

# Analysis of Scientific Production on the use of Big Data Analytics in Performance Measurement Systems

J. Assandre and R. Martins

**Abstract**— Performance measurement systems have a critical role in organizations' management, transforming data into relevant information for decision makers. In recent decades, the amount of data and information generated and shared has increased immensely, providing unprecedented opportunities and challenges for such systems. Faced with this scenario, this article aims to analyze the use of big data analytics in performance measurement systems to clarify the nexus between them. Furthermore, the aim is also to identify the trends and opportunities for future research. To achieve that, we carried a scientific map out using bibliometric analysis. The major results of the research show that the use of big data analytics in PMS has increased in recent years without considering the performance measurement systems' characteristics. Incorporating artificial intelligence technologies such as machine learning and deep learning could improve the domain, creating opportunities for empirical works such as the use of unstructured data and applications in Industry 4.0.

**Index Terms**—Bibliometric Analysis, Performance Measurement Systems, Performance Measures, Industry 4.0, Big Data Analytics

## I. INTRODUÇÃO

A medição de desempenho é definida como o processo de quantificar a eficiência e eficácia das ações e possui um papel crítico na gestão do desempenho em qualquer organização [1]-[3], [7]. Um conjunto de medidas de desempenho que interage com o ambiente em que é utilizado e faz parte do sistema de gestão é definido como um sistema de medição de desempenho (SMD) [4]-[6], [71], [118].

Os sistemas de medição de desempenho também possuem características e processos próprios [10] cujas informações geradas podem ser utilizadas para diferentes fins como: planejar e administrar um negócio; auxiliar na comunicação; gerir a implantação de estratégias; influenciar comportamentos; e promover o aprendizado e aperfeiçoamento, dentro de um ciclo de vida dividido em desenvolvimento, implantação e uso/revisão [10], [16]. No entanto, nas últimas décadas, a quantidade de dados e informações geradas e compartilhadas por pessoas, empresas,

administração pública, setores sem fins lucrativos, autores de pesquisa científica, entre outras fontes, aumentou exponencialmente [17],[30],[51], apresentando oportunidades sem precedentes para melhorar o desempenho dos negócios e enfrentar os novos desafios [20], [23], [115], [116].

*Big data* é essa grande quantidade de dados complexos e heterogêneos gerados por uma multiplicidade de plataformas, como mídias sociais, rastros de telefonia móvel, dispositivos de tráfego, comunicação de máquina para máquina, redes de sensores, sistemas ciber-físico e Internet das Coisas (IoT), geolocalização em formatos estruturados, semiestruturados e não estruturados (vídeos, imagens, áudio) [9], [16], [17], [23], [30]. *Big data* é definido por 5 Vs: volume, variedade, velocidade, veracidade, e valor de dados gerados, processados e analisados pelas pessoas e organizações [13], [18], [21], [24]. É uma das tecnologias fundamentais para o desenvolvimento e sobrevivência das organizações [33], [52].

Já *big data analytics* (BDA) é a combinação de *big data* com a aplicação de métodos e técnicas avançadas de análise de dados [9], [14], [21], [25], [72], [92]. BDA tem o potencial de extrair informações valiosas de grandes conjuntos de dados ambíguos, incompletos, condicionais e inconclusivos. Isso pode melhorar o processo de tomada de decisão, minimizar riscos, expandir o entendimento do modelo de negócios, facilitar a implantação de estratégias de negócios, criar novos modelos de negócios e revelar informações ocultas [9], [26], [34], [44]. Assim, se adequadamente integrado aos SMDs das organizações, esse potencial do BDA, poderá aumentar as oportunidades de melhoria de desempenho dos negócios [18], [19].

Contudo, o conhecimento sobre o assunto parece fragmentado [26] e não existe um mapeamento sobre a aplicação de técnicas de BDA nos SMDs, reforçando a impressão de o assunto ainda estar num estado inicial [34]. Ainda, não é sabido se a hipótese promissora de tal aplicação [47] é realmente uma realidade nas organizações, pois apesar de indicar a existência da relação [19], faltam trabalhos com uma investigação mais profunda sobre o tema. Esforços consideráveis são despendidos para acompanhar o ritmo de crescimento de uma estrutura em permanente mudança [90], [116]. Por isso, este artigo tem o objetivo responder quatro questões sobre a relação entre BDA e SMD:

RQ1. Qual a descrição do campo de estudo sobre a aplicação de BDA em SMDs?

RQ2. Qual é a estrutura conceitual da aplicação de BDA em SMDs e como está ocorrendo sua evolução?

J. A. Assandre, Departamento de Engenharia de Produção, Universidade Federal de São Carlos (UFSCar), São Carlos, São Paulo, Brasil, assandre@ufscar.br.

R. A. Martins, Departamento de Engenharia de Produção, Universidade Federal de São Carlos (UFSCar), São Carlos, São Paulo, Brasil, ram@dep.ufscar.br.

RQ3. Qual é a estrutura intelectual do campo utilizada pelos autores que publicaram sobre a aplicação de BDA em SMDs?

RQ4. Quais são as tendências e oportunidades para futuros trabalhos sobre a utilização de BDA em SMDs?

Este artigo está organizado em seis seções: esta introdução apresenta as motivações e objetivos da pesquisa; a segunda seção apresenta um referencial teórico; os conceitos básicos de bibliometria são abordados na terceira seção e a quarta seção trata do método de pesquisa utilizado. Os resultados da análise bibliométrica são apresentados e analisados na quinta seção, além de sugestões de trabalhos futuros na área.

## II. REFERENCIAL TEÓRICO

Como parte fundamental dos sistemas de gestão de desempenho das organizações [1], [3], [7], os SMDs proporcionam comunicação aberta e transparente entre as várias partes interessadas de uma organização [2], [8] e podem ser analisados em três níveis: as medidas individuais, o conjunto de medidas/indicadores (o SMD como entidade) e o ambiente em que ele é utilizado [4]. O nível das medidas de desempenho individuais está geralmente relacionado aos objetivos e estratégias da organização. O conjunto de medidas pode ser agrupamento por semelhanças ou seguindo a lógica de causa-efeito esperada entre as medidas. Por fim, o sistema é usado em um ambiente interno e precisa ser consistente com a cultura organizacional, e no ambiente externo deve considerar *stakeholders* como clientes, fornecedores e concorrentes numa perspectiva de cadeia de suprimentos [32].

As características necessárias de um SMD são o uso de medidas de desempenho juntamente com uma infraestrutura de apoio, os processos para seleção e desenvolvimento de medidas com coleta, manipulação e análise dos dados, gestão da informação, avaliação de desempenho e ferramentas de revisão. Além dos propósitos para medir o desempenho, como gerir a estratégia, comunicar o desempenho, influenciar o comportamento, e aprendizado e o aperfeiçoamento [10]. Um SMD precisam ser dinâmicos para continuar útil para tomada de decisão frente às mudanças dos ambientes interno e externo das organizações [2], [12], [16], [28], além de fornecer informações úteis sobre o desempenho para auxiliar na tomada de decisões corretas [27], [53], [102]. Assim, em um ciclo de vida que abrange seu projeto, implantação e uso/revisão [2], [16], [45], [46], [93], o SMD evolui de forma a se adaptar às mudanças na estratégia, nos processos de produção, às novas tecnologias e na estrutura organizacional [18], [45].

O grande volume de dados complexos e heterogêneos gerados cada vez mais rápidos por diferentes tipos de plataformas [9], [17], pode exigir mudanças nos SMDs [47], uma vez que o conceito de *big data* trouxe destaque para o uso das análises avançadas de dados [18], [19], [21], [23], [24], [31], [41], [94], concretizadas por meio do BDA [9], [26], [72] e que podem ser aplicadas nos três níveis de análise dos sistemas de medição de desempenho. O BDA viabiliza diferentes formas de analisar uma grande massa de dados capturados e armazenados pela organização de fontes internas, da sua cadeia de suprimentos e fora dela também [11], [67], [86]. Existem três tipos de análises (descritiva, preditiva e prescritiva) que

possibilitam obter informações e *insights*, para tomada de decisões e auxiliar na implantação de novas ações [25], [68], [78], [81], [86], [85].

A análise descritiva é a forma de análise mais comum no BDA [30], [67] e usa as informações obtidas a partir de dados históricos brutos de fontes internas e externas da organização [9], [48], [81] com objetivo de entender e apresentar o que aconteceu no passado [9], [48], [67], [68], [78], desde alguns minutos após o evento ter ocorrido até períodos que compreendem muitos anos [67]. Este tipo de análise responde à pergunta “o que aconteceu?” [9], [48], de forma a alertar, explorar e reportar a ocorrência de eventos [77], além de proporcionar generalizações sobre uma população [9]. Geralmente, as análises são simples e usam algumas medidas de estatística básica como média, mediana, moda, desvio padrão, quartis, porcentagens e medição de frequência de eventos específicos [11], [30], [78]. Contudo, a análise descritiva possui uma extensão chamada “análise de diagnóstico” que também relata o passado e envolve tanto a leitura passiva, quanto a interpretação dos dados com objetivo de responder a perguntas como “por que isso aconteceu?” e ajudar a compreender as razões dos eventos ocorridos e os relacionamentos entre diferentes tipos de dados [30], [48], por meio de um processo contínuo e elaborado de mineração de dados [30].

Os resultados das análises descritivas também pode ser incorporada nas análises preditivas [48] para descoberta de padrões e captura de relacionamentos em conjuntos de dados [22]. As análises preditivas compreendem uma variedade de técnicas que preveem resultados futuros (“o que vai acontecer?”) com base em dados históricos e atuais, sendo baseadas principalmente em métodos estatísticos e são subdivididas em dois grupos de métodos e técnicas [11], [22], [48], [68], [81], [91]. O primeiro grupo procura descobrir os padrões históricos no resultado e extrapolar para o futuro. O segundo grupo, por meio de técnicas como regressão lineares, tem o objetivo de capturar as interdependências entre o resultado e variáveis explicativas, e assim fazer previsões [22].

Relativamente nova, a análise prescritiva ainda é pouco usada pelas organizações [48], [67], [68], porém vem despertando cada vez mais o interesse [68], uma vez que tem como objetivo propor “o que deve ser feito” frente a um cenário [11], [48], [67], [77], [78]. Em sua essência, a análise prescritiva propõe um ou mais cursos de ações e mostrar o resultado/influência de cada um conforme suas restrições (“o que devo fazer?”) [48], [67], [68]. Novas tecnologias de informação e comunicação como a Internet das coisas (IoT), *streaming*, inteligência artificial e operações de negócios orientadas por sensores e *digital twins* reforçam as oportunidades que a análise prescritiva pode oferecer às empresas para tomada de decisões e alcançar o melhor curso de ação para o futuro [68].

Existem diferentes técnicas de BDA a serem usadas, conforme as necessidades e objetivos da organização. Entre estas técnicas é possível usar como exemplos das ferramentas analíticas o *text mining*, processamento de linguagem natural [21], *social media analytics*, análise de imagens e vídeos [22].

Estas técnicas permitem operacionalizar as análises descritivas, preditivas e prescritivas a partir de diferentes fontes e usar dados estruturados, semiestruturados e não estruturados.

Os dados estruturados são aqueles armazenados em campos fixos de tabelas ou arquivos contidos em bancos de dados e planilhas eletrônicas [14], [15], [49]. Enquanto os dados não estruturados e semiestruturados abrangem todos os dados que não podem ser facilmente inseridos em colunas, linhas e campos [15], [21], [25], [87]. Normalmente, os dados não estruturados e semiestruturados possuem grande quantidade de textos, mas também podem conter datas, sons e imagens. A principal diferença entre eles é a presença de alguma estrutura nos dados semiestruturados, útil para análises, como *tags* ou outros tipos de marcadores, usados para identificar certos elementos nos dados, mas sem uma estrutura rígida [15].

### III. MÉTODO DE PESQUISA

#### A. Análise Bibliométrica

A síntese de descobertas de pesquisas anteriores é uma das tarefas mais importantes para a compreensão e o avanço de um campo de estudo [26], [65], [74]. Considerando que um campo de estudo é resultado de pesquisas cumulativas que pode ser capturada e sintetizada [55], [76], uma análise objetiva e quantitativa com uso de modelos matemáticos e métodos bibliográficos, auxiliados por *softwares* específicos, proporciona de forma transparente e reproduzível a medição dos processos de disseminação do conhecimento [38], [69], [96], [98] e diminui o viés dos pesquisadores durante o processo de estudo do campo [26], [65].

A análise bibliométrica é um método rigoroso com estas características que cada vez mais é usado para explorar e analisar grandes volumes de dados de publicações com objetivo de descobrir tendências emergentes no desempenho de artigos e periódicos, padrões de colaboração [76], apresentar as nuances evolutivas, identificar áreas emergentes sobre o tema [76], [80] e explorar a estrutura intelectual de um domínio específico na literatura existente [76]. Os métodos bibliométricos possuem dois usos principais: análise de desempenho e mapeamento científico. A análise de desempenho utiliza dados bibliográficos para avaliar grupos de atores científicos como países, universidades, departamentos e pesquisadores, e o impacto de suas atividades. O mapeamento científico tem como objetivo revelar a estrutura e dinâmica dos campos científicos, melhorando a qualidade na elaboração de revisões [65], [76], [90] e proporcionando identificar as redes de pesquisadores e suas motivações [69], [79], [90].

#### B. Fluxo da Análise

O fluxo de trabalho para desenhar o conhecimento científico de um campo, por meio de uma abordagem quantitativa, pode ser delineado em cinco etapas. Primeiro, as perguntas de pesquisa são definidas bem como os métodos bibliométricos adequados para resposta são escolhidos, além do intervalo de tempo a ser analisado. Na segunda etapa, o indexador científico é selecionado ou criado. A terceira etapa do processo consiste no uso de *softwares* bibliométricos para análise dos dados. Na

quarta etapa, são aplicados métodos de visualização dos resultados alcançados na etapa anterior. Finalmente, os resultados são interpretados e descritos [65], [96].

TABELA I  
MÉTODOS BIBLIOMÉTRICOS PARA CADA RQ

| RQ | Métodos bibliométricos   |
|----|--|
| 1  | Análise descritiva da dinâmica de publicações e citações, autores mais produtivos, e fontes mais relevantes  |
| 2  | Análise descritiva das palavras-chave definidas pelos autores<br>Análise de rede de coocorrência de palavras-chaves<br>Sobreposição de cores em rede de coocorrência de palavras-chave |
| 3  | Análise de rede de citações<br>Análise de rede de cocitações<br>Acoplamento bibliográfico  |

A Tabela 1 apresenta os métodos bibliométricos definidos na primeira etapa para as três primeiras questões deste artigo. Para a segunda etapa, o índice científico *Web of Science* mostrou-se o mais adequado para as análises de redes devido à padronização do formato do metadado de referências citadas [65], [70]. Ainda, na segunda fase do processo, também deve ser dada uma atenção especial para definir termos de busca que representem com precisão o campo examinado, considerando a necessidade de busca nos títulos, resumos e palavras-chaves dos registros [65]. A Tabela 2 oferece a estratégia de busca com uma síntese das informações do protocolo utilizado, incluindo as categorias para análise.

Nas etapas seguintes, para o desenvolvimento das análises descritivas e síntese das análises das estruturas conceitual e intelectual, foi utilizado *IDE RStudio* em conjunto com o pacote *R Bibliometrix*, versão 3.2.1. Também foram usados para auxiliar análises o software *VOSviewer* versão 1.6.10 e planilhas eletrônicas. O *Bibliometrix* é um pacote R para análise abrangente de mapeamento científico, que fornece um conjunto de rotinas para pesquisa quantitativa em bibliometria e cienciométrica [36], [56], [70], [82]. Ele foi usado na elaboração das análises descritivas, além das análises das estruturas intelectual e conceitual do campo de pesquisa. O *VOSviewer* tem recursos versáteis de observação, além de mapas de redes de coocorrência de termos, visualizações baseadas em análises de cocitação, citação ou acoplamento bibliográfico [56], [62], [70], [119]. Ele foi utilizado no estudo das estruturas intelectual e conceitual do campo, o que possibilitou a elaboração de análises de redes. Por fim, a apresentação dos dados analisados foi realizada por meio de tabelas, gráficos, quadros e figuras, sendo os resultados interpretados e descritos nas próximas seções da pesquisa. Estas análises também permitiram a resposta da quarta questão de pesquisa.

TABELA II  
PROTOCOLO DE COLETA DE DADOS

| Filtros           | Especificações   |
|-------------------|--|
| Tipo de documento | Articles, Articles in Press, Conference Paper, Proceedings Paper, Review, Book; Book Chapter   |
| Termos de busca   | <b>Grupo 1:</b> <i>big data*</i> e <i>data analytics*</i> ;<br><b>Grupo 2:</b> <i>performance measur*</i> ; <i>performance metric*</i> ; <i>key-performance indicator*</i> ; <i>measur* performance</i> ; <i>performance indicator*</i> ; <i>KPI*</i> ,  |
| Operador booleano | AND entre grupos. OR entre termos  |
| Base de dados     | Web of Science   |
| Áreas de pesquisa | Computer Science Information Systems;<br>Engineering Mechanical; Management;<br>Operations Research Management Science;<br>Engineering Industrial; Business; Engineering Manufacturing; Automation Control Systems; Green Sustainable Science Technology;<br>Business Finance; Engineering Environmental;<br>Engineering Multidisciplinary e Social Sciences Interdisciplinary |
| Idioma            | Inglês   |
| Ano de publicação | Sem restrição  |

#### IV. RESULTADOS

A etapa final de uma análise bibliométrica consiste em interpretar os resultados alcançados [65], [75]. A seguir serão apresentados os resultados da análise bibliométrica descritiva sobre a aplicação de BDA em SMDs, além de uma análise da estrutura intelectual e conceitual do campo de pesquisa e sua evolução no período.

##### A. Panorama dos Estudos sobre Aplicação de BDA em SMD

Dos 479 documentos da amostra, 258 são artigos publicados em periódicos científicos (53,8%); 168 artigos publicados em *conference proceedings* (35%), e 53 outros tipos de documentos (11%). A distribuição dos documentos por tipo de publicação evidencia a contemporaneidade do tema, uma vez que a produção científica é bastante disseminada em conferências. Além disso, a data de publicação dos documentos selecionados para pesquisa reforça o achado anterior, visto que a publicação mais antiga data 2012. Apesar deste artigo estudar *performance measurement* e *data analytics*, não possui como objeto principal a relação BDA e SMD, o que desperta ainda mais a hipótese de inovação do tema.

A imagem (Fig. 1) ilustra a produção científica sobre o tema ao longo do período de 2012 a abril de 2022, junto com o impacto em termos da citação média dos artigos por ano. Observa-se que a produção científica anual teve um crescimento contínuo de 2012 até 2020, com uma taxa média acima de 42%. Entretanto, o maior crescimento ocorreu entre os anos de 2013 e 2014 com uma taxa de 733%, passando de 3 para 25 trabalhos publicados, respectivamente.

Os maiores impactos da produção científica são dos anos de 2018 e 2020, considerando a citação média dos artigos por ano, calculada pela razão entre o total de citação dos trabalhos publicados no ano, dividido pelo número de anos que os artigos foram publicados. Isso indicou uma tendência fora das

previsões, uma vez que documentos com maior tempo de publicação científica tiveram mais tempo para obter citações quando comparados com os mais recentes.




Fig. 1. Número de publicações por ano.

A análise das citações é uma forma de medir o impacto de documentos, autores e periódicos mais influentes em campo de pesquisa específico e seu valor para comunidade acadêmica [56], [65], [76]. A Tabela 3 apresenta os 15 documentos mais citados, em termos de total de citações e total de citações por ano da publicação, entre 2012 e abril de 2022. Desta forma, indica os trabalhos e autores mais relevantes em termos de impacto para o campo até o momento, além das fontes de publicação.

TABELA III  
DOCUMENTOS MAIS CITADOS

| DOCUMENTO              | Periódico/Livro                 | Tt. Cit. | TC Year | Gr. |
|------------------------|---------------------------------|----------|---------|-----|
| AMASYALI et al., 2018  | <i>Ren. Sust. Energy Rev.</i>   | 507      | 101,4   | 1   |
| WU et al., 2014        | <i>IEEE Internet Things J.</i>  | 300      | 33,33   | 3   |
| MANAVALAN et al., 2019 | <i>Computers Ind. Eng.</i>      | 201      | 50,25   | 3   |
| PORTUGAL et al., 2018  | <i>Expert Systems Appl.</i>     | 183      | 36,60   | 3   |
| SINGH et al., 2014     | <i>Information Sciences</i>     | 135      | 15,0    | 3   |
| STIEGLITZ et al., 2014 | <i>Bus. Inf. Syst. Eng.</i>     | 112      | 12,44   | 2   |
| WAMBA et al., 2020     | <i>Int. J. Prod. Res</i>        | 94       | 31,33   | 1   |
| APPELBAUM D, 2017      | <i>Int. J. Accoun Inf Sys.</i>  | 94       | 15,67   | 1   |
| VENKATESH et al. 2020  | <i>Robotics Comp.</i>           | 86       | 28,7    | 1   |
| VERBRAKEN et al. 2014  | <i>European J. Oper. Res.</i>   | 79       | 8,79    | 1   |
| CHANG, 2015            | <i>Ad Hoc Networks</i>          | 77       | 9,33    | 3   |
| BEHL A, 2019           | <i>Annals Ope. Res.</i>         | 77       | 19,25   | 1   |
| JEBLE et al., 2018     | <i>Int. J. Logistics Manag.</i> | 74       | 14,8    | 1   |
| KWON e SIM, 2013       | <i>Expert Sys. Appl.</i>        | 72       | 7,2     | 2   |
| LU et al., 2015        | <i>Res. Cons. Recycling</i>     | 71       | 8,88    | 2   |

Os documentos da Tabela 3 foram agrupados a partir de seus objetivos, de forma a apresentar possíveis perspectivas. O Grupo 1 contém trabalhos com foco na geração de dados para

indicadores de desempenho que poderão ser usados em SMDs. No Grupo 2, foram identificados trabalhos com uso de dados não estruturados e diferentes tipos de mineração de dados. Por fim, o Grupo 3 apresenta trabalhos com enfoques técnicos, como computação cognitiva, IOT, Indústria 4.0, sistemas especializados e recuperação de dados.

A análise descritiva mostrou que 1.537 autores publicaram algum trabalho com relação a SMD e BDA no período, com uma média de 3,21 autores por documento. Apenas 35 autores publicaram trabalhos com autoria única no período.

A Lei de Lotka prevê que dentro de um campo do saber uma quantidade pequena de autores tende a publicar uma grande quantidade de trabalhos. Quando isso ocorre indica que o campo atingiu um grau elevado de maturidade [117], [122].

A aplicação da Lei de Lotka demonstrou que o campo ainda não segue seu modelo estabelecido em que o número de autores que fazem  $n$  contribuições em determinado campo é aproximadamente  $1/n^2$  do número de autores que publicaram apenas uma única vez [66], [83] e que a proporção daqueles que fazem uma contribuição única é de aproximadamente 60% ou superior [66]. A percentagem de documentos de autores que publicaram um único artigo é de 93,5% (Fig. 2). A dispersão de publicações permite concluir que ainda não existe um núcleo de autores que seja referencial no campo.

A figura (Fig. 3) apresenta os 10 autores mais produtivos no período de tempo estudado. O tamanho das bolhas representa a quantidade de artigos publicados e a intensidade da cor é proporcional ao total de citações por ano. Pode ser observado que os 10 autores publicaram algum trabalho entre os anos de 2018 e 2022 e que a média de publicações entre os autores mais produtivos é de 3,8 trabalhos no período. Assim, acerca do número de publicações, Zhang J. se destaca como o mais regular e produtivo sobre o tema. Ele investiga a aplicação de tecnologias de *big data* para soluções empresariais, como o fluxo de trabalho e a implantação de análises descritivas e preditivas em KPIs, junto com o *machine learning*.



Fig. 2. Comparação da produtividade com o padrão de Lotka.

Com 4 documentos publicados no período, Arnaboldi se destaca pelo impacto de suas publicações medido pelo número

de citações. Esse outro autor pesquisa a gestão de desempenho. Lihui Wang aparece como o terceiro autor mais relevante na amostra como publicações entre 2016 e 2022 e tem como seus principais temas de estudo o uso de sistemas digitais e ciberfísicos na manufatura inteligente e Indústria 4.0, planejamento auxiliado por computador, manufatura em nuvem, visão computacional, aplicação de realidade aumentada em processos produtivos, entre outras tecnologias. O uso das tecnologias de BDA para indicadores de desempenho de produção em tempo real em empresas de manufatura com elementos da Indústria 4.0, sistemas *cyber-physical* e internet das coisas (IOT), também foram objetos de estudo de autores como Li Da Xu e Chong Wu.

Com divulgação mais rápida em comparação a um livro, os periódicos científicos são um meio de divulgação com credibilidade e procurados por cientistas para divulgar suas pesquisas [83]. Assim, a análise de periódicos é outra forma que pode revelar como o tema interessa às várias correntes de pesquisa e diferentes campos [55].

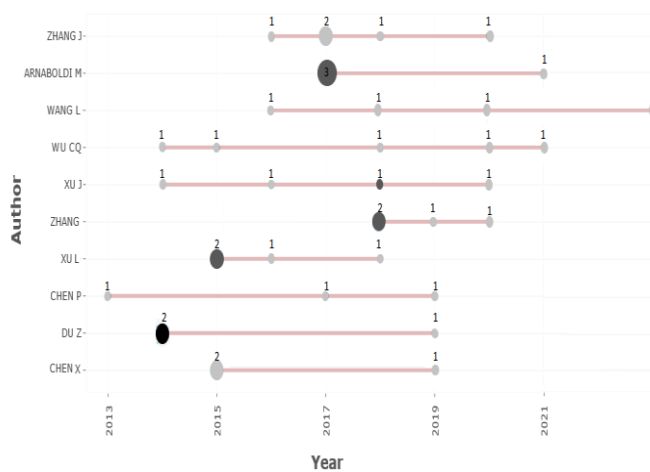


Fig. 3. Produção por Autor durante o período.

Os documentos da amostra foram publicados por 308 periódicos e indicam uma grande dispersão nas fontes (Fig. 4). Apesar desta grande diversidade, ao analisar a dinâmica dos 10 maiores periódicos com publicações sobre o assunto, foi possível identificar a liderança da *IEEE Access*, uma vez que no ano de 2019 foram publicados 6 artigos e outros 9 trabalhos em 2020, além de seis novas publicações em 2021.

Apesar de ser um jornal sobre sustentabilidade, cultura ambiental, econômica e aspectos sociais, *Sustainability* aparece como o segundo periódico com mais publicações sobre o tema, com um total de 13 artigos publicados no período. Assim como o *IEEE Access*, este periódico apresenta constância, uma vez que possui trabalhos entre 2018 e 2021, além de publicações já em 2022. Tendência esta observada para o *Computers & Industrial Engineering* com publicações de 2018 a 2021.




Fig. 4. Fontes de publicação.

A análise da quantidade de trabalhos publicados nos últimos 3 anos pelos 10 periódicos com mais publicações sobre o tema, permite inferir um interesse crescente na aplicação de BDA para medição de desempenho, principalmente por fontes relacionadas à área da computação e engenharia, uma vez que apenas a *Sustainability* não pertence a estes dois campos. Essas fontes de publicação apresentam foco na aplicação e métodos de *design* de sistemas inteligentes e especialistas, em disciplinas como engenharia, informática e ciência da informação, economia, negócios, comércio eletrônico, meio ambiente e saúde, além do interesse por trabalhos sobre desenvolvimento de novas metodologias computadorizadas para resolver problemas de engenharia industrial como a *Computers & Industrial Engineering* e a *International Journal of Production Research*.

### B. Estrutura Conceitual do Campo

A análise descritiva de palavras-chave revela as temáticas e a construção da identidade de um campo [42], [76], além de evidenciar a direção dos trabalhos publicados [42]. Entre as 1.838 palavras-chaves usadas pelos 1.537 autores na amostra, as 10 mais atribuídas são apresentadas (Fig. 5).

A análise dinâmica destas palavras-chave demonstra um crescimento contínuo dos termos *machine learning*, *deep learning*, *data mining* e *data analytics*, sendo acompanhados na maioria dos anos pelos termos *performance measurement* e *analytics*. *Big data* apesar de apresentar variações, continua sendo o termo mais utilizado pelos autores da amostra. Este comportamento representa uma tendência de estudos envolvendo aprendizagem de máquinas e análises avançadas de dados na relação entre *big data* e SMDs, além de destacar a importância que estas tecnologias começam a ter no campo de estudo.




Fig. 5. Dinâmica de palavras-chaves.

Análises fatoriais, diferentes tipos de mapas, análise de rede e a combinação de abordagens, também fornecem uma visão de campos científicos, de forma a representar relações entre conceitos em um conjunto de publicações [65], [82]. A rede de coocorrência de palavras-chaves permite entender os tópicos tratados num campo de pesquisa com objetivo de definir quais são as questões mais importantes e mais recentes, além de auxiliar no estudo da evolução dos temas.

A estrutura cognitiva do campo de estudo também pode ser revelada por meio da análise da coocorrência dos termos presentes em títulos, palavras-chaves e resumos de documentos [61], [65], [76], [82], [84], [100]. Nestas análises, o tamanho dos nós da rede reflete a frequência de ocorrência das palavras-chave, enquanto a distância indica a coocorrência em uma dada quantidade de publicações [62], [66]. A espessura da linha que liga os dois nós indica a intensidade de coocorrência de palavras nos documentos e que os conceitos associados a esses termos estão relacionados [65].

Como o princípio da análise de coocorrência de palavras-chave associa maior significância para os termos mais usados [64], [66], as palavras-chaves abaixo do critério de corte não foram incluídas na interpretação. Assim, a análise abrangeu os 40 termos com maior frequência de ocorrência, e com no mínimo cinco coocorrência, representadas pela ligação entre nós. Como parâmetros para formação dos *clusters*, foi usada a intensidade de associação para a normalização e o mínimo de 5 termos para formação dos *clusters*. Na rede de coocorrência das palavras-chave, formada por 3 *clusters* (Fig. 6), *big data* apresentou maior centralidade e maior número de interação com outros termos com destaque para as palavras *analytics* e *machine learning*, o que possibilitou identificar três *clusters*.

O primeiro *cluster*, com maior número de termos, é mais dominante, sendo identificado na análise de coocorrência de palavras-chave como *cluster 1*. O grupo sugere trabalhos com foco principal na medição de desempenho com uso de BDA, e se mostra como o campo de estudo objeto desta pesquisa, uma vez que apresenta palavras relacionadas a SMDs, como *benchmarking*, *supply chain management*, *ensemble learning*, *business intelligence* e *business analytics*. Da mesma forma, o

cluster apresenta termos técnicos de computação e comuns em trabalhos sobre infraestrutura de *big data*, como *hadoop* e *mapreduce*, além das palavras que integram os dois campos, como *big data*, *data mining*, *machine learning* e *deep learning*.

As áreas da computação e medição de desempenho também podem ser identificadas por meio dos outros dois *clusters* de palavras-chaves informadas pelos autores.

O *cluster 2* apresenta termos relacionados com o campo da computação como *cloud computing* e *fog computing*. Enquanto o *cluster 3* apresenta termos relacionados a medição de desempenho e SMDs, como *performance measurement*, *supply chain*, *management* e *sustainability*. A intensidade e proximidade dos termos *machine learning*, *deep learning*, *data mining*, *cloud computer* e *data analytics* com a palavra-chave *big data*, representa a importância que estas tecnologias têm para o campo de estudo sobre *big data*. Estes termos também caracterizam uma possibilidade de trabalhos para estudar o uso de ferramentas de inteligência artificial em sistemas de medição de desempenho, como *deep learning* e *machine learning*, já indicada na análise descritiva de palavras-chaves.

Contudo, diferente do *cluster 2* que possui alguns assuntos como *analytics* e *cloud computing*, que funcionam como ligação com o grupo principal, o *cluster 3* não apresenta palavras-chave com esta característica. As palavras-chave deste grupo se ligam diretamente aos termos centrais do campo, porém a uma distância maior que outros assuntos, indicando poucas coocorrências, além de uma intensidade fraca desta relação. Desta forma, corroborando com o estudo de Mello e Martins [19], quanto a necessidade de explorar mais esta relação entre *big data* e SMD.

alterações na estrutura do campo e capturar seu desenvolvimento ao longo do tempo [65].

A rede apresentada (Fig. 7) ilustra, não apenas a estrutura da rede de coocorrências, mas também a dinâmica temporal das palavras-chaves definidas pelos autores e seus relacionamentos. Esta análise identifica que a relação entre *big data* e medição de desempenho teve como foco inicial, até 2016, as tecnologias envolvendo a grande quantidade e variedade de dados, além de múltiplas fontes, destacando termos como *cloud computing*, *internet of things* e *analytics*. A partir de 2016, surgem na análise da rede com mais frequência as palavras-chave *hadoop* e *mapreduce*, que indicam a influência destas tecnologias no campo de forma a viabilizar o uso de *big data* em SMDs. Neste mesmo período, os termos *data mining* e *benchmarking* aparecem com cor igual ao termo *big data* e a mesma proximidade das palavras-chaves *performance measures*, *supply chain management*, *performance* e *machine learning* do centro da rede e corroboram com a ideia.

A análise também indica uma tendência, a partir de 2019, já identificada na análise descritiva e de coocorrências de palavras-chaves, referente ao maior uso de tecnologias de *machine learning*. Ligados com maior intensidade a *machine learning*, termos como *deep learning*, *artificial intelligence*, *data analytics* e *classification* se destacam neste período. Frente às potencialidades destas tecnologias combinadas com as características do *big data*, é possível inferir um maior uso de dados não estruturados nos SMDs. Esta combinação de técnicas de inteligência artificial e *big data* também podem proporcionar maior uso de análises preditivas pelos SMDs.

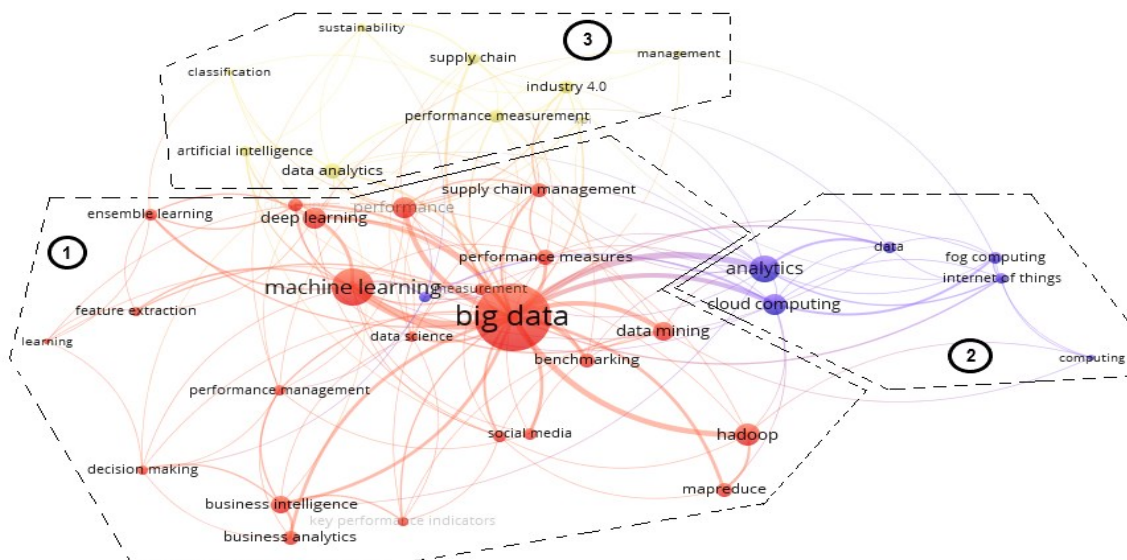


Fig. 6. Rede de coocorrência das palavras-chaves

Idêntica à visualização de rede, a sobreposição de cores é utilizada para mapear aspectos da amostra [62], em que o conjunto dos principais documentos é dividido em vários períodos e os dados bibliométricos separados são analisados para encontrar

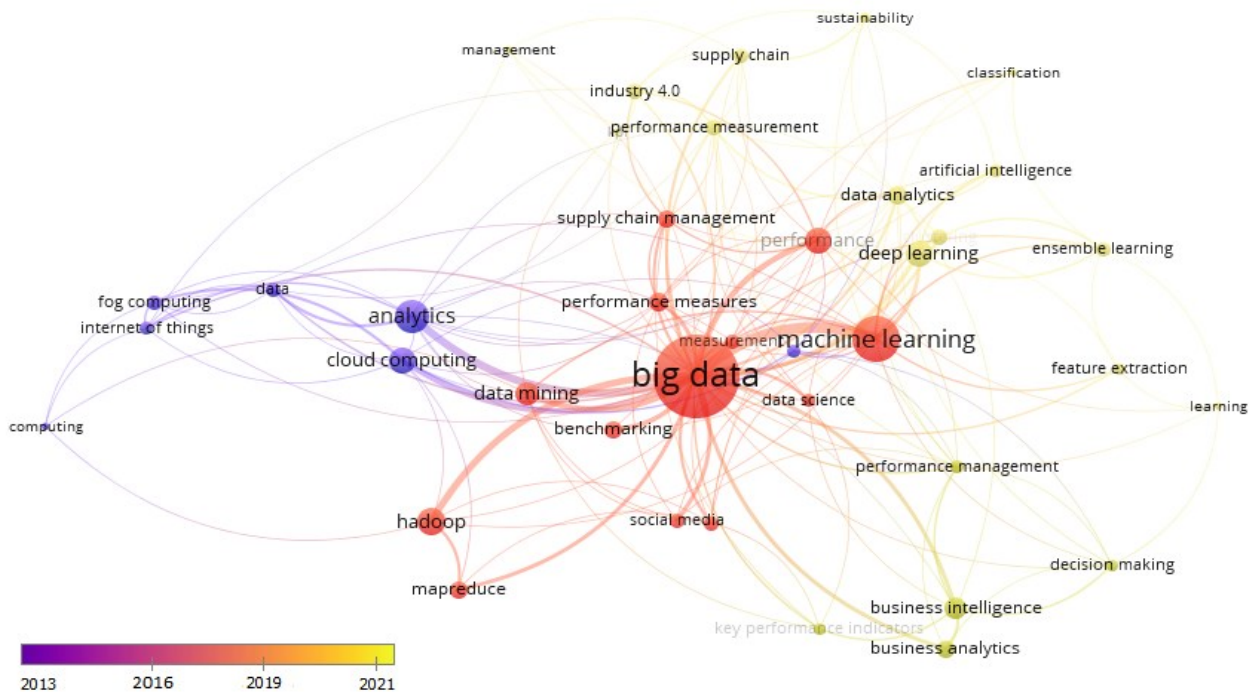


Fig. 7. Dinâmica de palavras-chave.

### C. Estrutura Intelectual do Campo e Dinâmica dos Elementos

A análise de citações de trabalhos da amostra busca encontrar os documentos mais influentes e revelar a base de conhecimento do campo de estudo, além de fornecer informações sobre a estrutura intelectual [65], [104]. A cocitação de trabalhos que analisa a ligação entre dois documentos, por meio da frequência com que são citados juntos, também pode ser usada para revelar a estrutura intelectual de um campo de pesquisa [41], [76], tendo como base o agrupamento objetivo de conteúdo semelhante. Documentos estreitamente vinculados apresentam um alto número de cocitações [76], [105], [106]. Desta forma, dentro de uma rede de cocitações, duas publicações são conectadas quando coexistem na lista de referências de outra publicação. Além de encontrar as mais influentes publicações e estudiosos sobre o campo de estudo, a análise também possibilita descobrir agrupamentos temáticos [41], [76].

Os 30 artigos mais citados na amostra (Fig. 8) e com no mínimo 5 cinco cocorrência e os trabalhos mais influentes apresentados na Tabela 4 aparecem em diferentes *clusters* de pesquisa. O documento com maior número de citações e influência dentro de seu *cluster* e da amostra é Chen; Chiang e Storey [25] que, além de avaliar o valor comercial do *big data*, apresenta uma estrutura interpretativa que analisa as perspectivas e aplicações desta tecnologia. O trabalho é acompanhado no grupo pelo artigo de Waller e Fawcett [63], que apresenta oportunidades de pesquisa no gerenciamento da cadeia de suprimentos combinadas com ciência de dados, análise preditiva e *big data*, além de enfatizar as habilidades e conhecimentos necessários.

Além de apresentar conceitos importantes para o uso de *big data*, McAfee et al. [107] trata da necessidade de mudar a cultura para tomada de decisão e assim obter melhor desempenho da empresa, além de conceituar as características do *big data em 3Vs* (volume, velocidade e variedade). Estes documentos, entre outros como Hazen [99] e Kaplan e Norton [112], formam um *cluster* com publicações úteis para fundamentação de novas pesquisas sobre o tema, porém sem foco prático na medição de desempenho. O valor comercial para diferentes segmentos, a percepção de usuários e gestores quanto a seu potencial e vantagem competitiva, os impactos em setores da economia, possíveis oportunidades de melhoria de desempenho das empresas, mudança na privacidade e na vida das pessoas, além do efeito nos negócios, governo etc., são temas abordados neste *cluster*.

Outro *cluster* agrupa trabalhos como de Wamba et al. [108], que apresentam uma revisão sistemática e como resultado uma estrutura interpretativa que analisa as perspectivas de definição e as aplicações da tecnologia, frente a escassez de pesquisas empíricas para avaliar o valor comercial do *big data*. Também com foco no uso de BDA na medição de desempenho das empresas, Wamba et al. [109] propõe um modelo de capacidade de análise de *big data* e analisa seus efeitos. O impacto na assimilação do *big data* e da análise preditiva na cadeia de suprimentos e desempenho organizacional, estudado no artigo de Gunasekaran et al. [73], compõem este *cluster* com outros trabalhos. O grupo representa a preocupação em estudar a influência das ferramentas de BDA no contexto dos sistemas de medição de desempenho.

O *cluster* 3 agrupa publicações com foco na aplicação da



tecnologia de BDA no ambiente das organizações, como o artigo de Wang, Gunasekaran e Ngai [18] que revisam e classificam a literatura sobre a aplicação do BDA nos negócios nas áreas de logística e gestão da cadeia de suprimentos com foco na estratégia e operações. O *cluster* também contém publicações com enfoque no uso de BDA na, Indústria 4.0, serviços de finanças e economia, e saúde, além do uso de dados não estruturados.

Os trabalhos mais citados dentro de cada *cluster* também são os mais influentes, como pode ser notado na imagem (Fig. 8) e Tabela 4. Entretanto, com pouca intensidade nas ligações com publicações fora do grupo.

A análise do *link strength* dos 30 trabalhos mais citados, mostra que apesar da amostra possuir trabalhos que se destacam no número de citações e interação com outras publicações em seu grupo, não é possível localizar muitos documentos com forte penetração em outros *clusters*.

O artigo *Business intelligence and analytics: From big data to big impact* de Chen; Chiang e Storey [25] com 310 *link strength*, se destaca porque interage com vários trabalhos dos outros dois *clusters*. Com um *link strength* menor que Chen; Chiang e Storey [25], Walleer e Fawcett [63] também acaba integrando os 3 grupos e aparece como um trabalho importante para o campo de estudo.

Wamba também recebe destaque na análise de *link strength*, uma vez que tem o segundo e quinto trabalhos mais influentes, porém tendo pouca penetração no cluster 3, apesar de sua importância para os *clusters* 2. Com menos citações Wang; Gunasekaran e Ngai [18] é bem influente nas pesquisas sobre o uso de BDA em logística e gestão da cadeia de suprimentos, mesmo sendo publicado mais recente.

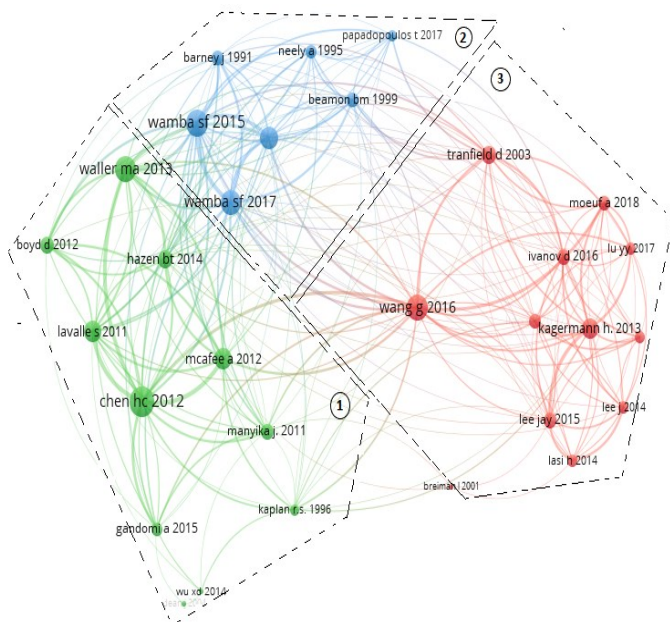


Fig. 8. Cocitação de trabalhos.

TABELA IV  
ARTIGO MAIS CO-CITADOS EM CADA CLUSTER

| Referencia                | Cit . | Link Str. | Cluster |
|---------------------------|-------|-----------|---------|
| CHEN et al. (2012)        | 27    | 310       | 1       |
| WALLER e FAWCETT (2013)   | 14    | 231       | 1       |
| MCAFEE et al. (2012)      | 17    | 162       | 1       |
| LAVALLE et al. (2011)     | 11    | 157       | 1       |
| WAMBA (2015)              | 15    | 255       | 2       |
| WAMBA et al. (2017)       | 10    | 214       | 2       |
| GUNASEKARAN et al. (2017) | 10    | 181       | 2       |
| BEAMON (1999)             | 18    | 77        | 2       |
| WANG et al. (2016)        | 18    | 233       | 3       |
| KAGERMANN et al (2013)    | 13    | 138       | 3       |
| TRANFIELD et al. (2003)   | 11    | 118       | 3       |
| LEE J et al. (2015)       | 10    | 93        | 3       |

A análise dos *link strengths* possibilita inferir que o campo de estudo tem sua base de conhecimento nas pesquisas sobre sistemas de informação para negócios e o uso de DBA em logística e gestão da cadeia de suprimentos, uma vez que os trabalhos sobre tecnologias para *big data* e infraestrutura não aparecem entre os 10 artigos mais influentes. A análise também demonstra que estudos relacionados ao impacto do *big data* em setores da economia, valor comercial de sua implantação, percepção de usuários e desempenho da empresa são os mais influentes. Já os trabalhos que possuem como foco a aplicação prática do BDA em SMD ainda não influenciam fortemente a base de conhecimento do campo de estudo.

Como forma de medir a semelhança entre trabalhos, o acoplamento bibliográfico usa o número de referências compartilhadas por dois documentos. Quanto mais as referências citadas entre dois artigos são as mesmas, mais forte é a conexão entre eles, e indica possíveis correntes de pesquisa [65], [76], [106]. A rede (Fig. 9) apresenta os grupos com maior semelhança dentro da amostra, considerando um número mínimo de 10 citações e usando apenas os 30 trabalhos mais citados.

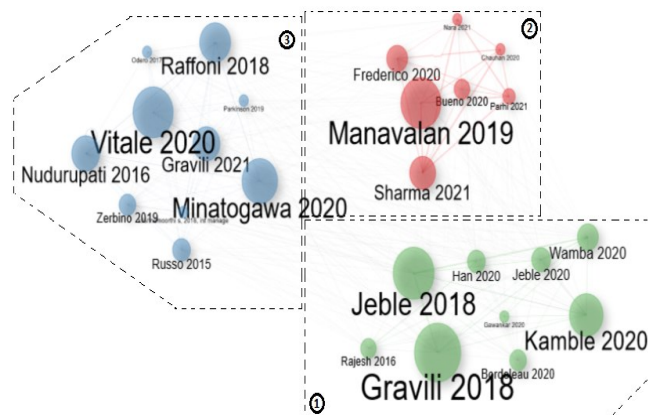


Fig. 9. Acoplamento bibliográfico.

A análise de acoplamento bibliográfico possibilita identificar três *clusters* de trabalhos. O primeiro grupo representa uma corrente de pesquisa com documentos voltados ao uso de BDA em *performance systems and business management*, como Jebble [110] que desenvolve um modelo teórico para explicar o impacto do *big data* e da análise preditiva no objetivo de desenvolvimento de negócios sustentáveis da organização [123] e Kamble e Gunasekaran [2] que estuda a implantação de SMDs com uso de BDA. Neste grupo também se destaca Wamba [111] cujo objetivo foi estudar a influência do BDA na capacidade de melhoria da agilidade e desempenho das organizações.

Um segundo *cluster* formado por documentos como Manavalan e Jayakrishna [103], que estudam a necessidade das empresas de manufatura acelerarem mudanças com foco na sustentabilidade e fazer uso de tecnologia como internet das coisas (IoT) para explorar as oportunidades potenciais, e Frederico et al. [97]. O grupo de documentos apresenta uma abordagem teórica baseada no *Balanced Scorecard* com relação à medição de desempenho em cadeias de fornecimento para Indústria 4.0. Por fim, um terceiro grupo apresenta estudos sobre o impacto e oportunidades a partir da relação entre SMD e *big data*, como Nudurupati, Tebboune e Hardman [101] que estuda os desafios para medir o desempenho na era digital, frente às constantes mudanças no ambiente externo das organizações que exige a adaptação dos SMDs, junto com a necessidade de lidar com a grande quantidade e variedade de dados gerados. Outros documentos mais recentes e apresentados neste *cluster* são Gravili et al. [113] que tenta entender o papel da análise de dados e *big data* na criação de valor em saúde e Vitale, Cupertino e Riccaboni [114] que frente a relutância das pequenas e médias empresas em adotar as tecnologias formais, analisam como o *big data* afeta seus sistemas de gestão e controle.

## V. CONCLUSÕES

A análise bibliométrica dos artigos selecionados ajudou a diminuir a lacuna de conhecimento quanto à relação entre BDA e SMD, por meio da resposta das quatro questões de pesquisa. A questão RQ1: qual a descrição do campo de estudo sobre a aplicação de BDA em SMDs? Permitiu constatar que o domínio do campo de estudo sobre o uso de BDA em SMDs, ainda é incipiente, uma vez que o trabalho mais antigo foi publicado em 2012 e a disseminação da produção científica da área está em conferências. Por meio da Lei de Lotka foi possível verificar que não existe um núcleo de autores que estabelecem um paradigma a ser seguido apesar de serem encontrados autores proeminentes. Isso corrobora com a ideia de incipiência e convergindo para os resultados apresentados por Chong e Shib [34]. Um crescimento significativo e constante de publicações que envolvem o tema já a partir de 2013, foi identificado e indica um maior interesse pela relação entre os temas SMD e BDA. Contudo, também foi indicada uma tendência fora das previsões, uma vez que documentos publicados no período entre 2018 e 2020, tiveram maior impacto, mesmo com menor tempo para obter citações.

Os resultados das análises das principais fontes de publicação

permitiram identificar um interesse pelo tema por periódicos que disseminam pesquisas sobre o uso e desenvolvimento de sistemas especialistas, aplicações e métodos de *design* de sistemas inteligentes e computação inteligente em disciplinas como engenharia, ciências naturais, ciência da informação, economia, negócios, comércio eletrônico, meio ambiente, logística e saúde. A análise da dinâmica dos periódicos mais influentes sobre o assunto, também possibilitou identificar uma tendência de liderança da *IEEE Access*, a partir de 2019, com continuidade de publicações sobre o assunto pela *Expert Systems with Applications*, *Production Planning & Control* e *Computers & Industrial Engineering*.

Outro resultado importante está na análise descritiva dos documentos mais citados, os quais focam na geração de dados para indicadores de desempenho que poderão ser usados em SMD. Esta análise também identifica a ideia de uso de dados não estruturados, com origem em redes sociais e mineração de dados, além de trabalhos com enfoque técnico, como estudos sobre computação cognitiva, IoT, inteligência artificial, sistemas especializados, Indústria 4.0 e recuperação de dados. Desta forma, isso indica uma forte influência da área de ciência da computação no desenvolvimento do campo e ausência de estudos que considerem as características dos SMD, uma vez que os trabalhos possuem foco apenas em medidas de desempenho específicas.

A análise da estrutura conceitual do campo e sua evolução, para resposta da questão RQ2, por meio de diferentes ferramentas, reforçou os resultados apresentados por Mello, Leite e Martins [47] nos primeiros anos de pesquisa, quanto ao desenvolvimento paralelo sobre SMDs e BDA, uma vez observados um grupo específico para análise de desempenho de negócios e outro com publicações com foco na área de computação. Entretanto, é possível identificar a mudança de cenários no campo de estudo, uma vez que a análise de *clusters* de palavras-chaves indica a formação de um grupo composto por trabalhos com termos relacionados às áreas dos dois outros grupos.

Outra mudança de cenário está no crescimento contínuo dos termos *machine learning* e *data analytics*, entre as palavras-chave definidas pelos autores da amostra, além dos termos *deep learning* e *data mining*, que apresentam comportamento parecido na maioria dos anos, indicando uma tendência de estudos envolvendo *machine learning*, e destaca a importância que estas tecnologias começam a ter no campo de estudo. A incorporação de tecnologias de inteligência artificial, principalmente de *deep learning*, também indica um maior uso de dados não estruturados na medição de desempenho. Assim, é possível propor que a relação entre *big data* e medição de desempenho tem sua evolução em três fases.

A primeira fase, iniciada em 2012, teve como foco inicial, até 2016, as tecnologias envolvendo a grande quantidade e variedade de dados, além de múltiplas fontes. Uma segunda fase, entre os anos de 2016 e 2019, com o amadurecimento do campo de estudo e uma maior aproximação entre as áreas de computação e medição de desempenho. Por fim, uma terceira fase indica uma maior utilização de tecnologias de inteligência artificial para uso de dados não estruturados.

A análise da estrutura intelectual do campo, realizada para resposta da questão RQ3, indicou que apesar da evolução do campo de estudo, sua base de conhecimento é concentrada em pesquisas sobre o possível impacto do *big data* em setores da economia e desempenho das organizações. Trabalhos que possuem como foco a aplicação prática do BDA em SMD ainda não influenciam fortemente o campo de estudo, de forma a indicar uma lacuna nas pesquisas, o que é uma oportunidade para desenvolvimento de pesquisas. Contudo, a análise da estrutura intelectual do campo indica a existência de uma corrente de pesquisa voltada ao uso do BDA nos *performance measurement systems and business management* e trabalhos sobre a aplicação na gestão da cadeia de suprimentos com foco empírico, que pode representar mudanças no campo, porém sem considerar os elementos que compõem os SMDs, e que segundo Wang [18] compromete o grande potencial do BDA em criar valor para os negócios. A análise da estrutura intelectual do campo também identificou correntes de pesquisa com foco no estudo dos desafios e oportunidades para a medição de desempenho frente ao grande volume de dados, e no contexto da Indústria 4.0, a qual tem entre suas tecnologias o *big data*.

Uma visão mais ampla da relação BDA e SMD permitiu identificar a aproximação das áreas que formam o campo de estudo e tendências de pesquisas. Entre as tendências se destaca o uso de tecnologias de inteligência artificial como *machine learning e deep learning*, principalmente voltadas à análise de dados não estruturados de diferentes formatos para aplicações no contexto da Indústria 4.0 para diferentes setores da economia.

Este movimento de aproximação das áreas fortalece ainda mais o relacionamento entre BDA e SMDs e aumenta a interação entre as correntes de pesquisa, de forma a contribuir para o desenvolvimento da base de conhecimento e diminuição da lacuna por trabalhos empíricos no campo. Contudo, é necessário que ao trazer estas tecnologias para área de gestão e aplicações na Indústria 4.0, sejam considerados os elementos dos SMDs como infraestrutura, medidas de desempenho, processos e propósitos, de forma a explorar seus benefícios para o gerenciamento de objetivos e auxiliar em vantagens competitivas.

Assim, como resposta a questão RQ4, o aprofundamento sobre o tema, por meio de análises de conteúdo de documentos já publicados e pesquisas voltadas a aplicação prática do BDA em SMDs, como o uso de *machine learning e deep learning*, com propósitos de planejar e gerenciar um negócio, administrar a implantação da estratégia, influenciar comportamentos e promover o aprendizado e a melhoria, considerando suas características e processos necessários, como no contexto da Indústria 4.0, parece ser um caminho natural para novos trabalhos acadêmicos e uma oportunidade de pesquisa. Da mesma forma, conhecer como o BDA impacta o uso dos SMDs em diferentes contextos, estudar o processo de aprimoramento e ciclo de vida desses sistemas, frente ao volume cada vez mais de dados e desenvolvimento de novas tecnologias de processamento e análise, podem fomentar novas pesquisas.

## REFERÊNCIAS

- [1] K. Bhadani, G. Asbjörnsson, E. Hulthén and M. Evertsson, "Development and implementation of key performance indicators for aggregate production using dynamic simulation", *Minerals Engineering*, vol. 145, pp. 106065, 2020, doi: 10.1016/j.mineng.2019.106065.
- [2] S. S. Kamble and A. Gunasekaran, "Big data-driven supply chain performance measurement system: a review and framework for implementation," *Int. J. Prod. Res.*, vol. 58, no. 1, pp. 65–86, 2020, doi: 10.1080/00207543.2019.1630770.
- [3] M. Bourne, M. Franco-Santos, P. Micheli, and A. Pavlov, "Performance measurement and management: a system of systems perspective," *Int. J. Prod. Res.*, vol. 56, no. 8, pp. 2788–2799, 2018, doi: 10.1080/00207543.2017.1404159.
- [4] A. Neely, M. Gregory and K. Platts, "Performance measurement system design: a literature review and research agenda", *Int. J. Oper. Prod. Manag.*, vol. 15, no. 4, pp. 80-116, 1995.
- [5] D.M. Gutierrez, L.F. Scavarda, L. Fiorencio and R.A. Martins, "Evolution of the performance measurement system in the Logistics Department of a broadcasting company: An action research", *Int. J. Prod. Econ.*, vol. 160, pp. 1-12, 2015, doi: 10.1016/j.ijpe.2014.08.012.
- [6] A. Taylor and M. Taylor, "Antecedents of effective performance measurement system implementation: an empirical study of UK manufacturing firms", *Int. J. Prod. Res.*, vol. 51, no. 18, pp. 5485-5498, 2013, doi: 10.1080/00207543.2013.784412.
- [7] P.C. Van Fenema and B.M. Keers, "Interorganizational Performance Management: A Co-evolutionary Model", *Int. J. Manag. Reviews*, vol. 20, no. 3, pp. 772-799, 2018, doi: 10.1111/ijmr.12180.
- [8] C. Forza and F. Salvador, "Assessing some distinctive dimensions of performance feedback information in high performing plants", *Int. J. Oper. Prod. Manag.*, vol. 20 no. 3, pp. 359-385, 2000, doi: 10.1108/01443570010308112.
- [9] P. Ghavami, *Big Data Analytics Methods: Analytics Techniques in Data Mining, Deep Learning and Natural Language Processing. 2nd Edition*, Walter de Gruyter GmbH & Co KG, 2019.
- [10] M. Franco-Santos et al., "Towards a definition of a business performance measurement system", *Int. J. Oper. Prod. Manag.*, vol. 27 no. 8, pp. 784-801, 2007, doi.org/10.1108/01443570710763778.
- [11] E. Siow, T. Tiropanis and W. Hall, "Analytics for the internet of things: A survey", *ACM computing surveys (CSUR)*, vol. 51, no. 4, pp. 1-36, 2018, doi: 10.1145/3204947.
- [12] F. Franceschini et al., "Designing performance measurement systems", *Management for Professionals*. Springer Nature, 2019.
- [13] P. Zikopoulos, C. Eaton, D. Deroos, T. Deutsch, and G. Lapis, *Understanding Big Data: analytics for enterprise class Hadoop and streaming data*. McGraw-Hill, 2012.
- [14] K.S. Divya, P. Bhargavi and S. Jyothi, "Machine learning algorithms in big data analytics", *Int. J. Comput. Sci. Eng.*, vol. 6, no. 1, pp. 64-70, 2018.
- [15] B. Marr, "Big Data: Using SMART big data, analytics and metrics to make better decisions and improve performance", *John Wiley & Sons*, 2015.
- [16] H.J. Jang, J. Sim, Y. Lee and O. Kwon, "Deep sentiment analysis: Mining the causality between personality-value-attitude for analyzing business ads in social media", *Expert Syst. appl.*, vol. 40, no. 18, pp. 7492-7503, 2013, doi: 10.1016/j.eswa.2013.06.069.
- [17] S. Tanwar, S. Tyagi and N. Kumar, eds. *Multimedia big data computing for IoT applications: concepts, paradigms and solutions*. Vol. 163. Springer, 2019.
- [18] G. Wang, A. Gunasekaran, E. W. T. Ngai, and T. Papadopoulos, "Big data analytics in logistics and supply chain management: certain investigations for research and applications," *Int. J. Prod. Econ.*, vol. 176, pp. 98–110, 2016, doi: 10.1016/j.ijpe.2016.03.014.
- [19] R. Mello and R.A. Martins, "Can Big Data Analytics Enhance Performance Measurement Systems?", *IEEE Eng. Manag. Review*, vol. 47, no. 1, pp. 52-57, 2019, doi: 10.1109/EMR.2019.2900645.
- [20] A. Alexander, M. Kumar and H. Walker, "A decision theory perspective on complexity in performance measurement and management", *Int. J. Oper. Prod. Manag.*, vol. 38, no. 11, pp. 2214-2244, 2018, doi: 10.1108/IJOPM-10-2016-0632.

- [21] P. Russom et al., "Big data analytics", *TDWI best practices report, fourth quarter*, vol. 19, no. 4, pp. 1-34, 2011.
- [22] A. Gandomi and M. Haider, "Beyond the hype: Big data concepts, methods, and analytics", *Int. J. Inf. Manag.*, v. 35, no. 2, pp. 137-144, 2015, doi: 10.1016/j.ijinfomgt.2014.10.007.
- [23] C. Antoniou et al., "Towards a generic benchmarking platform for origin-destination flows estimation/algorithm: Design, demonstration and validation", *Trans. Res. Part C: Emerging Technologies*, vol. 66, pp. 79-98, 2016, doi: 10.1016/j.trc.2015.08.009.
- [24] R. Kitchin, "Big Data, New Epistemologies and Paradigm Shifts", *Big Data and Society*, vol.1, no.1, pp.1-12, 2014, doi:10.1177/2053951714528481.
- [25] H. Chen, R. H. L. Chiang, and V. C. Storey, "Business intelligence and analytics: from big data to big impact," *MIS Q.*, vol. 36, no. 4, pp. 1165-1188, 2012.
- [26] S. Khanra, A. Dhir and M. Mäntymäki, "Big data analytics and enterprises: a bibliometric synthesis of the literature", *Enterprise Inf. Systems*, pp. 1-32, 2020, doi: 10.1080/17517575.2020.1734241.
- [27] M. Kennerley and A. Neely, "Measuring performance in a changing business environment," *Int. J. Oper. Prod. Manag.*, vol. 23, no. 2, pp. 213-229, 2003, doi: 10.1108/01443570310458465.
- [28] M. Kennerley and A. Neely, "Performance measurement frameworks: a review." *Business performance measurement: Theory and practice*, pp. 145-155, 2002: 145-155, doi: 10.1108/0144357031045846.
- [29] H. Kagermann, W. Wahlster, and J. Helbig, "Recommendations for implementing the strategic initiative Industrie 4.0," 2013.
- [30] U. Sivarajah, M.M. Kamal, Z. Irani and V. Weerakkody, "Critical analysis of Big Data challenges and analytical methods", *J. Bus. Res.*, vol 70, pp. 263-286, 2017, doi: 10.1016/j.jbusres.2016.08.001.
- [31] M. Gupta and J. F. George, "Toward the development of a big data analytics capability," *Inf. Manag.*, vol. 53, no. 8, pp. 1049-1064, 2016, doi: 10.1016/j.im.2016.07.004.
- [32] R.C. Mergulhão and R.A.Martins, "Relação entre sistemas de medição de desempenho e projetos Seis Sigma: estudo de caso múltiplo", *Production*, vol. 18, no. 2, pp. 342-358, 2008.
- [33] L. Liu et al., "Deep learning for generic object detection: A survey", *Int. J. of computer vision*, vol. 128, no. 2, pp. 261-318, 2020, doi: 10.1007/s11263-019-01247-4.
- [34] D. Chong, H Shi, "Big data analytics: a literature review". *Journal Manag. Analytics*, vol. 2, no. 3, pp. 175-201, 2015, doi:10.1080/23270012.2015.1082449.
- [35] K. Amasyali, and M.E. Nora M, "A review of data-driven building energy consumption prediction studies." *Renewable and Sustainable Energy Reviews*, vol.81, pp. 1192-1205, 2018, doi: 10.1016/j.rser.2017.04.095.
- [36] M. Aria and C. Cucurullo, "Package 'Bibliometrix'", 2020 [Online]. Available:[https://cran.r-project.org/web/packages/bibliometrix/bibliometrix .pdf/](https://cran.r-project.org/web/packages/bibliometrix/bibliometrix.pdf)
- [37] B.M. Beamon, "Measuring supply chain performance," *Int. J. Oper. Prod. Manag.*, vol. 19, no. 3, pp. 275-292, 1999, doi: 10.1108/01443579910249714.
- [38] A. Behl and P. Dutta, "Humanitarian supply chain management: a thematic literature review and future directions of research", *Annals of Operations Research*, vol. 283, no. 1, pp. 1001-1044, 2019, doi: 10.1007/s10479-018-2806-2
- [39] L. Bornmann, H.D. Daniel, "Does the h-index for ranking of scientists really work?", *Scientometrics*, vol. 65, pp. 391-392, 2005, doi: 10.1007/s11192-005-0281-4.
- [40] K. Singh, S.C. Guntuku, A. Thakur and C. Hota, "Big Data Analytics framework for Peer-to-Peer Botnet detection using Random Forests", *Information Sciences*, vol. 278, pp. 488-497, 2014, doi: 10.1016/j.ins.2014.03.066.
- [41] D.E. Rossetto et al., "Structure and evolution of innovation research in the last 60 years: review and future trends in the field of business through the citations and co-citations analysis", *Scientometrics*, vol. 115, pp. 1329-1363, 2018, doi: 10.1007/s11192-018-2709-7.
- [42] D. Tranfield, D. Denyer and P. Smart, "Towards a methodology for developing evidence informed management knowledge by means of systematic review", *British Journal Manag.*, vol. 14 no. 3, pp. 207-222, 2003, doi.org/10.1111/1467-8551.00375.
- [43] S. Talwar, P. Kaur and F.S. Wamba, "Big Data in operations and supply chain management: a systematic literature review and future research agenda", *Int. J. Prod. Res.*, vol. 59, no. 11, pp. 3509-3534, 2021, doi: 10.1080/00207543.2020.1868599.
- [44] M. Chen, "The influence of big data analysis of intelligent manufacturing under machine learning on start-ups enterprise", *Enterprise Inf. Systems*, pp. 1-16, 2019, doi: 10.1080/17517575.2019.1694180.
- [45] M. Bourne, J. Mills, M. Wilcox, A. Neely, and K. Platts, "Designing, implementing and updating performance measurement systems," *Int. J. Oper. Prod. Manag.*, vol. 20, no. 7, pp. 754-771, 2000, doi: 10.1108/01443570010330739.
- [46] M. Bourne, A. Neely, J. Mills, and K. Platts, "Implementing performance measurement systems: a literature review," *Int. J. Bus. Perform. Manag.*, vol. 5, no. 1, pp. 1-24, 2003, doi: 10.1504/IJBPM.2003.002097.
- [47] R. Mello, L. Leite and R.A. Martins, "Is Big Data the Next Big Thing in Performance Measurement Systems?", In: *Industrial & Systems Engineering Research Conference*, Montreal, 2014.
- [48] R. Soltanpoor and T. Sellis, "Prescriptive Analytics for Big Data", In: *Databases Theory and Applications. ADC 2016. Lecture Notes in Computer Science()*, vol 9877. Springer, doi: 10.1007/978-3-319-46922-5\_19.
- [49] E. K. JUUSO, "Smart Adaptive Big Data Analysis with Advanced Deep Learning", *Open Engineering*, vol. 8, no. 1, pp. 403-416, 2018, doi.org/10.1515/eng-2018-0043.
- [50] S. LaValle, E. Lesser, R. Shockley, M. S. Hopkins, and N. Kruschwitz, "Big Data, analytics and the path from insights to value," *MIT Sloan Management Review*, vol. 52, no. 2, pp. 21-31, 2011.
- [51] S. Raschka and V. Mirjalili, Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2. *Packt Publishing Ltd*, 2019.
- [52] M. Rüßmann et al., "Industry 4.0: the future of productivity and growth in manufacturing," 2015. [Online]. Available: [https://www.bcg.com/ptbr/publications/2015/engineered\\_products\\_project\\_business\\_industry\\_4\\_future\\_productivity\\_growth\\_manufacturing\\_industries](https://www.bcg.com/ptbr/publications/2015/engineered_products_project_business_industry_4_future_productivity_growth_manufacturing_industries).
- [53] U.S. Bititci, U. Turner and C. Begemann, "Dynamics of performance measurement systems", *Int. J. Oper. Prod. Manag.*, vol. 20 no. 6, pp. 692-704, 2000, doi: 10.1108/01443570010321676.
- [54] D. Appelbaum, A. Kogan, M. Vasarhelyi, and Z. Yan, "Impact of business analytics and enterprise systems on managerial accounting," *Int. J. Account. Inf. Syst.*, vol. 25, pp. 29-44, 2017, doi: 10.1016/j.accinf.2017.03.003
- [55] L. Ardito, V. Scuotto, M. Del Giudice and A.M. Petruzzelli, "A bibliometric analysis of research on Big Data analytics for business and management", *Management Decision*, vol. 57 no. 8, pp. 1993-2009, 2019, doi: 10.1108/MD-07-2018-0754
- [56] P. Pradhan, "Science mapping and visualization tools used in bibliometric & scientometric studies: An overview.", 2017.
- [57] I. Portugal, P. Alencar and D. Cowan, "The use of machine learning algorithms in recommender systems: A systematic review", *Expert Syst. Appl.*, vol. 97, pp. 205-227, 2018, doi: 10.1016/j.eswa.2017.12.020.
- [58] J. Lee, B. Bagheri, and H. A. Kao, "A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems," *Manuf. Lett.*, vol. 3, pp. 18-23, 2015, doi: 10.1016/j.mfglet.2014.12.001.
- [59] T. Verbraken, C. Bravo, R. Weber and B. Baesens, "Development and application of consumer credit scoring models using profit-based classification measures", *European J. Oper. Res.*, vol. 238, no. 2, pp. 505-513, 2014, doi: 10.1016/j.ejor.2014.04.001.
- [60] V.G. Venkatesh et al., "System architecture for blockchain based transparency of supply chain social sustainability", *Robotics and Computer-Integrated Manufacturing*, vol. 63, pp. 101896, 2020, doi: 10.1016/j.rcim.2019.101896.
- [61] S.A.S. Vanz, I.R.C. Stumpf, "Procedimentos e ferramentas aplicados aos estudos bibliométricos", *Informação & Sociedade: estudos*, vol. 20, no. 2, pp. 67-75, 2010, <http://hdl.handle.net/10183/173225>.

- [62] N.J. Van Eck and L. Waltman, "VOSviewer manual", *Leiden: Univeriteit Leiden*, vol. 1, no. 1, pp. 1-53, 2013.
- [63] M. A. Waller and S. E. Fawcett, "Data science, predictive analytics, and big data: a revolution that will transform supply chain design and management," *J. Bus. Logist.*, vol. 34, no. 2, pp. 77–84, 2013, doi: 10.1111/jbl.12010.
- [64] G.M. Zanghelini, "Análise da evolução dos temas de pesquisa da ACV no Brasil baseada na relação de co-words", *Revista Latino-Americana em Avaliação do Ciclo de Vida*, vol. 1, n. Especial, pp. 34, 2017.
- [65] I. Zupic and T. Čater, "Bibliometric methods in management and organization," *Organ. Res. Methods*, vol. 18, no. 3, pp. 429–472, 2015, doi: 10.1177/1094428114562629.
- [66] S. Lima and F.A. Carlos Filho, "Bibliometric analysis of scientific production on sharing economy", *Revista de Gestão*, vol. 26 no. 3, pp. 237-255, 2019, doi: 10.1108/REGE-01-2019-0018
- [67] H. Mousannif, H. Sabah, Y. Douiji and Y. Oulad Sayad, "Big data projects: just jump right in!", *Int. J. of Pervasive Computing and Communications*, vol. 12 no. 2, pp. 260-288, 2016, doi: 10.1108/IJPC-04-2016-0023.
- [68] K. Lepenioti et al. "Prescriptive analytics: Literature review and research challenges", *Int. J. of Information Management*, vol. 50, pp. 57-70, 2020, doi: 10.1016/j.ijinfomgt.2019.04.003.
- [69] P. Ingwersen, "Bibliometrics/Scientometrics and IR. A methodological bridge through visualization", 2011.
- [70] J. A. Moral-Muñoz, E. Herrera-Viedma, A. Santisteban-Espejo and M.J. Cobo, "Software tools for conducting bibliometric analysis in science: An up-to-date review", *Profesional Información*, vol. 29, no.1, doi: 10.3145/epi.2020.ene.03.
- [71] A. Neely, M. Gregory and K. Platts, "Performance measurement system design: a literature review and research agenda", *Int. J. Oper. Prod. Manag.*, vol.25, no. 12, p. 1228–1263, 2005, doi: 10.1108/01443570510633639.
- [72] N.K. Dev, R. Shankar, R. Gupta and D. Jingxin, "Multi-criteria evaluation of real-time key performance indicators of supply chain with consideration of big data architecture", *Computers & Industrial Engineering*, vol. 128, pp. 1076-1087, 2019, doi: 10.1016/j.cie.2018.04.012.
- [73] A. Gunasekaran et al., "Big data and predictive analytics for supply chain and organizational performance," *J. Bus. Res.*, vol. 70, pp. 308–317, 2017, doi: 10.1016/j.jbusres.2016.08.004.
- [74] Q. Gui, C. Liu and D. Du, "Globalization of science and international scientific collaboration: A network perspective", *Geoforum*, vol. 105, pp. 1-12, 2019, doi: 10.1016/j.geoforum.2019.06.017.
- [75] B. Fahimnia, J. Sarkis and H. Davarzani, "Green supply chain management: a review and bibliometric analysis", *Int. J. Prod. Econ.*, vol. 162, pp. 101-114, 2015, doi: 10.1016/j.ijpe.2015.01.003.
- [76] N. Donthu et al., "How to conduct a bibliometric analysis: An overview and guidelines", *J. Bus. Res.*, vol. 133, pp. 285-296, 2021, doi: 10.1016/j.jbusres.2021.04.070.
- [77] T.H. Davenport and J.G. Haris, *Competição analítica: vencendo através da nova ciência*. Alta Books, 2020.
- [78] T.H. Davenport, *Analytics 3.0*. Harvard business review, vol. 91, no. 12, pp. 64-72, 2013.
- [79] G.V. Chueke and M. Amatucci. "O que é bibliometria? Uma introdução ao Fórum." *Internext*, vol. 10, no.2, pp. 1-5, 2015, doi:10.18568/1980-4865.1021-5.
- [80] F. Caviggioli and E. Ughetto, "A bibliometric analysis of the research dealing with the impact of additive manufacturing on industry, business and society," *Int. J. Prod. Econ.*, vol. 208, pp. 254–268, 2019, doi: 10.1016/j.ijpe.2018.11.022.
- [81] J. D. Camm, J. J. Cochran, M. J. Fry, J. W. Ohlmann, D. R. Anderson and D. J. Sweeney, "Business Analytics and Operations Research" in , *Cengage*, pp. 194, 2019, doi: 10.1109/IS48319.2020.9199954.
- [82] M. Aria and C. Cuccurullo, "Biblioshiny, bibliometrix for no coders", 2019 [Online]. Available: <http://bibliometrix.org/biblioshiny/>
- [83] A.G. Ferreira, "Bibliometria na avaliação de periódicos científicos." *DataGramaZero-Revista de Ciência da Informação*, vol.11, pp.1-9, 2010.
- [84] X.Y. Leung, J. Sun and B. Bai, "Bibliometrics of social media research: A co-citation and co-word analysis", *Int. J. of Hospitality Management*, vol. 66, pp. 35-45, 2017, doi: 10.1016/j.ijhm.2017.06.012.
- [85] P.S. Deshpande, S.C. Sharma and S.K. Peddoju, "Predictive and prescriptive analytics in Big-data Era", In: *Security and data storage aspect in cloud computing*, Springer, Singapore, 2019, pp. 71-81.
- [86] H.S. Lamba and S.K. Dubey, "Analysis of requirements for big data adoption to maximize IT business value", In: 4th International Conference on Reliability, Infocom Technologies and Optimization. IEEE, 2015. pp. 1-6.
- [87] M.M. Najafabadi. et al., "Deep learning applications and challenges in big data analytics", *Journal of Big Data*, vol. 2, no. 1, 2015, doi: 10.1186/s40537-014-0007-7.
- [88] V. Chang, "Towards a Big Data system disaster recovery in a Private Cloud", *Ad Hoc Networks*, vol. 35, pp. 65-82, 2015, doi: 10.1016/j.adhoc.2015.07.012.
- [89] J.S. Chou, C.F. Tsai, A.D. Pham and Y.H. LU, "Machine learning in concrete strength simulations: Multi-nation data analytics", *Construction and Building Materials*, vol. 73, pp. 771-780, 2014, doi: 10.1016/j.conbuildmat.2014.09.054.
- [90] M.J. Cobo, A.G.López-Herrera, E. Herrera-Viedma and F. Herrera, "An approach for detecng, quanfyng, and visualizing the evoluon of a research field: A praccal applicaon to the fuzzy sets theory field", *Journal of Informetrics*, vol. 5, pp.146-166, 2011, doi:10.1016/j.joi.2010.10.002.
- [91] T.H. Davenport, "What do we talk about when we talk about analytics?", *Enterprise analytics, op. perf., proc. dec.big data*, pp. 9-18, 2013.
- [92] A.Z. Faroukhi et al., "Big data monetization throughout Big Data Value Chain: a comprehensive review", *J Big Data*, vol. 7, no. 3, 2020, doi: 10.1186/s40537-019-0281-5.
- [93] F. Franceschini, G. Maurizio and M. Domenico, *Designing performance measurement systems: theory and practice of key performance indicators*. Springer, 2018.
- [94] J.Z. Zhang et al., "Big Data Analytics and Machine Learning: A Retrospective Overview and Bibliometric Analysis", *Expert Syst. Appl.*, vol. 184, pp. 115561, 2021, doi: 10.1016/j.eswa.2021.115561.
- [95] Q. Wu et al., "Cognitive internet of things: a new paradigm beyond connection," *IEEE Internet Things J.*, vol. 1, no. 2, pp. 129–143, 2014, doi: 10.1109/JIOT.2014.2311513.
- [96] M. Aria and C. Cuccurullo, "Bibliometrix: an R-tool for comprehensive science mapping analysis," *J. Informetr.*, vol. 11, no. 4, pp. 959–975, 2017, doi: 10.1016/j.joi.2017.08.007.
- [97] G.F. Frederico, J.A. Garza-Reyes, A. Kumar and V. Kumar, "Performance measurement for supply chains in the Industry 4.0 era: a balanced scorecard approach", *Int. J Prod. Perfor. Manag.*, vol. 70, no. 4, pp. 789-807, 2021, doi: 10.1108/IJPPM-08-2019-0400.
- [98] A. Gaur and M. Kumar, "A systematic approach to conducting review studies: an assessment of content analysis in 25years of IB research", *Journal of World Business*, vol. 53 no. 2, pp. 280-289, 2018, doi: 10.1016/j.jwb.2017.11.003.
- [99] B. T. Hazen, C. A. Boone, J. D. Ezell, and L. A. Jones-Farmer, "Data quality for data science, predictive analytics, and big data in supply chain management: an introduction to the problem and suggestions for research and applications," *Int. J. Prod. Econ.*, vol. 154, pp. 72–80, 2014, doi: 10.1016/j.ijpe.2014.04.018.
- [100] Q. He, "Knowledge discovery through co-word analysis," *Libr. Trends*, vol. 48, no. 1, pp. 133–159, 1999.
- [101] S. S. Nudurupati, S. Tebboune, and J. Hardman, "Contemporary performance measurement and management (PMM) in digital economies," *Prod. Plan. Control*, vol. 27, no. 3, pp. 226–235, 2016, doi: 10.1080/09537287.2015.1092611.
- [102] S. S. Nudurupati, P. Garengo and U.S. Bititci, "Impact of the changing business environment on performance measurement and management practices", *Int. J. Prod. Econ.*, vol. 232, 2021, doi: 10.1016/j.ijpe.2020.107942.
- [103] E. Manavalan and K. Jayakrishna, "A review of Internet of Things (IoT) embedded sustainable supply chain for industry 4.0 requirements", *Computers & Industrial Engineering*, vol. 127, pp. 925-953, 2019, doi: 10.1016/j.cie.2018.11.030

- [104] A. Perianes-Rodriguez, L. Waltman and N.J. Van Eck, "Constructing bibliometric networks: A comparison between full and fractional counting", *Journal of Informetrics*, vol. 10, no. 4, pp. 1178-1195, 2016, doi: 10.1016/j.joi.2016.10.006.
- [105] A. Kücher and B. Feldbauer-Durstmüller, "Organizational failure and decline—A bibliometric study of the scientific front end", *J. Bus. Res.*, vol. 98, pp. 503-516, 2019, doi: 10.1016/j.jbusres.2018.05.017.
- [106] M.C.C. Grácio, "Acoplamento bibliográfico e análise de cocitação: revisão teórico-conceitual", *Enc. Bibli.: rev. elet. bib. cien. da inf.*, vol. 21, no. 47, pp. 82-99, 2016, doi: 10.5007/1518-2924.2016v21n47p82.
- [107] A. McAfee and E. Brynjolfsson, "Big data: the management revolution," *Harvard Business Review*, vol. 90, no. 10, p. 4, 2012.
- [108] S. F. Wamba, S. Akter, A. Edwards, G. Chopin, and D. Gnanzou, "How 'big data' can make big impact: findings from a systematic review and a longitudinal case study," *Int. J. Prod. Econ.*, vol. 165, pp. 234-246, 2015, doi: 10.1016/j.ijpe.2014.12.031.
- [109] S. F. Wamba, A. Gunasekaran, S. Akter, S. J. fan Ren, R. Dubey, and S. J. Childe, "Big data analytics and firm performance: effects of dynamic capabilities," *J. Bus. Res.*, vol. 70, pp. 356-365, 2017, doi: 10.1016/j.jbusres.2016.08.009.
- [110] S. Jeble, R. Dubey, S. J. Childe, T. Papadopoulos, D. Roubaud, and A. Prakash, "Impact of big data and predictive analytics capability on supply chain sustainability," *Int. J. Logist. Manag.*, vol. 29, no. 2, pp. 513-538, 2018, doi: 10.1108/IJLM-05-2017-0134.
- [111] S.F. Wamba, M.M. Queiroz and L.Trinchera, "Dynamics between blockchain adoption determinants and supply chain performance: An empirical investigation", *Int. J. Prod. Econ.*, vol. 229, 2020, doi: 10.1016/j.ijpe.2020.107791.
- [112] R. S. Kaplan and D. P. Norton, "Using the Balanced Scorecard as a strategic management system," *Harvard Business Review*, p. 14, 1996.
- [113] G. Gravili, M. Benvenuto, A. Avram, and C. Viola, "The influence of the Digital Divide on Big Data generation within supply chain management," *Int. J. Logist. Manag.*, vol. 29, no. 2, pp. 592-628, 2018, doi: 10.1108/IJLM-06-2017-0175.
- [114] G. Vitale, S. Cupertino and A. Riccaboni, "Big data and management control systems change: the case of an agricultural SME", *J. Manag. Control*, vol. 31, pp. 123-152, 2020, doi: 10.1007/s00187-020-00298-w.
- [115] E.M. El-Alfy and S.A. Mohammed, "A review of machine learning for big data analytics: bibliometric approach", *Technology Analysis & Strategic Management*, pp. 1-22, 2020, doi:10.1080/09537325.2020.1732912.
- [116] H. Dai, H. Wang, G. Xu, J. Wan and M. Imran, "Big data analytics for manufacturing internet of things: opportunities, challenges and enabling.
- [118] U.S. Bititci, A.S. Carrie and L. McDevitt, "Integrated performance measurement systems: a development guide", *Int. J. Oper. Prod. Manag.*, vol. 17 no. 5, pp. 522-534, 1997, doi: 10.1108/01443579710167230
- [119] J. Bragge et al., "Unveiling the intellectual structure and evolution of external resource management research: Insights from a bibliometric study", *J. Bus. Res.*, vol. 97, pp. 141-159, 2019, doi: 10.1016/j.jbusres.2018.12.050.
- [120] S. Stieglitz et al. Social media analytics. *Business & Information Systems Engineering*, vol. 6, no. 2, pp. 89-96, 2014, doi: 10.1007/s12599-014-0315-7
- [121] W. Lu et al. "Benchmarking construction waste management performance using big data." *Resources, Conservation and Recycling* vol. 105, pp. 49-58, 2015, doi: 10.1016/j.resconrec.2015.10.013
- [122] F. Osareh and E. Mostafavi. "Lotka's Law and authorship distribution in Computer Science using Web of Science (WoS) during 1986-2009." *Collnet Journal of Scientometrics and Information Management*, vol. 5, no.2, pp. 171-183, 2011.
- [123] M. A. Lopes and R.A. Martins. "Mapping the impacts of industry 4.0 on performance measurement systems." *IEEE Latin America Transactions*, vol. 19, no.11, pp. 1912-1923, 2021.

technologies", *Enterprise Inf. Systems*, pp.1279-1303, 2020, doi: 10.1080/17517575.2019.1633689.

- [117] Chen, Ye-Sho, and Ferdinand F. Leimkuhler. "A relationship between Lotka's law, Bradford's law, and Zipf's law." *Journal of the American Society for Information Science* 37.5 (1986): 307-314.



**Junior Aparecido Assandre** possui graduação em Administração e Mestrado em Gestão e Sistemas Públicos (2015). Atualmente é candidato de doutorado em Engenharia de Produção na Universidade Federal de São Carlos. Pesquisa os seguintes temas: Sistema de Medição de Desempenho e Big Data Analytics para Medição de Desempenho.



**Dr. Roberto A. Martins** possui graduação, mestrado e doutorado em Engenharia de Produção pela Universidade de São Paulo. Atualmente é Professor Titular da Universidade Federal de São Carlos com interesses nos temas de pesquisa: Sistemas de Medição de Desempenho para Gestão de Cadeias de Suprimentos Sustentáveis, Uso de BDA.