

Casos baseados em *Machine Learning* (indústria 4.0): Revisão Sistemática – benefícios gerados

Bianca Tasso Afonso (UFPR) biancatassoafonso@gmail.com
Jéssica Bruna Perussi (UFPR) jessicabrunaperussi@hotmail.com
Robson Seleme (UFPR) robsonseleme@hotmail.com

Resumo:

Em tempos de um novo modelo de indústrias e dos avanços tecnológicos, introduzidos pela Indústria 4.0, a utilização de modelos preditivos e o aprendizado automático tornam-se elementos importantes a serem alcançados. Na linha de produção, os sistemas automatizados geram dados que alimentam uma rede de aprendizado de máquina, sendo os mesmos analisados em tempo real e fornecendo informações que aumentam a produtividade e minimizam os tempos de resposta da entrega, ajudando a otimizar processos complexos de produção. Esses dados, posteriormente, são utilizados para treinar modelos preditivos. Neste artigo é apresentada uma revisão sistemática dos estudos de caso com aplicações de *machine learning* em processos da indústria 4.0, seus resultados e os benefícios gerados. A pesquisa foi realizada nas bases *Web of Science*, *Scopus* e *ScienceDirect*, utilizando uma combinação de grupos de palavras-chave que representam *Machine Learning* e Indústria 4.0. O resultado obtido apresenta dados que geram *insights* sobre o funcionamento de máquina, a fim de reconhecer objetos, auxiliar na tomada de decisão e evitar erros, falhas e pausas na produção.

Palavras chave: *Machine Learning*, Indústria 4.0, *Smart manufacturing*.

Cases based on Machine Learning (industry 4.0): Systematic Review - benefits generated

Abstract

In times of a new industries model and technological advances, introduced by the Industry 4.0, the use of predictive models and the automatic learning became important elements to be reached. On the production line, the automated systems generate data that feed a machine learning network, which are analyzed in real time and provide information that increases the productivity and minimizes delivery response times, helping to optimize complex production processes. These data, posteriorly, are used to train predictive models. In this paper is presented a systematic review of case studies with machine learning applications in industry 4.0 processes, their results and benefits generated. The research was performed at the Web of Science, SCOPUS and ScienceDirect databases, using a combination of key-words groups that represent Machine Learning and Industry 4.0. The obtained result presents data that generated insights about the machine operation, in order to recognize objects, to aid in the decision making and to avoid errors, failures and brakes in the production.

Key-words: Machine learning, Industry 4.0, Smart manufacturing.

1. Introdução

A quarta revolução industrial define novos parâmetros para os quais a atual indústria deve caminhar. A identificação de falhas em tempo hábil e redução de ociosidade de máquina confere diversas vantagens em um ambiente que torna-se cada vez mais competitivo e exigente, tanto

no que diz respeito à qualidade de seus produtos, como em seus serviços prestados e tempo de resposta (ADEMUJIMI, BRUNDAGE E PRABHU, 2017). Nas fábricas inteligentes, as máquinas são autônomas em suas tarefas, transmitindo e incorporando informações de forma a interagir com o mundo físico e virtual (PARTICKE *et al*, 2017).

Em meio a este contexto, surge a aplicabilidade do *machine learning* (aprendizado de máquina) que, segundo Patel *et al* (2016) e Voyant *et al* (2017), é diversa e visa atender às necessidades impostas pelo mercado: reconhecimento de padrão, classificação de problemas, filtro de *spam*, mineração de dados e previsão de problemas.

O objetivo do presente trabalho é estudar pesquisas que explorem a aplicabilidade do aprendizado de máquina na Indústria 4.0. Uma revisão sistêmica foi realizada buscando estudos de casos para uma análise da contribuição da informação preditiva diante os principais objetivos da nova concepção da indústria.

2. Revisão da literatura

A revisão da literatura da pesquisa em questão irá abordar, brevemente, os conceitos de indústria 4.0 e seus pilares. Em seguida, serão tratados os temas de capacidade em tempo real e *machine learning*.

2.1 Indústria 4.0 e seus cenário

A quarta revolução industrial, também denominada de indústria 4.0, incorpora avanços tecnológicos para o desenvolvimento do que é chamado de fábrica inteligente. Produtos e máquinas tornam-se inteligentes de forma que não só possuem habilidades de computação, comunicação e controle, mas também autonomia e sociabilidade (WANG *et al*, 2015). Hermann, Pentek e Otto (2015) definem princípios de *design* para os cenários Indústria 4.0. São seis as características que as instituições identificam como possíveis pilotos para a Indústria 4.0: Interoperabilidade, virtualização, descentralização, capacidade em tempo real, orientação a serviço e modularidade.

1. Interoperabilidade: é a capacidade dos sistemas cyber-físicos, indivíduos e fábricas inteligentes comunicarem-se uns com os outros por meio da Internet das Coisas e da Internet (HERMANN, PENTEK E OTTO, 2015);
2. Virtualização: propõe a criação de uma cópia virtual do sistema físico para fins de planejamento e avaliação (KUNZ *et al*, 2016)
3. Descentralização: tomada de decisão de acordo com as necessidades da produção, podendo ser realizada por diferentes sistemas autônomos (HERMANN, PENTEK E OTTO, 2015);
4. Capacidade em tempo real: para Jodlbauer, Schagerl e Brunner (2016) é a obtenção e tratamento de dados de forma imediata e capacidade de resposta em tempo real;
5. Orientação a serviço: a Indústria 4.0 está aliada ao conceito de *Internet of Services* (IOS), os quais podem beneficiar tanto o ambiente interno como o ambiente externo à organização Foidl e Felderer (2016)
6. Modularidade: dentro dos conceitos de Indústria 4.0, as indústrias precisam oferecer flexibilidade como, por exemplo, alteração de tarefas das máquinas, mudanças de características dos produtos, flutuações sazonais e variação de demanda HERMANN, PENTEK E OTTO, 2015).

2.2 Machine learning

O *Machine Learning* (ML) – aprendizado de máquinas em português – é classificado como um campo da Inteligência Artificial (AI), tendo evoluído da teoria de reconhecimento de padrões e aprendizagem computacional, segundo Mahdavinejad *et al* (2018)

De acordo com Voyant *et al* (2017), o *machine learning* é capaz de aprender partindo de previsões de dados, resultando em previsões orientadas e/ou apresentando soluções de saída. Para isso, um grupo de métodos de é utilizado, que desenvolvendo algoritmos e tornando as previsões mais precisas para novos dados, segundo Patel *et al* (2016). Por esta razão, um dos pontos críticos do *machine learning* se trata da qualidade dos mesmos, visto que os algoritmos aprendem com estes dados (VOYANT *et al*, 2017). Assim, Voyant *et al* (2017) e Mahdavinejad *et al* (2018) destacam que a vantagem deste método é a capacidade de resolver problemas que não podem ser representados por meio de algoritmos explícitos.

Para Guégan e Hassani (2018), a característica de aprendizado por padrões gerais, experiência, bem como a precisão das previsões e refinamento dos dados permite um grande número de áreas de atuação do *machine learning*.

Os dados de entrada dos algoritmos de aprendizagem são denominados, segundo Voyant *et al* (2017) e Mahdavinejad *et al* (2018), conjunto de treinamento. Existem, de um modo geral, existem 3 (três) formas de aprendizagem, segundo Kourou *et al* (2015) e Patel *et al* (2016): supervisionada, semi-supervisionada e não supervisionada.

O modo de aprendizagem supervisionada é definido por Kourou *et al* (2015), Voyant *et al* (2017) e Mahdavinejad *et al* (2018) como um conjunto rotulado de dados objetivando estimar ou mapear os dados de entrada para a saída desejada. Aplicações nas quais estes rótulos possuem uma quantidade finita de categorias distintas são conhecidas como tarefas de classificação; aquelas com uma ou mais variáveis contínuas são conhecidas como regressão (MAHDAVINEJAD ET AL, 2018).

Por sua vez, o modo de aprendizagem não supervisionada trata-se de um modelo capaz de encontrar estruturas ocultas nos dados de entrada, sem a necessidade de conhecer as saídas, segundo Voyant *et al* (2017). Dentre os principais métodos utilizados, estão a mineração de dados, extração de recursos e *clustering*, aplicados no pré-processamento, agrupando dados que possuem características semelhantes, segundo Kourou *et al* (2015), Voyant *et al* (2017) e Mahdavinejad *et al* (2018).

O modo de aprendizagem semi-supervisionada possui conjunto de dados de treinamento rotulados e não rotulados, sendo caracterizado por uma combinação dos modos supervisionado e não supervisionado (KOUROU ET AL, 2015).

Para os métodos citados – classificação, regressão, *clustering* e extração de recursos – existem os algoritmos de aplicação e, segundo Mahdavinejad *et al* (2018) e Oh *et al* (2018), os seguintes podem ser destacados: *Naive Bayes*, *Support Vector Machine* (SVM), Regressão linear, classificação e árvore de decisão. De acordo com Kourou *et al* (2015), estes algoritmos possuem maior desempenho se menores, pois os dados desnecessários são eliminados e os modelos desenvolvidos tornam-se mais robustos.

3. Metodologia

A pesquisa deste artigo consistiu na realização de uma Revisão Sistemática da Literatura (RSL), visando encontrar pesquisas que contemplem estudos de casos relacionados ao assunto proposto e identificar aqueles que seriam relevantes ao conteúdo deste artigo. A escolha pela aplicação de uma RSL se deu pelo fato de se tratar de uma ferramenta para identificar, pesquisar e analisar

materiais publicados e disponíveis no assunto abordado, segundo Kitchenham e Charters (2007). Para tal os autores indicam que três etapas são necessárias para a elaboração da RSL, conforme apresentado a seguir: Planejar a revisão; Realizar a revisão; Documentar a revisão.

3.1 Planejar a revisão

Na etapa de planejamento da revisão da literatura é necessário, segundo Kitchenham e Charters (2007) identificar a necessidade de revisão, especificar as perguntas de pesquisa, desenvolver um protocolo de revisão e validar o mesmo. A necessidade de realizar esta revisão se dá pelo fato de a pesquisa se tratar de uma revisão da literatura, e sua relevância é apresentada no tópico de Introdução deste artigo, juntamente com a pergunta de pesquisa. Em seguida, foi definido o protocolo de revisão e feita a validação do mesmo obtendo o seguinte resultado:

- Definir as palavras-chave;
- Definir as bases de busca dos materiais;
- Não restringir o intervalo de tempo;
- Considerar todos os tipos de documento para avaliação;
- Remover arquivos duplicados;
- Realizar leitura dos resumos dos materiais para selecionar apenas estudos de caso.

As palavras-chave definidas para pesquisa foram: 1) *Machine Learning*, 2) *Deep learning*, 3) *Decision Tree*, 4) *Independent Component Analysis*, 5) *ICA*, 6) *Regression*, 7) *Classification*, 8) *Discriminative Model*, 9) *Generative Model*, 10) *Supervised Learning*, 11) *Clustering*, 12) *Support Vector Machine*, 13) *Naïve Bayes*, 14) *Industrie 4.0*, 15) *Industry 4.0*, 16) *Smart Manufacture*, 17) *Smart Manufacturing* e 18) *Smart Factory*.

As bases, por sua vez, são as seguintes: *Web of Science*, *ScienceDirect* e *SCOPUS*. Por se tratar de um assunto atual e das combinações entre as palavras-chave, não foram definidas restrições de intervalo de tempo, assim como foram considerados todos os tipos de documentos.

3.2 Realizar e documentar a revisão

A etapa de realização da revisão consiste, de acordo com Kitchenham e Charters (2007), na aplicação do protocolo de revisão desenvolvido na etapa anterior, extrair e sintetizar os dados. A documentação, por sua vez, consiste em registrar as etapas da pesquisa – conforme apresentado neste tópico de Metodologia –, para que outras pessoas sejam capazes de reproduzi-las fielmente, alcançando os mesmos resultados.

Inicialmente materiais com as palavras-chave definidas foram pesquisados nas bases definidas. Foram utilizados combinadores booleanos para identificação das pesquisas desejadas. Os resultados dessa pesquisa são apresentados na Tabela 1.

Palavras-chave	Web of Science	SCOPUS	ScienceDirect
"Machine Learning" OR "Deep learning" OR "Decision Tree" OR "Independent Component Analysis" OR "ICA" OR "Regression" OR "Classification" OR "Discriminative Model" OR "Generative Model" OR "Supervised Learning" OR "Clustering" OR "Support Vector Machine" OR "Naïve Bayes" AND "Industrie 4.0" OR "Industry 4.0" OR "Smart Manufacture" OR "Smart Manufacturing" OR	161	316	80

"Smart Factory"

Fonte: os Autores (2018)

Tabela 1 – Resultados da primeira etapa da pesquisa

Em seguida, foi utilizado o *software Mendeley* para remover as pesquisas duplicadas, restando a seguinte quantidade de artigos: *Web of Science* – 63 artigos; SCOPUS – 261 artigos e *ScienceDirect* – 67 artigos.

Para este total de artigos realizou-se a leitura completa dos respectivos resumos, visando selecionar somente aqueles que se tratavam de estudos de caso baseados em *machine learning*. Após esta etapa o total de artigos selecionados para leitura completa foi de: *Web of Science* – 3 artigos; SCOPUS – 19 artigos e *ScienceDirect* – 11 artigos.

Após a leitura integral e definida a relevância ao objetivo desta pesquisa, o total de artigos selecionados é apresentado na Tabela 2.

Palavras-chave	Web of Science	SCOPUS	ScienceDirect
"Machine Learning" OR "Deep learning" OR "Decision Tree" OR "Independent Component Analysis" OR "ICA" OR "Regression" OR "Classification" OR "Discriminative Model" OR "Generative Model" OR "Supervised Learning" OR "Clustering" OR "Support Vector Machine" OR "Naïve Bayes" AND "Industrie 4.0" OR "Industry 4.0" OR "Smart Manufacture" OR "Smart Manufacturing" OR "Smart Factory"	0	8	4

Fonte: os Autores (2018)

Tabela 2 – Resultados da leitura dos resumos dos artigos

Após a leitura integral dos artigos, foram desconsiderados aqueles que não apresentavam estudo de caso – aplicação de *machine learning* – e aqueles em que os estudos de caso que não estavam ambientados no contexto da indústria 4.0.

4. Análise e resultados

Conforme apresentado na Tabela 2, foi obtido um total de 12 artigos de estudo de caso aplicados em ambientes de indústria 4.0. O total de artigos selecionados na base *Web of Science*, foi 0, entretanto este valor não significa a inexistência de artigos de estudo de caso. Pesquisas duplicadas nas bases foram removidas, ou seja, podem haver estudos que foram eliminados que estão na base *Web of Science*. Dentre os 3 selecionados – após a leitura do resumo – para leitura integral, identificou-se que nenhum destes estudos de caso estava aplicado à ambientes da 4.0.

Os dados dos artigos selecionados para análise são apresentados na Tabela 3, com as seguintes informações: “Título da pesquisa”, “Autores”, “Ano de publicação” e “Revista”.

Título da pesquisa	Autores	Ano de publicação	Revista/Congresso
<i>Deep learning for big data applications in CAD and PLM – Research review, opportunities and case study</i>	Dekhtiar <i>et al</i>	2018	<i>Computers in Industry</i>
<i>Smart optimization of a friction-drilling process based on boosting ensembles</i>	Bustillo <i>et al</i>	2018	<i>Journal of Manufacturing Systems</i>
<i>Smart manufacturing analytics application for semi-continuous manufacturing process – a use case</i>	Mehta, Butkewitsch-Choze e Seaman	2018	<i>Procedia Manufacturing</i>
<i>Validation of PERFoRM reference architecture demonstrating an application of data mining for predicting machine failure</i>	Chakravorti <i>et al</i>	2018	<i>Procedia CIRP</i>
<i>Visual inspection system for smart manufacture of home appliances</i>	Liu, Gu e Wang	2017	<i>5th IEEE International Symposium on Robotics and Intelligent Sensors, IRIS 2017</i>
<i>Adaptive SVM-based real-time quality assessment for primer-sealer dispensing process of sunroof assembly line</i>	Oh <i>et al</i>	2018	<i>Reliability Engineering and System Safety</i>
<i>Auto-sorting System Towards Smart Factory based on Deep learning for Image Segmentation</i>	Wang <i>et al</i>	2018	<i>IEEE Sensors Journal</i>
<i>Real-time predictive maintenance for wind turbines using Big Data frameworks</i>	Canizo <i>et al</i>	2017	<i>2017 IEEE International Conference on Prognostics and Health Management, ICPHM 2017</i>
<i>Machine learning predictive model for industry 4.0</i>	Candanedo <i>et al</i>	2018	<i>Communications in Computer and Information Science</i>
<i>A data-driven approach of load monitoring on laminated composite plates using support vector machine</i>	Gwon e Fekrmandi	2018	<i>Proceedings of SPIE - The International Society for Optical Engineering</i>
<i>From measurements to knowledge - Online quality monitoring and smart manufacturing</i>	Tamminen <i>et al</i>	2018	<i>Advances in Data Mining. Applications and Theoretical Aspects</i>
<i>Quality prediction modeling for multistage manufacturing based on classification and association rule mining</i>	Kao <i>et al</i>	2017	<i>2nd International Conference on Precision Machinery and Manufacturing Technology, ICPMMT 2017</i>

Fonte: os Autores (2018)

Tabela 3 – Informações básicas dos artigos selecionados

De acordo com os dados apresentados na tabela 3, verificou-se que todas as pesquisas selecionadas são dos de 2017 e 2018, das quais 75% são do ano de 2018. Esta informação representa a atualidade do tema e o quanto o mesmo está evoluindo, expandindo suas aplicações – em diversas áreas – e o espaço ainda existente para inovações e propostas de aplicação.

Com relação às revistas e congressos de publicação não há nenhuma repetição, exceto pelo *IEEE Xplore Digital Library*, com um total de 3 pesquisas publicadas pelo editor em diferentes

congressos e no *journal* do mesmo.

Outras informações analisadas nas pesquisas foram os “Objetivo(s)”, “Método”, “Aplicação” e “Resultados” apresentados na Tabela 4.

Título da pesquisa	Objetivo(s)	Método	Aplicação	Resultados
<i>Deep learning for big data applications in CAD and PLM – Research review, opportunities and case study</i>	Apresentar soluções e ferramentas que permitem o desenvolvimento de sistemas de apoio à decisão e processamento de dados de imagens	<i>Deep learning</i>	Sistema de apoio de decisão e processamento de imagens	O modelo apresentado foi considerado modesto pelos autores, podendo ser estendido em larga escala para sistemas empresariais. Em conclusão, o modelo <i>deep learning</i> se apresenta bastante eficiente no que para solucionar problemas relacionados à manufatura
<i>Smart optimization of a friction-drilling process based on boosting ensembles</i>	Propor uma nova estratégia para contornar as limitações para altos custos de experimento com relação ao tamanho do conjunto de dados em processos de fricção-perfuração	Rede neural artificial e árvore de decisão	Testes para processos de fricção-perfuração	Os resultados da modelagem mostraram que as técnicas de <i>machine learning</i> são capazes de extrair informações de um pequeno conjunto de dados de testes de perfuração por atrito, desde que os dados de entrada não sejam muito reduzidos
<i>From measurements to knowledge - Online quality monitoring and smart manufacturing</i>	Desenvolver um sistema de monitoramento <i>on-line</i> de qualidade para adquirir informações e compartilhar com operadores, ajudando na descoberta de novas soluções alternativas de melhoria de produtos e processo de fabricação.	<i>Machine learning</i> para integrar diferentes tipos de métodos de modelagem estatística no monitoramento da qualidade	Qualidade de produto e processos de fabricação	Os resultados codificados por cores conferem fácil interpretação visual, sendo satisfatório para os dois estudos de caso
<i>Smart manufacturing analytics application for semi-continuous manufacturing process – a use case</i>	Discutir um estrutura de análise de dados para processos de manufatura semi-contínuos	Uso dos métodos de classificação e algoritmo <i>Support Vector Machines</i> (SVM)	Qualidade do produto	A estrutura proposta teve como base o <i>machine learning</i> , para criar métodos mais confiáveis e modelos de processos mais robustos, obtendo-se êxito
Título da pesquisa	Objetivo(s)	Método	Aplicação	Resultados

<i>Validation of PERFoRM reference architecture demonstrating an application of data mining for predicting machine failure</i>	Melhorar a flexibilidade da produção de partes de carcaça de compressores industriais e separadores de gás	Uso do modelo árvore de decisão para exploração e classificação dos dados	Análise de causa raiz e suporte na tomada de decisões na manutenção	Implantação de programa de agendamento das paradas de manutenção, evitando paradas inesperadas e geração de um modelo preditivo de decisão
<i>Visual inspection system for smart manufacture of home appliances</i>	Utilizar câmeras de auto-aprendizagem em robôs para inspeção da fabricação de eletrodomésticos	Aplicação de diferentes métodos de <i>machine learning</i> e estrutura em <i>cloud computing</i>	Inspeção visual de eletrodoméstico	Remoção de trabalhos complicados e tediosos para as áreas de engenharia e ajustes de parâmetros
<i>Adaptive SVM-based real-time quality assessment for primer-sealer dispensing process of sunroof assembly line</i>	Propor uma estrutura de pré-processamento de dados para tomada de decisão e implementar um sistema de avaliação de qualidade	Aplicação de <i>Support Vector Machine</i> (SVM) adaptado, originando o modelo <i>Adaptive Support Vector Machine</i> (ASVM)	Validação da qualidade de produto	Os resultados apresentaram precisão de 99% do modelo ASVM e, ao detectar um defeito, um alerta é gerado para que especialistas possam verificar
<i>Auto-sorting System Towards Smart Factory based on Deep learning for Image Segmentation</i>	Propor um sistema de classificação automática de detecção de triagem de peças de máquinas	<i>Deep learning</i> e classificação	Deteção por imagem	O modelo desenvolvido reconheceu, de forma eficiente e precisa, o objeto das imagens captadas pelos sensores visuais
<i>Real-time predictive maintenance for wind turbines using Big Data frameworks</i>	Apresentar uma abordagem de manutenção preditiva para um Big Data a fim de prever falhas de turbinas eólicas	Modelo preditivo monitorado pelo algoritmo <i>Random Forest</i> , <i>machine learning</i> , classificação de dados e arquitetura de <i>Big Data</i> em <i>cloud computing</i>	Qualidade de produção e detecção de falhas	Os modelos preditivos obtiveram uma taxa de sucesso de 81%-85% e uma precisão geral de 76%. Entretanto, a precisão dos modelos para 2 das 17 turbinas eólicas diminuíram entre 70%-75%. Quanto à precisão entre os erros, a hipótese é de que quanto mais classes, pior a precisão para modelos preditivos
<i>Machine learning predictive model for industry 4.0</i>	Utilizar algoritmos de <i>machine learning</i> para projetar modelos preditivos com base em dados do sistema de aquecimento, ventilação e ar condicionado para testar o desempenho do equipamento e observar se a temperatura ideal é mantida	Regressão	Determinar se a temperatura do equipamento está sendo mantida	A precisão do modelo é semelhante ao <i>Random Forest</i> e prevê o mau funcionamento do sistema de aquecimento, ventilação e ar condicionado. Para grandes volumes, o ideal é implementar outras técnicas de <i>machine learning</i> voltadas ao uso de conjuntos de dados maiores
Título da pesquisa	Objetivo(s)	Método	Aplicação	Resultados

<i>A data-driven approach of load monitoring on laminated composite plates using support vector machine</i>	Investigar a resposta da superfície ao método de excitação, utilizando um método baseado em dados para monitoramento de carga em uma estrutura de placa composta laminada	<i>Support Vector Machine (SVM)</i>	Detectar parafusos soltos, delaminação em estruturas compostas, corrosão interna em dutos e monitoramento de carga e impacto	O modelo classificou corretamente com uma precisão de até 99,8%
<i>Quality prediction modeling for multistage manufacturing based on classification and association rule mining</i>	Propor uma combinação de análise de componentes de uma linha de produção	Uso de algoritmo de classificação e mineração de regras de associação	Qualidade do produto acabado e análise de causas raízes	O modelo auxiliou na obtenção de informações de qualidade, permitindo melhorias de processo e evitando defeitos. O modelo pode, em alguns casos, otimizar o processo de fabricação

Fonte: os Autores (2018)

Tabela 4 – Resumo do conteúdo abordado nos artigos de estudo de caso selecionados

Conforme analisado com relação aos objetivos, percebeu-se diversas aplicações voltadas à acompanhamento da qualidade de produtos, apoio na tomada de decisões e previsões, representando um total de aproximadamente 58% de estudos de caso voltados para inspeção e qualidade.

Dentre os métodos e algoritmos de *machine learning* utilizados, os que apresentam maior aplicação são, respectivamente: classificação, aplicado em 42% dos estudos e *Support Vector Machine (SVM)*, aplicado em 25% dos estudos.

Em todos os estudos de caso analisados, a aplicação de *machine learning* resultou em melhorias de processo, qualidade, e análise de dados. Em alguns estudos de caso “*Smart optimization of a friction-drilling process based on boosting ensembles*” e “*Machine learning predictive model for industry 4.0*”, percebeu-se que a quantidade de dados é um fator de relevância e, de acordo com essas quantidades, outros métodos de *machine learning* devem ser aplicados para melhor desempenho.

Outra observação se faz com relação às aplicações em diversas áreas da indústria 4.0 do *machine learning*, desde turbinas eólicas à inspeção de eletrodomésticos. Desta forma percebeu-se a vasta aplicação dos métodos e as diversas áreas em que estes podem ser aplicados.

5. Considerações finais e conclusões

O presente trabalho propôs uma análise dos estudos de casos sobre a aplicação de *machine learning* na Indústria 4.0. Para isso, se realizou uma revisão sistêmica da literatura nas bases *Web of Science*, *Scopus* e *Science Direct*. Por meio dessa pesquisa, observou-se que a maioria das pesquisas de *machine learning* são destinados à propostas e experimentos, discorrendo-se sobre a importância da aplicação de *machine learning* no modelo da nova indústria, porém com poucas aplicações (estudos de casos).

Dentre as pesquisas analisadas, somente 12 enquadraram-se na proposta de estudo deste artigo, sendo todos muito recentes, ano de 2017 e 2018. Apesar de, em sua maioria, os resultados serem

positivos, a contribuição é pequena diante da real significância do uso de *machine learning* nas proporções atuais da Indústria 4.0, sendo esta um das propostas de trabalho de pesquisas futuras.

Apresenta-se que o principal benefício relatado pelos os estudos de casos está voltado a qualidade, sete dos doze trabalhos foram aplicados pra identificação de falhas e/ou análise de causas, os demais trabalhos são destinados a detecção de objetos e tomada de decisão em diferentes finalidades: flexibilização, redução de custos e programação da produção.

Conclui-se que a utilização de *machine learning* é caracterizado nos seis princípios de *design* de cenários descritos no item 2. Revisão da literatura: Interoperabilidade, pois contribui no entendimento da troca de dados; Virtualização no âmbito de identificar a lógica das operações e aumentar sua agilidade e flexibilidade, permitindo potencializar decisões táticas; Descentralização uma vez que permite recebimento de informação de várias fontes; Capacidade em tempo real diante da velocidade do uso da informação para detecção, prevenção e resolução de problemas em nível operacional; Orientação a serviços devido as demandas por um menor tempo; e Modularidade, auxiliando a repensar modo de agir e se organizar.

Outra proposta para trabalhos futuros seria a realização de um levantamento e análise das propostas de uso do *machine learning* e seus conceitos dentro da Indústria 4.0 e quais os objetivos visam alcançar.

“O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.”

Referências

ADEMUJIMI, T. T.; BRUNDAGE, M. P.; PRABHU, V. V. *A Review of Current Machine Learning Techniques Used in Manufacturing Diagnosis*. IFIP Advances in Information and Communication Technology, Vol. 513, p. 407–415, 2017.

BUSTILLO, A.; URBKAIN, G.; PEREZ, J. M.; PEREIRA, O. M.; LACALLE, L. N. DE. *Smart optimization of a friction-drilling process based on boosting ensembles*. Journal of Manufacturing Systems, 2018.

CANDANEDO, I. S.; NIEVES, E. H.; GONZÁLEZ, S. R.; MARTÍN, M. T. S.; BRIONES, A. G. *Machine learning predictive model for industry 4.0*. Communications in Computer and Information Science, Vol. 877, p. 501–510, 2018.

CANIZO, M.; ONIEVA, E.; CONDE, A.; CHARRAMENDIETA, S.; TRUJILLO, S. *Real-time predictive maintenance for wind turbines using Big Data frameworks*, 2017 IEEE International Conference on Prognostics and Health Management, ICPHM 2017.

CHAKRAVORTI, N.; RAHMAN, M. M.; SIDOUMOU, M. R.; WEINERT, N.; GOSEWEHR, F.; WERMANN, J. *Validation of PERFoRM reference architecture demonstrating an application of data mining for predicting machine failure*. Elsevier B.V, 2018.

DEKHTIAR, J.; DURUPT, A.; BRICOGNE, M.; EYNARD, B.; ROWSON, H.; KIRITSIS, D. *Deep learning for big data applications in CAD and PLM – Research review, opportunities and case study*. Computers in Industry, Vol. 100, p. 227–243, 2018.

FOIDL, H.; FELDERER, M. *Research Challenges of Industry 4.0 for Quality Management*, 2016.

GUÉGAN, D.; HASSANI, B. *Regulatory learning: How to supervise machine learning models? An application to credit scoring*. The Journal of Finance and Data Science, Vol. 4, p. 157–171, 2018.

GWON, Y. S.; FEKRMANDI, H. *A data-driven approach of load monitoring on laminated composite plates using support vector machine*. The International Society for Optical Engineering, 2018.

HERMANN, M.; PENTEK, T.; OTTO, B. *Design Principles for Industrie 4.0 Scenarios: A Literature Review*, 2015.

JODLBAUER, H.; SCHAGERL, M.; BRUNNER, M. *Industrie 4.0 versus automation*. ZWF Zeitschrift fuer Wirtschaftlichen Fabrikbetrieb, Vol. 111, n. 4, p. 222–224, 2016.

KAO, H.-A.; HSIEH, Y.-S.; CHEN, C.-H.; LEE, J. *Quality prediction modeling for multistage manufacturing based on classification and association rule mining*. MATEC Web of Conferences, 2017.

KITCHENHAM, B.; CHARTERS, S. *Guidelines for performing systematic literature reviews in software engineering*. Keele University and Durham University Joint Report, 2007.

KOUROU, K.; EXARCHOS, T. P.; EXARCHOS, K. P.; KARAMOUZIS, M. V.; FOTIADIS, D. I. *Machine learning applications in cancer prognosis and prediction*. Computational and Structural Biotechnology Journal, Vol. 13, p. 8–17, 2015.

KUNZ, A.; ZANK, M.; FJELD, M.; NESCHER, T. *Real Walking in Virtual Environments for Factory Planning and Evaluation*. Procedia CIRP, Vol. 44, p. 257–262, 2016.

LIU, T.; GU, H.; WANG, D. *Visual Inspection System for Smart Manufacture of Home Appliances*. IEEE 5TH INTERNATIONAL SYMPOSIUM ON ROBOTICS AND INTELLIGENT SENSORS, 2017

MAHDAVINEJAD, M. S.; REZVAN, M.; BAREKATAIN, M.; ADIBI, P.; BARNAGHI, P.; SHETH, A. P. *Machine learning for internet of things data analysis: a survey*. Digital Communications and Networks, Vol. 4, n. 3, p. 161–175, 2018.

MEHTA, P.; BUTKEWITSCH-CHOZE, S.; SEAMAN, C. *Smart manufacturing analytics application for semi-continuous manufacturing process - A use case*. Elsevier B.V., 2018

OH, Y.; RANSIKARBUM, K.; BUSOGI, M.; KWON, D.; KIM, N. *Adaptive SVM-based real-time quality assessment for primer-sealer dispensing process of sunroof assembly line*. Reliability Engineering & System Safety, 2018.

PARTICKE, F.; KOLBENSCHLAG, R.; HILLER, M.; PATINO-STUDENCKI, L.; THIELECKE, J. *Deep Learning for Real-Time Capable Object Detection and Localization on Mobile Platforms*. Conference Series-Materials Science and Engineering, 2017.

PATEL, M. J.; KHALAF, A.; AIZENSTEIN, H. J. *Studying depression using imaging and machine learning methods*. NeuroImage: Clinical, Vol. 10, p. 115–123, 2016.

TAMMINEN, S.; TIENSUU, H.; FERREIRA, E.; HELAAKOSKI, H.; KYLLÖNEN, V.; JOKISAARI, J.; PUUKKO, E. *From measurements to knowledge - Online quality monitoring and smart manufacturing*. Lecture Notes in Computer Science, Vol. 10933, p. 17–28, 2018.

VOYANT, C.; NOTTON, G.; KALOGIROU, S.; NIVET, M. L.; PAOLI, C.; MOTTE, F.; FOUILLOY, A. *Machine learning methods for solar radiation forecasting: A review*. Renewable Energy, Vol. 105, p. 569–582, 2017.

WANG, T.; YAO, Y.; CHEN, Y.; ZHANG, M.; TAO, F.; SNOUSSI, H. *Auto-sorting System Towards Smart Factory based on Deep learning for Image Segmentation*. IEEE Sensors Journal, 2018.