDD: 338.4766

Bibliotecário: Elias Barbosa da Silva CRB-9/1894



MINISTÉRIO DA EDUCAÇÃO  
SETOR SETOR DE TECNOLOGIA  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA DE  
PRODUÇÃO - 40001016070P1

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA DE PRODUÇÃO da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **PAULO HENRIQUE AMORIM SANTOS** intitulada: **Os desafios e benefícios da implantação das tecnologias da Indústria 4.0 no setor químico de processo contínuo.**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua aprovação no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 25 de Fevereiro de 2019.

IZABEL CRISTINA ZATTAR

Presidente da Banca Examinadora (UFPR)

ROBSON SELME

Avaliador Interno (UFPR)

FABIANO OSCAR DROZDA

Avaliador Interno (UFPR)

SILVANA PEREIRA DETRO

Avaliador Externo Pós-Doc (UFPR)

*Dedico esta dissertação à minha amada esposa Tassiane e minha filha Erica, cujo sorriso é o melhor de todos os incentivos.*

*Aos meus pais, pela motivação aos estudos e por me apoiarem durante todo o tempo em que estive desenvolvendo este trabalho.*

*Também dedico à minha orientadora Prof<sup>a</sup> Izabel Zattar, por me mostrar o caminho à pesquisa e à didática, com sua competência e atenção.*

## RESUMO

As tecnologias da Indústria 4.0 proporcionam grandes melhorias no ambiente produtivo das indústrias químicas de processo contínuo. A disponibilidade de grande quantidade de dados em tempo real permite a integração das operações unitárias e a intensificação de processos, proporcionando aumento de lucro, aperfeiçoamento do diagnóstico preditivo de falhas e auxiliando no gerenciamento de segurança e sustentabilidade da produção. Contudo, o setor apresenta obstáculos específicos na implantação das tecnologias 4.0, devido à sua intrínseca complexidade. Nesse contexto, o objetivo deste trabalho é apontar as dificuldades, Fatores Críticos de Sucesso e benefícios da implantação das tecnologias da Indústria 4.0 específicos ao setor. Para tal foi realizada uma abrangente revisão sistemática da literatura pela metodologia PRISMA, na qual foram analisados mais de 10000 documentos das bases Google Academics® e Scopus. Desafios de implantação incluem o desenvolvimento de sistemas de respostas à falhas confiáveis para processos de altos riscos e Escassez de casos de sucesso de implantação. Dentre as necessidades identificadas para o setor ainda destacam-se a crescente preocupação em pesquisa e desenvolvimento para simplificar sistemas complexos e intensificar operações. A literatura também é convergente sobre os Fatores Críticos de Sucesso, como na criação de sistemas de medição, transmissão e coleta de dados confiáveis e modelos de avaliação de saúde, segurança e meio ambiente. Dentre os benefícios, citam-se o melhor gerenciamento de produtos perigosos e melhorias em gerenciamento de recursos e eficiência energética. A evolução do setor perante as inovações da Indústria 4.0 é evidenciada e são apresentadas oportunidades de pesquisas futuras na área. O estudo é direcionado à gestores do setor, que buscam informações para projetos de implantação das tecnologias 4.0, e também, para pesquisadores em busca de novos temas na área.

Palavras-chave: Indústria 4.0; Indústria Química de Processo Contínuo; Gerenciamento de Eventos Anormais; Segurança de Processos; Sustentabilidade Ambiental.

## ABSTRACT

The technologies of Industry 4.0 provide great improvements in the productive environment of the continuous process chemical industries. The availability of a large amount of real-time data allows the integration of unit operations and process intensification, providing increased profitability, improving fault predictive diagnostics, and assisting with safety management and production sustainability. However, the industry presents specific obstacles in deploying 4.0 technologies because of its intrinsic complexity. The objective of this work is to point out the sector-specific difficulties, Critical Success Factors and benefits when implementing Industry 4.0 technologies. In order to achieve this objective, a comprehensive PRISMA systematic review of the literature was carried out, in which more than 10000 documents were analyzed, from Google Achademics® and Scopus. Some implementation challenges are the development of reliable fault response systems for high risk processes and the scarcity of deployment success cases. Among the emerging necessities identified for the sector, the concern to simplify complex systems and intensify operations is highlighted. The literature also converges on Critical Success Factors, such as the creation of reliable measurement, transmission and data collection systems and health, safety and environmental assessment models. Among the benefits are the improved management of hazardous products and improvements in resource management and energy efficiency. The evolution of the industry in the face of the innovations of Industry 4.0 is evidenced and future research opportunities are presented in the area. The study is aimed at managers of the sector, who seek information for implementing 4.0 technologies, and also for researchers looking for new topics in the area. Future research opportunities in the area are also presented. The study shows the evolution of the industry in the face of Industry 4.0 innovations.

Keywords: Industry 4.0; Continuous Process Chemical Industry; Abnormal Events Management; Processes Safety; Environmental Sustainability.

## LISTA DE ILUSTRAÇÕES

QUADRO 1 - DEFINIÇÕES DAS TECNOLOGIAS DA INDÚSTRIA 4.0 (CONTINUA)	18
FIGURA 1 – DIAGRAMA DE FLUXO DO PRISMA UTILIZADO PARA A CONSTRUÇÃO DA AMOSTRA FINAL DE ARTIGOS ESTUDADOS NA REVISÃO DA LITERATURA.....	21
QUADRO 2 - TERMOS DE BUSCA UTILIZADOS NA PESQUISA.....	22
GRÁFICO 1 - FREQUÊNCIA DE ABORDAGEM DAS TECNOLOGIAS DA INDÚSTRIA 4.0.....	26
GRÁFICO 2 - APLICAÇÃO DAS TECNOLOGIAS DA INDÚSTRIA 4.0 NOS SEGMENTOS DA INDÚSTRIA QUÍMICA DE PROCESSO CONTÍNUO.....	29
QUADRO 3 - TECNOLOGIAS DA INDÚSTRIA 4.0 EM USO NA INDÚSTRIA QUÍMICA DE PROCESSOS CONTÍNUO.....	32
QUADRO 4 - DIFICULDADES DE APLICAÇÃO DAS TECNOLOGIAS 4.0 NO SETOR .....	35
QUADRO 5 - FATORES CRÍTICOS DE SUCESSO NA IMPLANTAÇÃO DAS TECNOLOGIAS 4.0 ESPECÍFICOS AO SETOR QUÍMICO CONTÍNUO .....	40
QUADRO 6 – BENEFÍCIOS AMBIENTAIS E DE SEGURANÇA ORIUNDOS DAS TECNOLOGIAS 4.0 NA INDÚSTRIA QUÍMICA DE PROCESSO CONTÍNUO.....	45

## LISTA DE SIGLAS

ABIQUIM	- Associação Brasileira da Indústria Química
AICHe	- American Institute of Chemical Engineers
APICS	- American Production and Inventory Control Society
CFD	- Computational Fluid Dynamics
CLA	- Casual Link Assessment
CPS	- Cyber-Physical Systems
EUA	- Estados Unidos da América
FCS	- Fatores Críticos de Sucesso
GPS	- Global Positioning System
HMI	- Human-Machine Interface
HSE	- Health, Safety and the Environment
IoT	- Internet of Things
JPS	- J-Park Simulator
M2M	- Machine-to-Machine
NSF	- National Science Foundation
PRISMA	- Preferred Reporting Items for Systematic Reviews and Meta Analyses
RFID	- Radio-Frequency Identification
SMLC	- Smart Manufacturing Leadership Coalition
SPM-EVO	- Smart Process Manufacturing Engineering Virtual Organization
TI	- Tecnologia da Informação
UE	- União Europeia
WBF	- World Batch Forum

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>10</b>
1.1	OBJETIVOS .....	11
1.1.1	Objetivo geral .....	11
1.1.2	Objetivos específicos.....	12
1.2	JUSTIFICATIVA.....	12
1.3	LIMITAÇÕES DO TRABALHO .....	13
<b>2</b>	<b>REFERENCIAL TEÓRICO</b> .....	<b>14</b>
2.1	INDUSTRIAS QUÍMICAS DE PROCESSO DE CONTÍNUO .....	14
2.2	INDÚSTRIA 4.0 .....	17
<b>3</b>	<b>METODOLOGIA</b> .....	<b>21</b>
3.1	MÉTODO DA REVISÃO SISTEMÁTICA DA LITERATURA .....	21
3.2	COLETA DE MATERIAL .....	22
3.3	PRINCÍPIOS DA REVISÃO .....	24
<b>4</b>	<b>REVISÃO SISTEMÁTICA DA LITERATURA</b> .....	<b>25</b>
4.1	TRABALHOS TEÓRICOS DAS TECNOLOGIAS 4.0 NO SETOR QUÍMICO DE PROCESSO CONTÍNUO .....	25
4.2	CASOS DE IMPLANTAÇÃO DAS TECNOLOGIAS 4.0 NA INDÚSTRIA QUÍMICA CONTÍNUA .....	28
4.3	DIFICULDADES NA IMPLANTAÇÃO DAS TECNOLOGIAS 4.0.....	33
4.3.1	Dificuldades para a implantação das tecnologias 4.0 na indústria química de processo contínuo .....	34
4.4	FATORES CRÍTICOS DE SUCESSO PARA A IMPLANTAÇÃO DAS TECNOLOGIAS 4.0 .....	38
4.4.1	Fatores Críticos de Sucesso para a implantação das Tecnologias 4.0 nas indústrias químicas de processo contínuo .....	40
4.5	BENEFÍCIOS AMBIENTAIS E DE SEGURANÇA DA IMPLANTAÇÃO DAS TECNOLOGIAS 4.0 .....	44
4.5.1	Benefícios ambientais e de segurança da implantação das tecnologias 4.0 nas indústrias químicas de processo contínuo .....	44
<b>5</b>	<b>CONCLUSÕES</b> .....	<b>53</b>
	<b>REFERÊNCIAS</b> .....	<b>56</b>

APÊNDICE A – ARTIGO SUBMETIDO PARA O PERIÓDICO <i>COMPUTERS &amp; CHEMICAL ENGINEERING</i> .....	67
APÊNDICE B - ARTIGO PUBLICADO NO VIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO (CONBREPRO 2018).....	102
ANEXO A – COMPROVANTE DE SUBMISSÃO À REVISTA <i>COMPUTERS &amp; CHEMICAL ENGINEERING</i> .....	110
ANEXO B – CERTIFICADO DE PUBLICAÇÃO NO VIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO .....	111

## 1 INTRODUÇÃO

A quarta revolução industrial, é muito mais que uma tendência da automação. Ela consiste em um conjunto de novas práticas de manufatura que utilizam a capacidade de comunicação e de armazenamento de grandes quantidades de dados, permitidos pelos avanços tecnológicos atuais. Desta forma, a Indústria 4.0 tem como objetivo desenvolver modelos, métodos e ferramentas apropriadas às indústrias manufatureiras. (THOBEN et al. 2017), e, assim sendo, é caracterizada pelo avanço das interações entre pessoas, máquinas e recursos, e a consequente descentralização dos processos produtivos. (HERMANN et al., 2016). Essas inovações serão causadoras de uma grande alteração na atual estrutura profissional, impactando não somente a indústria, mas também à sociedade em geral. (KOTYMKOVA, 2017).

As novas tecnologias que acompanham a Indústria 4.0 são baseadas na comunicação em rede, onde uma grande quantidade de informação (*Big Data*) é gerada como uma cópia virtual da planta. A disponibilidade de informação de todo o sistema produtivo permite novas maneiras de conduzir o gerenciamento da indústria. Sistemas ciber-físicos (*Cyber Physical Systems*, ou *CPS*) monitoram em tempo real os processos físicos, através de sensores, atuadores e simuladores, aumentando a eficiência do processo através de tomadas de decisões descentralizadas. (HERMANN et. al. 2016). Além disso, existe uma integração comunicativa dos elementos do sistema produtivo através do uso da internet sem fio (denominada de Internet das Coisas, *Internet of Things*, ou *IoT*), sincronizada com o processamento de dados gerados pelos sistemas ciber-físicos. (KAGERMANN et al., 2013). Desta forma, a Indústria 4.0 propõe a adoção de uma infraestrutura capaz de integrar a inteligência de manufatura de uma linha de produção em tempo real. (KUMAR et al., 2015).

Apesar de ainda necessitar provar seus benefícios à sociedade (KOTYMKOVA, 2017), o número de publicações recentes sobre o tema são indícios de sua aceitação na indústria. Isso também mostra o interesse da sociedade acadêmica nessa promissora evolução do ambiente industrial. Implantar a Indústria 4.0, entretanto, é muitas vezes um projeto complexo, apresentando diversos obstáculos característicos a cada setor manufatureiro. (CHIANG et al., 2017).

A indústria química de processo contínuo apresenta grande potencial de melhoria perante as novas perspectivas da Indústria 4.0. A operação segura e

eficiente das plantas requer monitoramento constante de milhares de variáveis de processo, e hoje, o gerenciamento de situações anormais ainda é atribuído a operadores humanos. (SHU et al., 2016). Para a indústria química de processo contínuo, portanto, o objetivo da Indústria 4.0 não é apenas maximizar o lucro, mas também reduzir acidentes e preservar o meio ambiente. (CHRISTOFIDES, 2007). Trabalhos recentes como o de Chiang et al. (2017) e Ji et al. (2016) comprovam benefícios específicos ao setor, no uso das novas tecnologias como o *Big Data* e os sistemas ciber-físicos.

Assim, as indústrias químicas enfrentam a necessidade de identificar os benefícios e obstáculos ao implantar tecnologias da Indústria 4.0 em processos contínuos. Surge então uma questão de pesquisa: **“Quais os desafios e benefícios da implantação das tecnologias da Indústria 4.0 no setor químico de processo contínuo?”**. Este trabalho busca responder a essa questão através de uma revisão sistemática da literatura pertinente. A fim de fornecer uma resposta mais adequada à questão de pesquisa principal declarada, quatro subquestões de pesquisa são listadas como segue:

- 1) “Quais os desafios para a implantação das tecnologias 4.0 nas indústrias químicas de processo contínuo?”;
- 2) “Que fatores críticos de sucesso garantem a implantação das tecnologias 4.0 nas indústrias químicas de processo contínuo?”;
- 3) “As tecnologias 4.0 proporcionam benefícios para a melhoria de gerenciamento de segurança nas indústrias químicas de processo contínuo?”;
- 4) “Quais os benefícios da implantação das tecnologias 4.0 nas indústrias químicas de processo contínuo para melhoria da sustentabilidade ambiental?”.

## 1.1 OBJETIVOS

Este trabalho é estruturado sob um objetivo geral, apresentado na sequência, bem como os objetivos específicos necessários para atingir ao objetivo geral proposto.

### 1.1.1 Objetivo geral

Identificar as dificuldades, fatores críticos de sucesso e benefícios proporcionados pela implantação das tecnologias da Indústria 4.0 no setor químico de processo contínuo.

### 1.1.2 Objetivos específicos

Os objetivos específicos, os quais auxiliarão no atingimento do objetivo do trabalho, são a saber:

- a) Realizar uma Revisão Sistemática da Literatura, apresentando uma análise crítica das publicações relativas ao tema;
- b) Identificar as principais tecnologias relacionadas a Indústria 4.0 já implementadas no setor químico de processo contínuo;
- c) Identificar os desafios de implantação das tecnologias 4.0 específicos às indústrias químicas de processo contínuo;
- d) Identificar os Fatores Críticos de Sucesso da implantação das tecnologias 4.0 específicos às indústrias químicas de processo contínuo;
- e) Analisar os benefícios ambientais e de segurança consequentes da implantação das tecnologias 4.0 nas indústrias químicas de processo contínuo;

## 1.2 JUSTIFICATIVA

A Indústria 4.0 possui uma proposta diferente de produção, e necessita de pesquisa em definição, comprovação de eficiência, modelagem e novas tecnologias. (LI, 2016). Dadas as atuais projeções otimistas, pode parecer surpreendente que exista tão pouca literatura conciliando essas novas tecnologias à indústria química. (CHIANG et al., 2017). Porém, isso se deve ao fato de que os conceitos prevalentes de economia de escala e operação contínua inibem a exploração dos potenciais benefícios da indústria 4.0, dificultando um gerenciamento sistêmico da cadeia de suprimentos. (SCHLÖGL, 2017).

Para o processo produtivo, essas tecnologias são promissoras em melhorias de percepção de demanda e coordenação da produção. Tais tecnologias permitem identificar instantaneamente gargalos da produção e a avaliação de benefícios relacionados à sua eliminação. Assim, estudar a inovação tecnológica na indústria de processo contínuo se mostra de grande interesse para o ponto de vista econômico. (CHARPENTIER, 2016). Portanto, compilar os desafios, Fatores Críticos de Sucesso e benefícios de implantação de projetos 4.0 na indústria química de processo contínuo

são objetivos que vão em convergência com uma necessidade já identificada por vários autores.

### 1.3 LIMITAÇÕES DO TRABALHO

Dado que o Brasil ainda possui um baixo número de empresas que aplicam as tecnologias estudadas, a proposta não prevê a implementação ou avaliação de um estudo de caso. Assim, o estudo é realizado a partir de uma revisão sistemática da Literatura. O trabalho proposto é direcionado para o setor de indústrias químicas, mais especificamente aquelas que possuem processos químicos contínuos, não sendo incluído os setores alimentício e farmacêutico.

## 2 REFERENCIAL TEÓRICO

A seguir são apresentados os assuntos que fundamentam este trabalho. Para o levantamento de referencial teórico, inicialmente são abordadas diferentes definições de processo contínuo para a indústria química. Além da caracterização do setor, é analisada a evolução de sua automatização e digitalização, a fim de contextualizar as inovações advindas pela indústria 4.0. Em seguida, é apresentado o surgimento da quarta revolução industrial, a sua importância para a manufatura e as definições das tecnologias propostas.

### 2.1 INDUSTRIAS QUÍMICAS DE PROCESSO DE CONTÍNUO

Devido às vantagens dos processos contínuos, hoje, a maioria dos produtos químicos, petroquímicos, alimentícios e de consumo são manufaturados continuamente. (ENGISCH; MUZZIO, 2015). Muitos trabalhos colaboram com a caracterização dos processos contínuos. Woodward (1977) os define como a padronização de produtos e a produção minimamente interrompida. Para Buffa (1979), em um processo contínuo, há extrema inflexibilidade dos equipamentos e recursos. Russomano (1979) alega que, neste tipo de produção, o tempo de *set up* se mostra muito pequeno, quando comparado ao tempo despendido na operação. Para Toledo, Ferro e Serra (1986), a característica essencial à compreensão lógica de operação de um processo contínuo é a não dependência direta entre o ritmo de trabalho e a produtividade. Já Fransoo e Rutten (1994) apresentam as características dos processos contínuos como sete:

1. Alta velocidade de produção, pouco trabalho humano;
2. Clara determinação de capacidade, uma rotina para todos os produtos, baixa flexibilidade;
3. Baixa complexidade do produto;
4. Baixo valor agregado;
5. Tempos de parada causam grande impacto;
6. Pequeno número de etapas de produção;
7. Número limitado de produtos.

Toledo, Truzzi e Ferro (1989) afirmam que o termo contínuo, comumente utilizado, possui diferentes significados. Os autores alegam que, para a indústria química, o termo é associado a um processo de vazão constante, oposta ao processo em batelada. Condizente com os autores, outra definição, apresentada pelo World Batch Forum (WBF), é a de que os processos contínuos ocorrem quando uma corrente líquida, gasosa ou particulada se move em fluxo, e não há elementos discretos contabilizáveis. (HAWKINS; BRANDL; BOYES, 2010). Borges e Dalcol (2002) também apresentam uma definição sobre as indústrias contínuas que se adapta muito bem à realidade das indústrias químicas: os autores alegam que os equipamentos são interligados por tubulações, se diferenciando dos sistemas discretos, onde diversas estações são distribuídas em galpões. Assim, a aparência externa dessas indústrias é a de um único grande equipamento.

Os processos contínuos têm a vantagem de realizar suas etapas com o potencial para o uso de automação e controle de processos avançados, reduzindo o custo de trabalho. Além disso, os processos contínuos também possuem qualidade estabilizada e incidência baixa de perda de lotes de produção. (ROBERGE et al., 2008). Quanto aos mecanismos de controle dos equipamentos em indústrias de processo contínuo, segundo Borges e Dalcol (2002) pode-se encontrar três níveis distintos de escala de controle:

- O controle se localiza junto a cada equipamento;
- O controle se localiza ainda no equipamento, contudo possui inteligência própria (automatizado) sendo capaz de por si mesmo fazer auto correções se os parâmetros estiverem fora do programado;
- O controle é automatizado não somente para um equipamento isolado, e sim realizado para todos os equipamentos através da centralização das informações em uma sala de controle;

O projeto de processos químicos contínuos é geralmente desenvolvido em estado estacionário, assumindo que o sistema de controle pode ser desenvolvido para manter o processo no nível operacional desejado e dentro das restrições de projeto. Borges e Dalcol (2002) afirmam que o elevado capital investido nas plantas e a natureza intrínseca dos processos resultam em um trabalho ininterrupto, que, unido ao baixo tempo de processamento, resulta em produções em larga escala. Após o início de uma produção contínua, se torna muito difícil distinguir entre si a matéria-prima, os insumos e os produtos. Porém, um processo dinâmico pode limitar a eficácia

do sistema de controle, levando a um gerenciamento que é incapaz de atender às especificações do projeto (SEIDER et al., 2010). Desta forma, a análise dinâmica é essencial na identificação de áreas específicas da instalação que têm dificuldades em atingir o estado estacionário (ASPENTECH, 2010).

Integrar todas as operações de uma unidade contínua é certamente recompensador e tem consequências no Controle da Qualidade e na automação. (NICLOUD; 2016). Para Borges e Dalcol (2002), a necessidade de automação na indústria de processo contínuo é sempre crescente. Segundo os autores, os processos produtivos nessas indústrias geralmente são complexos e requerem um grande número de mecanismos de controle para permitir respostas rápidas. Ademais, os fluxos da indústria de processo contínuo possuem composições e concentrações dinâmicas, dado as complexas reações químicas, influenciadas por inúmeras variáveis de processo. Além disso, é característico da indústria química a necessidade de redução de problemas de segurança, dado às consequências relacionadas a vazamentos de substâncias tóxicas e inflamáveis. Ainda, os acidentes, mesmo os de menor porte, que envolvam apenas parte do processo, prejudicam a produtividade como um todo, devido ao elevado nível de interdependência e integração das várias fases do processo (TOLEDO; FERRO e TRUZZI, 1989).

Para Passos e Aragão (2013), é natural que a indústria de produção contínua, não tenha acumulado aprendizagem significativa nas ferramentas de gestão da produção características das indústrias automobilísticas. Segundo os autores, a natureza própria dos processos químicos contínuos dispensa a adoção de muitas práticas correntes da engenharia de produção. No entanto, a necessidade atual de reduções cada vez mais frequentes de variabilidade de parâmetros de processos contínuos atraiu para a indústria química ferramentas as quais eram aplicadas prioritariamente na indústria de processos montados (PASSOS; ARAGÃO, 2013).

A evolução dentro da indústria química nos últimos trinta anos mostra uma melhoria maciça em áreas de segurança, eficiência e conforto (SCHMITT, 2014; LEE E SEONG, 2014). Gradualmente, a indústria química se transformou em uma indústria semiautônoma, conectando componentes eletrônicos e software aos dispositivos mecânicos existentes. Os processos químicos modernos são altamente automatizados devido à contribuição de sistemas avançados de controle de processos. (ZHANG et al., 2018) Todos os parâmetros críticos das máquinas são conectados a um sistema de controle centralizado. (DHASON, 2018). Nas duas

últimas décadas, a simulação tem sido amplamente utilizada em processos químicos contínuos. Nesse período, ocorreu um aumento significativo na utilização de ferramentas computacionais que têm sido usadas para aprofundar as análises de processos. (TAQVI et al., 2016).

## 2.2 INDÚSTRIA 4.0

A inovação industrial muitas vezes é impulsionada pela competitividade e pelo aumento da demanda, exigindo processos mais rápidos, eficientes e sustentáveis. Nos últimos anos, tecnologias de transmissão, armazenamento e organização de dados vêm melhorando substancialmente a eficiência da produção. As indústrias estão cada vez mais aderindo a avanços tecnológicos em cibernética, integração de recursos computacionais e infraestruturas de TI. (REIS; KENETT, 2018). Isso se dá pela combinação de recursos, maquinário e informação, criando um sistema de manufatura inteligente: a Indústria 4.0. (JI et al., 2016).

Indústria 4.0 é um termo que foi usado pela primeira vez em 2011, em Hannover Messe, na Alemanha (originalmente *industrie 4.0*), e é atualmente usado em todo o mundo para expressar os avanços tecnológicos que caracterizam a quarta revolução na fabricação industrial. (GRUSCHKA; LÜSSEM, 2018). Para Davis et al. (2012), a Indústria 4.0 é uma plataforma designada à integração tecnológica. Através de uma visão macroscópica da empresa e da cadeia de suprimentos, ela cria um novo paradigma na melhoria de processos, proporcionando maiores retornos de futuros investimentos. Baur e Wee (2015) definem a Indústria 4.0 como a próxima fase na digitalização do setor manufatureiro, impulsionado por quatro inovações:

- O aumento surpreendente de volume de dados, potência computacional e conectividade;
- O surgimento de recursos de análise e inteligência de negócios;
- Novas formas de interação homem-máquina, como interfaces de toque e sistemas de realidade aumentada;
- Melhorias na transferência de instruções digitais para o mundo físico, como robótica avançada e impressão 3D.

Dentre as tecnologias mais difundidas citam-se a Internet das coisas, sistemas ciber-físicos, comunicação máquina-a-máquina (M2M), Computação em Nuvem e *Big Data*. (GRUSCHKA; LÜSSEM, 2018). Com uma visão mais madura

sobre os potenciais das tecnologias que acompanham a Indústria 4.0, Hermann, Pentek e Otto (2016) definem a Indústria 4.0 como aquela cujos sistemas ciber-físicos se comunicam através da Internet das Coisas no auxílio de execuções de tarefas humanas e mecânicas. Para Zhang et al. (2018), a indústria 4.0 foca na conexão dos processos produtivos, através da sua integração horizontal e vertical. Esses avanços nas tecnologias digitais permitem a fabricação orientada ao consumidor, individualizada e mais ágil, conectada com a cadeia de suprimentos e com robusto gerenciamento logístico. (STRANDHAGEN et al., 2017).

O QUADRO 1 apresenta as tecnologias da Indústria 4.0 com suas definições.

QUADRO 1 - DEFINIÇÕES DAS TECNOLOGIAS DA INDÚSTRIA 4.0 (CONTINUA)

<b>Tecnologia</b>	<b>Definição</b>
<i>Big Data</i>	Extração de valor de grandes volumes e variedades de dados, com alta velocidade de captura, identificação e análise. (FEBLOWITZ, 2012).
Internet das Coisas ( <i>Internet Of Things</i> )	Todos os tipos de dispositivos sensores que estejam conectados à internet, formando uma rede de identificação inteligente e gerenciável. (LI; LIU, 2010).
Internet Industrial das Coisas ( <i>Industrial Internet of Things</i> )	Máquinas, computadores e pessoas permitindo operações industriais inteligentes usando análise avançada de dados. (SADIKU et al., 2017).
Internet de Serviços ( <i>Internet of Services</i> )	Serviços que têm a capacidade de ser hospedados em máquinas de ponta para fornecer recursos via internet sem fio a qualquer objeto físico suportado com capacidade de comunicação. (BALAKRISHNAN; SANGAIAH, 2016).
Computação em Nuvem ( <i>Cloud Computing</i> )	Serviço baseado em internet, que permite o uso e o envio de recursos através de um servidor virtual. (HAO et al., 2015).
Sistemas ciber-físicos ( <i>Cyber-Physical Systems</i> )	Sinergia entre a computação, comunicação e controle com os componentes físicos, sendo essa interação superior à automação e aquisição de dados de hoje. (SQUIRE; SONG, 2014).
Fabricação Aditiva ( <i>Additive Manufacturing</i> )	Também conhecido como impressão 3D, envolve a fabricação de uma peça, depositando o material camada por camada. (CONNER et al., 2014).
Aprendizado de Máquina ( <i>Machine Learning</i> )	A detecção automatizada de padrões em dados que possam ser significantes. (SHALEV-SHWARTZ; SHAI BEN-DAVID, 2014).

QUADRO 1 - DEFINIÇÕES DAS TECNOLOGIAS DA INDÚSTRIA 4.0 (CONCLUSÃO)

<i>Máquina a Máquina (Machine-To-Machine)</i>	Habilidade de componentes industriais de se comunicar entre si. (SIKORSKI et al., 2017).
Interação Humano-Máquina <i>(Human Machine Interaction)</i>	Interação e comunicação entre usuário e máquina, criando um Sistema técnico dinâmico. (JOHANNSEN, 2009).
<i>Identificação por Radio-Frequência (Radio Frequency Identification)</i>	Uso de ondas de radio para transmissão de dados em conjunto com etiquetas e leitores, com o propósito de identificação e rastreamento de objetos. (AJAMI; RAJABZADEH, 2013).
Protocolo de Confiança <i>(Blockchain)</i>	Banco de dados eletrônico segregado, cujas regras de compartilhamento e atualização das informações são passíveis de definição. (SIKORSKI; HAUGHTON; KRAFT, 2017).
Fábrica Virtual <i>(Virtual Factory)</i>	Combinação de tecnologias de Tecnologia de Informação relacionadas à manufatura, baseada em tecnologia de manufatura digital. (CHOI; KIM NOI, 2015).
Realidade Aumentada <i>(Augmented Reality)</i>	Uma tecnologia que sobrepõe objetos virtuais (componentes aumentados) ao mundo real. (AKÇAYIR; AKÇAYIR, 2017).
Gêmeos Digitais <i>(Digital Twins)</i>	Relação bidirecional entre um artefato físico e o conjunto de seus modelos virtuais. (SCHLEICH et al., 2017).
Segurança Cibernética Inteligente <i>(Smart Cyber Security)</i>	Tecnologias inteligentes anti-malware detectam softwares furtivos maliciosos e os combatem. (HIMSS ASIA NPAC, 2016).

FONTE: O autor (2019).

As tecnologias 4.0 permitem usar uma nova inteligência que remove restrições no processo de tomada de decisões, dado a disponibilidade da informação. (DAVIS et al., 2012). As inovações de suas aplicações são resultados da combinação dessas tecnologias de comunicação e informação com a automação industrial. (KAGERMANN; WAHLSTER; HELBIG, 2013). Através da combinação de técnicas avançadas de manufatura e tecnologias digitais, a Indústria 4.0 permite o desenvolvimento dos sistemas produtivos de forma que se promova a integração de seus elementos. Essa melhoria da inteligência de manufatura possibilita aos gestores a criação de dados mais confiáveis e úteis, impulsionando a criação de ferramentas de tomadas de decisões mais acuradas e com menor tempo de resposta. Assim, essa integração aumenta a flexibilidade, adaptabilidade e eficiência dos processos, melhorando a comunicação entre produtores e consumidores. (JOLY et al., 2018).

A conexão entre os sistemas físicos e digitais permite a criação de novas arquiteturas tecnológicas, baseadas na fusão entre a tecnologia da informação e a

automação industrial. (SABELLA, 2018). Essas novas tecnologias de monitoramento e controle do processo buscam atender as exigências atuais do mercado consumidor. (YAO; GE, 2018), e dão o potencial para melhoria de processos de inspeção de forma não presencial. (MEYENDORF et al. 2017). Através do uso de tecnologias de identificação por novos tipos de sensores, é possível a aquisição de grande quantidade de dados em tempo real por máquinas, equipamentos e produtos. (STOCK; SELINGER, 2016). Para Utz, Neumann e Tafreschi (2018), a qualidade dos dados é um dos principais requisitos para a tomada de decisões bem-sucedidas na Indústria 4.0. Além disso, a qualidade dos dados é crucial para obter o engajamento do usuário e a aceitação de serviços. (DING et al., 2018).

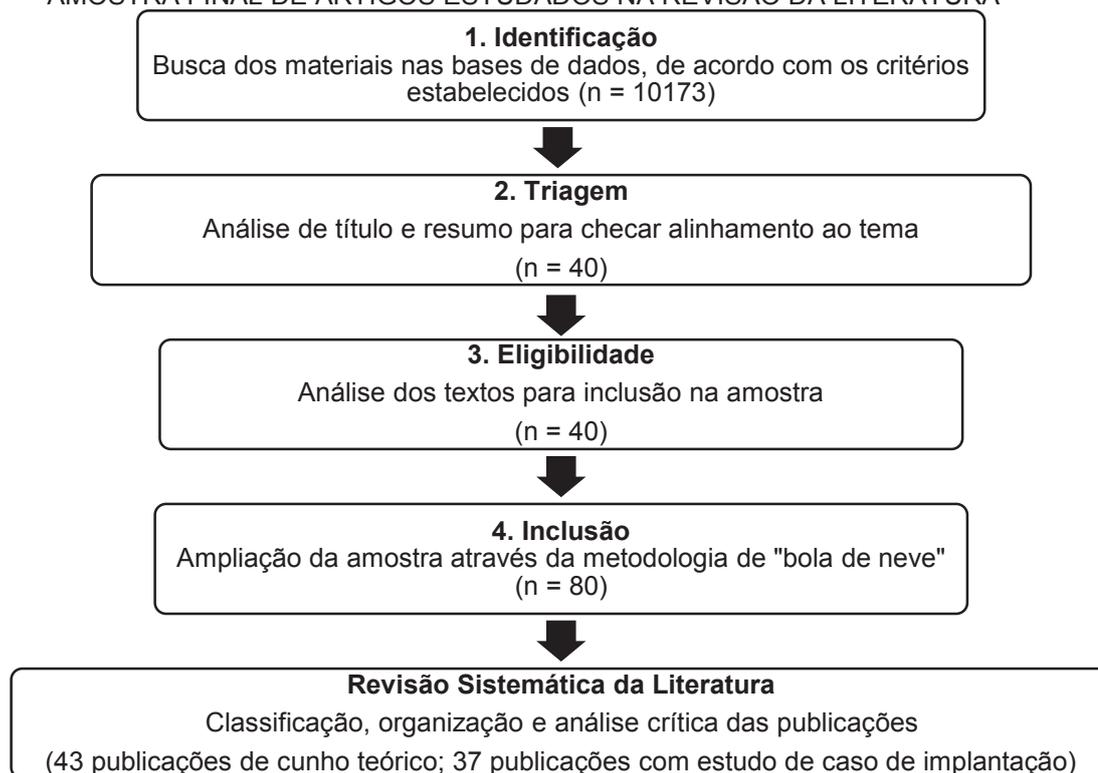
A maioria das empresas que instituem Computação em Nuvem e *Big Data* buscam melhorar a gestão de qualidade de seus sistemas. (PICKETT, 2016). A análise de *Big Data* permite a medição e monitoramento de processos em tempo real para um gerenciamento de qualidade superior, logística e cumprimento de pedidos. (GEORGE; HAAS; PENTLAND, 2014). Em uma época de alta concorrência, onde as empresas estão incorporando a Indústria 4.0 e *Big Data* em seus modelos de negócio, é obrigatório que a manufatura garanta a implantação de um sistema de gerenciamento de qualidade avançado em toda a sua cadeia de abastecimento. (SOARES; SOLTANI; LIAO, 2017).

A complexidade das tecnologias da Indústria 4.0, porém, resulta em uma dificuldade de estabelecer um procedimento padrão de sua aplicação. Muitos sistemas de manufatura não estão prontos para gerenciar grandes volumes de dados devido às altas demandas em acesso a dados e qualidade. O pleno desenvolvimento do potencial da Indústria 4.0 ainda requer esforços tanto na integração quanto na coordenação de cada tecnologia. (AHUETT-GARZA; KURFESS, 2018).

## 2.3 METODOLOGIA MÉTODO DA REVISÃO SISTEMÁTICA DA LITERATURA

A metodologia utilizada para realização da revisão sistemática foi o PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), descrito por Moher et al. (2009). A Declaração PRISMA consiste em uma lista de verificação de 27 itens e um diagrama de fluxo de quatro fases. O objetivo da Declaração PRISMA é ajudar os autores a melhorar relatórios de revisões sistemáticas e meta-análises. (MOHER et al., 2009). O diagrama de fluxo do PRISMA que relata as quatro diferentes fases desta revisão sistemática da literatura é apresentado na FIGURA 1 e resume os passos adotados para a construção da amostra final de artigos considerados para a revisão sistemática da literatura. Não foi elaborado um protocolo de revisão sistemática, e a metodologia adotada não foi registrada.

FIGURA 1 – DIAGRAMA DE FLUXO DO PRISMA UTILIZADO PARA A CONSTRUÇÃO DA AMOSTRA FINAL DE ARTIGOS ESTUDADOS NA REVISÃO DA LITERATURA



FONTE: Adaptado de Moher et al. (2009).

Os 27 itens da Declaração PRISMA foram usados como base para a construção da revisão sistemática da literatura. Para criar a amostra de publicações sobre as tecnologias da Indústria 4.0 na indústria química de processo contínuo,

primeiramente, foram definidos os bancos de dados para a busca de material e então selecionados os termos de busca.

#### 2.4 COLETA DE MATERIAL

Os bancos de dados escolhidos foram o Google Acadêmico® e a base Scopus. O Google Acadêmico® é uma ferramenta de busca na web de acesso livre, que indexa uma grande variedade de textos da literatura acadêmica em uma variedade de formatos de publicação. Enquanto o Google não publica o tamanho do banco de dados do Google Acadêmico®, pesquisadores estimam que ele contém mais de 160 milhões de documentos, oferecendo uma diversidade de publicações úteis e viabilizando uma robusta análise da literatura (ORDUÑA-MALEA et al., 2015). Já a base Scopus é o maior banco de dados de resumos e citações da literatura com revisão por pares (revistas científicas, livros, processos de congressos e publicações do setor).

A definição dos termos de busca (QUADRO 2) foi baseada no tema de estudo, utilizando o termo de busca principal “*Chemical Industry*” e o cruzamento dos 25 setores da indústria química de processo contínuo, definidos pela Associação Brasileira da Indústria Química (ABIQUM), a 19 termos comumente relacionados às tecnologias da Indústria 4.0.

QUADRO 2 - TERMOS DE BUSCA UTILIZADOS NA PESQUISA.

<b>Termo de Busca Principal</b>	<b>Setores</b>	<b>Tecnologias</b>
---------------------------------	----------------	--------------------

	<i>"Fertilizers"</i>	<i>"Big Data"</i>
	<i>"Industrial gas"</i>	<i>"Internet of Things"</i>
	<i>"Petrochemical"</i>	<i>"Industrial Internet of Things"</i>
	<i>"Plastic industry"</i>	<i>"Internet of Services"</i>
	<i>"Resins"</i>	<i>"Cloud Computing"</i>
	<i>"Rubber"</i>	<i>"Cyber-Physical Systems"</i>
	<i>"Elastomer"</i>	<i>"Additive Manufacturing"</i>
	<i>"Synthetic fiber"</i>	<i>"Machine Learning"</i>
<i>"Chemical Industry"</i>	<i>"Artificial fiber"</i>	<i>"Augmented Reality"</i>
	<i>"Pesticides"</i>	<i>"Virtual Factory"</i>
	<i>"Soap"</i>	<i>"Digital Twins"</i>
	<i>"Detergents"</i>	<i>"Machine-to-Machine"</i>
	<i>"Cleaning products"</i>	<i>"Human Machine Interface"</i>
	<i>"Cosmetics"</i>	<i>"Radio Frequency Identification"</i>
	<i>"Perfume"</i>	<i>"Smart Cyber Security"</i>
	<i>"Hygiene"</i>	<i>"Blockchain"</i>
	<i>"Paints"</i>	<i>"Smart Manufacturing"</i>
	<i>"Varnish"</i>	<i>"Industry 4.0"</i>
	<i>"Polishes"</i>	<i>"Smart Factory"</i>
	<i>"Adhesive"</i>	
	<i>"Explosive"</i>	
	<i>"Solvent"</i>	
	<i>"Dye"</i>	
	<i>"Chlorine"</i>	
	<i>"Alkali"</i>	

FONTE: O autor (2019).

Por exemplo, uma das combinações de busca utilizadas foi:

"CHEMICAL INDUSTRY" AND "PETROCHEMICAL" AND "MACHINE LERNING"

Como resultado obtiveram-se 475 combinações de busca. Oriundos das bases de dados foram considerados ao todo 10173 documentos para análise de alinhamento ao tema.

## 2.5 PRINCÍPIOS DA REVISÃO

Para garantir consistência na elegibilidade dos documentos, os seguintes princípios foram definidos:

- Não foram considerados documentos cujo idioma não era inglês, português ou espanhol;
- Não foram consideradas publicações cujo título e resumo não se mostraram relacionados ao tema da revisão;
- Não foram utilizados limites quanto à data de publicação;
- Foram considerados elegíveis artigos de revista, artigos de congresso, livros, relatórios técnicos, dissertações e teses.

Após a aplicação dos critérios de elegibilidade definidos nos princípios da revisão, foram obtidas 40 publicações que efetivamente relacionavam tecnologias da Indústria 4.0 à indústria química de processo contínuo. Essas publicações foram então submetidas ao procedimento de “bola de neve”, que é uma forma de construção de amostra que se utiliza de cadeias de referências bibliográficas, sendo especialmente útil para estudar determinadas áreas de estudo difíceis de serem acessadas. (VINUTO, 2014). Assim, a partir das referências bibliográficas desses 40 documentos, foi possível identificar outros artigos relevantes através de seus títulos, que foram então submetidos a um novo processo de triagem e de elegibilidade.

Com a inclusão de 40 novos artigos através do procedimento de “bola de neve” foi possível reunir uma seleção final de 80 artigos relevantes ao tema. Obtida a amostra final de publicações, foi então realizada a leitura completa de cada trabalho, a fim de identificar as dificuldades de implantação e os fatores críticos de sucesso, relativos à implantação das tecnologias da Indústria 4.0 na indústria química de processo contínuo. Ainda, para cada publicação, foram identificados os benefícios ambientais e de segurança oriundos da implantação das tecnologias 4.0 no setor.

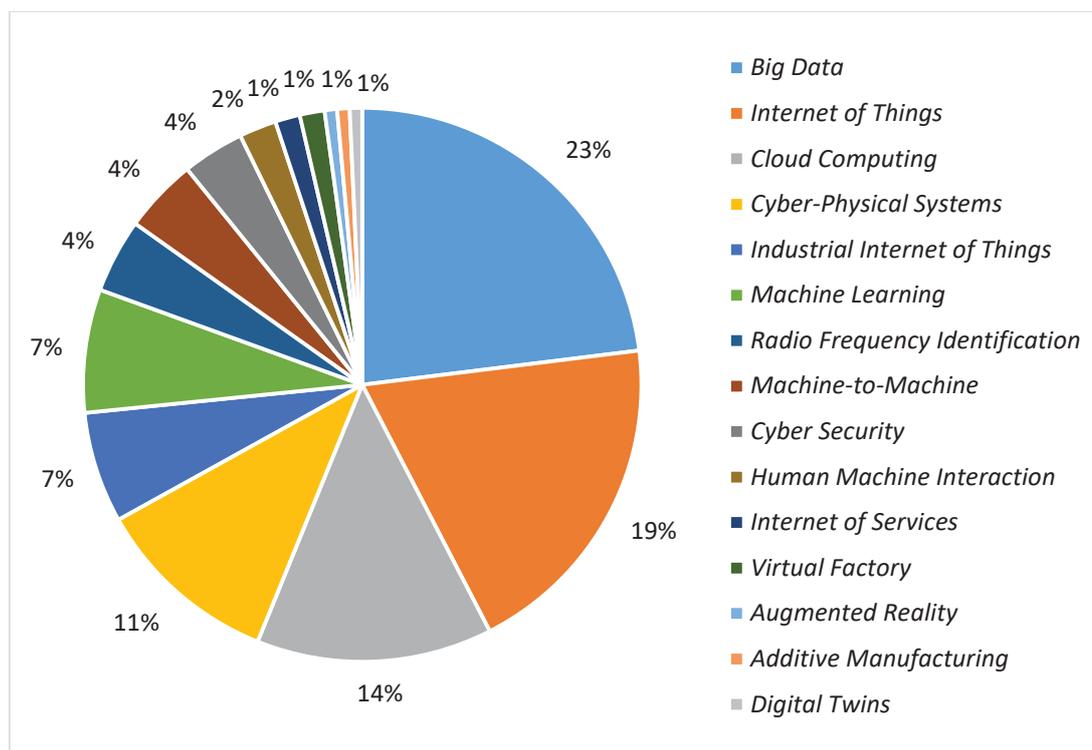
### 3 REVISÃO SISTEMÁTICA DA LITERATURA

A partir da amostra de artigos encontrados na literatura foi possível identificar artigos teóricos sobre as perspectivas da Indústria 4.0 na indústria química de processo contínuo e estudos de casos com aplicações práticas. Primeiramente, são abordados os artigos teóricos, que permitem a discussão do desenvolvimento da Indústria 4.0 no setor. Em seguida, é apresentada uma análise dos casos de implantação, que fornece uma visão mais realista das necessidades particulares da indústria química de processo contínuo. Em sequência, são apresentados os desafios de implantação das tecnologias 4.0 comuns à todas as empresas e desafios específicos às indústrias químicas de processo contínuo. De maneira semelhante, são apontados os Fatores Críticos de Sucesso, gerais e específicos ao setor. Por fim, é realizado um levantamento dos benefícios ambientais e de segurança advindos da Indústria 4.0, seguido de uma análise de sua real importância para a indústria química de processo contínuo, sob estes aspectos.

#### 3.1 TRABALHOS TEÓRICOS DAS TECNOLOGIAS 4.0 NO SETOR QUÍMICO DE PROCESSO CONTÍNUO

Para cada artigo revisado, de caráter teórico ou prático, primeiramente foi realizada uma busca para identificar as principais tecnologias 4.0 utilizadas nas indústrias químicas de processo contínuo. O estudo revelou uma maior tendência das publicações em *Big Data*, Internet das Coisas, Computação em Nuvem e Sistemas Ciber-Físicos (GRÁFICO 1). Juntas, essas três tecnologias somam 67% das menções às tecnologias 4.0.

GRÁFICO 1 - FREQUÊNCIA DE ABORDAGEM DAS TECNOLOGIAS DA INDÚSTRIA 4.0



FONTE: O autor (2018).

Na sequência foi feita uma análise das publicações de cunho teórico, as quais reafirmam a importância do desenvolvimento dessas três tecnologias para a indústria química de processo contínuo. Para o setor, a necessidade de novos recursos computacionais dedicados ao processo de controle já era prevista por Ydstie (2002). Para o autor, a padronização no sistema de comunicação de dispositivos e a simulação como ferramenta de análise preditiva seriam fundamentais para as novas tecnologias de informação. O autor é responsável pela publicação do primeiro trabalho correlato a integração da física e das redes de comunicação como perspectivas futuras no controle de processos químicos. Desde então, o número de publicações vem crescendo e a revolução 4.0 da manufatura química, ganhando notoriedade. Três anos após o trabalho de Ydstie, Grossmann (2005) publica um artigo que atinge maior visualização do meio acadêmico. O autor previa benefícios às empresas surgindo da interface da engenharia química com a pesquisa operacional. Ainda, afirmava que o cenário do mercado global exigiria novas tecnologias de manufatura para preservação da competitividade.

Com referência a ambos os trabalhos, Christofides (2007) dá continuidade a pesquisa com colaboração de Jim Davis, que se tornaria o mais importante

pesquisador da área nos próximos anos. Em “*Smart Plant Operations: Vision, Progress and Challenges*” os autores identificam os desenvolvimentos recentes em controle de processos, melhorias e sistemas de monitoramento. Em suas conclusões, os autores enaltecem a necessidade de um plano de coordenação da pesquisa nesta área, e a carência de colaboração entre a academia e indústria, para que seja possível atender às demandas de mudanças.

Em 2008, foi realizado um *workshop* sobre processos de manufatura, patrocinado pela *National Science Foundation (NSF)* e a *Smart Process Manufacturing Engineering Virtual Organization (SPM-EVO)*. O objetivo do *workshop* era promover uma colaboração focada no estudo da Indústria 4.0, criando uma base de fundamentação para as pesquisas posteriores. Há concordância de que a manufatura inteligente de processos deve ser definida como uma empresa integrada, baseada em conhecimento e rica em modelos, na qual todas as ações são determinadas e executadas proativamente. (DAVIS et al., 2008).

Após um período de poucas publicações específicas sobre a Indústria química 4.0, Davis e Edgar (2012) voltam a publicar sobre o tema, com auxílio de outros colaboradores, no trabalho “*Smart manufacturing, manufacturing intelligence and demand-dynamic performance*”. Mais de 30% dos trabalhos posteriores sobre Indústria 4.0 na indústria química usariam este artigo como referência bibliográfica. Se trata de uma base de conceitos e definições mais madura, com um maior conhecimento sobre o potencial e as limitações das tecnologias de comunicação em ambientes fabris. Davis e Swink (2014) abordam sistemas que englobam as dimensões comerciais em sistemas compreensivos. Com o auxílio de outros colaboradores, os autores publicam em 2015 uma revisão anual sobre a engenharia química e biomolecular, focando na arquitetura e desenvolvimento da infraestrutura de tecnologia da informação almejada pela Indústria 4.0. Esse artigo é amplamente referenciado pelos autores mais modernos.

Dentre as publicações mais recentes, Kohlert (2015) apresenta em sua tese uma investigação prática de métodos de análise de *Big Data* para os processos de fabricação de filmes poliméricos, para atender melhor às exigências e desafios da produção. Hao et al.(2015) realizam a elaboração de uma plataforma de integração das informações sobre as tecnologias de Internet das Coisas e Computação em Nuvem na indústria química. Já Thienen et al. (2016) avaliam os principais aplicativos da Indústria 4.0 em diferentes estágios dos produtos químicos. Inaba, K. (2016)

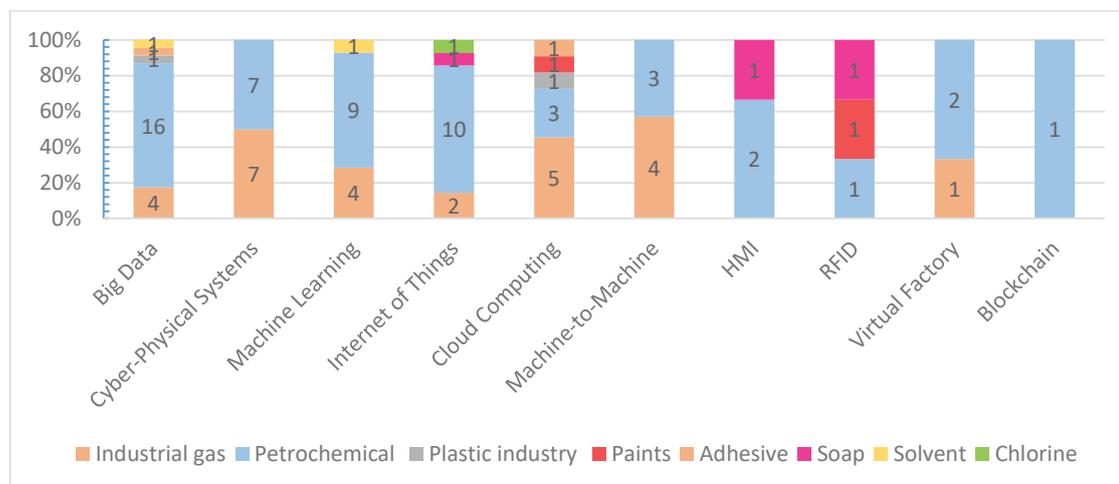
apresenta uma análise de integração de uma refinaria em um complexo petroquímico. O estudo conclui na necessidade de um sistema de *Big Data* e Internet das Coisas para melhorar produtividade e eficiência. Hassani et al. identificam através de uma revisão da literatura o impacto da inovação tecnológica na indústria de petróleo, como redução de custos, redução de desperdícios de tempo e ganho de eficiência. García et al. (2017) traz uma proposta para a integração vertical, que permite acesso a dados a menores custos. Khare e Chin (2017) publicam o primeiro trabalho identificado que utiliza o termo “*Smart Chemical Industry*”. No artigo, os autores discutem os benefícios de utilizar a coleta eficiente de dados como fonte de conhecimento. Wang et al. (2017) focam nas instalações de armazenagem e transporte de petróleo e gás. Os autores pesquisam sobre a análise de riscos e criam um novo modelo de gerenciamento a partir do monitoramento de *Big Data*. Ge et al. (2017) fornecem uma revisão sobre aplicações de mineração de dados e análise existentes na indústria de processos nas últimas décadas. He, Wang e Vahdat (2017) revisam o estado da arte da tecnologia de sistemas ciber-físicos. Além disso, os autores exploram o potencial de sensores e Internet das Coisas para fabricação.

### 3.2 CASOS DE IMPLANTAÇÃO DAS TECNOLOGIAS 4.0 NA INDÚSTRIA QUÍMICA CONTÍNUA

Além dos trabalhos teóricos e preditivos sobre as tecnologias advindas da Indústria 4.0, foram encontrados na literatura casos de aplicação prática destas tecnologias em equipamentos, simulações ou plantas industriais do setor químico.

Uma primeira análise desta amostra apresenta o cruzamento das abordagens práticas de cada tecnologia com os respectivos segmentos do setor químico investigados. O resultado pode ser observado no (GRÁFICO 2), que apresenta o número de casos de aplicação de cada tecnologia no setor. Estudos de caso que apresentaram a aplicação de mais de uma tecnologia foram contabilizados mais de uma vez.

GRÁFICO 2 - APLICAÇÃO DAS TECNOLOGIAS DA INDÚSTRIA 4.0 NOS SEGMENTOS DA INDÚSTRIA QUÍMICA DE PROCESSO CONTÍNUO



FONTE: O autor (2018).

A tecnologia de *Big Data* é a que possui maior número de aplicações industriais, fato decorrente da necessidade das empresas de manipular grande quantidade de variáveis físico-químicas característica do setor. É possível observar uma predominância de uso de *Big Data*, *Machine Learning* e Internet das Coisas no segmento petroquímico e de Computação em Nuvem e Machine-to-Machine na produção de gases industriais. A tecnologia de Sistemas Ciber-Físicos possui aplicações em ambos estes segmentos. *Big Data* e Computação em Nuvem são encontrados funcionando em um maior número de segmentos diferentes. Outras tecnologias com menor frequência de aplicação, como Identificação por Radio-Frequência e *HMI* já foram aplicadas no setor de fabricação industrial de saponáceos.

A predominância de casos práticos de aplicação das tecnologias de *Big Data*, Internet das Coisas, Computação em Nuvem e Sistemas Ciber-Físicos é coerente com as preposições encontradas na análise das publicações de cunho teórico, evidenciando a necessidade do setor químico contínuo em desenvolver ferramentas computacionais de transmissão, armazenamento e análise de grandes quantidades de dados.

Greg Martin (2009) publicou o primeiro trabalho relacionado a aplicação da indústria química 4.0: uma análise das vantagens da tecnologia de internet sem fio na indústria petroquímica. A utilização da internet sem fio permite a disponibilidade de informação em tempo real, novas ferramentas para manutenção de equipamentos e melhoria em segurança, através do acesso remoto. (MARTIN, 2009).

Chang et al. (2011) implementam uma interface Humano-máquina baseada em um microprocessador de pequena escala e lógica programável, usada em um processo de biomassa, proporcionando excelente capacidade de supervisão.

Davis e Edgar (2012) proporcionam exemplos de aplicação da manufatura inteligente em processos e em cadeias de suprimentos. Dentre eles, se destaca o exemplo da ExxonMobil que construía uma infraestrutura de informação em suas diversas unidades. Focando na comunicação, gerenciamento e segurança, a empresa obteve ganhos no planejamento de seu portfólio de produtos.

Natarajan, Ghosha, e Srinivasan (2012) propõe uma sistema, chamado *OntoSafe*, que fornece a possibilidade de gerenciamento de situações anormais. Já em 2014, os autores trazem uma proposta de aplicar esta arquitetura baseada em multi agentes para a supervisão de plantas de larga escala. Outro trabalho no contexto de gerenciamento de situações anormais na indústria química é o de Rathinasabapathy, et al. (2016), o qual desenvolveu uma metodologia de diagnóstico qualitativo chamado de *Causal Link Assessment (CLA)*.

Publicações mais recentes incluem Belaud et al. (2014), que introduzem uma plataforma de simulação, engenharia, visualização 3D e gerenciamento de *Big Data* para a indústria química. Já Qin (2014), amplamente citado, define a tecnologia de *Big Data*, descrevendo sua utilização, e proporcionando perspectivas para a indústria de processos químicos. Blackburn et al. (2015) propõe um modelo de previsão de demanda baseado em *Big Data* e superior à métodos estatísticos baseados em histórico partindo de dados da indústria química BASF. Squire e Song (2014) apresentam dois casos de sucessos de implantação de Sistemas Ciber-Físicos em indústrias químicas. Respondendo ao progresso tecnológico, Ji et al. (2016) discutem um modelo de indústria química inteligente baseado em Sistemas Ciber-Físicos. Zhang e Zhao (2017) propoem um modelo de diagnóstico de falhas baseado em redes inteligentes extensíveis, aplicável em melhoria de segurança. Zhang et al. (2018) apresentam uma estratégia para melhorar a agilidade operacional de uma refinaria a partir de *Big Data* e lógica Fuzzy. Dhason (2018) apresenta um sistema de suporte avançado para operadores em fábricas de produtos químicos, para realizar operações e manutenção segura e confiável da planta. Sikorski, Haughton e Kraft (2017) são os únicos autores que exploram aplicações de tecnologia de Blockchain, propondo a descentralização como medida de segurança para interações Machine-to-Machine (M2M).

Sobre a indústria petroquímica em específico, os trabalhos encontrados foram publicados em 2016 e 2017. Yuan, Qin e Zhao (2017) trazem exemplos de aplicação, como a detecção por falhas através do uso de *Big Data* em uma unidade de craqueamento catalítico. Em outra linha de pesquisa, Hamzeh (2016) investiga diferentes métodos de análise de *Big Data* usados na indústria de gás e petróleo, como *Hadoop*®, *Microsoft*® *MURA*, *IBM*® *InfoSphere*® e *Oracle*®.

Ainda se destaca a tese de doutorado de Kumar (2016) sobre reforma de metano, sendo um trabalho completo em teoria e experimentação. O trabalho surge a partir de Korambath et al. (2014), aonde os autores desenvolveram um protótipo de ensaio para um modelo de controle de temperatura de fornos, pela combinação de Computação em Nuvem e tecnologias de serviços online. Na tese de Kumar (2016), foi apresentada uma pesquisa de controle no perfil de temperatura em um forno industrial de reforma de metano. Para isso, se utilizam sensores de infravermelho que produzem uma grande quantidade de dados. O gerenciamento e aproveitamento dessa *Big Data* proporcionaram vários resultados positivos, incluindo a implantação e monitoramento de uma infraestrutura computacional de Indústria 4.0. A disseminação de seu trabalho com a colaboração de outros pesquisadores (principalmente Baldea e Edgar) proporcionou a publicação de outros artigos sobre o tema. Como resultados, se incluem um framework de sensores e modelos de Fluidodinâmica Computacional (CFD) para controle de ensaios de produção de hidrogênio (KUMAR, BALDEA; EDGAR, 2016c), um modelo de predição da distribuição de temperatura do forno baseado na alimentação de combustível (KUMAR, BALDEA; EDGAR, 2016b) e as formulações de design de configuração para a melhoria de distribuição de temperatura do forno e atuação das válvulas. (KUMAR, BALDEA; EDGAR, 2016a). Dentre as tecnologias estudadas em seus trabalhos incluem-se *Big Data*, Computação em Nuvem, *M2M*, e *Virtual Factory*. Kumar, Baldea e Edgar (2017) publicaram também sobre a redução do custo energético do processo.

Dentre outros trabalhos publicados, alguns se destacam por abordar possibilidades de redução de danos ambientais provenientes de produção química, através do uso das tecnologias de Indústria 4.0. Pan et al. (2015) propõem a implantação da Indústria 4.0 no design e melhoria do parque eco-industrial de Jurong Island em Singapura. O trabalho de Kleinlanghorst et al. (2016) apresenta o *J-Park Simulator (JPS)*, que é uma virtualização eco-industrial que combina conceitos de interação *Machine-to-Machine (M2M)* e modelagem matemática para gerar uma

plataforma de design de parques eco-industriais. Zhou et al. (2018) desenvolvemo uma ontologia para parques eco-industriais. Os autores apresentam uma estrutura conceitual incluindo cinco níveis operacionais (operações unitárias, processos, plantas, redes de recursos industriais e parques ecoindustriais), e a aplicam para guiar o projeto de uma estrutura de conhecimento para *Jurong Island*.

O QUADRO 3 apresenta as publicações de casos práticos e as respectivas tecnologias 4.0 aplicadas, identificando os autores e o ano de publicação.

QUADRO 3 - TECNOLOGIAS DA INDÚSTRIA 4.0 EM USO NA INDÚSTRIA QUÍMICA DE PROCESSOS CONTÍNUO.

<b>Tecnologia</b>	<b>Autores/ Ano</b>
<i>Internet of Things</i>	Martin, 2009; Wassick, 2009; Zuehlke, 2010; Davis et al., 2012; Chung; Hsiao; Chen, 2014; Kumar; Baldea; Edgar, 2015-2017; Kleinelanghorst et al., 2016; Yuan; Qin; Zhao, 2017; Hassani; Silva; Al Kaabi, 2017; García et al., 2017; Sikorski; Haughton; Kraft, 2017; Liu et al., 2018
<i>Big Data</i>	Wassick, 2009; Gao; Shang; Kokossis, 2009; Davis et al., 2012; Natarajan; Ghosh; Srinivasan, 2012; Belaud et al., 2014; Blackburn et al., 2015; Windmann et al., 2015; Pan et al., 2015; Kumar; Baldea; Edgar, 2015, 2016 (a; b; c; d), 2017; Ji et al., 2016; Shu et al., 2016; Hamzeh, 2016; Rathinasabapathy, 2016; Korambath et al, 2016; Yuan; Qin; Zhao, 2017; Hassani; Silva; Al Kaabi, 2017; Chiang; Lu; Castillo, 2017; Geng et al., 2017; Leeuw, 2017; Zhang et al., 2018
<i>Cyber-Physical Systems</i>	Wassick, 2009; Davis et al., 2012; Natarajan; Ghosh; Srinivasan, 2012; Natarajan; Srinivasan, 2014; Squire; Song, 2014; Pan et al., 2015; Kumar; Baldea; Edgar, 2015, 2016 (a; b; c; d), 2017; Ji et al., 2016; Garcia et al., 2017
<i>Cloud Computing</i>	Belaud et al., 2014; Kumar; Baldea; Edgar, 2015, 2016 (a; b; c; d), 2017; Shu et al., 2016; Korambath et al, 2016; Yuan; Qin; Zhao, 2017; Chiang; Lu; Castillo, 2017; Leeuw, 2017; Luo et al., 2017
<i>Radio-Frequency Identification</i>	Zuehlke, 2010; Chung; Hsiao; Chen, 2014; Luo et al., 2017
<i>Human Machine Interface</i>	Zuehlke, 2010; Chang et al., 2011; Chung; Hsiao; Chen, 2014; Rathinasabapathy, 2016
<i>Machine Learning</i>	Gao; Shang; Kokossis, 2009; Natarajan; Ghosh; Srinivasan, 2012; Natarajan; Srinivasan, 2014; Windmann et al., 2015; Kumar; Baldea; Edgar, 2015, 2016 (a; b; c; d), 2017; Kleinelanghorst et al., 2016; Korambath et al, 2016; Geng et al., 2017; Zhang et al., 2018; Ragab et al., 2018
<i>Machine-to-Machine</i>	Kumar; Baldea; Edgar, 2015, 2016 (a; b; c; d), 2017; Kleinelanghorst et al., 2016; Garcia et al., 2017; Sikorski; Haughton; Kraft, 2017; Ragab et al., 2018
<i>Virtual Factory</i>	Kumar; Baldea; Edgar, 2015, 2016 (a; b; c; d), 2017; Kleinelanghorst et al., 2016; Korambath et al, 2016
<i>Blockchain</i>	Sikorski; Haughton; Kraft, 2017

FONTE: O autor (2019).

Através da literatura, é possível perceber casos de aplicação de *Big Data* em conjunto à tecnologia de *Machine Learning*. (KUMAR; BALDEA; EDGAR, 2015). Isso se justifica pela necessidade da indústria química de processo contínuo de automatizar o gerenciamento da grande quantidade de dados físico-químicos coletados em processo. Além disso, as duas tecnologias podem ser utilizadas para garantir melhores protocolos de segurança à eventos adversos (NATARAJAN; SRINIVASAN, 2014). Para melhor compreender as particularidades do setor, são apresentadas a seguir as dificuldades de implantação de tecnologias 4.0 comuns à todas as empresas e dificuldades específicas da indústria química de processo contínuo.

### 3.3 DIFICULDADES NA IMPLANTAÇÃO DAS TECNOLOGIAS 4.0

Segundo Helu et al. (2015), as dificuldades de implantação das tecnologias da Indústria 4.0 podem ser agrupadas em torno de requisitos de recursos e treinamento, riscos de Segurança Cibernética, características físicas do ambiente de fabricação, e padronização das interfaces de softwares. Para Knop (2017) e Gezdur e Bhattacharjya (2017), a implantação das tecnologias 4.0 exige custo, tempo e esforço de implantação. Bogle, (2017), Yuan, Qin e Zhao (2017), e Reitze et al. 2018 afirmam que a indústria 4.0 deve ser flexível quanto ao mercado e sua demanda. Gezdur e Bhattacharjya (2017), Knop (2017), Isaksson, Harjunkoski e Sand (2018) e Bogle acrescentam à isto necessidade de adaptar a produção ao desejo do consumidor. Desta forma, confirma-se a necessidade das empresas de adaptar seus modelos de negócios, identificada por Ydstie (2002), Davis e Edgar (2008) e Squire e Song (2014).

A literatura é unânime em identificar a dificuldade de gerenciar, analisar e utilizar a grande quantidade de dados da Indústria 4.0. Para muitos autores, esta dificuldade reside em obter robustez e confiabilidade dos sistemas comunicativos. (LIU; WEI; XU; JI, 2018; ZHOU et al., 2018; ISAKSSON; HARJUNKOSKI; SAND, 2018). Para Zhang et al. (2018), Yang (2018) e Joly et al. (2018), o desafio é garantir que o sistema atinja resposta em tempo real. Neste sentido, YAN et al., (2017) acrescentam que outro fator limitante é a capacidade de comunicação do sistema, sendo a disponibilidade de banda um fator fundamental. Chiang, Lu e Castillo (2017),

Zhang et al. (2018) e Joly et al. (2018) confirmam a necessidade das empresas de possuir eficiência computacional e disponibilidade de banda larga.

Hermann, Pentek e Otto (2016) e Qian, Zhong e Du (2017) alegam ainda que as novas tecnologias exigem o desenvolvimento de interfaces Homem-Máquina que facilitem a operação do usuário. Khare e Chin (2017), Knop (2017) e Chiang, Lu e Castillo (2017) afirmam que para isto, é necessário o desenvolvimento de mão de obra especializada e assistência técnica compatível a essas inovações. Segundo os autores, dado a complexidade das tecnologias da Indústria 4.0, a interdisciplinaridade exigida da equipe é alta.

Outra dificuldade identificada por diversos autores é a coordenação com a cadeia de suprimentos. (BOGLE, 2017; LEEUW, 2017; BALDEA et al., 2018; ISAKSSON; HARJUNKOSKI; SAND, 2018). Para isto, é necessário garantir a conexão e integração das operações e softwares utilizados pelos fornecedores e clientes. (KNOP, 2017; BALDEA et al., 2018). Thoben, Wiesner e Wuest (2017) e Kusiak (2017) concordam que as padronizações necessárias para a conectividade das máquinas e a integração de dados são os maiores desafios encontrados. Além disso, os autores afirmam que garantir a Segurança Cibernética é um desafio contínuo. Neste sentido, a garantia de Segurança Cibernética também é identificada por Christofides et al., (2007), Squire e Song (2014), Hermann, Pentek e Otto (2016) e Bogle (2017), e é uma preocupação que acompanha a evolução da quarta revolução industrial. Porém, enquanto esses desafios são similares entre diversos setores manufatureiros, existem dificuldades específicas ao setor químico contínuo. (BOGLE, 2017).

### **3.3.1 Dificuldades para a implantação das tecnologias 4.0 na indústria química de processo contínuo**

Ydstie (2002) já previa como dificuldades da inovação tecnológica no setor a modelagem e transcrição de sistemas complexos e a integração dos métodos de controle com os novos sistemas de informação. Christofides et al. (2007) apontam como desafios da indústria química de processo contínuo a conectividade dos elementos de controle, a resposta em tempo real, e o sistema de resposta às falhas. Em acordo com os autores, Bogle (2017) afirma que os desafios técnicos que confrontam o desenvolvimento das tecnologias 4.0 são relacionados à robustez e

segurança, a previsão das propriedades de mistura, e novos paradigmas de modelagem de processos químicos. A modelagem e transcrição detalhada dos sistemas, deve ser feita quando possível, e o desenvolvimento de novas operações unitárias, produtos e sistemas de medição simplificam sistemas complexos, permitindo a adaptação do processo caso haja indisponibilidade de dados.

O QUADRO 4 apresenta as dificuldades de implantação da Indústria 4.0 sob o ponto de vista da indústria química de processo contínuo, identificadas nos artigos obtidos através da revisão da literatura, as quais serão discutidas na sequência.

QUADRO 4 - DIFICULDADES DE APLICAÇÃO DAS TECNOLOGIAS 4.0 NO SETOR

Dificuldade	Autores/ Ano
Modelar e transcrever sistemas complexos	Ydstie, 2002; Grossmann, 2005; Venkatasubramanian, 2008; Wassick, 2009; Zuehlke, 2010; Natarajan; Ghosh; Srinivasan, 2012; Qin, 2014; Windmann et al., 2015; Kumar et al. 2015; Kumar; Baldea; Edgar, 2016; Li, 2016; Dai et al., 2016; Shu et. al., 2016; Bogle, 2017; Ge et al., 2017; Sun et al., 2017; Chiang; Lu; Castillo, 2017; Yuan; Qin; Zhao, 2017; García et al., 2017; Liu; Wei; Xu; Ji, 2018; Zhang et al., 2018; Zhou et al., 2018; Ragab et al., 2018; Baldea et al., 2018; Joly et al., 2018
Adaptar os métodos clássicos de controle aos novos sistemas de informação	Ydstie, 2002; Natarajan; Ghosh; Srinivasan, 2012; Korombath et al., 2014; Rathinasabapathy et al., 2016; Yuan; Qin; Zhao, 2017; Chiang; Lu; Castillo, 2017; Baldea et al., 2018; Joly et al., 2018; Reitze et al., 2018
Desenvolver sistemas de resposta a falhas confiáveis para processos de altos riscos	Christofides et al., 2007; Gao, Shang, Kokossis, 2009; Wassick, 2009; Li; Liu, 2010; Natarajan; Ghosh; Srinivasan, 2012; Davis et al., 2012; Qin, 2014; Squire; Song, 2014; Luo et al., 2015; Windmann et al., 2015; Dai et al., 2016; Shu et. al., 2016; Rathinasabapathy et al. 2016; Chen et al., 2016; Bogle, 2017; Leeuw, 2017; Yuan; Qin; Zhao, 2017; He et al., 2017; Liu et al., 2018; Yang, 2018; Ragab et al., 2018; Baldea et al., 2018
Criar modelos de avaliação de saúde, segurança e meio ambiente	Christofides et al., 2007; Davis; Edgar, 2008; Natarajan; Ghosh; Srinivasan, 2012; Belaud et al., 2014; Squire; Song, 2014; Luo et al., 2015; Dai et al., 2016; Li, 2016; Shu et. al., 2016; Bogle, 2017; Leeuw, 2017; Yuan; Qin; Zhao, 2017; Khare; Chin, 2017; Qian; Zhong; Du, 2017; Liu; Wei; Xu; Ji, 2018;
Modificações nas plantas e interrupções na produção	Davis; Edgar, 2008; Natarajan; Ghosh; Srinivasan, 2012; Natarajan; Ghosh; Srinivasan, 2014; Squire; Song, 2014; Dai et al., 2016; Leeuw, 2017; Khare; Chin, 2017; Knop, 2017; Baldea et al., 2018; Reitze et al., 2018; Isaksson; Harjunkoski; Sand, 2018;
Desenvolver novos processos de síntese, intensificar operações e adaptar produtos	Venkatasubramanian, 2008; Bogle, 2017; Leeuw, 2017; Baldea et al., 2018; Reitze et al., 2018
Escassez de casos de sucesso de implantação	Christofides et al., 2007; Davis; Edgar, 2008; Montanus, 2016. He et al., 2017;

FONTE: O autor (2019).

*Modelar e transcrever sistemas complexos:* Para Yuan, Qin e Zhao (2017), o primeiro desafio é obter modelos de confiança para unidades de processamento químico, especialmente para reatores complexos. A complexidade das misturas e reações químicas exigem a capacidade dos modelos matemáticos de considerarem inúmeras propriedades físico-químicas. (BOGLE, 2017). García et al. (2017) confirma que converter *Big Data* complexo em decisões operacionais requer novos recursos de manipulação e análise de dados. Yuan, Qin e Zhao (2017) também questionam se a indústria confiará e adotará os resultados de melhorias. Os modelos de confiabilidade de sistemas químicos apresentam limitações em condições complexas. O grande volume de dados pode sobrecarregar a capacidade do sistema de analisar e utilizar eficientemente as informações do processo. (CHIANG; LU; CASTILLO, 2017). Além disso, com a evolução dos processos químicos modernos, as informações necessárias para a supervisão do processo são distribuídas por diversas fontes diferentes, o que exige esforço em integração do gerenciamento de dados. (Natarajan; Ghosh; Srinivasan, 2012);

*Adaptar os métodos clássicos de controle aos novos sistemas de informação:* os novos métodos de controle precisam ser desenvolvidos e integrados à realidade das operações em diferentes escalas sob efeito dos diferentes fenômenos físicos da indústria química. (YDSTIE, 2002). A combinação de diferentes fontes de dados para tirar conclusões significativas através da análise de *Big Data* é uma tarefa difícil. (CHIANG; LU; CASTILLO, 2017). Korombath et al. (2014) afirma que a interação entre as operações de fabricação e as diversas alternativas para usar tais informações é um exemplo dos desafios associados à implantação das tecnologias 4.0 na indústria química. A indústria exige novas plataformas digitais escalonáveis que atualizem o nível de tecnologia da instrumentação atual. (Yuan; Qin; Zhao, 2017).

*Desenvolver sistemas de resposta à falhas confiáveis para processos de altos riscos:* o diagnóstico de plantas químicas industriais é uma tarefa difícil e necessária. (Rathinasabapathy et al. 2016). O desafio é analisar os dados do processo com precisão e rapidez, para que ações corretivas possam ser tomadas em tempo hábil. (Rathinasabapathy et al. 2016). Segundo Bogle (2017), a detecção de perigos deve ser incorporada diretamente nos sistemas, porque a operação próxima às condições ideais geralmente sobrecarrega as operações, resultando em maior probabilidade de falhas. Para Khare e Chin (2017), o aspecto mais importante em uma indústria química é a segurança. He et al. (2017) afirmam que a extração de informações úteis do *Big*

*Data* é um desafio significativo para o monitoramento de falha de processos. Shu et al. (2016) alegam que apesar do conceito de diagnóstico de falhas de processos ser uma questão de pesquisa antiga, ainda existem poucos sistemas satisfatoriamente aplicados em processos químicos reais.

*Criar modelos de avaliação de saúde, segurança e meio ambiente:* segundo Liu, Wei, Xu e Ji (2018) o gerenciamento online de saúde, segurança e meio ambiente (HSE) é um dos requisitos mais importantes da indústria química 4.0, uma vez que, cada vez mais, o consumidor exige da indústria políticas de sustentabilidade. Shu et al. (2016) reafirmam que a tomada de decisão oportuna, confiável e automática, suportando os operadores sobre as situações anormais nos processos químicos, é uma função de cognição indispensável para a digitalização do setor. Segundo Natarajan, Ghosh e Srinivasan (2012), a confiabilidade do sistema é um dos fatores mais importantes para avaliar o estado da saúde, segurança e meio ambiente das indústrias químicas. Para Bogle (2017), os processos específicos que estão ligados a saúde, segurança e meio ambiente são críticos, e devem ser devidamente modelados.

*Modificações nas plantas e interrupção da produção:* O aspecto mais importante em uma indústria química de processo contínuo é a manutenção de sua capacidade máxima possível. (Khare; Chin, 2017). Natarajan, Ghosh e Srinivasan (2014) citam que, apesar disso, a estrutura física da planta de processo contínuo é constantemente passível de mudança. Por exemplo, certas seções da planta podem ser retiradas (por semanas ou meses) para manutenção de rotina. Deste modo, os modelos matemáticos devem ser passíveis às adequações necessárias a tais mudanças (Natarajan; Ghosh; Srinivasan, 2012). Já Davis e Edgar (2008) identificam como principal dificuldade da implantação da Indústria 4.0 a interrupção da produção, extremamente evitada em processos contínuos. Uma vez que existe rara comprovação quantitativa dos benefícios econômicos de implantar as tecnologias 4.0, os autores também identificam a necessidade de pesquisa na implantação gradual, cuja interrupção da produção seja minimizada. Assim, o gerenciamento de mudanças precisa ser mantido e documentado, especialmente quando envolve fatores de segurança da indústria. (SQUIRE; SONG, 2014).

*Indisponibilidade de dados:* fabricantes de produtos químicos enfrentam o desafio de melhorar a capacidade da planta já existente e ao mesmo tempo reduzir os custos de manutenção. (KHARE; CHIN, 2017). Segundo Khare e Chin, ambos os desafios têm em comum a necessidade de obtenção de dados através de

instrumentação e análise dos dados disponíveis em tempo real. Além disso, para sistemas complexos com dados disponíveis em menor escala, os modelos de avaliação de confiabilidade são vulneráveis à instabilidade do sistema. (Liu; Wei; Xu; Ji, 2018). Li e Liu (2010) citam como exemplo o baixo nível de disponibilidade de informação na logística da indústria química. Ainda, Hamzeh (2016). Acrescenta a dificuldade das empresas em trabalhar com dados de diferentes fontes.

*Desenvolver novos processos de síntese, intensificar operações e adaptar produtos:* Bogle (2017) afirma que um requisito da Indústria 4.0 é a aproximação da indústria ao consumidor. Neste sentido, com o avanço da tecnologia de processos químicos, existem possibilidades de combinação de múltiplas operações em operações unitárias compactas, intensificando os processos operacionais. (BOGLE, 2017). Venkatasubramanian (2008) identifica na intensificação de processos oportunidades de contribuições nos campos de design de produtos químicos novos, criação de infraestrutura específica, sistemas de extração de dados, ambientes de gerenciamento de conhecimento e visualização de processos químicos.

*Escassez de casos de sucesso de implantação:* A aplicação da Internet das Coisas para grande quantidade de sensores e dados não tem atraído muita atenção dos pesquisadores e profissionais da indústria. Uma possível razão é que os benefícios de tais aplicações não foram reconhecidos ou testados. (HE et al., 2017). Devido à novidade da Indústria 4.0 e à falta de casos de uso comprovados, ainda não é claro os benefícios operacionais e monetários da adoção dos elementos da Indústria 4.0. (MONTANUS, 2016).

### 3.4 FATORES CRÍTICOS DE SUCESSO PARA A IMPLANTAÇÃO DAS TECNOLOGIAS 4.0

O método Fator Crítico de Sucesso (FCS) é destaque no trabalho de Rockart (1979). Segundo o autor, o método proporciona um desempenho competitivo bem-sucedido à organização, por intermédio da identificação das medidas necessárias para a obtenção do sucesso. A identificação dos fatores críticos de sucesso permitem o foco estratégico em ações prospectivas e corretivas que garantem o desenvolvimento de um projeto. (COLAUTO et al., 2004). Para Gezdur e Bhattacharjya (2017) deve-se levar em conta que os projetos de transformação digital podem demandar um tempo e esforço consideráveis. No caso dos Fatores Críticos de

Sucesso para a implantação das tecnologias 4.0, observa-se que há uma conversão dos autores encontrados na literatura, independentemente do tipo de indústria.

Um dos Fatores Críticos de Sucesso mais citados é a necessidade de conectividade de softwares e padronização de comunicação entre máquinas, de forma integrada à cadeia de suprimentos. (YAN et al., 2017; IVEZIC; KULVATUNYOU; SRINIVASAN, 2014; HELU; HEDBERG, 2016; THOBEN; WIESNER; WUEST, 2017). Outro fator importante é a eficiência computacional e a disponibilidade de banda larga. (JUNG, 2015; LU, 2017). Uma vez que as tecnologias são dependentes da plataforma digital e da internet sem fio, a transmissão de dados em tempo real é dependente dessa infraestrutura. Em relação ao gerenciamento de dados, a literatura é convergente em afirmar que existe necessidade em descentralizar análise e utilização de *Big Data*. (LU, 2017; JUNG et al., 2015; O'DONOVAN et al., 2015; HELU et al., 2015). Além disso, o armazenamento de dados deve ser protegido um sistema confiável de Segurança Cibernética (HELU et al., 2015; KUSIAK, 2017).

Da parte dos recursos humanos, a implantação das tecnologias 4.0 são projetos dependentes de colaboradores capacitados e comprometidos. (HELU et al. 2015; CHOI; KIM; NOH, 2015; THOBEN; WIESNER; WUEST, 2017; O'DONOVAN et al., 2015). Jung (2015) e Lu (2017) afirmam que ainda se faz necessário uma interface amigável entre os veículos digitais e os operadores. Lu (2017) e Helu e Hedberg (2015) afirmam que existe uma mudança de paradigma da produção 4.0, focando no desejo do consumidor e exigindo flexibilidade do processo quanto ao mercado e a demanda. Se baseando no desenvolvimento da Indústria 4.0, Li (2016) propõe uma definição dos recursos necessários no setor petroquímico para a nova indústria: gerenciamento de dados, resposta em tempo real, Segurança Cibernética, mão de obra especializada e evolução da interface Humano-Máquina. Qian, Zhong e Du (2017) apresentam os três fatores críticos principais dentro da realidade de processos industriais químicos da China: descrever o processo de produção usando modelos matemáticos precisos, melhoria de processos de uma abordagem mista, multiobjetiva e multimensurável, e um método para tomada de decisões de produção e gestão.

Hermann, Pentek e Otto (2016), baseados em análise quantitativa de textos, trazem em seu artigo princípios de design para a Indústria 4.0. A análise de textos identificou quatro princípios de design sobre como implantar as novas tecnologias: interconexão, transparência de informação, decisões descentralizadas e assistência técnica.

### 3.4.1 Fatores Críticos de Sucesso para a implantação das Tecnologias 4.0 nas indústrias químicas de processo contínuo

Em relação a indústria química de processo contínuo, a revisão da literatura aponta fatores críticos de sucesso específicos os quais são apresentados no QUADRO 5 e discutidos na sequência.

QUADRO 5 - FATORES CRÍTICOS DE SUCESSO NA IMPLANTAÇÃO DAS TECNOLOGIAS 4.0 ESPECÍFICOS AO SETOR QUÍMICO CONTÍNUO

Fator Crítico de Sucesso	Autores
Minimização de modificações na planta ou interrupções no processo produtivo não planejadas.	Natarajan; Ghosh; Srinivasan, 2012; Natarajan; Ghosh; Srinivasan, 2014; Squire; Song, 2014; Leeuw, 2017; Baldea et al., 2018; Reitze et al., 2018; Isaksson; Harjunkoski; Sand, 2018;
Infraestrutura e instalações compatíveis com os requisitos das novas tecnologias	Natarajan; Ghosh; Srinivasan, 2012; Rathinasabapathy et al., 2016; Yuan; Qin; Zhao, 2017; Chiang; Lu; Castillo, 2017; Baldea et al., 2018;
Sistemas de gerenciamento de eventos adversos confiáveis para processos de alto risco.	Gao, Shang, Kokossis, 2009; Wassick, 2009; Natarajan; Ghosh; Srinivasan, 2012; Davis et al., 2012; Squire; Song, 2014; Windmann et al., 2015; Shu et. al., 2016; Rathinasabapathy et al. 2016; Chen et al., 2016; Leeuw, 2017; Yuan; Qin; Zhao, 2017; Liu et al., 2018; Ragab et al., 2018; Baldea et al., 2018
Modelos de avaliação de saúde, segurança e meio ambiente	Belaud et al., 2014; Squire; Song, 2014; Leeuw, 2017; Yuan; Qin; Zhao, 2017; Liu; Wei; Xu; Ji, 2018;
Investimento em pesquisa e desenvolvimento para simplificar sistemas complexos e intensificar operações, adaptando o processo caso haja indisponibilidade de dados.	Leeuw, 2017; Baldea et al., 2018; Reitze et al., 2018
Sistemas de medição, transmissão e coleta de dados confiáveis.	Kumar et al. 2015; Hamzeh, 2016; Rathinasabapathy et al. 2016; Chen et al., 2016; Liu; Wei; Xu; Ji, 2018; Isaksson; Harjunkoski; Sand, 2018;
Modelagem e transcrição detalhada dos sistemas, quando possível	Wassick, 2009; Zuehlke, 2010; Natarajan; Ghosh; Srinivasan, 2012; Windmann et al., 2015; Kumar et al. 2015; Kumar; Baldea; Edgar, 2016; Shu et. al., 2016; Chiang; Lu; Castillo, 2017; Yuan; Qin; Zhao, 2017; García et al., 2017; Liu; Wei; Xu; Ji, 2018; Zhang et al., 2018; Zhou et al., 2018

FONTE: O autor (2019).

*Minimização de modificações na planta ou interrupções no processo produtivo não planejadas:* LIU et al. (2018) afirma que as causas de muitos acidentes graves, como os ocorridos na Flixborough, Piper Alpha e Petrobras® são originários de mudanças no fluxograma do processo, especificação de equipamento, e outros descritores principais de processo. Assim, uma vez que a indústria química continua está sob constante modificações, os sistemas de controle e segurança da fábrica devem estar em constante atualização. Dai et al. (2016) resumem que quaisquer mudanças durante as operações devem ser refletidas para a supervisão da produção em tempo real. Esse gerenciamento de mudanças, seja para especialização ou reconfiguração da indústria química (ou ainda de sua cadeia de suprimentos) requer esforço um adicional das empresas, segundo Knop (2017). Baldea et al. (2018) a variabilidade do processo é inevitável, a coordenação entre o controle do processo e a programação da produção é indispensável, utilizando a tecnologia disponível para maximizar a produção de sistemas que operam em paralelo.

*Infraestrutura e instalações compatíveis com os requisitos das novas tecnologia:* Segundo Bogle (2017), os métodos computacionais manipulam múltiplos estágios dentro da cadeia de suprimentos do setor químico, sendo necessário considerar as restrições técnicas de uma manufatura flexível em cada etapa. Neste sentido, faz-se necessário incorporar a capacidade de lidar com a incerteza na demanda e produção. Para este fim, a evolução dos sistemas de medição, transmissão e coleta de dados deve focar na Segurança Cibernética, qualidade de dados e velocidade de transmissão e uso. (ZHAO, 2017; CHIANG; LU; CASTILLO, 2017). Baldea et al. (2018) afirmam ainda que uma das principais idéias da indústria química de processo contínuo inteligente é a conexão das operações em paralelo.

*Sistemas de gerenciamento de eventos adversos confiáveis para processos de alto risco:* Para Yuan, Qin e Zhao (2017), dentro do contexto de *Big Data*, o gerenciamento de alarmes, monitoramento do processo, diagnóstico de falhas de equipamentos e monitoramento do comportamento humano devem ser integrados para obter uma plataforma confiável e escalonável. Natarajan, Ghosh e Srinivasan (2012) confirmam que a detecção de anormalidades no processo é essencial para que ações corretivas sejam eficazes, a fim de manter a qualidade do produto, evitar paralisações e acidentes. Li e Liu (2010) fornecem como exemplo a gestão de segurança da logística da indústria química, que deve necessariamente ser confiável, dado que lida, muitas vezes, com produtos inflamáveis, explosivos, tóxicos e

corrosivos. Para Dai et al., (2016), o objetivo das novas tecnologias deve incluir a redução significativa de incidentes de segurança. A necessidade de um sistema de detecção de falhas robusto e a minimização de acidentes é um consenso entre os autores, uma vez que este é o Fator Crítico de Sucesso mais comumente identificado na literatura.

*Modelos de avaliação de saúde, segurança e meio ambiente:* Squire e Song (2014), as estatísticas de segurança sugerem que a maioria das lesões é resultado de incidentes violentos no local de trabalho. Para Qian, Zhong e Du (2017), a meta para fabricação ótima no processo industrial químico é promover a produção eficiente, verde e segura. Uma vez que a indústria 4.0 depende de sistemas confiáveis, modelos de avaliação de saúde, segurança e meio ambiente devem ser incorporados ao sistema de controle convencional. (BOGLE, 2017). Bogle ainda afirma que, dado que os processos químicos são muitas vezes de alto risco, é um aspecto-chave a correta modelagem matemática aonde questões de saúde, segurança e ambientais exigem previsões precisas. Christofides et al. (2007) afirmam que essas medidas também podem trazer grandes benefícios econômicos, uma vez que situações anormais causam bilhões de dólares em perdas anualmente. Em outras palavras, Yuan, Qin, e Zhao (2017) citam que a avaliação de riscos deve ser o primeiro passo no gerenciamento de situações anormais. Para este fim, Baldea et al., (2018) cita o emprego da intensificação de processos químicos em módulos distribuídos como ferramenta para diminuir riscos.

*Investimento em pesquisa e desenvolvimento para simplificar sistemas complexos e intensificar operações, adaptando o processo caso haja indisponibilidade de dados:* Zhang et al. (2018) vê na tecnologia de *Big Data* a oportunidade contornar a indisponibilidade de dados e a dificuldade de modelar sistemas complexos através do histórico de dados empíricos. Shu et. al. (2016) afirmam que devido ao aumento de tamanho e complexidade dos processos químicos modernos e da quantidade de dados históricos disponíveis, os métodos baseados em histórico mostram grandes avanços no diagnóstico de falhas. Para Ge et al., (2017), a modelagem, monitoramento, previsão e controle de processos orientados por dados tem se mostrado viável a partir do uso de técnicas de *Machine Learning*. Outra alternativa para contornar a indisponibilidade de dados é o projeto de módulos de produção distribuídos, através da intensificação de processos. Para Baldea et al. (2018), a intensificação de processos também permite a transição de processos em batelada

para operação contínua, minimizando a variabilidade do processo, e garantindo qualidade através de sistemas automatizados.

*Sistemas de medição, transmissão e coleta de dados confiáveis:* Para Sun et al. (2017) extrair mais conhecimento e informações de dados de produção permitem aumentar a compreensão da dinâmica do sistema e apoiar o melhor operação dos equipamentos de forma eficiente. Montanus (2016) confirma que isso dá origem a oportunidades para análises mais eficientes e inteligentes e melhor controle de sistemas industriais, podendo até causar mudanças disruptivas na maneira como esses sistemas são projetados e utilizados. Porém, segundo Bogle (2017) embora uma quantidade considerável de dados de tendência histórica seja coletada em operações, a indústria química não incorpora grandes bancos de dados de demanda diretamente em seus sistemas de controle. Neste sentido, Rathinasabapathy et al. (2016) afirmam que modelos qualitativos tem a vantagem de serem rigorosos mesmo quando há dados ou informações insuficientes, substituindo sistemas de instrumentação avançados.

*Modelagem e transcrição detalhada dos sistemas, quando possível:* A descrição correta dos processos produtivos são pré-requisitos matemáticos para o desenvolvimento de sua modelagem. (NATARAJAN; GHOSH; SRINIVASAN, 2012). O trabalho de Liu, Wei, Xu e Ji (2018) é um exemplo de como a modelagem matemática é capaz de diminuir a complexidade das variáveis da indústria química de processo contínuo, incluindo fatores humanos, equipamentos, materiais e dados de meio ambiente. Zhou et al. (2018) vêem como pré-requisito para implantação das tecnologias 4.0 a criação de uma representação virtual do mundo físico, através de uma plataforma de comunicação digital. Já para Windmann et al. (2015), é fundamental o desenvolvimento de sistemas de assistência a autoaprendizagem, que identifiquem relações relevantes pela observação dos complexos processos de fabricação. Os autores acreditam que a tecnologia de *Machine Learning* auxiliam na modelagem detalhada de sistemas a fim de detectar automaticamente falhas, anomalias e necessidade de melhorias.

Trabalhos teóricos ainda apontam a necessidade de estimar riscos e recursos envolvidos nos projetos de implantação. (CHRISTOFIDES et al., 2007; DAVIS; EDGAR, 2008; MONTANUS, 2016. HE et al., 2017).

### 3.5 BENEFÍCIOS AMBIENTAIS E DE SEGURANÇA DA IMPLANTAÇÃO DAS TECNOLOGIAS 4.0

Embora a segurança dos processos e o gerenciamento de situações anormais tenham sido aprimorados em todo o mundo nos últimos vinte anos, não há um declínio geral claramente visível nos principais eventos de acidentes observados nos EUA ou na UE (PITBLADO, 2011). Apesar de todos os benefícios que os novos sistemas de controle têm a oferecer (tais como custos mais baixos, qualidade consistente do produto e segurança aprimorada), os acidentes ainda acontecem e causaram grande número de baixas, perdas ambientais e econômicas. (ZHANG et al., 2018).

Deste modo, as operações da Indústria 4.0 baseiam suas metas de saúde, segurança e meio ambiente como objetivos de desempenho, para que a agilidade e eficiência não permitam que as falhas reais e potenciais comprometam as operações, sejam elas acidentais ou deliberadas. (CHRISTOFIDES, 2007). As melhorias em saúde, segurança e meio ambiente podem incluir: não liberação de materiais tóxicos ao meio ambiente, redução de impacto em árvores adjacentes às instalações operacionais, e redução de violações físicas e de Segurança Cibernética. (CHRISTOFIDES, 2007). Assim, as novas tecnologias promovem agilidade operacional e fornecem à indústria a capacidade de rápida detecção e consequente adaptação às perturbações internas e externas.

#### **3.5.1 Benefícios ambientais e de segurança da implantação das tecnologias 4.0 nas indústrias químicas de processo contínuo**

Hoje, a indústria química é considerada uma das operações mais complexas, em termos de controle de saúde, segurança e meio ambiente. (DHASON, 2018). Para a indústria química de processo contínuo, as tecnologias 4.0 não somente proporcionam benefícios econômicos, mas também garantem melhorias em segurança e saúde a seus colaboradores. A indústria química de processo contínuo ambientada na inovação 4.0 é aquela caracterizada pela consciência ambiental, alta eficiência, segurança e sustentabilidade. (LI, 2016). Hoje, as novas tecnologias da Indústria 4.0 já impactam o mercado de trabalho, a produção industrial, pesquisa, educação e cuidados com saúde, segurança e meio ambiente. O uso de dados na indústria de processos químicos demonstrou melhorias na eficiência, confiabilidade e

segurança. (CHIANG; LU; CASTILLO, 2017). Segundo os autores, a indústria é capaz de cumprir demandas de consumo de maneira limpa, por um baixo custo e de forma sustentável.

A seguir, listam-se os benefícios ambientais e de segurança proporcionados pela adoção das tecnologias 4.0 nas indústrias químicas de processo contínuo (QUADRO 6).

QUADRO 6 – BENEFÍCIOS AMBIENTAIS E DE SEGURANÇA ORIUNDOS DAS TECNOLOGIAS 4.0 NA INDÚSTRIA QUÍMICA DE PROCESSO CONTÍNUO

<b>Benefícios</b>	<b>Autores</b>
Monitoramento intensivo para manutenção preditiva de equipamentos.	Montanus, 2016; Sadiku; Musa; Musa, 2017; Dhason, 2018;
Melhorar a previsão de falhas e eventos anormais, reduzindo incidentes de segurança	Christofides, 2007; Ge et al., 2014; Baaziz; 2014; Dai et al., 2016; Yuan; Qin; Zhao, 2017; Chiang; Lu; Castillo, 2017; Thoben et al., 2017; Qian; Zhong; Du, 2017; Liu et al., 2018; Joly, 2018; Dhason, 2018; Ali Al-Jlibawi, 2018;
Melhoria em gerenciamento de recursos e eficiência energética.	David; Edgar, 2008; Ge et al., 2014; Belaud et al., 2014; Li, 2016; Chiang; Lu; Castillo, 2017; Bogle, 2017;
Melhor gerenciamento de produtos perigosos.	Christofides, 2007; Li; Liu, 2010; Thienen et al, 2016; Li; 2016; Sadiku; Musa; Musa, 2017; Qian, Zhong, Du, 2017; Isaksson; Harjunkoski; Sand, 2018;
Redução de impactos ambientais através de processos mais limpos.	Christofides, 2007; Ge et al., 2014; Belaud et al., 2014; Li; 2016; Hamzeh, 2016; Li, 2016; Chiang; Lu; Castillo, 2017; Bogle, 2017; Baldea et al., 2018;
Possibilitar melhor avaliação de desempenho ambiental	Davis; Edgar, 2008; Ge et al., 2014; Belaud et al., 2014; Hamzeh, 2016; Fu; Shu; Liu, 2016; Ji et al., 2016; Thoben et al., 2017; Qian; Zhong; Du, 2017; Sadiku; Musa; Musa, 2017;
Correção de erros em tempo real e remediação ambiental	Li, Liu; 2010; Hamzeh, 2016; Natarajan; Ghosh; Srinivasan, 2014; Thoben et al., 2017; Sadiku; Musa; Musa, 2017; Liu et al., 2018; Joly, 2018;
Avanço em controle de processos, gerenciamento de dados e otimização	Davis; Edgar, 2008; Baaziz, 2014; Ge et al., 2014; Hamzeh, 2016; Thoben et al., 2017, Sadiku; Musa; Musa, 2017; Chiang; Lu; Castillo, 2017; Liu et al., 2018;

FONTE: O autor (2019).

*Monitoramento intensivo para manutenção preditiva de equipamentos:* Hoje, na indústria química, os operadores de campo precisam andar dentro da fábrica para realizar o monitoramento e a manutenção de equipamentos. Há muita pouca pesquisa focada no sistema de suporte efetivo para os trabalhadores de campo móveis. (DHASON, 2018). Um dos principais benefícios da tecnologia da informação na quarta

revolução industrial é garantir a autonomia do processo, focando na manutenção preditiva. Para isto, utiliza-se em conjunto *Big Data*, *Machine Learning*; comunicação a partir da conectividade sem fio da Internet das Coisas; e inspeção de plantas, utilizando drones aéreos e terrestres para garantir segurança e eficiência em tarefas críticas. (DHASON, 2018). Esses drones também podem ser adicionados ao sistema de suporte para maior segurança e confiabilidade das operações. Para Dhason, os drones podem ser usados para diferentes propósitos em plantas químicas, dentre os quais citam-se a conectividade sem fio, inspecionar corrosão, rachaduras, vazamentos e outras anomalias, especialmente em áreas elevadas e perigosas, e a coleta de amostras. Outro exemplo é fornecido por Chung, Hsiao e Chen (2014), que afirmam que um sistema de patrulha por RFID eficaz e seguro poderia ajudar a indústria química em gestão, proteção da vida dos funcionários, e segurança dos ativos da empresa, estabelecendo um ambiente mais seguro e saudável.

As análises de acidentes mostram que em sua maioria, existe falha humana envolvida e fraca capacidade dos sistemas de proporcionar adequada Interação Homem-Máquina. As empresas que adotam tecnologias de *HMI*, a Internet das Coisas e a tecnologia de visualização 3D são capazes de reagir mais rapidamente a alertas e alarmes, resultando em uma maior eficácia geral dos equipamentos e dos processos de manutenção. (SADIKU, MUSA, MUSA, 2017). Assim, o aumento da autonomia dos ativos por meio de um monitoramento mais intensivo e da manutenção preditiva de equipamentos autônomos descentralizados é reconhecido pelo setor como vantagens da adoção das tecnologias 4.0. (MONTANUS, 2016)

*Melhorar a previsão de falhas e eventos anormais, reduzindo incidentes de segurança:* Apesar de que algumas empresas possam levar a cultura de segurança e o gerenciamento de segurança de processos como os principais impulsionadores para o aprimoramento da prevenção de acidentes, técnicas como detecção e diagnóstico de falhas de processos em tempo real serão outra chave técnica viável para evitar grandes acidentes. Desta forma, existe a migração de uma programação reativa para uma de previsão, aonde pode-se aumentar a segurança e a lucratividade. (JOLY, 2018).

Dentro do contexto de *Big Data*, gerenciamento de alarme, monitoramento de processo, diagnóstico de falha de equipamento e monitoramento do comportamento humano devem ser integrados para obter uma plataforma de gerenciamento de situação anormal confiável e escalável. (YUAN; QIN; ZHAO, 2017). Além disso, a

Interação com computador é a janela do operador para o sistema de supervisão. As interfaces de usuário utilizam um design gráfico avançado para imitar exatamente a planta, onde os operadores podem controlar, monitorar e analisar dados. Sistemas modernos também criam relatórios, enviam notificações e gerenciam o controle de alarmes (DHASON, 2018). Os componentes de proteção individual permitem registrar o contexto, a situação e o status do trabalhador, máquina, planta e processo e ativa mecanismos de proteção antes que um perigo possa ocorrer. (THOBEN et al. 2017).

Os métodos baseados no histórico de processos quantitativos possuem um grande potencial de aplicação na indústria química. (ZHANG; ZHAO, 2017). Como os sistemas químicos são geralmente estáveis apenas por um breve período, algoritmos de aprendizagem e previsão de dados são de grande valia. (LIU et al., 2016). A potencial aplicação de sensores específicos permite a coleta de dados de difícil mensuração, coleta de dados em ambientes de trabalho perigosos e cujo requerimento de controle é difícil. (ALI AL-JLIBAWI, 2018). Nestes sistemas, as variáveis são parametrizadas a partir de equipamentos inteligentes, que compartilham dados, são conscientes de seu meio, processam informações e controlam o processo de forma descentralizada e autônoma. (THOBEN et al. 2017). Assim, os processos produtivos podem ser executados com menor número de interrupções, o que melhora o nível de segurança e corresponde as exigências legais para com os colaboradores. Qian, Zhong e Du (2017) também salientam que a segurança 4.0 não é apenas àquela que garante a confiabilidade necessária do processo de fabricação, mas também se refere à preservação da informação empresarial, por meio de diagnósticos de falhas e técnicas de controle.

*Melhoria em gerenciamento de recursos e eficiência energética:* Para Li (2016), a indústria química 4.0 é baseada na profunda integração, e possibilita otimizar a utilização de seus recursos, aumentando a produtividade global da cadeia de suprimentos. Troca e utilização de produtos e subprodutos mútuos entre empresas, bem como utilitários, é utilizada para integrar materiais, água, energia e informação em diferentes camadas, estabelecer uma relação de acoplamento simbiótica, melhorar a eficiência na utilização de recursos e proteger o meio ambiente. (LI, 2016).

Devido a necessidade de reduzir recursos, a crescente conscientização para a sustentabilidade, o processamento ecológico e sustentável torna-se cada vez mais importante. Assim, esforços nas indústrias químicas têm integrado a preocupação ambiental no estágio inicial do projeto do produto ou processo (preliminar) de um

parque industrial. (BELAUD et al., 2014). Redução da pegada de carbono, energia e matéria-prima do produto é, portanto, fortemente almejada. A fabricação sustentável inclui a reutilização, com uma visão de ciclo de vida de produtos e processos (DAVID; EDGAR, 2008).

Uma plataforma de gerenciamento de cadeia de suprimento integrada que cruza várias unidades de negócios na indústria química é construída para realizar ajustes e controles dinâmicos sob as principais restrições de proteção de materiais, energia e meio ambiente. (LI, 2016). A troca e utilização de produtos e subprodutos entre empresas, bem como utilitários, é utilizada para integrar materiais, água, energia e informação, estabelecer uma relação de acoplamento simbiótica, melhorar a eficiência na utilização de recursos e proteger o meio ambiente. (LI, 2016). Para Zhou et al. (2018) esta simbiose industrial é a principal característica de um parque industrial ecológico. Segundo os autores, ela permite que várias plantas operando independentemente compartilhem recursos e utilidades comuns. Através da rede, os resíduos e subprodutos produzidos a partir de uma planta podem ser utilizados em outra como matéria-prima. Geralmente, três tipos de sistemas simbióticos industriais têm sido investigados: rede de água, rede de energia e rede de materiais. (ZHOU et al., 2018).

Assim, a tecnologia de economia de energia, redução de emissões, e produção verde utiliza cada vez mais as tecnologias avançadas de simulação, integração e otimização de processos. (LI, 2016). Para Bogle, o benefício dessas novas tecnologias é a fabricação ágil, robusta e sustentável, que minimiza o desperdício e maximiza a lucratividade. (BOGLE, 2017). Uma melhor inteligência de fabricação aplicada em toda a empresa e sua cadeia de suprimentos permite minimizar o uso de energia e material, enquanto maximiza a sustentabilidade ambiental, saúde, segurança e competitividade. (DAI e tal., 2016).

*Melhor gerenciamento de produtos perigosos:* Como a segurança é a principal prioridade na fabricação e gestão de empresas industriais, o monitoramento de produtos químicos perigosos e da pegada ambiental tem atraído cada vez mais atenção de gestores. (QIAN; ZHONG; DU, 2017). Em um processo de produção industrial, o vazamento de objetos contínuos representa uma séria ameaça à segurança da produção. (LIU et al., 2018). Neste sentido, o rastreamento obtido pela utilização da Internet das Coisas terá um impacto significativo em orientar a evacuação de pessoas em caso de acidente e facilitará a remediação ambiental. (LIU

et al., 2018). Para resolver problemas processo de armazenamento de produtos químicos perigosos, a Internet das Coisas pode ser aplicadas a também tanques de armazenamento com monitoramento em tempo real. (LI, LIU, 2010). As tecnologias 4.0 também permitem o rastreamento de colaboradores, fornecendo dados do indivíduo pessoa e sua localização continuamente monitorada, permitindo um mapeamento tridimensional de todos os funcionários em chão de fábrica (SQUIRE; SONG, 2014).

A previsão de toxicidade química também é um benefício da aplicação das novas tecnologias. Métodos de *Machine Learning*, principalmente máquinas de vetores de suporte e sistemas neurais artificiais, têm sido utilizados para analisar conjuntos de dados de bioensaios in vitro para prever a toxicologia química (SADIKU, MUSA, MUSA, 2017). A técnica baseia-se em utilizar produtos químicos cujos dados toxicológicos são conhecidos e desenvolvem-se ferramentas de classificação preditiva. (SADIKU, MUSA, MUSA, 2017).

Monitorar os produtos químicos durante o trânsito pode ser realizado por dispositivos equipados com um GPS para rastrear a localização do veículo. Enquanto isso, vários sensores medem as propriedades físicas dos produtos químicos, bem como a condição do veículo através de dados como impactos de choque. (THIENEN et al., 2016). O sistema gera alertas quando o veículo está perto do local do cliente ou está envolvido em um impacto ou colisão, ou quando as propriedades físicas dos produtos químicos sendo transportados excedem os parâmetros definidos, desencadeando ação automatizada ou manual intervenção. Isso proporciona maior controle de riscos ambientais nesse processo delicado, através do monitoramento e controle de condições de substâncias químicas, e ajuda a garantir o transporte seguro de produtos químicos perigosos. (THIENEN et al., 2016). O monitoramento do status em tempo real de transporte de produtos químicos perigosos também garante a possibilidade de rápida mitigação em casos de acidentes ambientais. (LI, LIU, 2010). Mobilidade, sites não tripulados e operações remotas, todos contribuem para operações e controle de processos mais automatizados e seguros. (ISAKSSON et al., 2018).

*Redução de impactos ambientais através de processos mais limpos:* Enquanto a indústria química de processo contínuo ganhou muitos desenvolvimentos nas últimas décadas, o problema da sustentabilidade recebeu recentemente grande atenção em questões relacionadas a poluição e proteção do ambiente, como monitoramento das emissões de gases, tratamento de esgoto e análises de poluição.

(GE et al., 2014). A minimização da pegada ambiental (energia, água e emissões) é mais facilmente atingível em um ambiente 4.0, porque os processos são projetados para minimizar todos e quaisquer impactos externos adversos, através de constante monitoramento. O controle da poluição, a ecoeficiência, o pensamento sobre o ciclo de vida e a ecologia industrial são os principais passos das práticas sustentáveis da manufatura 4.0. (BELAUD et al., 2014).

A intensificação de processos e a excelência operacional também são focos da Indústria 4.0. Trata-se de um conceito que se expandiu ao longo das últimas duas décadas. Seu propósito é combinar múltiplas unidades no mesmo dispositivo físico. (BALDEA et al., 2018) Ao trazer vários processos físicos e químicos em estreita proximidade física, esses sistemas intensificados minimizam as limitações de transferência. Como consequência, tais dispositivos tendem a ser menores e mais eficientes do que as convencionais operações unitárias. Além disso, reduzir as dimensões traz vantagens em segurança. (BALDEA et al., 2018).

*Possibilitar melhor avaliação de desempenho ambiental:* Dentre os benefícios da Indústria 4.0, Qian, Zhong e Du (2017) citam a possibilidade de realizar o monitoramento do ciclo de vida da pegada ambiental. Assim, garante-se uma utilização mais abrangente dos recursos e a minimização da emissão de poluentes. Para Sadiku, Musa e Musa (2017), *Machine Learning*, pode ser empregado para uma melhor avaliação de desempenho de sustentabilidade. Ainda, torna-se possível realizar análises ao longo da evolução cronológica da indústria dos processos. (GE et al., 2017). A tecnologia aliada ao gerenciamento de *Big Data* é a chave para acelerar o ritmo da inovação química e da fabricação econômica. (SADIKU, MUSA E MUSA 2017). Além disso, com a ajuda de uma inteligência abrangente dos processos de negócios e tomada de decisões, as empresas poderiam se adaptar a requisitos ambientais mais rigorosos e a mudanças nas necessidades dos clientes. (JI et al., 2016). A prosperidade da tecnologia de *Blockchain* também remete ao desenvolvimento da sustentabilidade ambiental, com objetivos de redução de alterações climáticas a longo prazo. Como exemplo, os autores citam um projeto chamado *EP-Chain*, que foca no desenvolvimento de *Blockchain* e Internet das Coisas para aplicações de proteção ambiental. Seu objetivo é prover uma ferramenta de segurança e confiabilidade para armazenamento, gerenciamento e cálculo de dados ambientais.

*Correção de erros em tempo real e remediação ambiental:* Outro aspecto importante para o futuro refere-se à recuperação do processo. A detecção de anormalidades do processo é essencial para que ações corretivas sejam eficazes a fim de manter a qualidade do produto, e evitar paralisações e acidentes. (NATARAJAN; GHOSH; SRINIVASAN, 2012). Quando ocorre uma falha, e ela é detectada e diagnosticada, e ações de recuperação adequadas precisam ser planejadas e implementadas. Um passo importante antes de implementar a ação de recuperação seria validar as ações planejadas, possivelmente usando simulação. (NATARAJAN; SRINIVASAN, 2014). Para Sadiku, Musa e Musa (2017), *Machine Learning* pode ajudar os fabricantes a encontrar soluções de problemas mais rapidamente. Se o sistema estiver conectado a um Sistemas Ciber-Físico, uma mudança pode ser reconhecida de forma rápida, enquanto mudanças manuais exigem análise e correção humana. Segundo Hamzeh (2016), através do monitoramento ambiental em tempo real, é possível prever dados de emissão de poluentes e ajustar o processo para garantir a conservação do meio ambiente.

A mineração de dados e a análise de processo fornecem um conhecimento mais útil aos gestores, tornando o processo mais compreensível e eficiente para análises de sustentabilidade. Como resultado, o processo pode ser capaz de prever os eventos anormais que podem causar degradação da sustentabilidade, melhorar a eficiência energética de todo o processo, e diagnosticar seu desempenho relacionado à segurança de processos, poluição ambiental, e consumo de energia. (GE et al., 2017).

*Avanço em controle de processos, gerenciamento de dados e otimização* O melhoramento de toda a fábrica está no centro do pensamento da engenharia de processos. (BOGLE, 2017). Assim, a indústria 4.0 reage proativamente, evitando problemas ambientais, de saúde e de segurança ao mesmo tempo que aproveita oportunidades para otimização operacional e monitoramento das condições ambientais. (DAVIS; EDGAR, 2008).

Abordagens baseadas em dados são usadas para melhor estimar as demandas dos consumidores, otimizar o gerenciamento de energia e reduzir impacto ambiental. (CHIANG; LU; CASTILLO, 2017). Para Baaziz (2014), a redução de riscos em saúde, segurança e meio ambiente é possibilitada a partir do gerenciamento de dados e planejamento da produção. Para o autor, isto se dá evitando criar condições perigosas para os trabalhadores e controlando riscos ambientais. Tais dados de

gerenciamento de saúde, segurança e meio ambiente nos sistemas químicos incluem gerenciamento de operação, cronograma de produção, monitoramento de processos, operação logística em tempo real, e o gerenciamento de dados de múltiplas fontes, heterogêneos e massivos. (LIU et al., 2018). Dentre tais informações constam registros de proteção de componentes, histórico de situações adversas, estado dos trabalhadores, máquinas planta e processo e mecanismos de proteção preditiva a colisões, vazamentos, perigos tóxicos e de inflamabilidade. (THOBEN et al. 2017). Ambas as eficiências energéticas e ambientais da indústria de processos químicos dependem de operações otimizadas, que exigem controle avançado do processo. Para este fim, mineração profunda e análise de dados de processo podem descobrir mais conhecimento útil, tornando o processo mais compreensível e eficiente para análises de sustentabilidade. Como resultado, o processo se torna capaz de prever os eventos anormais, melhorar a eficiência energética de todo o processo, prever e diagnosticar desempenhos e monitorar a poluição ambiental. (GE et al., 2014).

## 4 CONCLUSÕES

Este trabalho buscou responder a questão de pesquisa proposta: “Quais os desafios e benefícios da implantação das tecnologias da Indústria 4.0 no setor químico de processo contínuo?”. Através de uma revisão sistemática da literatura pertinente, foi possível obter uma resposta às quatro subquestões de pesquisa, listadas como segue:

- 1) *“Quais os desafios para a implantação das tecnologias 4.0 nas indústrias químicas de processo contínuo?”*: Os desafios específicos do setor retomam à necessidade de modelar e transcrever os complexos sistemas químicos. Além de compreenderem diferentes escalas de parâmetros, o setor é caracterizado pelo grande número de variáveis físico-químicas que necessitam ser mensurados em tempo real. Uma vez que as substâncias processadas são geralmente perigosas, existe a necessidade de criar modelos de avaliação de saúde segurança e meio ambiente, uma vez que os sistemas de resposta a falhas devem ser confiáveis e preditivos. Assim, a indústria química de processo contínuo precisa adaptar os métodos clássicos de controle às tecnologias novas da Indústria 4.0, minimizando modificações e interrupções desnecessárias, e desenvolvendo novos processos de síntese, intensificação de operações e adaptando seus produtos às exigências do mercado.
- 2) *“Que fatores críticos de sucesso garantem a implantação das tecnologias 4.0 nas indústrias químicas de processo contínuo?”*: Os Fatores Críticos de Sucesso para o setor químico estão intimamente relacionados com a elaboração de uma infraestrutura de instalações compatíveis com os requisitos das tecnologias 4.0. Tais tecnologias exigem sistemas de medição, transmissão e coleta de dados confiáveis, e para que isto seja possível, exige-se um esforço em modelagem detalhada dos sistemas e adaptações que superem a indisponibilidade de dados. Dado o alto risco intrínseco a automatização de processos químicos, são Fatores Críticos de Sucesso a elaboração de sistemas de gerenciamento e mitigação de falhas confiáveis, modelos de saúde, segurança e meio ambiente e minimização de modificações na planta ou interrupções não planejadas.
- 3) *“As tecnologias 4.0 proporcionam benefícios para a melhoria de gerenciamento de segurança nas indústrias químicas de processo contínuo?”*: As tecnologias

4.0 permitem melhoria na previsão de falhas e eventos anormais, reduzindo incidentes de segurança. Ainda, cria novas possibilidades de monitoramento intensivo para manutenção preditiva dos equipamentos da indústria química, possibilitando obtenção de dados em ambientes de difícil aquisição. Outro benefício é a melhoria no gerenciamento e monitoria de produtos perigosos, tanto em processo como em armazenagem ou transporte. Avanços em controle de processos, gerenciamento de dados e otimização garantem um ambiente de trabalho mais seguro.

- 4) “*Quais os benefícios da implantação das tecnologias 4.0 nas indústrias químicas de processo contínuo para melhoria da sustentabilidade ambiental?*”: Através das inovações propostas pelas tecnologias 4.0, é possível realizar elaborar novos modelos de gerenciamento de recursos através de técnicas de reciclagem e melhorar a eficiência energética das cadeias de suprimento do setor. Além disso, processos mais limpos e intensificação de processos garantem redução de impactos ambientais e possibilitam melhor avaliação de desempenho ambiental, monitoramento da pegada ambiental e análise de ciclo de vida. Desta forma, a correção de erros se dá em tempo real, e possibilita rápida remediação ambiental em caso de acidentes.

Ainda, a análise da literatura revelou várias lacunas de pesquisa e necessidades de futuros estudos. A pesquisa em recuperação e extração de informações úteis associadas ao *Big Data*, objetivando melhoria, controle e gerenciamento, é o tópico mais amplamente abordado pelas publicações estudadas. Diversos autores concordam que pesquisas futuras devem focar em métodos de avaliação de qualidade de dados extraídos do processo e técnicas de limpeza de *Big Data*.

Para os complexos sistemas químicos, os dados muitas vezes se mostram indisponíveis. Neste sentido, também é necessário o desenvolvimento de modelos que utilizem o histórico de dados empíricos para contornar a instabilidade dos sistemas produtivos, bem como sistemas de armazenamento de *Big Data*. Publicações mais recentes afirmam que o desenvolvimento de módulos de processos intensificados é um promissor caminho para a indústria química de processo contínuo nessa nova revolução industrial.

A adaptação das tecnologias propostas pela Indústria 4.0 se faz necessária. Como exemplo, citam-se a pesquisa de projeto e atualização de redes de sensores,

comunicação entre máquinas em escalas maiores, atualização dos estudos de *Machine Learning* e o desenvolvimento da tecnologia de *Blockchain*, que apesar de possuir grande potencial de revolução, ainda é pouco explorada.

Além disso, o diagnóstico de falhas é um tema recorrente, e o estudo de sua aplicação no setor químico é essencial, principalmente ao que tange sobre a origem de falhas. Assim como novos modelos de avaliação de HSE, a pesquisa da integração das tecnologias perante a cadeia de suprimentos, e técnicas de Segurança Cibernética configuram o futuro do campo de pesquisa.

O maior desafio para o desenvolvimento da Indústria 4.0 no setor químico é a necessidade da comunidade científica em trabalhar de forma multidisciplinar, unindo os avanços da ciência da computação no gerenciamento de dados, ferramentas da engenharia de produção, a modelagem matemática e conhecimento técnico da engenharia de processos químicos.

## REFERÊNCIAS

- AHUETT-GARZA, H.; KURFESS, T. A brief discussion on the trends of habilitating technologies for Industry 4.0 and Smart manufacturing. 2018.
- AJAMI, S.; RAJABZADEH, A. 2013. Radio Frequency Identification (RFID) technology and patient safety. **J. Res. Med. Sci.**; v. 18, n. 9, p. 809-813.
- AKÇAYIR, M.; AKÇAYIR, G. Advantages and challenges associated with augmented reality for education: A systematic review of the literature. **Educational Research Review**, v. 20, p. 1-11. 2017.
- AL-JLIBAWI, A.; BIN OTHMAN, M. L.; AL-HUSEINY, M. S.; BIN ARIS, I. Efficient soft sensor modelling for advanced manufacturing systems by applying hybrid intelligent soft computing techniques. **International Journal of Simulation: Systems, Science & Technology**, v. 19, n. 3, p. 1-7. 2018.
- BAAZIZ, A.; QUONIAM, L. How to use Big Data technologies to optimize operations in Upstream Petroleum Industry. **International Journal of Innovation**, v. 1, n. 1, p. 19-25. 2014.
- BALAKRISHNAN, S. M.; SANGAIAH, A. K. Integrated QoUE and QoS approach for optimal service composition selection in internet of services (IoS). **Multimedia Tools and Applications**, v. 76, p. 22889-229116. 2016.
- BALDEA, M.; EDGAR, T.; STANLEY, B. L.; KISS, A. A. Modularization in Chemical Processing. **AIChE Special Section: Process Intensification**. 2018.
- BAUR, C.; WEE, D. A Successful Experience of International Training and Education in Manufacturing. **Creative Education**, v. 8, n. 1. 2017.
- BELAUD, J.; NEGNY, S.; DUPROS, F.; MICHÉA, D.; VAUTRIN, B. Collaborative simulation and scientific big data analysis: Illustration for sustainability in natural hazards management and chemical process engineering. **Computers in Industry**, v. 65, n. 3, p. 521-535. 2014. <http://dx.doi.org/10.1016/j.compind.2014.01.009>
- BLACKBURN, R.; LURZ, K.; PRIESE, B.; GÖB, R.; DARKOW, IL. Predictive analytics approach for demand forecasting in the process industry. **Intl. Trans. in Op. Res.**, v. 22, p. 407–428. 2015. <https://doi.org/10.1111/itor.12122>
- BOGLE, I. D. A Perspective on Smart Process Manufacturing Research Challenges for Process Systems Engineers. **Engineering**, v. 3, n. 2, p. 161-165. 2017. <http://dx.doi.org/10.1016/J.ENG.2017.02.003>
- BORGES, F. H.; DALCOL, P. R. T. **Indústrias de processo: comparações e caracterizações**. XXII Encontro Nacional de Engenharia de Produção. 2002.
- BUFFA, E. S. *Production Inventory Systems – Planning and Control*. 3ª Ed. Richard D. Irwin: Illinois. 1979.

CHANG, RF.; CHANG, CW.; TSENG, KH.; CHIANG, CL.; KAO, WS.; CHEN, WJ. Structural planning and implementation of a microprocessor-based human-machine interface in a stream-explosion process application. **Computer Standards & Interfaces**, v. 33, p. 232-248. 2011. <https://doi.org/10.1016/j.csi.2010.05.001>

CHARPENTIER, J. What Kind of Modern “Green” Chemical Engineering is Required for the Design of the “Factory of Future”? **Procedia Engineering**, v. 138, p. 445-458. 2016.

CHEN, Y.; LEE, G. M.; SHU, L.; CRESPI, N. Industrial Internet of Things-Based Collaborative Sensing Intelligence: Framework and Research Challenges. **Sensors**, v. 16, n. 215. 2016. <https://doi.org/10.3390/s16020215>.

CHIANG, L.; LU, B.; CASTILLO, I. Big Data Analytics in Chemical Engineering. The Dow Chemical Company, **Annu. Rev. Chem. Biomol. Eng.** 2017. <https://doi.org/10.1146/annurev-chembioeng-060816-101555>

CHOI, S.; KIM, B. H.; NOH, S. D. A Diagnosis and Evaluation Method for Strategic Planning and Systematic Design of a Virtual Factory in Smart Manufacturing Systems. **International Journal of Precision Engineering and Manufacturing**, v. 16, n. 6, p. 1107-1115. 2015.

CHRISTOFIDES, P. D.; DAVIS, J. F.; EL-FARRA, N. H.; CLARK, D.; HARRIS, K. R.; GIPSON, J. N. Smart plant operations: Vision, progress and challenges. **AIChE Journal**, v. 53, n. 11, p. 2734-2741. 2007. <https://doi.org/10.1002/aic.11320>

CHUNG, YF.; HSIAO, TC.; CHEN, SC.; The Application of RFID Monitoring Technology to Patrol Management System in Petrochemical Industry. **Wireless Pers Commun**, v. 79, p. 1063-1088. 2014. <https://doi.org/10.1007/s11277-014-1918-5>

COLAUTO, D.; GONÇALVES, C. M.; BEUREN, I. M.; DOS SANTOS, NERI. Os fatores críticos de sucesso como suporte ao sistema de inteligência competitiva: o caso de uma empresa brasileira. **Revista de Administração Mackenzie**, v. 5, n. 2. 2004.

CONNER, B. P.; MANOGHARAN, G. P.; MARTOF, A. N.; RODOMSKY, L. M.; RODOMSKY, C. M.; JORDAN, D. C.; LIMPEROS, J. W. Making sense of 3-D printing: Creating a map of additive manufacturing products and services. **Additive Manufacturing**, v. 1, p. 64-76. 2014.

DAI, Y.; WANG, H.; KHAN, F.; ZHAO, J. Abnormal situation management for smart chemical process operation. **Current Opinion in Chemical Engineering**, v. 14, p. 49-55. 2016. <http://dx.doi.org/10.1016/j.coche.2016.07.009>

DAVIS, J. et al. Smart Process Manufacturing Workshop Report. IN: **NSF Roadmap Development Workshop**. 2008.

DAVIS, J.; EDGAR, T. Smart Process Manufacturing—A Vision of the Future. **Design for Energy and the Environment**, p. 149-165. 2008.

DAVIS, J.; EDGAR, T.; PORTER, J.; BERNADEN, J.; SARLI, M. Smart manufacturing, manufacturing intelligence and demand-dynamic performance. **Computers & Chemical Engineering**, v. 47, p. 145-156. 2012. <http://dx.doi.org/10.1016/j.compchemeng.2012.06.037>

DAVIS, J.; SWINK, D. Smart Manufacturing, real-time networked information workflows and enterprise performance. IN: **SMLC papers**. 2014. Disponível em: <[https://smartmanufacturingcoalition.org/sites/default/files/scppe\\_april\\_2013.pdf](https://smartmanufacturingcoalition.org/sites/default/files/scppe_april_2013.pdf)> Acessado em 27 novembro de 2017.

DHASON, S. B. A. R. An Advanced context aware operator support system (CAOSS) for chemical plant operation. **Office of Graduate Programs of Florida Institute of Technology**. Tese. 2018.

DING, Z.; MEI, G.; CUOMO, S.; LI, Y.; XU, N. Comparison of Estimating Missing Values in IoT Time Series Data Using Different Interpolation Algorithms. **International Journal of Parallel Programming**. 2018.

ENGISCH, W.; MUZZIO, F. Using Residence Time Distributions (RTDs) to Address the Traceability of Raw Materials in Continuous Pharmaceutical Manufacturing. **Journal of Pharmaceutical Innovation**, v. 11, p. 64–81. 2016.

FEBLOWITZ J. The Big Deal About Big Data in Upstream Oil and Gas. IN: **IDC Energy Insights**, 2012

FRANSOO, J. C.; RUTTEN, W. G. M. M. A Typology of Production Control Situations in Process Industries. **International Journal of Operations e Production Management**, v. 14, n. 12, p. 47-57. 1994.

GAO, Y.; SHANG, Z.; KOKOSSIS, A. Agent-based intelligent system development for decision support in chemical process industry. **Expert Systems with Applications**, v. 36, n. 8, p. 11099-11107. 2009. <https://doi.org/10.1016/j.eswa.2009.02.078>

GARCÍA, M. V.; IRISARRI, E.; PÉREZ, F.; ESTÉVEZ, E.; MARCOS, M. An Open CPPS Automation Architecture based on IEC-61499 over OPC-UA for flexible manufacturing in Oil&Gas Industry. **IFAC-PapersOnLine**, v. 50, n. 1, p. 1231–1238. 2017. <https://doi.org/10.1016/j.ifacol.2017.08.347>

GE, Z.; SONG, Z.; DING S. Z.; HUANG, B. Data Mining and Analytics in the Process Industry: The Role of Machine Learning. **IEEE Access**, v.5, p. 20590-20616. 2017. <https://doi.org/10.1109/ACCESS.2017.2756872>

GENG, Z.; YANG, X.; HAN, Y.; ZHU, Q.; Energy optimization and analysis modeling based on extreme learning machine integrated index decomposition analysis: Application to complex chemical processes. **Energy**, v. 120, p. 67-78. 2017. <http://dx.doi.org/10.1016/j.energy.2016.12.090>

GEORGE, G.; HAAS, M.; PENTLAND, A. S. Big Data and Management. **Academy of Management Journal**, V. 57, n. 2, p.321-326. 2014.

GEZDUR, A.; BHATTACHARJYA, J. Digitization in the Oil and Gas Industry: Challenges and Opportunities for Supply Chain Partners. **Collaboration in a Data-Rich World**, p. 97-103. 2017.

GROSSMANN, I. Enterprise-wide optimization: A new frontier in process systems engineering. **AIChE Journal**, v. 51, n. 7, p. 1846-1857. 2005. <https://doi.org/10.1002/aic.10617>

GRUSCHKA, N.; LÜSSEM, J. Information Quality Challenges in Industry 4.0. IN: **ICIQ 2016, Ciudad Real (Spain)**, Paper 10, 2016.

HAMZEH, H. **Application of Big Data in Petroleum Industry**. Department of Electronics and Computer Engineering, 0-16. 2016.

HAO, Q.; ZHANG, F.; LIU, Z.; QIN, L. Design of Chemical Industrial Park Integrated Information Management Platform Based on Cloud Computing and IOT (The Internet of Things) Technologies. **International Journal of Smart Home**, v. 9, n. 4, p. 35-46. 2015. <http://dx.doi.org/10.14257/ijsh.2015.9.4.04>

HASSANI, H.; SILVA, E. S.; AL KAABI, A. M. The role of innovation and technology in sustaining the petroleum and petrochemical industry. **Technological Forecasting and Social Change**, v. 119, p. 1-17. 2017. <http://dx.doi.org/10.1016/j.techfore.2017.03.003>

HAWKINS, W.; BRANDL, D.; BOYES, W. **Applying Isa-88 in Discrete and Continuous Manufacturing**. World Batch Forum (WBF). 1<sup>a</sup> Ed. Momentum Press. 2010.

HE, P. Q.; WANG, J.; SHAH, D.; VAHDAT, N. Statistical Process Monitoring for IoT-Enabled Cybermanufacturing: Opportunities and Challenges. **IFAC-PapersOnLine**, v. 50, n. 1, p. 14946–14951. 2017. <https://doi.org/10.1016/j.ifacol.2017.08.2546>

HELU, M.; HEDBERG, T. Jr. Enabling Smart Manufacturing Research and Development using a Product Lifecycle Test Bed. **Procedia Manufacturing**, v.1, p. 86-97. 2015.

HELU, S.; MORRIS, K.; JUNG, K.; LYONS, K.; LEONG, S. Identifying performance assurance challenges for smart manufacturing. **Manuf Lett**, v, 6. p. 1-4. 2015.

HERMANN, M.; PENTEK, T.; OTTO, B. **Design Principles for Industrie 4.0 Scenarios**. 49th Hawaii International Conference on System Sciences (HICSS). 2016. <https://doi.org/10.1109/HICSS.2016.488>

HIMSS ASIA PACIFIC. **Cyber Security Threats in Thailand and the Need for SMART**. 2016. Disponível em: [http://www.himssasiapac.org/sites/default/files/HIMSSAP\\_ExclusiveArticles\\_CyberSecurityThreatsinThailand.pdf](http://www.himssasiapac.org/sites/default/files/HIMSSAP_ExclusiveArticles_CyberSecurityThreatsinThailand.pdf).

INABA, K.; The Common Integration The Group Operation of Petrochemical Complexes in Japan. **Journal on Innovation and Sustainability**, v. 5, n. 2, p. 94-102. 2016.

ISAKSSON, A. J.; HARJUNKOSKI, I.; SAND, G.; The impact of digitalization on the future of control and operations. **Computers and Chemical Engineering**, v. 114, p. 112 – 129. 2018. <https://doi.org/10.1016/j.compchemeng.2017.10.037>.

IVEZIC, N.; KULVATUNYOU, B.; SRINIVASAN, V. On architecting and composing through-life engineering information services to enable smart manufacturing. **Procedia CIRP**, v. 22, p. 45-52. 2014.

JI, X.; HE, G.; XU, J.; GUO, Y. Study on the mode of intelligent chemical industry based on cyber-physical system and its implementation. **Advances in Engineering Software**, v. 99, p. 18-26. 2016. <http://dx.doi.org/10.1016/j.advengsoft.2016.04.010>

JOHANNSEN, G. Human-Machine Interaction. **Control Systems, Robotics, and Automation**, IN: Encyclopedia of Life Support Systems, v. 21. 2009.

JOLY, M.; ODLOAK, D.; MIYAKE, M.; MENEZES, B. C.; KELLY, J. D. Refinery production scheduling toward Industry 4.0. **Brazilian Journal of Chemical Engineering**, V. 29, N. 2, p. 371 – 384. 2018. <https://doi.org/10.15302/J-FEM-2017024>

JUNG, K.; MORRIS, K. C.; LYONS, K. W.; LEONG, S.; CHO, H. Mapping Strategic Goals and Operational Performance Metrics for Smart Manufacturing Systems. **Procedia Computer Science**, v. 44, p. 184-193. 2015.

KAGERMANN, H.; WAHLSTER, W.; HELBIG, J. **Recommendations for implementing the strategic initiative Industrie 4.0: Final report of the Industrie 4.0 Working Group**, Frankfurt. 2013.

KHARE, C.; CHIN, ST. Potential for data analytics opportunities in SMART chemical Industry. **Chemistry Today**, v. 35, n. 2, p. 60-62. 2017.

KLEINELANGHORST, M. J. **J-Park Simulator: Roadmap to Smart Eco-Industrial Parks**. IN: Computational Modelling Group, University of Cambridge. 2016.

von KNOP, J.; Chemistry 4.0 Challenges and Solutions for the Digital Transformation. **Croat. Chem. Acta**, v. 89, n. 4, p. 397–402. 2017. <https://doi.org/10.5562/cca3132>.

KOHLERT, M. Multi-Sensory Data Analysis and On-Line Evaluation for Advanced Process Control and Yield Optimization in Polymer Film Industry. Tese. **TU Kaiserslautern**. 2015.

KORAMBATH, P.; WANG, J.; KUMAR, A.; HOCHSTEIN, L.; SCHOTT, B.; GRAYBILL, R.; DAVIS, J. Deploying Kepler Workflows as Services on a Cloud Infrastructure for Smart Manufacturing. **Procedia Computer Science**, v. 29, p. 2254-2259. 2014. <https://doi.org/10.1016/j.procs.2014.05.210>

KORAMBATH, P.; WANG, J.; KUMAR, A.; DAVIS, J.; GRAYBILL, R.; SCHOTT, B.; e BALDEA, M. A Smart Manufacturing Use Case: Furnace Temperature Balancing in Steam Methane Reforming Process via Kepler Workflows. **Procedia Computer Science**, v. 80, p. 680-689. 2016. <https://doi.org/10.1016/j.procs.2016.05.357>

KOTYNKOVA, M. Re-Industrialization of Europe: Industry 4.0 and the Future of Work. **European Scientific Journal**, Special Edition, p. 249-256. 2017.

KUMAR, A. **Model based Operation of Industrial Steam Methane Reformers using Large Scale Sensor Data**. (PhD Thesis). The University of Texas at Austin, Austin. 2016.

KUMAR, A.; BALDEA, M.; EDGAR, T. F. Smart Manufacturing: Application to an Industrial Scale Steam-Methane Reformer. **Proceedings of FOCAP/CPC**. University of Texas at Austin. 2017.

KUMAR, A.; BALDEA, M.; EDGAR, T. F. On optimal sensing and actuation design for an industrial scale steam methane reformer furnace. **AIChE Journal**, v. 62, n. 9, p. 3225-3237. 2016a. <https://doi.org/10.1002/aic.15333>

KUMAR, A.; BALDEA, M.; EDGAR, T. F. Real-time optimization of an industrial steam-methane reformer under distributed sensing. **Control Engineering Practice**, v. 54, p. 140-153. 2016b. <http://dx.doi.org/10.1016/j.conengprac.2016.05.010>

KUMAR, A.; BALDEA, M.; EDGAR, T. F. A physics-based model for industrial steam-methane reformer optimization with non-uniform temperature field. **Computers & Chemical Engineering**, v. 105, p. 224-236. 2016c. <http://dx.doi.org/10.1016/j.compchemeng.2017.01.002>

KUMAR, A.; EDGAR, T. F.; BALDEA, M. Multi-resolution model of an industrial hydrogen plant for plantwide operational optimization with non-uniform steam-methane reformer temperature field. **Computers & Chemical Engineering**, v. 107, p. 271-283. 2016d. <http://dx.doi.org/10.1016/j.compchemeng.2017.02.040>

KUMAR, A.; BALDEA, M.; EDGAR, T. F.; EZEKOYE, O. A. Smart Manufacturing Approach for Efficient Operation of Industrial Steam-Methane Reformers. **Industrial & Engineering Chemistry Research**, v. 54, p. 4360-4370. 2015. <https://doi.org/10.1021/ie504087z>

KUSIAK, A. Smart Manufacturing. **International Journal of Production Research**, v. 56, n. 1-2. 2017.

LEEuw, V. de. Industrie 4.0 in the Chemical Industry. **ARC Insights**. 2017.

LI, D. Perspective for smart factory in petrochemical industry. **Computers & Chemical Engineering**, v. 91, p. 136-148. 2016. <http://dx.doi.org/10.1016/j.compchemeng.2016.03.006>

LI, H.; LIU, Y.; **A Study of the Real-Time Monitoring System for Chemical Logistics Based on Internet of Things**. The Conference on Web Based Business Management. 2010.

LIU, W.; WEI, W.; XU, J.; JI, X.; A Hybrid Algorithm for the Reliability Evaluation Models of Chemical Systems. **Qual. Reliab. Engng. Int.**; v. 33, p. 1337–1349. 2017. <https://doi.org/10.1002/qre.2108>

LU, Y. Industry 4.0: A survey on technologies, applications and open research issues. **Journal of Industrial Information Integration**, v. 6, p. 1-10. 2017.

LUO, H.; WANG, K.; KONG, X. T. R.; LU, S. QU, T.; Synchronized production and logistics via ubiquitous computing technology. **Robotics and Computer Integrated Manufacturing**, v. 45, p. 99–115. 2017. <http://dx.doi.org/10.1016/j.rcim.2016.01.008>

MARTIN, G. Wireless networks improve refinery operation. **Hydrocarbon processing**, v. 88, n. 3, p. 29-32. 2009.

MONTANUS, M. **Business Models for Industry 4.0 Developing a Framework to Determine and Assess Impacts on Business Models in the Dutch Oil and Gas Industry**. (Master Thesis). Delft University Of Technology, Delft. 2016.

MEYENDORF, N. G. NDE for the 21st century: industry 4.0 requires NDE 4.0. IN: **Proceedings Volume 10171**. 2017.

MOHER, D.; LIBERATI, A.; TETZLAFF, J.; ALTMAN, D.G. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. **PLoS Med**, v. 6, n7. 2009.

NATARAJAN, S.; GHOSHA, K.; SRINIVASANA, R. An ontology for distributed process supervision of large-scale chemical plants. **Computers & Chemical Engineering**, v. 46, p. 124-140. 2012. <http://dx.doi.org/10.1016/j.compchemeng.2012.06.009>

NATARAJAN, S.; SRINIVASAN, R. Implementation of multi agents based system for process supervision in large-scale chemical plants. **Computers & Chemical Engineering**, v. 60, p. 182-196. 2014. <http://dx.doi.org/10.1016/j.compchemeng.2013.08.012>

NICOUD, R. M. **Chemistry Today**, v. 34, n. 4. p- 12-17. 2016.

O'DONOVAN, P.; LEAHY, K.; BRUTON, K.; O'SULLIVAN, D. T. J. An industrial big data pipeline for data-driven analytics maintenance applications in large-scale smart manufacturing facilities. **Journal of Big Data**, p. 2-25. 2015.

ORDUÑA-MALEA, E.; AYLLÓN, J. M.; MARTÍN-MARTÍN, A., DELGADO LÓPEZ-CÓZAR, E. Methods for estimating the size of Google Scholar. **Scientometrics**, v. 104 n. 3, p. 931-949. 2015.

PAN, M.; SIKORSKI, J.; KASTNER, C. A.; AKROYD, J.; MOSBACH, S.; LAU, R.; KRAFT, M. Applying Industry 4.0 to the Jurong Island Eco-industrial Park. **Energy Procedia**, v. 75, p. 1536-1541. 2015. <https://doi.org/10.1016/j.egypro.2015.07.313>

PASSOS, F.U.; ARAGÃO, I.R. Melhorias operacionais de processos contínuos acompanhadas por ferramentas da produção enxuta – estudo de caso em uma petroquímica brasileira. **REGE – Revista de Gestão**, v. 20, n. 2, p. 267-282, 2013.

PICKETT, L. Industry 4.0 and the NDT sea change. **Quality (BNP Media)**, v. 55, n. 4. 2016.

PITBLADO, R. Global process industry initiatives to reduce major accidents hazards. **Journal of Loss Prevention in the Process Industries**, v. 24, p. 57-62. 2011.

QIAN, F.; ZHONG, W.; DU, W. Fundamental Theories and Key Technologies for Smart and Optimal Manufacturing in the Process Industry. **Engineering**, v. 3, n. 2, p. 154-160. 2017. <http://dx.doi.org/10.1016/J.ENG.2017.02.011>

QIN, S. J. Process data analytics in the era of big data. **AIChE Journal**, v. 60, n. 9, p. 3092-3100. 2014. <https://doi.org/10.1002/aic.14523>

RAGAB, A.; EL-KOUJOK, M.; POULIN, B.; AMAZOUZ, M.; Fault diagnosis in industrial chemical processes using interpretable patterns based on Logical Analysis of Data. **Expert Systems with Applications**, v. 95, p. 368 – 383. 2018. <https://doi.org/10.1016/j.eswa.2017.11.045>.

RATHINASABAPATHY, R.; ELSASS, M. J.; JOSEPHSON, J. R.; DAVIS, J. F. A smart manufacturing methodology for real time chemical process diagnosis using causal link assessment. **AIChE Journal**, v. 62, n. 9, p. 3420-3431. 2016. <https://doi.org/10.1002/aic.15403>

REIS, M. S.; KENETT, R. Assessing the Value of Information of Data-Centric Activities in the Chemical Processing Industry 4.0. **Process Systems Engineering**, Vol. 00, n. 0, 2018.

REITZE, A.; JÜRGENSMEYER, N.; LIER, S.; KOHNKE, M.; RIESE, J.; GRÜNEWALD, M.; Roadmap for a Smart Factory: A Modular, Intelligent Concept for the Production of Specialty Chemicals. *Angew. Chem. Int. Ed*, v. 57, p. 4242– 4247. 2018. <https://doi.org/10.1002/anie.201711571>

ROBERGE, D. M.; ZIMMERMANN, B.; RAINONE, F.; GOTTSPONER, M.; EYHOLZER, M.; KOCKMANN, N. Microreactor Technology and Continuous Processes in the Fine Chemical and Pharmaceutical Industry: Is the Revolution Underway?. **Org. Process Res. Dev**, v. 12, n. 5, p. 905-910. 2008.

ROCKART, J.F. Chief Executives define their own data needs. **Harvard Business Review**, pp. 81-92, 1979.

RUSSOMANO, V. H. **Planejamento e Acompanhamento da Produção**. São Paulo: Pioneira. 1979.

SADIKU, M. N. O.; WAND, Y.; CUI, S.; MUSA, S. M. INDUSTRIAL INTERNET OF THINGS. *International Journal of Advances in Scientific Research and Engineering*, v. 3, n. 11. 2017. <http://dx.doi.org/10.7324/IJASRE.2017.32527>

SCHLEICH, B.; ANWER, N.; MATHIEU, L.; WARTACK, S. Shaping the digital twin for design and production engineering. *CIRP Annals*, v. 66, n. 1, p. 141-144. 2017.  
SCHLÖGL, R. **Catalysis 4.0**. *ChemCatChem*, v. 9, n. 4, p. 533-541. 2017.

SEIDER, W. D.; SEIDER, J. D.; LEWIN, D. R. **Product and Process Design Principles**. 3rd Edition. John Wiley & Sons. Inc., Hoboken, 2010.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. **Understanding Machine Learning: From Theory to Algorithms**. Cambridge: Cambridge University Press. 2014.

SHU, Y.; MING, L.; CHENG, F.; ZHANG, Z.; ZHAO, J. Abnormal situation management: Challenges and opportunities in the big data era. *Computers & Chemical Engineering*, v. 91, p. 104-113. 2016.  
<http://dx.doi.org/10.1016/j.compchemeng.2016.04.011>

SIKORSKI, J. J.; HAUGHTON, J.; KRAFT, M. Blockchain technology in the chemical industry: Machine-to-machine electricity market. *Applied Energy*, v. 195, p. 234-246. 2017.  
<http://dx.doi.org/10.1016/j.apenergy.2017.03.039>

SOARES, A., SOLTANI, E., & LIAO, Y.-Y. (2017). The influence of supply chain quality management practices on quality performance: an empirical investigation. *Supply Chain Management: An International Journal*, v. 22, n. 2, p. 122–144.

SQUIRE, R.; SONG, H. Cyber-physical systems opportunities in the chemical industry: A security and emergency management example. *Process Safety Progress*, v. 33, n. 4, p. 329-332. 2014.  
<https://doi.org/10.1002/prs.11676>

STOCK, T.; SELIGER, G. Opportunities of Sustainable Manufacturing in Industry 4.0. *Procedia CIRP*, v. 40, p. 536-541. 2016.

SUN, B.; JÄMSA-JOUNELA, S-L.; TODOROV, Y.; OLIVIER, L. E.; CRAIG, I. K. Perspective for equipment automation in process industries. *IFAC-PapersOnLine*, v. 50, n. 2, p. 65-70. 2017.  
<https://doi.org/10.1016/j.ifacol.2017.12.012>

TOLEDO, J. C.; FERRO, J. R.; TRUZZI, O. M. S. Indústrias de processo contínuo: novos rumos para a organização do trabalho. *Revista de Administração de Empresas*, v. 26, n. 1, p. 103-105. 1986.

THIENEN, S.; CLINTON, A.; MAHTO, M.; SHIDERMAN, B. **Industry 4.0 and the chemicals industry**. Deloitte University Press. 2016.

THOBEN, K.; WIESNER, S.; WUEST, T. “Industrie 4.0” and Smart Manufacturing – A Review of Research Issues and Application Examples. *International Journal of Automation Technology*, v. 11, n.1, p. 4-16. 2017.

UTZ, F.; NEUMANN, C.; TAFRESCHI, O. How to Discover Knowledge for Improving Availability in the Manufacturing Domain? IN: **Proceedings of the 51st Hawaii International Conference on System Sciences**, 2018.

VENKATASUBRAMANIAN, V. DROWNING IN DATA: Informatics and modeling challenges in a data-rich networked world. **AIChE Journal**, v. 55, n. 1, p. 2-8. 2008.<https://doi.org/10.1002/aic.11756>

VINUTO, J. A amostragem em bola de neve na pesquisa qualitativa: um debate em aberto. **Temáticas**, v. 44. 2014.

WANG, Q., ZHAO, X., HUANG, J., FENG, Y., SU, J., LUO, Z. 2017. **Addressing Complexities of Machine Learning in Big Data: Principles, Trends and Challenges from Systematical Perspectives**. No Prelo. Submetido em 2017. <https://doi.org/10.1016/j.procs.2017.08.052>

WASSICK, J. M. Enterprise-wide optimization in an integrated chemical complex. **Computers & Chemical Engineering**, v. 33, n. 12, p. 1950-1963. 2009.<https://doi.org/10.1016/j.compchemeng.2009.06.002>

WINDMANN, S. et al. Big Data Analysis of Manufacturing Processes. **Journal of Physics: Conference Series**, v. 659, p. 1-12. 2015.<https://doi.org/10.1088/1742-6596/659/1/012055>

WOODWARD, J. **Organização Industrial: Teoria e Prática**. São Paulo: Atlas. 1977.

YAO, L.; GE, Z. Big Data quality prediction in the process industry: A distributedparallel modeling framework. **Journal of Process Control**. Vol. 68, p. 1-13. 2018.

YDSTIE, B. E. New vistas for process control: Integrating physics and communication networks. **AIChE Journal**, v. 48, n. 3, p. 422-426. 2002.

YAN, H.; HUA, Q.; WANG, Y.; WEI, W.; IMRAN, M. Cloud robotics in Smart Manufacturing Environments: Challenges and countermeasures. **Journal of Computers and Electrical Engineering**, v. 63, i. 6, p. 56-65. 2017.

YANG, G.; Data Acquisition Technology of Chemical Equipment Based on Wireless Sensor Network. **Chemical Engineering Transactions**, v. 66. 2018.<https://doi.org/10.3303/CET1866158>.

YUAN, Z.; QIN, W.; ZHAO, J. Smart Manufacturing for the Oil Refining and Petrochemical Industry. **Engineering**, v. 3, n. 2, p. 179-182. 2017.<http://dx.doi.org/10.1016/J.ENG.2017.02.012>

ZHANG, Z.; Chen, D.; FENG, Y.; YUAN, Z.; CHEN, B.; QIN, W.; ZOU, S.; QIN, S.; HAN, J., A strategy for enhancing the operational agility of petroleum refinery plant using case based fuzzy reasoning method. **Computers and Chemical Engineering**, v. 111, p. 27-36. 2018.<https://doi.org/10.1016/j.compchemeng.2017.12.021>.

ZHOU, L. et al. **Towards a novel ontological infrastructure for chemical process simulation and optimization in the context of eco-industrial parks**. Cambridge Centre for Computational Chemical Engineering. 2017.

ZUEHLKE, D. SmartFactory—Towards a factory-of-things. **Annual Reviews in Control**, v. 34, p. 129–138. 2010. <https://doi.org/10.1016/j.arcontrol.2010.02.008>

**APÊNDICE A – ARTIGO SUBMETIDO PARA O PERIÓDICO *COMPUTERS & CHEMICAL ENGINEERING***

**CRITICAL SUCCESS FACTORS FOR IMPLEMENTING INDUSTRY 4.0 TECHNOLOGIES IN THE CONTINUOUS PROCESS CHEMICAL INDUSTRY**

Paulo Henrique Amorim Santos<sup>a</sup>, Izabel Cristina Zattar<sup>a,\*</sup>, Robson Seleme<sup>a</sup>

<sup>a</sup> Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal do Paraná, Av. Coronel Francisco Heráclito dos Santos, 210, Curitiba, Brasil.

\*Corresponding author. E-mail address: [izabel.zattar@gmail.com](mailto:izabel.zattar@gmail.com)

**ABSTRACT**

Industry 4.0 technologies provide great improvements in the productive environment of the continuous chemical industries. The availability of a large amount of real-time data allows the integration of unit operations and process intensification, providing increased profitability, fault predictive diagnostics, and assisting with safety management and production sustainability. However, the industry presents specific obstacles in deploying 4.0 technologies because of its intrinsic complexity.

The objective of this article is to discuss the sector-specific difficulties and the Critical Success Factors when implementing Industry 4.0 technologies. In order to achieve this objective, a comprehensive literature review was carried out, in which more than 10,000 documents were analyzed.

Among the emerging necessities identified for the sector, the need to simplify complex systems and intensify operations is highlighted. The literature also converges on the urgency for developing reliable systems for adverse event management, as well as the creation of health, safety and environmental assessment models.

**Keywords:** Industry 4.0; Continuous Processes Chemical Industry; Abnormal Events Management; Chemical Processes Safety; Chemical Plant integration.

**Declaration of interest:** None.

## INTRODUCTION

The fourth industrial revolution is much more than a trend for automation. It consists of a set of new manufacturing practices that utilize the higher communication capacity and storage of large amounts of data, enabled by current technological advances. In this way, Industry 4.0 aims to develop models, methods and tools appropriate to the manufacturing industries (Thoben et al., 2017) and is, therefore, characterized by the advancement of interactions between people, machines and resources, and the consequent decentralization of productive processes (Hermann et al., 2016).

The new technologies that accompany Industry 4.0 are based on network communication, where a large amount of information (Big Data) is generated as a virtual copy of the production plant. The availability of information throughout the production system allows for new ways of conducting industry management. Cyber-physical systems (CPS) monitor the physical processes in real time, through sensors, actuators and simulators, increasing the efficiency of the process through decentralized decision-making (Hermann et al., 2016). In addition, there is a communicative integration of elements of the production system (called the Internet of Things, or IoT) synchronized with the data processing generated by the CPS (Kagermnn et al., 2013). Industry 4.0 proposes the adoption of an infrastructure capable of integrating the manufacturing intelligence of a production line in real time (Kumar et al., 2015).

Although Industry 4.0 still needs to prove its benefits to society (Kotynkova, 2017), the number of recent publications on the subject are an indication of its acceptance in the industry. This also shows academia's interest in this promising evolution of the industrial environment. Deploying Industry 4.0, however, is often a complex project, presenting several obstacles that are characteristic of each manufacturing sector (Chiang et al., 2017).

The continuous chemical industry presents great potential for improvement in the new perspectives of Industry 4.0. The safe and efficient operation of plants requires constant monitoring of thousands of process variables and the current management of abnormal situations is still attributed to human operators (Shu et al., 2016). For the continuous chemical industry, therefore, the goal of Industry 4.0 is not only to maximize profit but also to reduce accidents and preserve the environment (Christofides et al.,

2007). Recent work, like that of Chiang et al. (2017) and Ji et al. (2016), prove specific benefits to the sector in the use of new technologies such as Big Data and CPS. Given current optimistic projections, it may seem surprising that there is so little literature reconciling these new technologies to the chemical industry (Chiang et al., 2017). However, this is due to the fact that in the continuous process chemical industry there are supply chain interface obstacles, which limit the potential of Industry 4.0 (Schlögl, 2017). In this sense, this article is guided by the following research question: "*What are the difficulties and Critical Success Factors related to the deployment of Industry 4.0 technologies in the continuous process chemical industry?*"

## **MATERIALS AND METHODS**

To create a select sample of papers on Industry 4.0 technologies in the continuous process chemical industry, the databases were first defined and then the search terms were selected. The chosen databases were Google Scholar® and the Scopus database. All searches were limited to results in English, Portuguese and Spanish, with no limitation on the year of publication. The definition of search terms (Table 1) was based on the theme of study, associating each sector of the continuous process chemical industry with the industry 4.0 technologies.

The searches were conducted using the main search term "Chemical Industry" and the cross-reference of the 25 chemical industry sectors with 19 terms commonly related to Industry 4.0 technologies; this resulted in 475 search combinations.

From the two databases, a total of 10,173 documents were considered for alignment analysis. From this initial sample, papers whose language was incompatible with the adopted criterion were disregarded. Also excluded were publications whose title and abstract were not related to the theme. As a result, 40 papers were obtained that effectively related Industry 4.0 technologies to the continuous chemical industry.

Table 1 - Search terms used in the research.

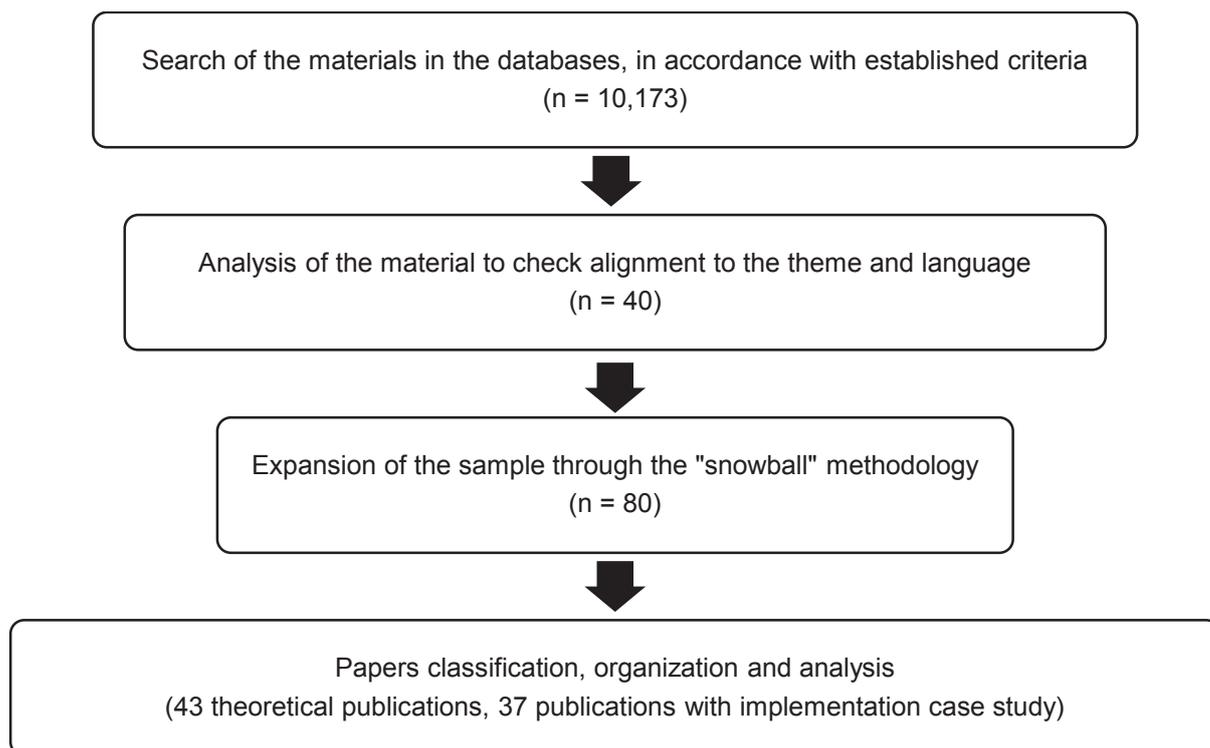
<b>Main Search Term</b>	<b>Sectors</b>	<b>Technologies</b>
<i>"Chemical Industry"</i>	<i>"Fertilizers"</i>	<i>"Big Data"</i>
	<i>"Industrial gas"</i>	<i>"Internet of Things"</i>
	<i>"Petrochemical"</i>	<i>"Industrial Internet of Things"</i>
	<i>"Plastic industry"</i>	<i>"Internet of Services"</i>
	<i>"Resins"</i>	<i>"Cloud Computing"</i>
	<i>"Rubber"</i>	<i>"Cyber-Physical Systems"</i>
	<i>"Elastomer"</i>	<i>"Additive Manufacturing"</i>
	<i>"Synthetic fiber"</i>	<i>"Machine Learning"</i>
	<i>"Artificial fiber"</i>	<i>"Augmented Reality"</i>
	<i>"Pesticides"</i>	<i>"Virtual Factory"</i>
	<i>"Soap"</i>	<i>"Digital Twins"</i>
	<i>"Detergents"</i>	<i>"Machine-to-Machine"</i>
	<i>"Cleaning products"</i>	<i>"Human Machine Interaction"</i>
	<i>"Cosmetics"</i>	<i>"Radio Frequency Identification"</i>
	<i>"Perfume"</i>	<i>"Smart Cyber Security"</i>
	<i>"Hygiene"</i>	<i>"Blockchain"</i>
	<i>"Paints"</i>	<i>"Smart Manufacturing"</i>
	<i>"Varnish"</i>	<i>"Industry 4.0"</i>
	<i>"Polishes"</i>	<i>"Smart Factory"</i>
	<i>"Adhesive"</i>	
<i>"Explosive"</i>		
<i>"Solvent"</i>		
<i>"Dye"</i>		
<i>"Chlorine"</i>		
<i>"Alkali"</i>		

SOURCE: The author (2018).

These papers were then subjected to the "snowball" procedure, which is a form of sample construction using bibliographic reference chains and is especially useful for

studying certain areas that are difficult to access (Vinuto, 2014). Thus, from the extension of the sample through references, it was possible to gather a final selection of 80 articles relevant to the theme. Figure 1 summarizes the steps taken to construct the final sample of articles considered in the literature review.

Figure 1 - Procedure adopted to construct the final sample of articles studied in the literature review



Source: The Authors (2018).

From the final sample, each publication was read in order to identify the implementation difficulties and critical success factors related to the implementation of the Industry 4.0 technologies in the continuous chemical industry.

## THEORY

The following are the subjects that underlie this work. For the theoretical reference survey, the definitions of continuous process chemical industries and of Industry 4.0 and its technologies are discussed.

## CHARACTERIZATION OF CONTINUOUS PROCESS CHEMICAL INDUSTRIES

Many papers corroborate the characterization of the continuous processes. Woodward (1977) defines them as the standardization of products and with minimally interrupted production. For Buffa (1979), there is extreme inflexibility of equipment and resources in a continuous process. Russomano (1979) argues that, in this type of production, the set up time is very small when compared to the time spent in the operation. For Toledo et al. (1986), the essential characteristic to the logical understanding of operation of a continuous process is the non-direct dependence between the rate of work and productivity. Fransoo and Rutten (1994) present seven characteristics of the continuous processes:

- 1) High production speed, little human labor;
- 2) Clear capacity determination, one routine for all products, low flexibility;
- 3) Low product complexity;
- 4) Low added value;
- 5) Stopping times cause great impact;
- 6) Small number of production steps;
- 7) Limited number of products.

Toledo et al. (1986) state that the continuous term, that is commonly used, has different meanings. The authors argue that, for the chemical industry, the term is associated with a constant flow process, as opposed to the batch process. According to the authors, another definition (presented by the World Batch Forum (WBF)) is that continuous processes occur when a liquid, gaseous or particulate stream moves in flux and there are no discrete countable elements (Hawkins et al., 2010). Borges and Dalcol (2002) also present a definition of continuous industries that adapts very well to the reality of the chemical industries. The authors argue that the equipment is interconnected by pipes, thereby differing from discrete systems, where several stations are distributed in sheds. Thus, the external appearance of these industries is that of a single, large piece of equipment. In addition, continuous process industry flows have dynamic compositions and concentrations, given the complex chemical reactions, which are influenced by numerous process variables.

Borges and Dalcol (2002) affirm that the high amount of capital invested in the plants and the intrinsic nature of the processes result in uninterrupted work, which, together with the low processing time, results in large-scale production. After the start of continuous production, it becomes very difficult to distinguish between the raw material, the inputs and the products. An ongoing process has the advantage of accomplishing its steps with the potential for the use of automation and advanced process control, reducing the cost of the work. In addition, continuous processes also have stabilized quality and low incidence of loss of production batches (ROBERGE et al., 2008). Due to the advantages of continuous processes, most chemical, petrochemical, food and consumer products are continuously manufactured today (Engisch and Muzzio, 2016).

### **Technologies geared towards Industry 4.0**

Industrial innovation is often driven by competitiveness and increased demand, requiring faster, more efficient and more sustainable processes. In recent years, transmission, storage and data organization technologies have substantially improved production efficiency. This is done by combining resources, machinery and information, creating an intelligent manufacturing system: Industry 4.0 (Ji et al., 2016).

For Davis et al. (2012), Industry 4.0 is a platform designed for technological integration. Through a macroscopic vision of the company and the supply chain, it creates a new paradigm in process optimization and provides greater returns on future investment. Industry 4.0 allows the use of a new intelligence that removes constraints on the decision-making process, given information availability (Davis et al., 2012).

Through the combination of advanced manufacturing techniques and digital technologies, Industry 4.0 allows the development of production systems in ways that promote the integration of its elements. With a more mature view on the technological potential of Industry 4.0, Hermann et al. (2016) define it as one whose CPS communicates through the IoT to aid in the execution of human and mechanical tasks. This improvement in manufacturing intelligence allows managers to create more reliable and useful data, allowing the creation of more accurate decision-making tools with less response time. For Zhang et al. (2018), Industry 4.0 focuses on the connection of productive processes through their horizontal and vertical integration. Thus, the technologies promote operational agility and provide industry with the ability

to rapidly detect and adapt to internal and external disturbances. Table 2 presents the main technologies of Industry 4.0 with their respective definitions.

Table 2 - Definitions of industry 4.0 technologies

<b>Technology</b>	<b>Definition</b>
<i>Big Data</i>	Extraction of value from large volumes and varieties of data, with high-speed capture, identification and analysis. (Feblowitz, 2012).
<i>Internet Of Things</i>	All types of sensor devices that are connected to the internet, forming a smart and manageable identification network. (Li and Liu, 2010).
<i>Industrial Internet of Things</i>	Machines, computers and people enabling intelligent industrial operations using advanced data analysis. (Sadiku et al., 2017).
<i>Internet of Services</i>	Services that have the capability to be hosted on leading-edge machines to provide wireless Internet resources to any supported physical object with communication capability. (Balakrishnan and Sangaiah, 2016).
<i>Cloud Computing</i>	Internet-based service that allows the use and sending of resources through a virtual server. (Hao et al., 2015).
<i>Cyber-Physical Systems</i>	Synergy between computing, communication and control with physical components; this interaction is superior to today's data automation and acquisition. (Squire and Song, 2014).
<i>Additive Manufacturing</i>	Also known as 3D printing, it involves the fabrication of a part by depositing the material layer by layer. (Conner et al., 2014).
<i>Machine Learning</i>	Automated detection of patterns in data that may be significant. (Shalev-Shwartz and Ben-David, 2014).
<i>Augmented Reality</i>	A technology that overlaps virtual objects (augmented components) to the real world. (Akçayir and Akçayir, 2017).
<i>Virtual Factory</i>	Combination of Information Technology related to manufacturing based on digital manufacturing technology. (Choi et al., 2015).
<i>Digital Twins</i>	Bi-directional relationship between a physical artifact and the set of its virtual models. (Schleich et al., 2017).
<i>Machine-To-Machine</i>	Ability of industrial components to communicate with each other. (Sikorski et al., 2017).
<i>Interação Humano-Máquina (Human Machine Interaction)</i>	Interaction and communication between human users and a machine, forming a dynamic technical system. (Johannsen, 2009).

<i>Radio Frequency Identification</i>	Use of radio waves for data transmission, if using tags and readers, for the purpose of identifying and tracking objects. (AJAMI; RAJABZADEH, 2013).
<i>Blockchain</i>	A segregated electronic database, whose rules for sharing and updating information are subject to definition. (SIKORSKI et al., 2017).
<i>Smart Cyber Security</i>	Intelligent anti-malware technologies that detect sneaky malicious software and combat them. (HIMSS ASIA PACIFIC, 2016).

SOURCE: The author (2018).

The complexity of Industry 4.0 technologies, however, results in a difficulty in establishing a standard procedure for its application. The full potential development of Industry 4.0 still requires efforts both in the integration and in the coordination of each technology (Ahuett-Garza and Kurfess, 2018).

## RESULTS AND DISCUSSION

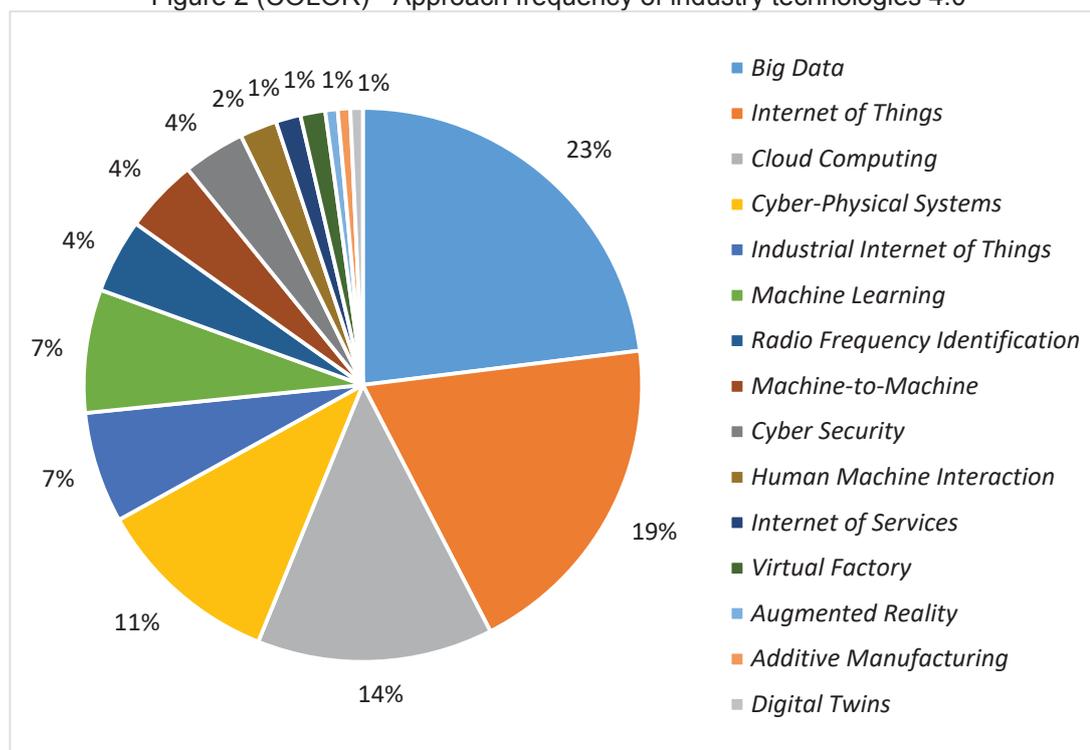
From the sample of articles found in the literature it was possible to identify theoretical articles on the perspectives of Industry 4.0 in the continuous chemical industry and also case studies with practical applications. First, the theoretical articles are discussed, which allow an analysis of the development of Industry 4.0 in the sector. Next, analyses of deployment cases are presented, which provide a more realistic view of the particular needs of the continuous chemical industry. Then, the challenges of deploying 4.0 technologies common to all companies as well as those specific to the continuous process chemical industries are discussed. Finally, the general and sector-specific Critical Success Factors are discussed.

### Theoretical work on the technologies of Industry 4.0 in the continuous chemical sector

For each reviewed article (whether of a theoretical or practical nature), a search was made to identify the main 4.0 technologies relating to the continuous process chemical industries. The study revealed a greater trend of publications mentioning Big Data, the Internet of Things, Cloud Computing and Cyber-Physical

Systems (Figure 2). Together, these four technologies account for 67% of the approaches.

Figure 2 (COLOR) - Approach frequency of industry technologies 4.0



SOURCE: The author (2018).

An analysis of theoretical publications was carried out, which reaffirmed the importance of the development of these four technologies for the continuous chemical industry. For this sector, the need for new computational resources dedicated to the control process was already predicted by Ydstie (2002), who believed that standardization in the communication system and simulation as a predictive analytical tool would be fundamental for the new information technologies. The author is responsible for the publication of the first identified paper relating to the integration of physics and communication networks as a future perspective in the control of chemical processes. Since then, the number of publications has been increasing and the 4.0 revolution in chemical manufacturing, has been gaining notoriety. Three years after the work of Ydstie, Grossmann (2005) published an article that reached a greater visualization of the academic environment. The author identified the benefits to companies emerging from the interface of chemical engineering with operational research. Moreover, he asserted that the global market scenario would require new manufacturing technologies to preserve competitiveness.

With reference to both works, Christofides et al. (2007) continued the research in collaboration with James Davis, who would become the most important researcher in this area in the next few years. In "*Smart Plant Operations: Vision, Progress and Challenges*" the authors identified recent developments in process control, optimization and monitoring systems. In their conclusions, the authors emphasized the need for a coordinated research plan in this area and highlighted the lack of collaboration between academia and industry.

In 2008, a workshop on manufacturing processes was held, sponsored by the National Science Foundation (NSF) and the Smart Process Manufacturing Engineering Virtual Organization (SPM-EVO). The purpose of the workshop was to foster further collaboration, focusing on the study of Industry 4.0 and creating a rationale for further research (Davis et al., 2008).

After a period of few specific publications on Chemical Industry 4.0, Davis and Edgar (2012) published "*Smart manufacturing, manufacturing intelligence and demand-dynamic performance*" on the subject, with the help of other collaborators. Over 30% of the subsequent work on Industry 4.0 in the chemical industry used this article as a bibliographical reference. It presented a more mature basis for concepts and definitions, with a greater knowledge about the potential and limitations of communication technologies in manufacturing environments. Davis and Swink (2014) also addressed systems that encompass commercial dimensions in comprehensive systems. With the help of other collaborators, the authors published an annual review on chemical and biomolecular engineering in 2015, focusing on the architecture and development of information technology infrastructure sought by Industry 4.0. This article is widely referenced by more modern authors.

Among the most recent publications, Hao et al. (2015) elaborate on a platform for integrating information on IoT and Cloud Computing technologies in the chemical industry. Thienen et al. (2016) evaluated Industry 4.0's main applications in the different stages of chemical production. Inaba (2016) presented an integration analysis of a refinery in a petrochemical complex. The study concluded on the need for a Big Data and IoT system to improve productivity and efficiency. García et al. (2017) proposed vertical integration, which would allow access to data at lower cost. Khare and Chin (2017) published the first identified work that used the term "Smart Chemical Industry". In the paper, the authors discussed the benefits of using efficient data collection as a source of knowledge. Wang et al. (2017) focussed on oil and gas

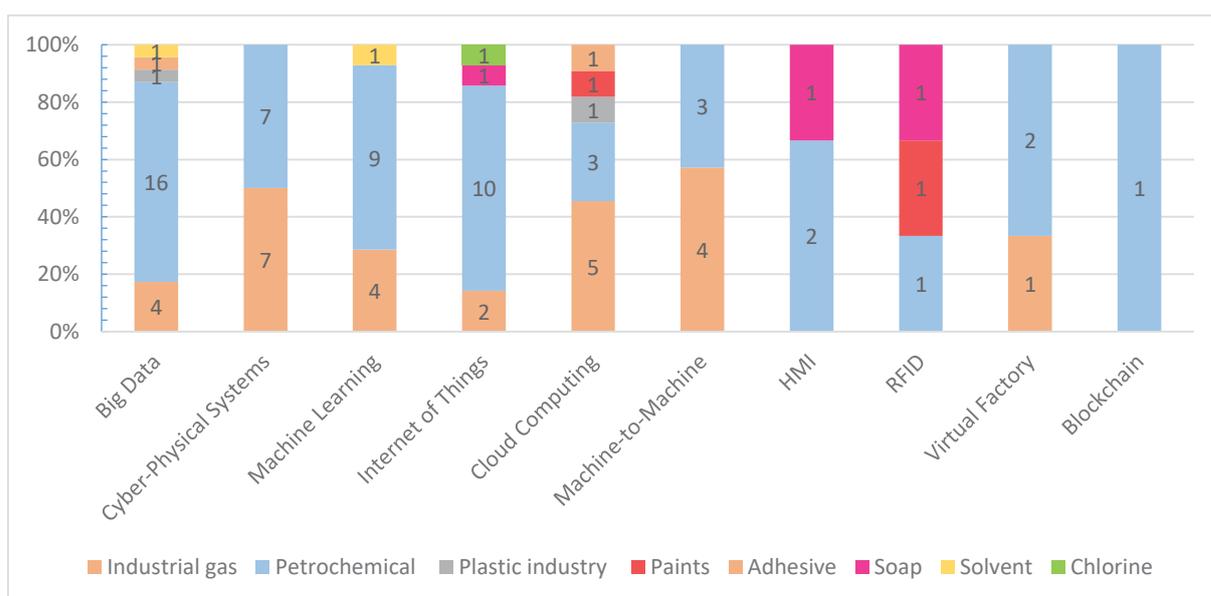
storage and transportation facilities. The authors researched risk analysis and created a new management model from Big Data monitoring. Ge et al. (2017) provided a review of data mining and analysis applications in the process industry over the last few decades. He et al. (2017) reviewed the state-of-the-art technology of cyber-physical systems. In addition, the authors explored the potential of sensors and IoTs for fabrication.

### Cases of deployment of Industry 4.0 technologies in the continuous chemical industry

In addition to the theoretical and predictive works on the technologies coming from Industry 4.0, the literature identified cases of practical application of these technologies in equipment, simulations or industrial plants in the chemical sector.

An initial analysis of this sample showed the intersection of the practical approaches of each technology with the respective investigated segments of the continuous chemical sector. The results can be observed in Figure 3.

Figure 3 (COLOR) - Application of industry technologies 4.0 in the segments of the continuous chemical industry



SOURCE: The author (2018).

Big Data technology is the one with the greatest number of industrial applications, due to the companies' need to manipulate a large number of physico-

chemical variables that characterize the sector. It is possible to observe a predominance of the use of Big Data, Machine Learning and IoT in the petrochemical segment and of Cloud Computing and Machine-to-Machine in the production of industrial gases. CPS technology has applications in both of these segments. Big Data and Cloud Computing are also found in a greater number of different segments. Other, less frequent, technologies, such as RFID and HMI, have already been applied in the industrial saponaceous manufacturing sector.

The predominance of practical applications of Big Data, IoT, Cloud Computing and CPS technologies is consistent with the proposals found in the analysis given in the theoretical publications and this is evidence of the need for the continuous chemical sector to develop computational tools for the transmission, storage and analysis of large amounts of data.

In 2009, Greg Martin published the first work related to the chemical industry's application of 4.0 technologies: an analysis of the advantages of wireless internet technology in the petrochemical industry. The use of wireless internet allows for the availability of real-time information, new maintenance tools for equipment and improvements in security through remote access (Martin, 2009). The next application corresponds to Chang et al. (2011) implementing a human-machine interface, based on a small scale microprocessor and programmable logic and used in a biomass process, providing excellent supervision capacity.

Davis et al. (2012) provided examples of applications of intelligent manufacturing in processes and supply chains. One of these examples was ExxonMobil, which built an outstanding information infrastructure in several of its units. Focusing on communication, management and security, the company made gains in planning its product portfolio.

Natarajan et al. (2012) proposed a system called OntoSafe, that provides the possibility of managing abnormal situations. In 2014, the authors brought forward a proposal to apply this multi-agent architecture for the supervision of large-scale plants. Another work in the context of management of abnormal situations in the chemical industry was that of Rathinasabapathy et al. (2016), which developed a qualitative diagnostic methodology called the Causal Link Assessment (CLA).

More recent publications include Belaud et al. (2014), which introduced a platform for the simulation, engineering, 3D visualization and management of Big Data for the chemical industry. Qin (2014) is widely quoted and defined Big Data technology,

describing its use and providing perspectives for the chemical process industry. Blackburn et al. (2015) proposed a model of demand forecasting based on Big Data which was superior to statistical methods, based on historical data from the BASF chemical industry. Squire and Song (2014) presented two cases of successful implementation of cyber-physical systems in the chemical industry. Responding to technological progress, Ji et al. (2016) discussed an intelligent chemical industry model based on CPS. Zhang et al. (2018) presented a strategy to improve the operational agility of a refinery from Big Data and Fuzzy Logic.

Works regarding the petrochemical industry, in particular, were published in 2016 and 2017. Yuan et al. (2017) and Hassani et al. (2017) provided different views on the application of 4.0 technologies. Yuan et al. (2017) gave examples of their application and Hassani et al. (2017) identified the impact of technological innovation on the oil industry (such as cost reduction, time wasting reduction and efficiency gains) through a literature review. In another line of research, Hamzeh (2016) investigated different methods of Big Data analysis used in the oil and gas industry, such as *Hadoop*®, *Microsoft*® *MURA*, *IBM*® *InfoSphere*® and *Oracle*®.

Also noteworthy is Kumar's doctoral thesis (2016) on methane reform, it being a complete work, in theory and experimentation. The work arises from Korambath et al. (2014), where the authors developed a test prototype for a furnace temperature control model, by combining Cloud Computing and online service technologies. In Kumar's thesis (2016), a control survey was presented on the temperature profile in an industrial methane reforming furnace. Infrared sensors that produce a large amount of data were used for this purpose. The management and utilization of this Big Data provided several positive results, including the implementation and monitoring of an Industry 4.0 computing infrastructure. The dissemination of his work with the collaboration of other researchers (mainly Michael Baldea and Thomas Edgar) inspired the publication of other articles on the subject. These resulted in a framework of sensors and models of Computational Fluid Dynamics (CFD) for the control of hydrogen production trials (Kumar et al., 2016c), a prediction model of furnace temperature distribution based on fuel (Kumar et al., 2016b) and the configuration design formulations for the improvement of furnace temperature distribution and valve actuation (Kumar et al., 2016a). The technologies studied in his work concern Big Data, Cloud Computing, M2M, and a Virtual Factory. Kumar et al. (2017) was also published regarding the reduction of the energy cost of the process.

Of all the published works, two stand out because of the possibilities of reducing environmental damage from chemical production through the use of Industry 4.0 technology (Pan et al., 2015). Pan et al. (2015) proposed the implementation of Industry 4.0 in the design and optimization of Jurong Island's eco-industrial park in Singapore. The work of Kleinlanghorst (2016) introduced J-Park Simulator (JPS), an eco-industrial virtualization that combines Machine-to-Machine (M2M) and mathematical modeling concepts to generate a design platform for eco-industrial parks.

Sikorski, Houghton and Kraft (2017) are the only authors to explore blockchain technology applications, proposing de-centralization as a safety measure for Machine-to-Machine (M2M) interactions.

Table 3 presents the relationship between the publications describing practical cases and the respective applied Industry 4.0 technologies, identifying the authors and the year of each publication investigated.

Table 3 – Industry 4.0 technologies in the continuous processes chemical industry.

<b>Technology</b>	<b>Author/ Year</b>
<i>Internet of Things</i>	Martin, 2009; Wassick, 2009; Zuehlke, 2010; Davis et al., 2012; Chung et al., 2014; Kumar et al, 2015-2017; Kleinlanghorst et al., 2016; Yuan et al., 2017; Hassani et al., 2017; Liu et al., 2017; García et al., 2017; Sikorski et al., 2017
<i>Big Data</i>	Wassick, 2009; Gao et al., 2009; Davis et al., 2012; Natarajan et al., 2012; Belaud et al., 2014; Blackburn et al., 2015; Windmann et al., 2015; Pan et al., 2015; Kumar et al., 2015, 2016 (a; b; c; d), 2017; Ji et al., 2016; Shu et al., 2016; Hamzeh, 2016; Rathinasabapathy, 2016; Korambath et al., 2016; Yuan et al., 2017; Hassani, et al. 2017; Chiang, et al., 2017; Geng et al., 2017; Leeuw, 2017; Zhang et al., 2018
<i>Cyber-Physical Systems</i>	Wassick, 2009; Davis et al., 2012; Natarajan et al., 2012; Natarajan; Srinivasan, 2014; Squire; Song, 2014; Pan et al., 2015; Kumar et al., 2015, 2016 (a; b; c; d), 2017; Ji et al., 2016; Garcia et al., 2017
<i>Cloud Computing</i>	Belaud et al., 2014; Kumar et al., 2015, 2016 (a; b; c; d), 2017; Shu et al., 2016; Korambath et al, 2016; Yuan et al. 2017; Chiang et al., 2017; Leeuw, 2017; Luo et al., 2017

<i>Radio-Frequency Identification</i>	Zuehlke, 2010; Chung et al., 2014; Luo et al., 2017
<i>Human Machine Interface</i>	Zuehlke, 2010; Chang et al., 2011; Chung et al., 2014; Rathinasabapathy, 2016
<i>Machine Learning</i>	Gao et al., 2009; Natarajan et al., 2012; Natarajan; Srinivasan, 2014; Windmann et al., 2015; Kumar et al., 2015, 2016 (a; b; c; d), 2017; Kleinlanghorst et al., 2016; Korambath et al., 2016; Geng et al., 2017; Zhang et al., 2018; Ragab et al., 2018
<i>Machine-to-Machine</i>	Kumar et al., 2015, 2016 (a; b; c; d), 2017; Kleinlanghorst et al., 2016; Garcia et al., 2017; Sikorski et al., 2017; Ragab et al., 2018
<i>Virtual Factory</i>	Kumar et al., 2015, 2016 (a; b; c; d), 2017; Kleinlanghorst et al., 2016; Korambath et al., 2016
<i>Blockchain</i>	Sikorski; Haughton; Kraft, 2017

SOURCE: The author (2018).

Through the literature, it is possible to identify cases of the application of Big Data in conjunction with Machine Learning technology (Kumar et al., 2015). This is justified by the need for the continuous process chemical industry to automate the management of the large amount of physico-chemical data collected during the process. In addition, the two technologies can be used to ensure better safety protocols for adverse events (Natarajan and Srinivasan, 2014). In order to better understand the particularities of the sector, the difficulties of implementing common 4.0 technologies for all companies and specific difficulties in the continuous chemical industry are presented below.

### **General difficulties in the Implementation of Industry 4.0**

According to Helu et al. (2015), the implementation difficulties of Industry 4.0 technologies can be grouped around resource and training requirements, cyber security risks, physical characteristics of the manufacturing environment, and standardization of software interfaces. For von Knop (2017) and Gezdur and Bhattacharjya (2017), the deployment of 4.0 technologies demands cost, time and effort. Bogle (2017), Yuan et al. (2017), and Reitze et al. (2018) affirmed that Industry 4.0 should be flexible regarding the market and its demand. Gezdur and Bhattacharjya (2017), von Knop (2017), Isaksson et al. (2018) and Bogle (2017) add to this the need

to adapt production to consumer desires. In this way, the companies' need to adapt their business models (identified by Ydstie (2002), Davis and Edgar (2008) and Squire and Song (2014)) was confirmed.

The literature is unanimous in identifying difficulties in managing, analyzing, and using the large amount of Industry 4.0 data. For many authors, this difficulty lies in obtaining robustness and reliability of the communicative systems (Zhou et al., 2017; Liu et al., 2017; Isaksson et al., 2018). For Zhang et al. (2018), Yang (2018) and Joly et al. (2018), the challenge was to ensure that the system responded in real time. In this sense, Yan et al. (2017) added that another limiting factor is the communication capacity of the system, with band availability being a fundamental factor. Chiang et al. (2017), Zhang et al. (2018) and Joly et al. (2018) confirmed the need for companies to have computational efficiency and broadband availability.

Hermann et al. (2016) and Qian et al. (2017) further claimed that new technologies require the development of Human-Machine interfaces that facilitate user operation. Khare and Ching (2017), Knop (2017) and Chiang et al. (2017) state that in order for this to happen, the development of specialized labor and technical assistance compatible with these innovations is necessary. According to the authors, given the complexity of the technologies of Industry 4.0, the required interdisciplinarity of the team must be high.

Another difficulty, identified by several authors, is coordination with the supply chain (Bogle, 2017; Leeuw, 2017; Baldea et al., 2018; Isaksson et al., 2018). For this, it is necessary to ensure the connection and integration of the operations and software used by suppliers and customers (von Knop, 2017; Baldea et al., 2018).

Thoben et al. (2017) and Kusiak (2017) agree that the standardizations required for machine connectivity and data integration are the major challenges encountered.

In addition, the authors stated that ensuring cybersecurity is a continuing challenge. In this sense, the guaranteeing of cybersecurity was also identified by Christofides et al. (2007), Squire and Song (2014), Hermann et al. (2016) and Bogle (2017) and is a concern that accompanies the evolution of the fourth industrial revolution.

## Difficulties for the implementation of Industry 4.0 in the continuous process chemical industry

While there are similar challenges across many manufacturing sectors, there are specific difficulties for the continuous chemical industry (Bogle, 2017). Ydstie (2002) already predicted difficulties of technological innovation in the sector, the modeling and transcription of complex systems and the integration of control methods with the new information systems. Christofides et al. (2007) identified the challenges of the continuous chemical industry as comprising the connectivity of the control elements, the real-time response, and the fault-response system. In agreement with the authors, Bogle (2017) affirmed that the technical challenges that confront the development of 4.0 technologies are related to robustness and security, the prediction of the properties of the mixtures, and new paradigms of modeling the chemical processes. Detailed modeling and transcription of systems should be done where possible and the development of new unit operations, products and measurement systems simplify complex systems, allowing process adaptation in the event of unavailability of data.

Table 4 presents the difficulties of 4.0 technology implementation from the point of view of the continuous processes chemical industry, identified in the articles obtained through the literature review, which will be discussed in sequence.

Table 4 - Difficulties in the implementation of 4.0 technologies for the continuous processes chemical industry

Difficulties	Authors / Year
Model and transcribe complex systems	Ydstie, 2002; Grossmann, 2005; Venkatasubramanian, 2008; Wassick, 2009; Zuehlke, 2010; Natarajan et al., 2012; Qin, 2014; Windmann et al., 2015; Kumar et al. 2015; Kumar et al., 2016; Li, 2016; Dai et al., 2016; Shu et. al., 2016; Bogle, 2017; Ge et al., 2017; Sun et al., 2017; Chiang et al., 2017; Yuan et al., 2017; Zhou et al., 2017; García et al., 2017; Liu et al., 2017; Zhang et al., 2018; Ragab et al., 2018; Baldea et al., 2018; Joly et al., 2018
Adapt classical control methods to new information systems	Ydstie, 2002; Natarajan et al., 2012; Korombath et al., 2014; Rathinasabapathy et al., 2016; Yuan et al., 2017; Chiang et al., 2017; Baldea et al., 2018; Joly et al., 2018; Reitze et al., 2018
Develop reliable fault response system for high risk processes	Christofides et al., 2007; Gao et al., 2009; Wassick, 2009; Li; Liu, 2010; Natarajan et al., 2012; Davis et al., 2012; Qin, 2014; Squire; Song, 2014; Luo et al., 2017; Windmann et al., 2015; Dai et al., 2016; Shu et. al., 2016; Rathinasabapathy et al. 2016; Chen et al., 2016; Bogle, 2017; Leeuw, 2017; Yuan et al., 2017; He et al., 2017; Liu et al., 2017; Yang, 2018; Ragab et al., 2018; Baldea et al., 2018

Create health, safety and environmental assessment models	Christofides et al., 2007; Davis; Edgar, 2008; Natarajan et al., 2012; Belaud et al., 2014; Squire; Song, 2014; Luo et al., 2017; Dai et al., 2016; Li, 2016; Shu et. al., 2016; Bogle, 2017; Leeuw, 2017; Yuan et al., 2017; Khare; Chin, 2017; Qian et al., 2017; Liu et al., 2017;
Plant modifications and production interruptions	Davis; Edgar, 2008; Natarajan et al., 2012; Natarajan; et al., 2014; Squire; Song, 2014; Dai et al., 2016; Leeuw, 2017; Khare; Chin, 2017; Knop, 2017; Baldea et al., 2018; Reitze et al., 2018; Isaksson et al., 2018;
Develop new synthesis processes, intensify operations and adapt products	Venkatasubramanian, 2008; Baldea et al., 2018; Bogle, 2017; Leeuw, 2017; Baldea et al., 2018; Reitze et al., 2018
Lack of deployment success cases	Christofides et al., 2007; Davis; Edgar, 2008; Montanus, 2016. He et al., 2017

SOURCE: The author (2018).

*Modeling and transcribing complex systems:* For Yuan et al. (2017), the first challenge was to obtain reliable models for chemical processing units, especially for complex reactors. The complexity of mixtures and chemical reactions require the ability of mathematical models to consider numerous physicochemical properties (Bogle, 2017). García et al. (2017) confirmed that converting complex Big Data into operational decisions requires new data manipulation and analysis capabilities. Yuan et al. (2017) also question whether the industry will trust and adopt the results of improvements. The reliability models of chemical systems have limitations under complex conditions. The large volume of data can overwhelm the capacity of the analysis system and adversely affect the efficiency of information processing (Chiang et al., 2017).

In addition to this, with the evolution of modern chemical processes, the information required for process supervision is distributed from several different sources, which requires effort in data management integration (Natarajan et al., 2012).

*Adapt classical control methods to new information systems:* new control methods need to be developed and integrated into real operations at different scales under the effect of different physical phenomena in the chemical industry (Ydstie, 2002). The combination of different data sources, to draw meaningful conclusions through Big Data analysis, is a difficult task (Chiang et al., 2017). Korombath et al. (2014) stated that the interaction between manufacturing operations and the various alternatives for the use of such information is an example of the challenges associated with deploying 4.0 technologies in the chemical industry. The industry requires new

scalable digital platforms that upgrade the technology levels of current instrumentation (Yuan et al., 2017).

*Develop reliable fault response system for high risk processes:* the diagnosis of industrial chemical plants is a difficult but necessary task (Rathinasabapathy et al. 2016). The challenge is to analyze the process data accurately and quickly so that corrective action can be taken in a timely manner (Rathinasabapathy et al. 2016). According to Bogle (2017), hazard detection must be incorporated directly into the systems because operating close to ideal conditions often overloads the operations, resulting in a higher probability of failure. For Khare and Chin (2017), the most important aspect in the chemical industry is safety. He et al. (2017) argued that extracting useful information from Big Data is a significant challenge for monitoring process failure. Shu et al. (2016) argued that although the concept of process failure diagnosis is an old research question, there are still only a few systems satisfactorily being applied in actual chemical processes.

*Create health, safety and environmental assessment models:* according to Liu et al. (2017), online health, safety and environmental management (HSE) is one of the most important requirements of Industry 4.0, as the consumer is increasingly interested in the industry's sustainability policies. The authors stated that system reliability is essential in the chemical industry. Shu et al. (2016) reaffirmed that timely, reliable and automatic decision-making (which supports operations in abnormal situations in chemical processes), is an indispensable cognitive function for the chemical industry 4.0. According to Natarajan et al. (2012), system reliability is one of the most important factors in assessing the health, safety and environmental state of the chemical industry as well as the likelihood of completing assigned tasks under certain conditions without failure. For Bogle (2017), specific processes that are linked to health, safety, and the environment are critical, and must be properly modeled.

*Modifications to plants and production interruption:* The most important aspect in a continuous chemical industry is the maintenance of its maximum possible capacity (Khare and Chin, 2017). Natarajan et al. (2014) mentioned that despite this, the physical structure of the continuous plant is constantly changeable. For example, certain sections of a plant may be removed for weeks or months for routine maintenance. Thus, mathematical models must be able to adapt to such changes (Natarajan et al., 2012). Davis and Edgar (2008) identified the main difficulty of the implementation of Industry 4.0 as being the interruption of production, which needs to be avoided in continuous processes.

Since there is only rare quantitative evidence of the economic benefits of deploying 4.0 technologies, the authors also identified the need for research in phased deployment, where production disruption is minimized. Thus, change management needs to be maintained and documented, especially when it involves industry safety factors (Squire and Song, 2014).

*Unavailability of data:* manufacturers face the challenge of improving the existing plants' capacity while reducing maintenance costs (Khare and Chin, 2017). According to Khare and Chin, both challenges have the need to obtain data through instrumentation and to analyse the data available in real time in common. In addition, for complex systems which has data available on a smaller scale, reliability assessment models are vulnerable to system instability (Liu et al., 2017). Li and Liu (2010) cited the low level of availability of information in the logistics of the chemical industry as an example. Hamzeh (2016) added the difficulty of companies working with data from different sources.

*Develop new synthesis processes, intensify operations and adapt products:* Bogle (2017) stated that one requirement of Industry 4.0 is the industry-to-consumer approach. In this sense, with the advancement of chemical process technology, there are possibilities of combining multiple operations in compact unit operations, intensifying the operational processes (Bogle, 2017). Venkatasubramanian (2008) identified opportunities for contributing to the fields of new chemical design, creation of specific infrastructures, data extraction systems, knowledge management environments and visualization of chemical processes.

*Lack of successful deployment cases:* the application of the Internet of Things to large numbers of sensors and data has not attracted much attention from researchers and industry professionals. One possible reason is that the benefits of such applications have not been recognized or tested (He et al., 2017). Due to the novelty of Industry 4.0 and the lack of proven cases of usage, the operational and monetary benefits of the adoption of the elements of Industry 4.0 are still unclear (Montanus, 2016).

### **General Critical Success Factors for 4.0 Technologies Deployment**

The identification of the Critical Success Factors allows strategic focus on prospective and corrective actions that guarantee the development of a project

(COLAUTO et al., 2004). For Gezdur and Bhattacharjya (2017) it must take into account that digital transformation projects can require considerable time and effort.

Researchers have some general agreement for the Critical Success Factors on the implementation of 4.0 technologies, regardless of the type of industry. One of the most cited Critical Success Factors is the need for software connectivity and standardization of communication between machines, integrated with the supply chain (Yan et al., 2017; Ivezic et al., 2014; Helu and Hedberg Jr, 2015; Thoben et al., 2017). Another important factor is the computational efficiency and availability of broadband (Jung et al., 2015; Lu, 2017). Since technologies are dependent on a digital platform and the wireless internet, real-time data transmission is dependent on this infrastructure.

In relation to data management, the literature is convergent in affirming that there is a need to de-centralize analysis and the use of Big Data (Lu, 2017; Jung et al., 2015; O'Donovan et al., 2015; Helu et al., 2015). In addition, the data store must be protected by a reliable cyber security system (Helu et al., 2015; Kusiak, 2017).

As far as human resources are concerned, the deployment of 4.0 technologies are dependent on trained and committed employees (Helu et al. 2015; Choi et al., 2015; Thoben et al., 2017; O'Donovan et al., 2015). Jung et al. (2015) and Lu (2017) argued that a user-friendly interface between digital vehicles and operators is still required. Lu (2017) and Helu and Hedberg (2015) stated that there is a paradigm shift of production 4.0, focusing on consumer desire and demanding process flexibility in both market and demand.

Based on the development of Industry 4.0, Li (2016) proposed a definition of the necessary resources in the petrochemical industry: data management, real-time response, cyber security, specialized manpower and evolution of the Human-Machine interface. Qian, Zhong and Du (2017) presented the three major critical factors within China's chemical industrial processes: describe the production process using accurate mathematical models, process optimization of a mixed, multi-objective and multimensurable approach, and a method for the optimization of production and management decision-making.

Hermann et al. (2016) based their article design principles for Industry 4.0 on quantitative analysis. The text analysis identified four design principles on how to implement the new technologies: interconnection, information transparency, de-centralized decisions and technical assistance.

## Critical Success Factors for the Implementation of 4.0 Technologies in Continuous Process Chemical Industries

In relation to the continuous process chemical industry, the literature review points to specific Critical Success Factors, which are presented in Table 5 and discussed in sequence.

Table 5 - Critical success factors in the implementation of industry 4.0 specific to the continuous chemical industry

Critical Success Factor	Authors / Year
Minimization of plant modifications or interruptions in the unplanned production process.	Natarajan et al., 2012; Natarajan et al., 2014; Squire and Song, 2014; Leeuw, 2017; Baldea et al., 2018; Reitze et al., 2018; Isaksson et al., 2018
Infrastructure and facilities compatible with the requirements of new technologies.	Natarajan et al., 2012; Rathinasabapathy et al., 2016; Yuan et al., 2017; Chiang et al. 2017; Baldea et al., 2018
Reliable adverse event management systems for high risk processes.	Gao et al., 2009; Wassick, 2009; Natarajan et al., 2012; Davis et al., 2012; Squire and Song, 2014; Windmann et al., 2015; Shu et. al., 2016; Rathinasabapathy et al. 2016; Chen et al., 2016; Leeuw, 2017; Yuan et al., 2017; Liu et al., 2017; Ragab et al., 2018; Baldea et al., 2018
Health, safety and environmental assessment models.	Belaud et al., 2014; Squire and Song, 2014; Leeuw, 2017; Yuan et al., 2017; Liu et al., 2017
Investment in research and development to simplify complex systems and intensify operations, adapting the process in case of unavailability of data.	Baldea et al., 2018; Leeuw, 2017; Baldea et al., 2018; Reitze et al., 2018
Reliable data measurement, transmission and data collection systems.	Kumar et al. 2015; Hamzeh, 2016; Rathinasabapathy et al. 2016; Chen et al., 2016; Liu et al., 2018; Isaksson et al., 2018
Detailed modeling and transcription of systems where possible.	Wassick, 2009; Zuehlke, 2010; Natarajan; et al., 2012; Windmann et al., 2015; Kumar et al. 2015; Kumar et al., 2016; Shu et. al., 2016; Zhou et al., 2017; Chiang et al., 2017; Yuan et al., 2017; García et al., 2017; Liu et al., 2017; Zhang et al., 2018;

SOURCE: The author (2018).

*Minimization of plant modifications or interruptions in the unplanned production process:* Liu et al. (2017) stated that the causes of many major accidents, such as those at Flixborough, Piper Alpha, and Petrobras®, originated from changes in the

process flow chart, equipment specification, and other key process descriptors. Thus, since the continuous chemical industry is under constant modification, the factory's control and safety systems must be constantly updated. Dai et al. (2016) concluded that any changes during operations should be reflected for the supervision of production in real time. Such change management, whether for specialization or reconfiguration of the chemical industry (or even its supply chain) requires an additional effort from companies, according to von Knop (2017). Baldea et al. (2017) affirmed that process variability is inevitable and coordination between process control and production scheduling is indispensable, utilizing available technology to maximize the production of systems operating in parallel.

*Infrastructure and facilities compatible with the requirements of the new technology:* according to Bogle (2017), computational methods manipulate multiple stages within the chemical industry supply chain and it is necessary to consider the technical constraints of flexible manufacturing at each stage. In this sense, it is necessary to incorporate the capacity to deal with uncertainty in demand and production. To this end, the evolution of measurement, transmission and data collection systems should focus on cyber security, data quality and speed of its transmission and use (Chiang et al., 2017). Baldea et al. (2017) further stated that one of the main ideas in the continuous intelligent chemical industry is the connection of operations in parallel.

*Reliable adverse event management systems for high risk processes:* for Yuan et al. (2017), within the context of Big Data, alarm management, process monitoring, equipment fault diagnosis and human behavior, monitoring must be integrated to achieve a reliable and scalable platform. Natarajan et al. (2012) confirmed that the detection of abnormalities in the process is essential in order for corrective actions to be effective and to maintain the quality of the product, avoid a halt in production and prevent accidents. Li and Liu (2010) provided an example of the logistics of safety management of the chemical industry, which must necessarily be reliable as it deals with flammable, explosive, toxic and corrosive products. For Dai et al. (2016), the goal of new technologies should include the significant reduction of security incidents. The need for a robust fault detection system and the minimization of accidents is a consensus among the authors, since this is the Critical Success Factor most commonly identified in the literature.

*Health, safety and environmental assessment models:* Squire and Song's (2014) safety statistics suggest that most injuries are the result of violent incidents in the workplace. For Qian et al. (2017), the goal for optimal manufacturing in the industrial chemical process is to promote efficient, green and safe production. Since Industry 4.0 depends on reliable systems, the health, safety and environmental assessment models should be incorporated into the conventional control system (Bogle, 2017). Bogle further argued that since chemical processes are often at high risk, it is a key aspect to correct mathematical modeling where health, safety and environmental issues require accurate predictions. Christofides et al. (2007) argued that such measures can also bring great economic benefits, since abnormal situations cause billions of dollars in losses annually. Yuan et al. (2017) pointed out that risk assessment should be the first step in managing abnormal situations. To this end, Baldea et al. (2017) cited the use of intensification of chemical processes in distributed modules as a tool to reduce risks.

*Investment in research and development to simplify complex systems and intensify operations, adapting the process in case of unavailability of data:* Zhang et al. (2018) considered that Big Data technology offers the opportunity to bypass data unavailability and the difficulty of modeling complex systems through the history of empirical data. Shu et al. (2016) argued that because of the increasing size and complexity of modern chemical processes and the amount of historical data available, historical-based methods show great advances in fault diagnosis. For Ge et al. (2017), the modeling, monitoring, prediction and control of data-driven processes has proven feasible through the use of Machine Learning techniques. Another alternative to circumvent the unavailability of data is the design of distributed production modules, through the intensification of processes. For Baldea et al. (2017), process intensification also allows the transition from batch processes to continuous operation, minimizing process variability and ensuring quality through automated systems.

*Reliable data measurement, transmission and data collection systems:* for Sun et al. (2017), extracting more knowledge and production data information allows an increase in the understanding of the dynamics of the system and supports the best operation of the equipment efficiently. Montanus (2016) confirmed that this gives rise to opportunities for more efficient and intelligent analyses and better control of industrial systems, and may even cause disruptive changes in the way these systems are designed and used. However, according to Bogle (2017), although a

considerable amount of historical trend data is collected in operations, the chemical industry does not incorporate large demand databases directly into its control systems. In this sense, Rathinasabapathy et al. (2016) argued that qualitative models have the advantage of being rigorous even when there is insufficient data or information, replacing advanced instrumentation systems.

*Detailed modeling and transcription of systems where possible:* correct descriptions of the productive processes are mathematical prerequisites for developing the models (Natarajan et al., 2012). The work of Liu et al. (2017) is an example of how mathematical modeling is capable of decreasing the complexity of variables in the continuous chemical industry, including human factors, equipment, materials, and environmental data. Zhou et al. (2017) saw that the creation of a virtual representation of the physical world, through a digital communication platform was a prerequisite for the deployment of 4.0 technologies. For Windmann et al. (2015), it is fundamental to develop self-learning assistance systems that identify relevant relationships by observing the complex manufacturing processes. The authors believe that the Machine Learning technology helps in the detailed modeling of systems in order to automatically detect failures, anomalies and the need for optimization.

Some theoretical studies have also identified as a Critical Success Factors the need to estimate risks, costs, time and resources involved in the implementation project (Christofides et al., 2007; Davis and Edgar, 2008; Montanus, 2016; He et al., 2017). However, the articles concerned with practical implementation of technologies in the chemical industry do not cite this as a necessity and so it was not considered.

## **CONCLUSION**

By analyzing the literature, it is possible to identify several research gaps and the need for future studies. The research on retrieval and extraction of useful information associated with Big Data, aiming optimization, and control and management, are the topics most widely approached by the publications studied. Several authors agree that future research should focus on data quality assessment methods, extracted from the process and Big Data cleaning techniques.

For complex chemical systems, the data are often unavailable. In this sense, it is also necessary to develop models that utilize the history of empirical data to overcome the instability of production systems, as well as Big Data storage systems.

More recent publications claim that the development of enhanced process modules is a promising path for the continuous process chemical industry in this new industrial revolution.

Adaptation of the technologies proposed by Industry 4.0 is necessary. Research on the design and updating of sensor networks, communication between machines on larger scales, updating of Machine Learning studies and the development of Blockchain technology has barely been explored, despite having great potential for the 4.0 revolution.

In addition, fault diagnosis is a recurring theme and the study of its application in the chemical industry is essential, particularly with regards to the origin of failures. As well as new HSE assessment models, the research of the integration of the technologies (before the supply chain) and cybersecurity techniques configure the future of the research field.

The biggest challenge for the development of Industry 4.0 in the chemical industry is the need for the scientific community to work in a multidisciplinary way, bringing together advances in computer science in data management, production engineering tools, mathematical modeling and technical engineering knowledge of chemical processes.

### **Acknowledgements**

Funding: This study was financed, in part, by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001.

### **References**

- Ahuett-Garza, H., Kurfess, T., 2018. A brief discussion on the trends of habilitating technologies for Industry 4.0 and Smart manufacturing.
- Ajami, S., Rajabzadeh, A., 2013. Radio Frequency Identification (RFID) technology and patient safety. *J. Res. Med. Sci.*, 18, 9, 809-813.
- Akçayir, M., Akçayir, G., 2017. Advantages and challenges associated with augmented reality for education: A systematic review of the literature. *Educational Research Review*, 20, 1-11.

Davis, J. et al., 2008. Smart Process Manufacturing Workshop Report. IN: NSF Roadmap Development Workshop.

Balakrishnan, S. M., Sangaiah, A. K., 2016. Integrated QoUE and QoS approach for optimal service composition selection in internet of services (IoS). *Multimedia Tools and Applications*, 76, 22889-229116.

Baldea, M., Edgar, T., Stanley, B. L., Kiss, A. A. 2018. Modularization in Chemical Processing. *AIChE Special Section: Process Intensification*.

Belaud, J., Negny, S., Dupros, F., Michéa, D., Vautrin, B., 2014. Collaborative simulation and scientific big data analysis: Illustration for sustainability in natural hazards management and chemical process engineering. *Computers in Industry*, 65, 3, 521-535. <http://dx.doi.org/10.1016/j.compind.2014.01.009>.

Blackburn, R., Lurz, K., Priese, B., Göb, R., Darkow, II. 2015. Predictive analytics approach for demand forecasting in the process industry. *Intl. Trans. in Op. Res*, 22, 407–428. <https://doi.org/10.1111/itor.12122>.

Bogle, I. D., 2017. A Perspective on Smart Process Manufacturing Research Challenges for Process Systems Engineers. *Engineering*, 3, 2, 161-165. <http://dx.doi.org/10.1016/J.ENG.2017.02.003>.

Borges, F. H.; Dalcol, P. R. T., 2002. Indústrias de processo: comparações e caracterizações. XXII Encontro Nacional de Engenharia de Produção.

Buffa, E. S., 1979. *Production Inventory Systems – Planning and Control*. 3<sup>a</sup> Ed. Richard D. Irwin: Illinois.

Chang, R. F., Chang, C. W., Tseng, K. H., Chiang, C. L., Kao, W. S., Chen, W. J., 2011. Structural planning and implementation of a microprocessor-based human-machine interface in a stream-explosion process application. *Computer Standards & Interfaces*, 33, 232-248. <https://doi.org/10.1016/j.csi.2010.05.001>.

Chen, Y., Lee, G. M., Shu, L., Crespi, N., 2016. Industrial Internet of Things-Based Collaborative Sensing Intelligence: Framework and Research Challenges. *Sensors*, 16, 215. <https://doi.org/10.3390/s16020215>.

Chiang, L., Lu, B., Castillo, I., 2017. Big Data Analytics in Chemical Engineering. *The Dow Chemical Company, Annu. Rev. Chem. Biomol. Eng.* <https://doi.org/10.1146/annurev-chembioeng-060816-101555>.

Choi, S., Kim, B. H., Noh, S. D., 2015. A Diagnosis and Evaluation Method for Strategic Planning and Systematic Design of a Virtual Factory in Smart Manufacturing Systems. *International Journal of Precision Engineering and Manufacturing*, 16, 6, 1107-1115.

Christofides, P. D., Davis, J. F., El-Farra, N. H., Clark, D., Harris, K. R., Gipson, J. N., 2007. Smart plant operations: Vision, progress and challenges. *AIChE Journal*, 53, 11, 2734-2741. <https://doi.org/10.1002/aic.11320>.

Chung, Y. F., Hsiao, T. C., Chen, S. C., 2014. The Application of RFID Monitoring Technology to Patrol Management System in Petrochemical Industry. *Wireless Pers Commun*, 79, 1063-1088. <https://doi.org/10.1007/s11277-014-1918-5>.

Colauto, D., Gonçalves, C. M., Beuren, I. M., Dos Santos, Neri,. 2004. Os fatores críticos de sucesso como suporte ao sistema de inteligência competitiva: o caso de uma empresa brasileira. *Revista de Administração Mackenzie*, 5, 2.

Conner, B. P., Manogharan, G. P., Martof, A. N., Rodomsky, L. M., Rodomsky, C. M., Jordan, D. C., Limperos, J. W., 2014. Making sense of 3-D printing: Creating a map of additive manufacturing products and services. *Additive Manufacturing*, 1, 64-76.

Dai, Y., Wang, H., Khan, F., Zhao, J., 2016. Abnormal situation management for smart chemical process operation. *Current Opinion in Chemical Engineering*, 14, 49-55. <http://dx.doi.org/10.1016/j.coche.2016.07.009>.

Davis, J., Edgar, T. 2008. Smart Process Manufacturing—A Vision of the Future. *Design for Energy and the Environment*, pp. 149-165.

Davis, J., Edgar, T., Porter, J., Bernaden, J., Sarli, M., 2012. Smart manufacturing, manufacturing intelligence and demand-dynamic performance. *Computers e Chemical Engineering*, 47, 145-156. <http://dx.doi.org/10.1016/j.compchemeng.2012.06.037>.

Davis, J., Swink, D., 2014. Smart Manufacturing, real-time networked information workflows and enterprise performance. IN: SMLC papers. Disponível em: <[https://smartmanufacturingcoalition.org/sites/default/files/scppe\\_april\\_2013.pdf](https://smartmanufacturingcoalition.org/sites/default/files/scppe_april_2013.pdf)> Acessado em 27 novembro de 2017.

Engisch, W., Muzzio, F., 2016. Using Residence Time Distributions (RTDs) to Address the Traceability of Raw Materials in Continuous Pharmaceutical Manufacturing. *Journal of Pharmaceutical Innovation*, 11, 64–81.

Febowitz J. The Big Deal About Big Data in Upstream Oil and Gas. IN: IDC Energy Insights, 2012.

Fransoo, J. C., Rutten, W. G. M. M., 1994. A Typology of Production Control Situations in Process Industries. *International Journal of Operations e Production Management*, 14, 12, 47-57.

Gao, Y., Shang, Z., Kokossis, A., 2009. Agent-based intelligent system development for decision support in chemical process industry. *Expert Systems with Applications*, 36, 8, 11099-11107. <https://doi.org/10.1016/j.eswa.2009.02.078>.

García, M. V., Irisarri, E., Pérez, F., Estévez, E., Marcos, M., 2017. An Open CPPS Automation Architecture based on IEC-61499 over OPC-UA for flexible manufacturing in Oil&Gas Industry. *IFAC-PapersOnLine*, 50, 1, 1231–1238. <https://doi.org/10.1016/j.ifacol.2017.08.347>.

Ge, Z., Song, Z., Ding S. Z., Huang, B., 2017. Data Mining and Analytics in the Process Industry: The Role of Machine Learning. *IEEE Access*, 5, 20590-20616. <https://doi.org/10.1109/ACCESS.2017.2756872>.

Geng, Z., Yang, X., Han, Y., Zhu, Q., 2017. *Energy*, 120, 67-78. <http://dx.doi.org/10.1016/j.energy.2016.12.090>.

Gezdur, A., Bhattacharjya, J., 2017. Digitization in the Oil and Gas Industry: Challenges and Opportunities for Supply Chain Partners. *Collaboration in a Data-Rich World*, 97-103.

Grossmann, I., 2005. Enterprise-wide optimization: A new frontier in process systems engineering. *AIChE Journal*, 51, 7, 1846-1857. <https://doi.org/10.1002/aic.10617>.

Hamzeh, H., 2016. Application of Big Data in Petroleum Industry. Department of Electronics and Computer Engineering, 0-16.

Hao, Q., Zhang, F., Liu, Z., Qin, L., 2015. Design of Chemical Industrial Park Integrated Information Management Platform Based on Cloud Computing and IOT (The Internet of Things) Technologies. *International Journal of Smart Home*, 9, 4, 35-46. <http://dx.doi.org/10.14257/ijsh.2015.9.4.04>.

Hassani, H., Silva, E. S., Al Kaabi, A. M., 2017. The role of innovation and technology in sustaining the petroleum and petrochemical industry. *Technological Forecasting and Social Change*, 119, 1-17. <http://dx.doi.org/10.1016/j.techfore.2017.03.003>.

Hawkins, W.; Brandl, D.; Boyes, W., 2010. Applying Isa-88 in Discrete and Continuous Manufacturing. *World Batch Forum (WBF)*. 1<sup>a</sup> Ed. Momentum Press.

He, P. Q., Wang, J., Shah, D., Vahdat, N., 2017. Statistical Process Monitoring for IoT-Enabled Cybermanufacturing: Opportunities and Challenges. *IFAC-PapersOnLine*, 50, 1, 14946–14951. <https://doi.org/10.1016/j.ifacol.2017.08.2546>.

Helu, M., Hedberg, T. Jr., 2015. Enabling Smart Manufacturing Research and Development using a Product Lifecycle Test Bed. *Procedia Manufacturing*, 1, 86-97.

Helu, S., Morris, K., Jung, K., Lyons, K., Leong, S., 2015. Identifying performance assurance challenges for smart manufacturing. *Manuf Lett*, 6, 1-4.

Hermann, M., Pentek, T., Otto, B., 2016. Design Principles for Industrie 4.0 Scenarios. 49th Hawaii International Conference on System Sciences (HICSS). <https://doi.org/10.1109/HICSS.2016.488>.

HIMSS ASIA PACIFIC. Cyber Security Threats in Thailand and the Need for SMART. 2016. Disponível em:  
<[http://www.himssasiapac.org/sites/default/files/HIMSSAP\\_ExclusiveArticles\\_CyberSecurityThreatsinThailand.pdf](http://www.himssasiapac.org/sites/default/files/HIMSSAP_ExclusiveArticles_CyberSecurityThreatsinThailand.pdf)>.

Inaba, K., 2016. The Common Integration The Group Operation of Petrochemical Complexes in Japan. *Journal on Innovation and Sustainability*, 5, 2, 94-102.

Isaksson, A. J., Harjunkoski, I., Sand, G., 2018. The impact of digitalization on the future of control and operations. *Computers and Chemical Engineering*, 114, 112–129. <https://doi.org/10.1016/j.compchemeng.2017.10.037>.

Ivezic, N., Kulvatunyou, B., Srinivasan, V., 2014. On architecting and composing through-life engineering information services to enable smart manufacturing. *Procedia CIRP*, 22, 45-52.

Ji, X., He, G., Xu, J., Guo, Y., 2016. Study on the mode of intelligent chemical industry based on cyber-physical system and its implementation. *Advances in Engineering Software*, 99, 18-26. <http://dx.doi.org/10.1016/j.advengsoft.2016.04.010>.

Johannsen, G., 2009. Human-Machine Interaction. *Control Systems, Robotics, and Automation*, IN: *Encyclopedia of Life Support Systems*, 21.

Joly, M., Odloak, D., Miyake, M., Menezes, B. C., Kelly, J. D., 2018. Refinery production scheduling toward Industry 4.0. *Brazilian Journal of Chemical Engineering*, 29, 2, 371–384. <https://doi.org/10.15302/J-FEM-2017024>.

Jung, K., Morris, K. C., Lyons, K. W., Leong, S., Cho, H., 2015. Mapping Strategic Goals and Operational Performance Metrics for Smart Manufacturing Systems. *Procedia Computer Science*, 44, 184-193.

Kagermann, H., Wahlster, W., Helbig, J., 2013. Recommendations for implementing the strategic initiative Industrie 4.0: Final report of the Industrie 4.0 Working Group, Frankfurt.

Khare, C., Chin, S. T., 2017. Potential for data analytics opportunities in SMART chemical Industry. *Chemistry Today*, 35, 2, 60-62.

von Knop, J., 2017. Chemistry 4.0 Challenges and Solutions for the Digital Transformation. *Croat. Chem. Acta*, 89, 4, 397–402. <https://doi.org/10.5562/cca3132>.

Kleinelanghorst, M. J., 2016. J-Park Simulator: Roadmap to Smart Eco-Industrial Parks. IN: *Computational Modelling Group*, University of Cambridge.

Korambath, P., Wang, J., Kumar, A., Hochstein, L., Schott, B., Graybill, R., Davis, J., 2014. Deploying Kepler Workflows as Services on a Cloud Infrastructure for Smart Manufacturing. *Procedia Computer Science*, 29, 2254-2259. <https://doi.org/10.1016/j.procs.2014.05.210>.

Korambath, P., Wang, J., Kumar, A., Davis, J., Graybill, R., Schott, B., E Baldea, M., 2016. A Smart Manufacturing Use Case: Furnace Temperature Balancing in Steam Methane Reforming Process via Kepler Workflows. *Procedia Computer Science*, 80, 680-689. <https://doi.org/10.1016/j.procs.2016.05.357>.

Kotynkova, M., 2017. Re-Industrialization of Europe: Industry 4.0 and the Future of Work. *European Scientific Journal*, Special Edition, 249-256.

Kumar, A., 2016. Model based Operation of Industrial Steam Methane Reformers using Large Scale Sensor Data. (PhD Thesis). The University of Texas at Austin, Austin.

Kumar, A., Baldea, M., Edgar, T. F., 2017. Smart Manufacturing: Application to an Industrial Scale Steam-Methane Reformer. *Proceedings of FOCAPO/CPC*. University of Texas at Austin.

Kumar, A., Baldea, M., Edgar, T. F., 2016a. On optimal sensing and actuation design for an industrial scale steam methane reformer furnace. *AIChE Journal*, 62, 9, 3225-3237. <https://doi.org/10.1002/aic.15333>.

Kumar, A., Baldea, M., Edgar, T. F., 2016b. Real-time optimization of an industrial steam-methane reformer under distributed sensing. *Control Engineering Practice*, 54, 140-153. <http://dx.doi.org/10.1016/j.conengprac.2016.05.010>.

Kumar, A., Baldea, M., Edgar, T. F., 2016c. A physics-based model for industrial steam-methane reformer optimization with non-uniform temperature field. *Computers e Chemical Engineering*, 105, 224-236. <http://dx.doi.org/10.1016/j.compchemeng.2017.01.002>.

Kumar, A., Edgar, T. F., Baldea, M., 2016d. Multi-resolution model of an industrial hydrogen plant for plantwide operational optimization with non-uniform steam-methane reformer temperature field. *Computers e Chemical Engineering*, 107, 271-283. <http://dx.doi.org/10.1016/j.compchemeng.2017.02.040>.

Kumar, A., Baldea, M., Edgar, T. F., Ezekoye, O. A., 2015. Smart Manufacturing Approach for Efficient Operation of Industrial Steam-Methane Reformers. *Industrial e Engineering Chemistry Research*, 54, 4360-4370. <https://doi.org/10.1021/ie504087z>.

Kusiak, A., 2017. Smart Manufacturing. *International Journal of Production Research*, 56, 1-2.

Leeuw, V. de. *Industrie 4.0 in the Chemical Industry*. ARC Insights. 2017.

Li, D., 2016. Perspective for smart factory in petrochemical industry. *Computers e Chemical Engineering*, 91, 136-148. <http://dx.doi.org/10.1016/j.compchemeng.2016.03.006>.

Li, H., Liu, Y., 2010. A Study of the Real-Time Monitoring System for Chemical Logistics Based on Internet of Things. *The Conference on Web Based Business Management*.

Liu, W., Wei, W., Xu, J., Ji, X., 2017. A Hybrid Algorithm for the Reliability Evaluation Models of Chemical Systems. *Qual. Reliab. Engng. Int.*, 33, 1337-1349. <https://doi.org/10.1002/qre.2108>.

- Lu, Y., 2017. Industry 4.0: A survey on technologies, applications and open research issues. *Journal of Industrial Information Integration*, 6, 1-10.
- Luo, H., Wang, K., Kong, X. T. R., Lu, S. Qu, T., 2017. Synchronized production and logistics via ubiquitous computing technology. *Robotics and Computer Integrated Manufacturing*, 45, 99–115. <http://dx.doi.org/10.1016/j.rcim.2016.01.008>.
- Martin, G., 2009. Wireless networks improve refinery operation. *Hydrocarbon processing*, 88, 3, 29-32.
- Montanus, M., 2016. Business Models for Industry 4.0 Developing a Framework to Determine and Assess Impacts on Business Models in the Dutch Oil and Gas Industry. (Master Thesis). Delft University Of Technology, Delft.
- Natarajan, S., Ghosha, K., Srinivasana, R., 2012. An ontology for distributed process supervision of large-scale chemical plants. *Computers & Chemical Engineering*, 46, 124-140. <http://dx.doi.org/10.1016/j.compchemeng.2012.06.009>.
- Natarajan, S., Srinivasan, R., 2014. Implementation of multi agents based system for process supervision in large-scale chemical plants. *Computers e Chemical Engineering*, 60, 182-196. <http://dx.doi.org/10.1016/j.compchemeng.2013.08.012>.
- O'donovan, P., Leahy, K., Bruton, K., O'sullivan, D. T. J., 2015. An industrial big data pipeline for data-driven analytics maintenance applications in large-scale smart manufacturing facilities. *Journal of Big Data*, 2-25.
- Pan, M., Sikorski, J., Kastner, C. A., Akroyd, J., Mosbach, S., Lau, R., Kraft, M., 2015. Applying Industry 4.0 to the Jurong Island Eco-industrial Park. *Energy Procedia*, 75, 1536-1541. <https://doi.org/10.1016/j.egypro.2015.07.313>.
- Qian, F., Zhong, W., Du, W., 2017. Fundamental Theories and Key Technologies for Smart and Optimal Manufacturing in the Process Industry. *Engineering*, 3, 2, 154-160. <http://dx.doi.org/10.1016/J.ENG.2017.02.011>.
- Qin, S. J., 2014. Process data analytics in the era of big data. *AIChE Journal*, 60, 9, 3092-3100. <https://doi.org/10.1002/aic.14523>.
- Ragab, A., El-Koujok, M., Poulin, B., Amazouz, M., 2018. Fault diagnosis in industrial chemical processes using interpretable patterns based on Logical Analysis of Data. *Expert Systems with Applications*, 95, 368–383. <https://doi.org/10.1016/j.eswa.2017.11.045>.
- Rathinasabapathy, R., Elsass, M. J., Josephson, J. R., Davis, J. F., 2016. A smart manufacturing methodology for real time chemical process diagnosis using causal link assessment. *AIChE Journal*, 62, 9, 3420-3431. <https://doi.org/10.1002/aic.15403>.
- Reitze, A., Jürgensmeyer, N., Lier, S., Kohnke, M., Riese, J., Grünewald, M., 2018. Roadmap for a Smart Factory: A Modular, Intelligent

Concept for the Production of Specialty Chemicals. *Angew. Chem. Int. Ed*, 57, 4242–4247. <https://doi.org/10.1002/anie.201711571>.

Roberge, D. M.; Zimmermann, B.; Rainone, F.; Gottsponer, M.; Eyholzer, M.; Kockmann, N., 2008. Microreactor Technology and Continuous Processes in the Fine Chemical and Pharmaceutical Industry: Is the Revolution Underway?. *Org. Process Res. Dev*, 12, 5, 905-910.

Russomano, V. H., 1979. *Planejamento e Acompanhamento da Produção*. São Paulo: Pioneira.

Sadiku, M. N. O., Wand, Y., Cui, S., Musa, S. M., 2017. INDUSTRIAL INTERNET OF THINGS. *International Journal of Advances in Scientific Research and Engineering*, 3, 11. <http://dx.doi.org/10.7324/IJASRE.2017.32527>.

Schleich, B., Anwer, N., Mathieu, L., Wartack, S., 2017. Shaping the digital twin for design and production engineering. *CIRP Annals*, 66, 1, 141-144.

Schlögl, R., 2017. Catalysis 4.0. *ChemCatChem*, 9, 4, 533-541.

Shalev-Shwartz, S.; Ben-David, S., 2014. *Understanding Machine Learning: From Theory to Algorithms*. Cambridge: Cambridge University Press.

Shu, Y., Ming, L., Cheng, F., Zhang, Z., Zhao, J., 2016. Abnormal situation management: Challenges and opportunities in the big data era. *Computers e Chemical Engineering*, 91, 104-113. <http://dx.doi.org/10.1016/j.compchemeng.2016.04.011>.

Sikorski, J. J., Haughton, J., Kraft, M., 2017. Blockchain technology in the chemical industry: Machine-to-machine electricity market. *Applied Energy*, 195, 234-246. <http://dx.doi.org/10.1016/j.apenergy.2017.03.039>.

Squire, R., Song, H., 2014. Cyber-physical systems opportunities in the chemical industry: A security and emergency management example. *Process Safety Progress*, 33, 4, 329-332. <https://doi.org/10.1002/prs.11676>.

Sun, B., Jämsä-Jounela, S-L., Todorov, Y., Olivier, L. E., Craig, I. K., 2017. Perspective for equipment automation in process industries. *IFAC-PapersOnLine*, 50, 2, 65-70. <https://doi.org/10.1016/j.ifacol.2017.12.012>.

Thienen, S., Clinton, A., Mahto, M., Shiderman, B., 2016. *Industry 4.0 and the chemicals industry*. Deloitte University Press.

Thoben, K., Wiesner, S., Wuest, T., 2017. “Industrie 4.0” and Smart Manufacturing – A Review of Research Issues and Application Examples. *International Journal of Automation Technology*, 11, 1, 4-16.

Toledo, J. C., Ferro, J. R., Truzzi, O. M. S., 1986. Indústrias de processo contínuo: novos rumos para a organização do trabalho. *Revista de Administração de Empresas*, 26, 1, 103-105.

Venkatasubramanian, V., 2008. DROWNING IN DATA: Informatics and modeling challenges in a data-rich networked world. *AIChE Journal*, 55, 1, 2-8. <https://doi.org/10.1002/aic.11756>.

Vinuto, J., 2014. A amostragem em bola de neve na pesquisa qualitativa: um debate em aberto. *Temáticas*, 44.

WANG, Q., Zhao, X., Huang, J., Feng, Y., Su, J., Luo, Z. 2017. Addressing Complexities of Machine Learning in Big Data: Principles, Trends and Challenges from Systematical Perspectives. <https://doi.org/10.1016/j.procs.2017.08.052>

Wassick, J. M., 2009. Enterprise-wide optimization in an integrated chemical complex. *Computers e Chemical Engineering*, 33, 12, 1950-1963. <https://doi.org/10.1016/j.compchemeng.2009.06.002>

Windmann, S. et al., 2015. Big Data Analysis of Manufacturing Processes. *Journal of Physics: Conference Series*, 659, 1-12. <https://doi.org/10.1088/1742-6596/659/1/012055>.

Woodward, J., 1977. *Organização Industrial: Teoria e Prática*. São Paulo: Atlas.

Yan, H., Hua, Q., Wang, Y., Wei, W., Imran, M., 2017. Cloud robotics in Smart Manufacturing Environments: Challenges and countermeasures *Journal Computers and Electrical. Engineering*, 63, 6, 56-65.

Yang, G., 2018. Data Acquisition Technology of Chemical Equipment Based on Wireless Sensor Network. *Chemical Engineering Transactions*, 66. <https://doi.org/10.3303/CET1866158>.

Ydstie, B. E., 2002. New vistas for process control: Integrating physics and communication networks. *AIChE Journal*, 48, 3, 422-426.

Yuan, Z., Qin, W., Zhao, J., 2017. Smart Manufacturing for the Oil Refining and Petrochemical Industry. *Engineering*, 3, 2, 179-182. <http://dx.doi.org/10.1016/J.ENG.2017.02.012>.

Zhang, Z., Chen, D., Feng, Y., Yuan, Z., Chen, B., Qin, W., Zou, S., Qin, S., Han, J., 2018. A strategy for enhancing the operational agility of petroleum refinery plant using case based fuzzy reasoning method. *Computers and Chemical Engineering*, 111, 27-36. <https://doi.org/10.1016/j.compchemeng.2017.12.021>.

Zhou, L. et al., 2017. Towards a novel ontological infrastructure for chemical process simulation and optimization in the context of eco-industrial parks. *Cambridge Centre for Computational Chemical Engineering*.

Zuehlke, D., 2010. SmartFactory—Towards a factory-of-things. *Annual Reviews in Control*, 34, 129–138. <https://doi.org/10.1016/j.arcontrol.2010.02.008>.

## APÊNDICE B - ARTIGO PUBLICADO NO VIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO (CONBREPRO 2018)

### Revisão sobre a qualidade de *Big Data* no contexto da Indústria 4.0

Paulo Henrique Amorim Santos (Universidade Federal do Paraná) [phas223@hotmail.com](mailto:phas223@hotmail.com)  
Izabel Cristina Zattar (Universidade Federal do Paraná) [izabel.zattar@gmail.com](mailto:izabel.zattar@gmail.com)

#### Resumo:

A necessidade de assegurar a qualidade de dados se intensifica ao gerenciar uma grande quantidade de informação. Existem obstáculos específicos para garantir a veracidade das informações coletadas, transmitidas e armazenadas em grande volume. Assim, com o desenvolvimento das tecnologias da Indústria 4.0 a pesquisa em *Big Data* evolui e se ramifica em novas áreas de estudo. Nesse contexto, o objetivo deste artigo é analisar criticamente a literatura relativa à análise da qualidade da tecnologia de *Big Data* na perspectiva da Indústria 4.0. A partir de uma abrangente revisão sistemática da literatura, é discutido a evolução do estudo perante as inovações recentes. Além disso, são identificados estudos de casos aonde as tecnologias já são utilizadas e a sua qualidade, avaliada. Dentre as necessidades identificadas, destacam-se a crescente preocupação em pesquisa e desenvolvimento de modelos estatísticos e computacionais, desenvolvimento de aprendizado de máquina e cuidados com segurança cibernética. A literatura também é convergente sobre a urgência em tornar acessível ao usuário a identificação de erros, através de processos transparentes. O estudo é direcionado à gestores, que buscam informações para projetos de implantação das tecnologias 4.0. Ainda, contribui-se com a comunidade acadêmica a partir da orientação à pesquisas futuras relativas ao tema.

**Palavras chave:** Qualidade de *Big Data*, Indústria 4.0, Análise de *Big Data*.

### Review about *Big Data* Quality in the Industry 4.0 context

#### Abstract

The need to protect the big data quality intensifies when managing a lot of information. There are specific obstacles to ensure the accuracy of information collected, transmitted and stored in large volumes. With the development of Industry 4.0 technologies, Big Data research has evolved and branched out into new areas of study. In this context, the objective of this article is to critically analyze the literature corresponding to the quality analysis of Big Data technology from the perspective of Industry 4.0. From a comprehensive systematic review of the literature, we discuss the evolution of the study in the face of recent innovations. In addition, case studies are identified where technologies are already used and its quality is assessed. Among the identified needs, we highlight the growing concern in research and development of statistical and computational models, development of machine learning and cyber security care. The literature also converges on the urgency of making it accessible to the user to identify errors easily, through transparent processes. The study is aimed at managers, who seek information for projects implementing the 4.0 technologies. Furthermore, it contributes to the academic community by orienting future research on the subject.

**Key-words:** Big Data Quality, Industry 4.0, Big Data Analytics

## Introdução

A Indústria 4.0 é um termo que foi usado pela primeira vez na Alemanha (originalmente *Industrie 4.0*), e é usado em todo o mundo para expressar os avanços tecnológicos que caracterizam a quarta revolução na fabricação industrial. (GRUSCHKA; LÜSSEM, 2016). Atualmente, as indústrias estão cada vez mais aderindo a avanços tecnológicos em cibernética, integração de recursos computacionais, infraestruturas de TI e novas tecnologias de obtenção e gerenciamento de dados. (REIS; KENETT, 2018). Essas novas tecnologias de monitoramento e controle do processo permitem atender as exigências atuais do mercado consumidor. (YAO; GE, 2018). Dentre as tecnologias mais difundidas citam-se a Internet das Coisas (IoT), sistemas ciber físicos (CPS), comunicação máquina-a-máquina (M2M), computação em nuvem e *Big Data*. (GRUSCHKA; LÜSSEM, 2016).

Neste ambiente, a qualidade da informação gerada é de importância central na Indústria 4.0. (REIS; KENETT, 2018). Para a indústria de processos, tanto a produtividade quanto a qualidade estão altamente relacionados à lucratividade e à segurança. (YAO; GE, 2018). Porém, assegurar a qualidade de dados é um grande desafio para qualquer organização, e é ainda mais desafiador no sentido de que as pessoas têm diferentes notações de definição e validação de dados. (MITTAL, 2013).

Assim, a qualidade de dados precisa ser assegurada para que os processos sejam confiáveis e significativos. Para garantir a qualidade e validade dos dados, é extremamente importante garantir que os dados corretos sejam usados. Isso requer padrões e procedimentos que tornam a informação compreensível, transferível e garante que a informação criada esteja disponível em todos os locais relevantes. (BERG; WILTS, 2018).

Neste contexto, este artigo objetiva analisar criticamente a literatura correspondente a análise de qualidade da tecnologia de Big Data na perspectiva da Indústria 4.0.

## Fundamentação Teórica

Devido ao aumento contínuo de volume de dados, mais recursos são necessários para rápida execução confiável de tarefas de análise de dados. (HÖLSCHER et al., 2018). Enquanto as primeiras publicações de Big Data focavam em seu valor potencial, ultimamente o foco de sua pesquisa tem sido a aplicação de tecnologias e técnicas que buscam o valor comercial da utilização dos dados. (KAMDI, 2018).

Existem na literatura, diferentes pontos de vista em relação as características que compõem um ambiente de Big Data. Três delas foram inicialmente identificadas por Doug Laney no início de 2001: volume, velocidade e variedade dos dados (LANEY, 2001). Anos mais tarde novas características como veracidade, valor e variabilidade foram incluídas. (ZIKOPOULOS et al., 2012; GANDOMI; HAIDER, 2015).

A qualidade de Big Data enquadra-se na característica de veracidade, sendo relacionada à confiabilidade dos dados. (NGUYEN et al., 2018). Um dado considerado de má qualidade é aquele que não pode ser convertido em informação e, portanto, não tem valor, enquanto que dados de qualidade possuem valor e geram informações significativas. (FAGUNDES; MACEDO; FREUND, 2018).

A análise de Big Data compreende técnicas e tecnologias para capturar, armazenar, transferir, analisar e visualizar uma quantidade enorme de dados não estruturados. Esse processo está se tornando um ativo importante para os gerentes de negócios, devido à sua capacidade de criar informações e valor de conhecimento (VERMA; BHATTACHARYYA; KUMAR, 2018).

O gerenciamento de qualidade Big Data é crítico para os aplicativos de IoT, especialmente para a análise de dados. (GE, BANGUI, BUHNOVA, 2018). Assim, não restam dúvidas de que as aplicações da tecnologia de Big Data podem melhorar a vantagens competitivas de empresas e

organizações. (LAI,2017). Big Data assim, é um ativo importante para ajudar empresas a aumentar as vantagens da competitividade no mercado. (LAI, 2017)

Para Utz, Neumann e Tafreschi (2018), a qualidade dos dados é um dos principais requisitos para a tomada de decisões bem-sucedidas na Indústria 4.0. Trata-se de um fator importante no fornecimento de soluções de alta qualidade. Para Firmani et al. (2018), as dimensões para qualidade da informação podem ser agrupadas em clusters: precisão, completude, consistência, redundância, legibilidade, acessibilidade, confiança e utilidade. A qualidade dos dados é uma característica essencial que determina a confiabilidade dos dados para tomada de decisões. Novas tecnologias, como as bases de dados Hadoop, NoSQL e MPP, surgiram para resolver os desafios do Big Data e permitir que novos tipos de produtos e serviços sejam entregues pelas empresas. (ABDULLAH et al., 2015).

Neste contexto, o conteúdo da informação nos dados de inspeção deve ser alto. Para dados digitalizados, recursos limitados de armazenamento, manipulação e análise podem criar problemas em sua análise. Thoben, Wiesner e Wuest (2017) citam como desafios no gerenciamento de Big Data o aumento da complexidade, dinâmica do sistema, qualidade de dados, validação e verificação e a comunicação entre as máquinas. Testar o Big Data é um dos principais desafios que a indústria enfrenta hoje em dia. (KAMDI, 2018).

A literatura de Big Data, tanto acadêmica como profissional, tem forte foco nas oportunidades, mas pouca atenção às ameaças que resultam do aproveitamento errado de dados. (CLARKE, 2016). Além disso, existem requisitos para infraestruturas de Big Data que se diferenciam em cada setor. Problemas como exatidão, integridade, riqueza de contexto, disponibilidade e duração do arquivamento já foram identificados como áreas onde a indústria precisa melhorar a qualidade dos dados para análise avançada. (MOYNE; ISKANDAR, 2017). Os fabricantes precisam acessar e trabalhar facilmente com dados de fabricação, não importando onde estejam localizados ou que aplicativos os criam. (WOOL et al., 2018). Assim, há a necessidade de verificar a precisão dos dados, eliminando o ruído através de metodologias de limpeza de dados. (MAZAHUA et al. 2016). A limpeza de dados é o processo de detectar e remover entradas imprecisas em um conjunto de dados. (GALLAGHER et al., 2018). Isso é para garantir a qualidade dos dados para que as decisões que são feitas a partir dos dados coletados são precisas e eficazes. (MAZAHUA et al. 2016).

## Metodologia

Para criar uma amostra seleta de publicações sobre o tema, primeiramente, foi definido o banco de dados para a busca de material e então selecionados os termos de busca.

O banco de dado escolhido foi o Google Acadêmico®. Todas as buscas foram limitadas à resultados em inglês, português e espanhol, havendo limitação a artigos mais recentes que 2010. A definição dos termos de busca foi baseada no tema de estudo, buscando abranger uma grande gama de publicações. Os algoritmos de busca utilizados foram:

1. "data quality" AND "*Big Data*" AND ("industry 4.0" OR "factory 4.0" OR "smart manufacturing");
2. "*Big Data* quality"

Oriundos da base de dados foram considerados ao todo 1354 documentos para análise de alinhamento ao tema. Desta amostra inicial foram desconsiderados os documentos cujo texto completo não estava disponível em Open Source ou cujo idioma era incompatível com o critério adotado. Ainda foram excluídas as publicações cujo título e resumo não se mostraram relacionados ao tema da revisão. Como resultado foram obtidos 162 publicações que efetivamente relacionavam-se ao tema. A leitura completa das obras reduziu a amostra final à 66 publicações. A Figura 1 resume os passos adotados para a construção da amostra final de

artigos considerados na revisão da literatura.

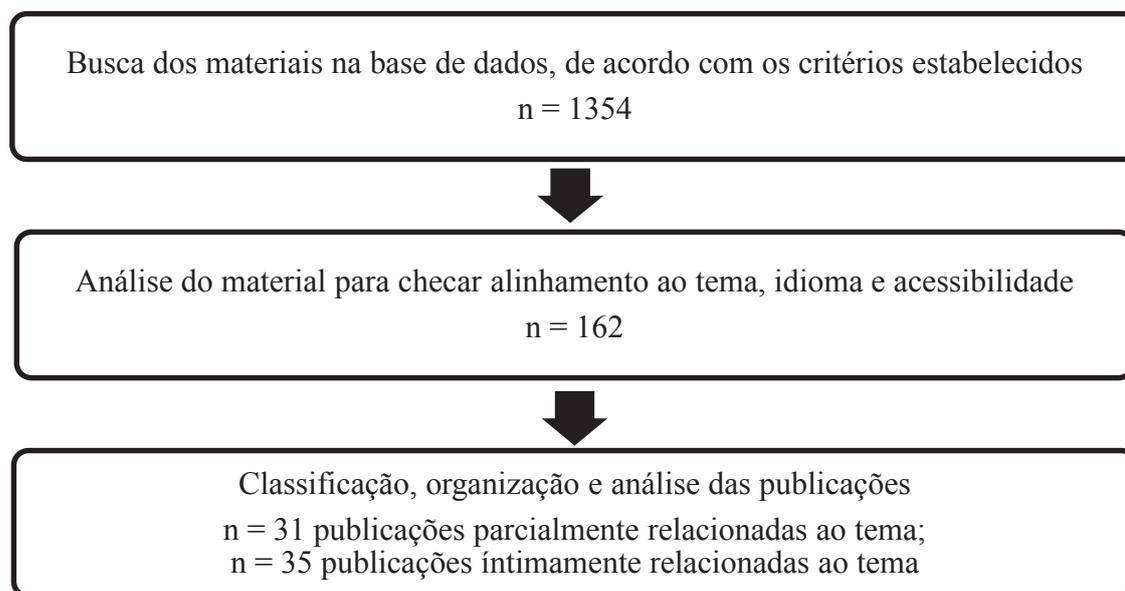


Figura 1 – Procedimento adotado para construção da amostra final de artigos estudados na revisão da literatura

A partir da amostra final, foi realizado uma análise crítica de cada publicação, e um estudo sobre o atual estado da análise de qualidade em *Big Data*. A Revisão Sistemática da Literatura apresentada neste artigo considera todas as publicações encontradas, tanto àquelas que são parcialmente relacionadas ao tema quanto trabalhos cujo foco é a investigação da qualidade de *Big Data*, de forma teórica ou prática.

### Revisão Sistemática da Literatura

A pesquisa de qualidade de dados pode ser rastreada até os anos 80, mas com o advento da era de Big Data, a qualidade de Big Data tem vindo a emergir como uma nova área de pesquisa. (GE, BANGUI, BUHNOVA, 2018). Haug e Arlbjorn (2011) identificam um conjunto de barreiras gerais para contra a garantia da alta qualidade de dados. Os resultados da pesquisa indicam que a falta de delegação de responsabilidades e a atualização dos dados são os aspectos que tem o maior impacto na qualidade dos dados. Além disso, a pesquisa mostra que a grande maioria das empresas acredita que sofre perdas devido a má qualidade dos dados.

Alguns dos trabalhos mais importantes da amostra datam de 2014: Hazen et al. (2014) introduziu o problema de qualidade dos dados no contexto da gestão da cadeia de abastecimento (SCM) e propos métodos para monitoramento e controle da qualidade dos dados. No mesmo ano, Woodall et al. (2014) determinam empiricamente que a qualidade dos dados é fator da dimensão dos dados. Como resultado, os autores confirmam que, com base em um dos exemplos estudados, a qualidade dos dados tem um impacto cada vez mais negativo nos resultados de classificação, à medida que o tamanho do conjunto de dados aumenta. Contudo, o método de classificação, usado neste caso, produziu melhores resultados com um maior conjunto de dados de entrada para treinar o modelo, mesmo proporcionando maior quantidade de erros. Casale (2015) considera a questão de como a engenharia dirigida por modelos deve suportar os softwares de uso intensivo de dados sistemas. Os autores analisam alguns dos principais desafios envolvidos no desenvolvimento destas ferramentas e nos modelos subjacentes.

Li, Gong e Liu (2016) estudam como os métodos intensivos de dados de avaliação de ciclo de vida de materiais são dependentes da alta qualidade e confiabilidade dos dados. Utz, Neumann e Tafreschi (2018) apresentam em seu artigo um modelo de processo específico visando

melhoria de disponibilidade de dados através da limpeza dos mesmo. Para eliminar o ruído e reconstruir valores faltantes, modelos de regressão e modelos probabilísticos assim como métodos de detecção discrepantes são aplicados. Madhikermi et al. (2016) abordam a Tomada de Decisão Multi-Critérios e a qualidade dos dados, dificilmente considerada nos sistemas de manutenção especializados existentes. No artigo, os autores desenvolvem um framework de avaliação de qualidade de relatórios de manutenção que permite facilmente avaliar qualidade de relatórios de manutenção em tempo real. O estudo de caso descreve como a ferramenta proposta está sendo usada por um fabricante de equipamentos multinacional finlandês para avaliar e aprimorar práticas de relatórios em um grupo específico ou em um grupo de filiais. Khodabakhsh, Ari e Bakir (2017) focam em seu artigo no estudo da veracidade no setor de petróleo e gás. Os erros de medição nos dados do sensor utilizado são categorizados em duas classes principais pelos autores: erros aleatórios (ruído estatístico) e erros grosseiros (devido a problemas nos dispositivos sensores). Para os autores, os dados precisam ser limpos e reconciliados antes de poderem ser usados no treinamento de algoritmos de mineração. Já Bokrantz et al. (2017) contribuem no campo da simulação de eventos discretos, contribuindo com o estudo sobre empirismo e qualidade de dados na simulação de um processo fabril. Pawar e Thakore (2017) propõem um sistema que melhora a qualidade dos dados coletados para a tomada de decisões de negócios. O documento contribui para fornecer uma solução através da introdução de um novo modelo de avaliação para avaliar e gerenciar a qualidade dos dados de mídia sociais. Santos et al. (2017) propõem a implementação de Big Data Analytics em uma organização multinacional (Bosch Car Multimedia - Braga), como estudo de caso. Para garantir a qualidade dos dados, uma análise preliminar dos dados disponíveis foi feita, identificando os atributos que apresentam anomalias, como valores errôneos ou dados ausentes. Sadiq et al., 2017 delineam um chamado à ação para promover o empirismo em pesquisa de qualidade de dados. No estudo, os autores indicam a presença de um continuum de dados que varia de real para dados sintéticos, o que tem implicações sobre como os métodos de qualidade de dados são avaliados. Song et al., (2017) focam em dados defeituosos gerados pela operação inadequada de componentes físicos e cibernéticos de um CPS de manufatura orientada a serviços (SMCPS), e desenvolvem políticas de gerenciamento efetivas para lidar com tais dados.

Reis e Kenett (2018) descrevem uma estrutura para avaliar, analisar e melhorar a qualidade das informações geradas em estudos empíricos, denominada InfoQ, utilizada no contexto da Indústria de Processamento Químico. Heinrich et al. (2018) propõem um conjunto de cinco requisitos para métricas de qualidade de dados para suportar a incerteza em uma gestão economicamente orientada a qualidade dos dados. Wahudi, Kuk e Janssen (2018) usam um estudo de caso de um grande empresa de telecomunicações para desenvolver um modelo padrão de processo genérico para melhorar a qualidade dos dados.

Dentro da amostra de artigos, ainda foram identificadas outras publicações com caráter de revisão de literatura sobre o tema. Abdullah et al. (2015) analisam as características da qualidade de Big Data e os processos de gerenciamento que estão envolvidos. Fagundes, Macedo e Freund (2018) apresentam um levantamento das publicações relacionadas à qualidade de dados em Big Data na base de dados Web of Science até o ano de 2016. Os autores apresentam um panorama geral das publicações relacionadas à qualidade de dados em ambientes de big, apresentando o local de publicação das pesquisas, uma síntese dos estudos, seus contextos de aplicação e principais autores. Biancone, Secinaro e Brescia (2018) definem qualidade de Big Data através de uma revisão e abordagem sistemática, entre janeiro de 2015 e dezembro 2016. O estudo investiga e fornece alguns pensamentos e ideias sobre o futuro da qualidade do Big Data e sua utilização na Governança em Saúde. O artigo ainda destaca a utilidade da qualidade do Big Data nas escolhas médicas em sistemas de informação.

A qualidade dos dados é crucial para obter o engajamento do usuário e a aceitação de serviços da Indústria 4.0. (DING et al., 2018). Porém, a maioria dos sistemas de automação não realiza

verificações de qualidade nos dados e é difícil avaliar se os dados podem ser confiáveis ou não. (RØDSETH; PERERA; MO, 2016). Segundo Ding et al., a existência dos valores anormais e valores ausentes é principalmente devido a resposta incorreta ou não resposta.

Uma avaliação de disponibilidade de dados consiste em uma análise estatística inicial e de alto nível dos recursos do modelo proposto. Os resultados permitem que o profissional tome uma decisão informada, com base na qualidade e integridade dos dados. (GALLAGHER et al., 2018). Quando grande quantidade de dados está disponível para calcular o recurso identificado, poucos dados ausentes possuem um baixo impacto no recurso extraído. (LEE, KAO, YANG, 2014). Medir e garantir a qualidade de dados significa transparência do processo de coleta de dados, meta-informação no contexto e propósito. Assim, a padronização de dados é a chave para garantir a qualidade dos dados. A falta de padronização pode criar os chamados dados incorretos que podem resultar na perda da confiabilidade dos modelos de análise. (WOOL et al., 2018).

Além desses impactos diretos, dados de baixa qualidade também podem levar a muitos efeitos intangíveis como insatisfação do cliente, tomada de decisão ineficaz e uma capacidade reduzida de executar estratégia (LAMBA; SINGH, 2018).

## Conclusões

As perspectivas para o futuro da pesquisa em qualidade de Big Data são convergentes entre os autores citados. Acredita-se que novos estudos vão incorporar os conhecimentos já existentes e estabelecer sistemas de aprendizagem orientados por dados que envolvam tanto a qualidade quanto as interações humanas. O processamento destes dados em grande escala possui uma grande promessa em estabelecer soluções técnicas mais eficientes e regimes operacionais novos. Novos modelos estatísticos e computacionais são necessários como ferramentas para melhorar tal abordagem.

Por outro lado, as várias fontes de erro que perturbam os processos analíticos devem ser melhor compreendidas para que se facilitem as escolhas de gerentes e tomadores de decisões, quando na implantação e utilização destas tecnologias. Neste sentido, é necessário estudar como integrar dados de diferente fontes e garantir a velocidade de transmissão em tempo real, que representa a base das demais tecnologias 4.0. O papel da qualidade de dados se torna cada vez mais importante na utilização da tecnologia de Big Data, e as generalizações devem ser cautelosas.

Assim, existe uma escolha crítica a ser feita pelos gestores entre esforço de investimento em melhoria de qualidade de dados e o aumento no volume de dados. Já é notável que as empresas que gerenciam seus dados como recurso estratégico e investem em qualidade avançam em confiabilidade, gerando valor tangível ao cliente. Portanto, para manter a competitividade, as empresas devem investir em serviços específicos para Big Data, o que requer treinamento e desenvolvimento da equipe e do sistema de automação.

## Referências

**ABDULLAH, N.; ISMAIL, S. A.; SOPHIAYATI, S.; SAM, S. M.** *Data Quality in Big Data: A Review*. Int. J. Adv. Soft. Comp.. Appl. Vol. 7, n. 3, 2015.

**ALJUMAILI, M.; WANDT, K.; KARIM, R.; TRETEN, P.** "eMaintenance ontologies for data quality support". *Journal of Quality in Maintenance Engineering*. Vol. 21, p. 358-374, 2015.

**BENHENNI, A. L.** *Pragmatic Big Data and smart manufacturing*. IN: 18th International Congress of Metrology, 2017.

**BERG, H.; WILTS, H.;** *Digital platforms as market places for the circular economy—requirements and challenges*. IN: Management Forum, 2018.

- BIANCONE, P. P.; SECINARO, S.; BRESCIA, V.** *A Review of Big Data Quality and an Assessment Method and features of Data Quality for Public Health Information Systems.* International Journal of Management Sciences and Business Research. Vol. 7, n. 1, p. 2226-8235, 2018.
- BOKRANTZ, J.; SKOOGH, A.; LÄMKULL, D.; HANNA, A.; PERERA, T.** *Data quality problems in discrete event simulation of manufacturing operations.* Simulation: Transactions of the Society for Modeling and Simulation International. Vol. 0, n. 0, 2017.
- CASALE, G. et al.** *DICE: Quality-Driven Development of Data-Intensive Cloud Applications.* IN: IEEE/ACM 7th International Workshop on Modeling in Software Engineering, 2015.
- CLARKE, R.** *Big Data, big risks.* Information Systems Journal. Vol. 26, p. 77–90, 2016.
- DING, Z.; MEI, G.; CUOMO, S.; LI, Y.; XU, N.** *Comparison of Estimating Missing Values in IoT Time Series Data Using Different Interpolation Algorithms.* International Journal of Parallel Programming. 2018.
- FAGUNDES, P. B.; MACEDO, D. D. J.; FREUND, G. P.** *A produção científica sobre qualidade de dados em Big Data: um estudo na base de dados web of Science.* Revista Digital de Biblioteconomia e Ciência da Informação. Vol.16, n.1, p. 194-210, 2018.
- FIRMANI, D.; MACELLA, M.; SCANNAPIECO, M.; BATINI, C.** *On the Meaningfulness of “Big Data Quality” (Invited Paper).* Data Science Engineering. Vol. 1, n. 1, p. 6-20, 2016.
- GALLAGHER, C. V.; LEAHY, K.; O'DONOVAN, P. BRUTON, K. O'SULLIVAN, D. T. J.** *Development and application of a machine learning supported methodology for measurement and verification (M&V) 2.0.* Energy & Buildings. Vol. 167, p. 8-22, 2018.
- GANDOMI, A.; HAIDER, M.** *Beyond the hype: Big Data concepts, methods, and analytics.* International Journal of Information Management. Vol. 35, n. 2, p. 137–144, 2015.
- GE, M.; BANGUI, H.; BUHNOVA, B.** *Big Data for Internet of Things: A Survey.* Future Generation Computer Systems. Vol. 87, p. 601–614, 2018.
- GRUSCHKA, N.; LÜSSEM, J.** *Information Quality Challenges in Industry 4.0.* IN: ICIQ 2016, Ciudad Real (Spain), Paper 10, 2016.
- HAUG, A.; ARLBJØRN, J. S.** *Barriers to master data quality.* Journal of Enterprise Information Management Vol. 2, n. 3, p. 288-303, 2011.
- HAZEN, B.T.; BOONE, C. A.; EZELL, J.D.; et al.** *Data Quality for data science, predictive analysis, and Big Data in supply chain management: an introduction to the problem and suggestions for research and applications.* International Journal of Production Economy. Vol. 154, p. 72–80, 2014.
- HEINRICH, B.; HRISTOVA, D.; KLIER, M.; SCHILLER, A.; SZUBARTOWICZ, M.** *Requirements for Data Quality Metrics.* Journal of Data and Information Quality. Vol. 9, n. 2, 2018.
- HÖLSCHER, D.; BAYER, T.; RUF, P.; REICH, C.; GUTY, F.** *A Big Data Quality Preprocessing and Domain Analysis Provisioner Framework using Cloud Infrastructures* IN: ALLDATA 2018: The Fourth International Conference on Big Data, Small Data, Linked Data and Open Data. 2018.
- KAMDI, A.** *Big Data Quality Assurance and Testing Framework.* International Journal for Innovative Research in Science & Technology. Vol. 4, n. 10, 2018.
- KHODABAKHSH, A.; ARI, I.; BAKIR, M.** *Cloud-based Fault Detection and Classification for Oil & Gas Industry.* IN: A. JORGE, G. LARRAZABAL, P. GUILLEN, R.L. LOPES (eds.): Proceedings of the Workshop on Data Mining for Oil and Gas (DM4OG), Houston, Texas, USA, 2017.
- LAI, ST.** *An Iterative and Incremental Data Quality Improvement Procedure for Reducing the Risk of Big Data Project.* Journal of Software. Vol. 12, n. 12, 2017.
- LAMBA, K.; SINGH, S. P.** *Modeling Big Data enablers for operations and supply chain management.* The International Journal of Logistics Management. Vol. 29, n. 2, pp. 629-658, 2018.
- LANEY, D.** *3D Data Management: Controlling Data Volume, Velocity, and Variety.* Application Delivery Strategies. Arquivo 949, 2001.
- LEE, J.; KAO, AH.; YANG, S.** *"Service innovation and smart analytics for industry 4.0 and Big Data environment".* Procedia CIRP. Vol. 16, p. 3-8, 2014.

- LI, X.; GONG, X.; LIU, Y.** *Development and application of basis database for materials life cycle assessment in china*. IN: 17th IUMRS International Conference in Asia (IUMRS-ICA), 2016.
- MADHIKERM, M. KUBLER, S.; ROBERT, J.; BUDA, A.; FRÄMLING, K.** *Data quality assessment of maintenance reporting procedures*. Expert Systems With Applications. Vol. 63, p. 145–164, 2016.
- MAZAHUA, L. R. et al.** *A general perspective of Big Data: applications, tools, challenges and trends*. J Supercomput. Vol 72. P. 3073–3113, 2016.
- MITTAL, A.** *Trustworthiness of Big Data*. International Journal of Computer Applications. Vol. 8, n.9, p. 0975 – 8887, 2013.
- MOYNE, J.; ISKANDAR, J.** *Big Data Analytics for Smart Manufacturing: Case Studies in Semiconductor Manufacturing*. Processes, Vol. 5, n. 9, 2017.
- NGUYEN, T.; ZHOU, L.; SPIEGLER, B.; IEROMONACHOU, P. LIN, Y.** *Big Data analytics in supply chain management: A state-of-the-art literature review*. Computers and Operations Research. Vol. 98, p. 254–264, 2018.
- PAWAR, S. H.; THAKORE, D.** *An Assessment Model to Evaluate Quality Attributes In Big Data Quality*. International Journal of Computer Science Trends and Technology. Vol. 5, n. 2, 2017.
- REIS, M. S.; KENETT, R.** *Assessing the Value of Information of Data-Centric Activities in the Chemical Processing Industry 4.0*. Process Systems Engineering, Vol. 00, n. 0, 2018.
- RØDSETH, O. J.; PERERA, L. P.; MO, B.** *Big Data in Shipping - Challenges and Opportunities*. IN: 15th International Conference on Computer and IT Applications in the Maritime Industries – COMPIT, 2016.
- SADIQ, S. et al.** *Data Quality – The Role of Empiricism*. SIGMOD Record. Vol. 46, n. 4, 2017.
- SANTOS, M.Y.; SÁ, J.O.; COSTA, C.; GALVÃO, J.; ANDRADE, C.; MARTINHO, B.; LIMA, F.V.; COSTA, E. et al.** *A Big Data analytics architecture for Industry 4.0*. IN: World Conference on Information Systems and Technologies. p.175–184, 2017.
- SANTOS, M. Y.; OLIVEIRA E SÁ, J.; ANDRADE, C.; LIMA, F. V.; COSTA, E.; COSTA, C.; MARTINHO, B.; GALVÃO, J.** *A Big Data system supporting Bosch Braga Industry 4.0 strategy*. International Journal of Information Management. Vol. 37, p. 750–760, 2017.
- SONG, Z.; SUN, Y.; WAN, J.; LIANG, P.** *Data quality management for service-oriented manufacturing cyber-physical systems*. Computers and Electrical Engineering. Vol. 64, p. 34-44, 2017.
- THOBEN, KD.; WIESNER, S.** *“Industrie 4.0” and Smart Manufacturing – A Review of Research Issues and Application Examples*. International Journal. of Automation Technology. Vol.11, n.1, 2017.
- UTZ, F.; NEUMANN, C.; TAFRESCHI, O.** *How to Discover Knowledge for Improving Availability in the Manufacturing Domain?* IN: Proceedings of the 51st Hawaii International Conference on System Sciences, 2018.
- VERMA, S.; BHATTACHARYYA, S. S.; KUMAR, S.** *An extension of the technology acceptance model in the Big Data analytics system implementation environment*. Information Processing and Management. Vol. 54, p. 791–806, 2018.
- WOODALL, P.; BOREK, A.; GAO, J.; OBERHOFER, M.; KORONIOS, A.** *An Investigation of How Data Quality is Affected by Dataset Size in the Context of Big Data Analytics*. IN: 19th International Conference on Information Quality (ICIQ), Xi’an, 2014.
- WOOL, J.; SHIN, S.J.; SEO, W.; MEILANITASARI, P.** *Developing a Big Data Analytics Platform for Increasing Sustainability Performance in Machining Operations*. The International Journal of Advanced Manufacturing Technology. 2018.
- YAO, L.; GE, Z.** *Big Data quality prediction in the process industry: A distributed parallel modeling framework*. Journal of Process Control. Vol. 68, p. 1-13. 2018.
- ZIKOPOULOS, P. et al.** *Understanding Big Data: Analytics for Enterprise Class Hadoop and Streaming Data*. New York: McGraw-Hill, 2012.

## ANEXO A – COMPROVANTE DE SUBMISSÃO À REVISTA *COMPUTERS & CHEMICAL ENGINEERING*

### 1 - Página de confirmação de submissão da revista (17/01/2019)

Computers & Chemical Engineering

Paulo Henrique Amorim Santos | My Journals | Log Out | Help EVISE\*

Home
Reports

- ✓ Enter Manuscript Information
- ✓ Upload Files
- ✓ Provide Additional Information
- ✓ Review & Submit

#### Thank you for submitting

You have designated Izabel Zattar as the Corresponding Author of this submission. All communications related to this submission will be sent to Izabel Zattar. The manuscript can now only be accessed from the new Corresponding Author's Homepage.

[Return to your Homepage](#)

### 2 - Detalhes da submissão

#### Manuscript Details

<b>Manuscript number</b>	CACE_2019_58
<b>Title</b>	CRITICAL SUCCESS FACTORS FOR IMPLEMENTING INDUSTRY 4.0 TECHNOLOGIES IN THE CONTINUOUS PROCESS CHEMICAL INDUSTRY
<b>Article type</b>	Review Article

#### Abstract

Industry 4.0 technologies provide great improvements in the productive environment of the continuous chemical industries. The availability of a large amount of real-time data allows the integration of unit operations and process intensification, providing increased profitability, fault predictive diagnostics, and assisting with safety management and production sustainability. However, the industry presents specific obstacles in deploying 4.0 technologies because of its intrinsic complexity. The objective of this article is to discuss the sector-specific difficulties and the Critical Success Factors when implementing Industry 4.0 technologies. In order to achieve this objective, a comprehensive literature review was carried out, in which more than 10,000 documents were analyzed. Among the emerging necessities identified for the sector, the need to simplify complex systems and intensify operations is highlighted. The literature also converges on the urgency for developing reliable systems for adverse event management, as well as the creation of health, safety and environmental assessment models.

<b>Keywords</b>	Industry 4.0; Continuous Processes Chemical Industry; Abnormal Events Management; Chemical Processes Safety; Chemical Plant integration.
<b>Manuscript category</b>	Cyberinfrastructure, informatics and intelligent systems
<b>Corresponding Author</b>	Izabel Zattar
<b>Corresponding Author's Institution</b>	Universidade Federal do Paraná
<b>Order of Authors</b>	Paulo Henrique Amorim Santos, Izabel Zattar, Robson Seleme
<b>Suggested reviewers</b>	Michael Baldea, Ignacio Grossmann, Venkat Venkatasubramanian, Jim Davis, Thomas F. Edgar

#### Submission Files Included in this PDF

##### File Name [File Type]

Cover Letter.doc [Cover Letter]

Highlights.docx [Highlights]

Abstract.docx [Abstract]

CSF FOR IMPLEMENTING I 4.0 TECHNOLOGIES IN THE CONT. PROC. CHEM. IND.docx [Manuscript File]

To view all the submission files, including those not included in the PDF, click on the manuscript title on your EVISE Homepage, then click 'Download zip file'.

## ANEXO B – CERTIFICADO DE PUBLICAÇÃO NO VIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



**CERTIFICADO 2018**

---

O trabalho

Revisão sobre a qualidade de Big Data no contexto da Indústria 4.0

sob autoria de

PAULO HENRIQUE AMORIM SANTOS  
IZABEL C ZATTAR

foi publicado nos anais do **VIII CONBREPRO**.  
Realizado de 05 a 07 de dezembro de 2018, no campus Ponta Grossa - PR  
da Universidade Tecnológica Federal do Paraná (UTFPR).

Realização: 

Apoio: 