Business intelligence e sistemas nebulosos na definição de lean score

Business intelligence and fuzzy systems in the definition of lean score

Pedro Dantas Bezerra Braga
Universidade Federal do Rio Grande do Norte | Natal | Brasil | pedro_braga@icloud.com
Tatiana Gondim do Amaral
Universidade Federal de Goiás | Goiânia | Brasil | tatianagondim@ufg.br
Reymard Sávio Sampaio de Melo
Universidade Federal da Bahia | Salvador | Brasil | reymard.savio@ufba.br

Resumo

Não há um consenso na literatura sobre o método mais adequado de se avaliar o nível de implementação de construção enxuta em empresas. Ao contrário dos métodos de avaliação existentes, o uso da lógica fuzzy reduz a subjetividade da avaliação. Este artigo usa o Business Intelligence para definir as regras de um modelo de sistema de inferência difuso para calcular o indicador de desempenho "lean score". A simulação pelo Power BI permitiu identificar vieses no modelo. As regras propostas foram locadas igualmente para cada uma das quatro variáveis de entrada do modelo: presença, complexidade, tempo e estágio.

Palavras-chave: Construção Enxuta. Lógica fuzzy. Desempenho Enxuto. Regras Fuzzy. Power BI.

Abstract

There is no consensus in the literature on the most appropriate method to assess the level of implementation of lean construction in companies. Unlike existing assessment methods, the use of fuzzy logic reduces the subjectivity of judgment. This article uses Business Intelligence to define the rules of a fuzzy inference system model to calculate the "lean score" performance indicator. The simulation by Power BI allowed identifying biases in the model. The proposed rules were placed equally for each of the four input variables of the model: presence, complexity, time, and stage.

Keywords: Lean construction. Fuzzy logic. Lean performance. Fuzzy rules. Power BI.

INTRODUÇÃO

A Construção Enxuta (do inglês *Lean Construction*) tem como objetivo maximizar o valor do produto, reduzindo desperdícios e custos [1]. Além do mais, a Construção enxuta foi definida pela junção de técnicas, práticas e princípios com a finalidade de melhorar os processos e sistemas na construção civil [2].

Estudos anteriores avaliaram a implementação do *Lean Construction* em empresas construtoras com a finalidade de identificar as oportunidades de melhorias no

Como citar:
BRAGA, P. D. B. .; AMARAL , T. G. do .; MELO , R. S. S. de . Business intelligence e sistemas nebulosos na definição de lean score. In: SIMPÓSIO BRASILEIRO DE TECNOLOGIA DA INFORMAÇÃO E COMUNICAÇÃO NA CONSTRUÇÃO, 3., 2021, Uberlândia. **Anais** [...]. Porto Alegre: ANTAC, 2021. p. 1-8. Disponível em: https://eventos.antac.org.br/index.php/sbtic/article/view/597. Acesso em: 3 ago. 2021.

processo de implementação [3]. Pesquisadores desenvolveram um protocolo de avaliação da implementação do *Lean construction* em auditorias que foram agrupadas as práticas e ações em 15 categorias, de acordo com os princípios pré-estabelecidos [4]. Enquanto outro estudo usou as regras *fuzzy* com o objetivo de propor uma ferramenta para avaliar o grau de implementação de L*ean Construction* de empresas (Lean Score), a partir da avaliação das práticas e ferramentas *lean* [5]. Seu modelo passou a examinar quatro parâmetros de entrada – presença, complexidade, tempo e estágio – e um parâmetro de saída, definida como *lean score*. As regras definidas apresentaram vieses de tendência, fazendo com que o modelo apresentasse tendências otimistas ou pessimistas dos resultados.

A Lógica *fuzzy* (Lógica difusa) proposta tem por finalidade utilizar um grau de adesão para representar a subjetividade e as incertezas decorrentes das ações humanas [6]. O seu benefício é decorrente da existência da avaliação do modelo ser qualitativa, envolvendo operações com as variáveis linguísticas, devido à dificuldade de eventos serem descritos numericamente [7]. Seu desenvolvimento possibilitou uma modelagem de problemas mais próximos da realidade, usado na previsão, tomada de decisão e controle das ações [6][8]. A Lógica *fuzzy* é composta a partir de regras que relacionam um conjunto de entradas (*inputs*) e um conjunto de saída (*outputs*), por meio de funções de pertinência.

Um dos desafios relacionados ao processo da Lógica fuzzy é a identificação da quantidade necessária de funções de pertinência e o processo de definição das regras, uma vez que é um processo naturalmente subjetivo [9]. Dessa forma, caso o problema seja mais complexo, ou seja, maior o número de regras, mais difícil é o processo de definição das funções de pertinência e das regras *fuzzy* [10].

O desenvolvimento do modelo analisado passou a avaliar as práticas do *Lean Construction* a partir da relação entre quatro *inputs* e um *output* [5]. As regras propostas foram elaboradas a partir da experiência prévia do referido autor na implementação do modelo. O estudo de [5] não fundamentou as regras a partir da literatura. Uma provável razão para esta ausência de fundamentação teórica nas regras se dá pelo fato de que a literatura existente não aborda parâmetros interrelacionados como estágio, complexidade, presença e tempo de implementação da construção enxuta. Tal estratégia seguida por [5] na elaboração das regras pode levar a atribuição de parâmetros tendenciosos das quatros variáveis.

Uma potencial maneira de atenuar essa tendência na atribuição das regras do FIS é por meio do uso de *Business Intelligence (BI).* O *BI* possibilita a visualização da uniformidade das regras, fornecendo informações úteis relativas ao processo de tomada de decisão [11]. Além do mais, é utilizado para apoiar as decisões estratégicas e de negócios, sendo direcionado a um objetivo e direção em um nível mais amplo [12]. Portanto, este estudo tem como objetivo propor o uso do *Business Intelligence* para definir as regras de um sistema nebuloso, ou *fuzzy inference systems* (FIS), voltado à determinação de um *lean score* [5].

MÉTODO DE PESQUISA

O método de pesquisa empregado foi a simulação, pois requer um modelo operacional que representa uma parcela ou o todo do sistema a ser desenvolvido [13]. De acordo com o apresentado na Figura 1, o sistema FIS contou com quatro variáveis de entrada – presença, complexidade, tempo e estágio, e cada um com três funções de pertinência. Além do mais, a variável de saída, definida como *lean score*, contou com 5 funções de pertinências.

Figura 1: Diagrama do modelo FIS analisado

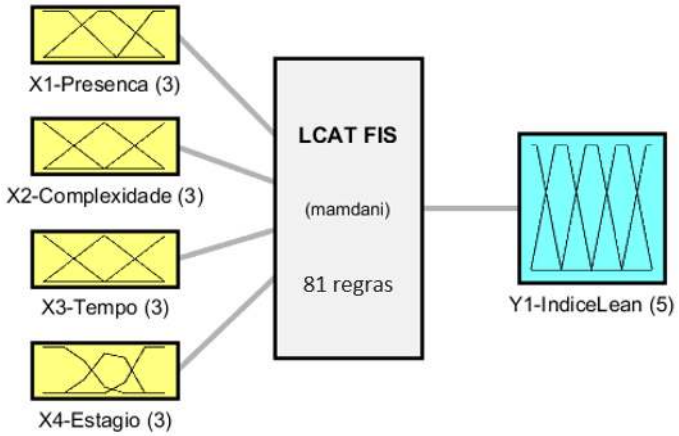

Fonte: Camargo Filho (2017).

As regras foram definidas com o tipo SE-ENTÃO para os parâmetros de entrada e saída. O número de regras utilizadas corresponde ao produto entre o número de funções de pertinência adotadas para cada uma das variáveis de entrada (*inputs*). Dessa forma, 81 regras foram apresentadas, a primeira e 71ª foram exemplificadas na Tabela 1.

Tabela 1: Sistema de regras do FIS

REGRAS	SE				ENTÃO
	X1-Presença	X2-Complexidade	X3-Tempo	X4-Estágio	Y1-Lean Score
1	Baixo	Pouco	Inicial	Inicial	Muito baixo
71	Médio	Muito	Amadurecimento	Melhoria contínua	Médio

Fonte: Camargo Filho (2017).

As variáveis são caracterizadas de acordo com práticas e ferramentas *lean* adotadas por empresas construtoras. O *input* de presença é definido de acordo com as práticas presentes nas obras, de acordo com o nível de implementação, podendo ser baixo, médio ou alto. Com relação a complexidade, sua caracterização ocorre de acordo com a dificuldade de implementação das práticas e ferramentas, variando de pouco, médio ou alta complexidade. No caso do tempo, sua definição é dada pelo tempo esperado para cada prática ser implementada, sua variação ocorre para o estágio inicial, amadurecimento ou melhoria contínua. Para o estágio, sua classificação ocorre a partir do tempo decorrido em cada uma das práticas e ferramentas analisadas, variando de inicial, amadurecimento ou melhoria contínua. Por fim, o *output*, caracterizado como *lean score*, é definido para representar o grau de implementação do L*ean Construction*,

sua variação ocorre a partir de uma escala em quatro níveis: muito baixo, baixo, médio, alto ou muito alto.

De acordo com o modelo FIS, as regras foram exportadas no formato EXCEL para uma plataforma desenvolvida de tratamentos de dados no *Power BI*, da *Microsoft*, com a finalidade de formar painéis interativos (*dashboard*) [14].

Ao integrar banco de dados das regras FIS em planilha eletrônica com o *Power BI* são escolhidos quais parâmetros serão analisados, com o *lean score* no eixo X e a contagem do índice atribuído para cada um dos quatro inputs no eixo Y, e suas respectivas legendas para cada um dos termos de associação. A representação gráfica adotada foi a de faixas.

A escolha do *software* foi devido a possibilidade de inserir diversas análises de forma interativa e online, permitindo que os autores conseguissem interagir e refletir sobre os resultados [15].

Dessa forma, foram analisadas todas as regras que foram atribuídas para cada função de pertinência nos *inputs* e *outputs*, a fim de obter a sua distribuição e possibilitar que sejam realizadas análises. De forma preliminar, as regras foram definidas aplicando-se uma média aritmética entre os valores de entrada, com a finalidade de obter um resultado que não haja nenhuma tendência otimista ou pessimista, de acordo com os valores atribuídos pelas variáveis *inputs*.

RESULTADOS E DISCUSSÕES

A distribuição das regras definidas para o *output* de seu modelo *fuzzy* está resumida na Tabela 2 [5]. A determinação das funções de pertinência possibilitou definir as regras de acordo com os termos de associação. Dessa forma, a partir da análise da distribuição, percebe-se que há uma tendência para os valores máximos e mínimos na definição do modelo proposto pelo autor, em que estão concentradas 30% e 33% das regras. Isso faz com que os resultados do modelo apresentem uma tendência otimista ou pessimista, dependendo dos valores atribuídos pelas variáveis *inputs*. Sendo assim, haverá uma menor possibilidade de haver situações *pouco enxutas* e *muito enxutas.*

Tabela 2: Quantidade de regras classificadas de acordo com o *Lean* Score apresentado por Camargo Filho (2017)

Lean Score	Quantidade	Percentual
Muito Baixo	24	30%
Baixo	9	11%
Médio	15	19%
Alto	6	7%
Muito Alto	27	33%

Fonte: os autores.

A distribuição da contagem de *lean score* desenvolvida para cada um dos *inputs* está representada pela Figura 2 [5]. A ferramenta do *Power BI* possibilita analisar a distribuição das regras *fuzzy* a partir de diferentes perspectivas, uma vez que é possível apresentar uma interação entre as análises. Dessa forma, é possível perceber a não

coerência das distribuições das regras, uma vez que a classificação do *lean score* está mal distribuído para os *inputs*. Enquanto as classificações "*muito alto*" e "*muito baixo*" dos inputs de estágio, complexidade, tempo e presença estão distribuídos com a mesma ordem de proporção das classificações *iniciais*, *amadurecimento* e de *melhoria contínua*, tornando incoerente os critérios de distribuição adotados.

Quando relacionado à análise de cada um dos *inputs*, o conceito do *estágio* de implementação na Figura 2 (à esquerda acima), é possível visualizar que na distribuição há estágios iniciais de desenvolvimento e classificados como enxuta, assim como o estágio de melhoria contínua em não enxuto. Além do mais, a ferramenta apresenta visualmente uma descontinuidade de *pouco complexo* (Figura 2, à direita acima) e de tempo inicial (Figura 2, à esquerda abaixo) com *muito* enxuto, permitindo identificar quais são as regras não coerentes a partir das interações. A presença, representada pela Figura 2 (à direita abaixo), é a única que tem uma distribuição diferente das anteriores, com regras *alto* e *baixo* tendendo a funções de pertinência *muito alto* e *muito baixo*, respectivamente. A partir disso, é possível identificar que a distribuição das regras ocorreu a partir do *input* de *presença*, sem que fosse levado em consideração as demais.

Figura 2: Contagem de L*ean Score* apresentado por Camargo Filho (2017) por Estágio (à esquerda acima), Complexidade (à direita acima), Tempo (à esquerda abaixo) e Presença (à direita abaixo)

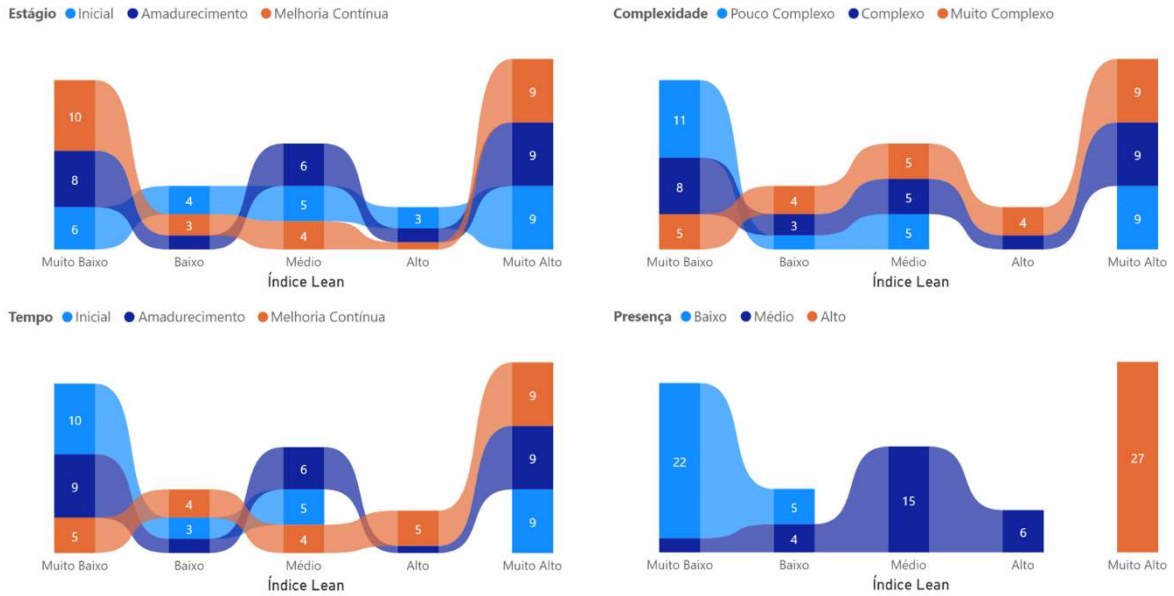

Fonte: os autores.

Com a utilização do Power BI, é apresentado na Tabela 3 a nova distribuição das regras *fuzzy*, levando em consideração as análises interativas que permitiram identificar quais foram as regras que estavam tendenciosas. A distribuição das regras está concentrada em índices centrais, cerca de 88% variando de *baixo* até *alto*, e sem que haja otimistas ou pessimistas. Sendo assim, há uma maior possibilidade de que apresente *lean scores* similares entre si, para *inputs* que também não variam tanto entre si.

Tabela 3: Quantidade de regras classificadas de acordo com o *Lean Score* proposta

Lean Score	Quantidade	Percentual
Muito Baixo	5	6%
Baixo	26	32%
Médio	19	23%
Alto	26	32%
Muito Alto	5	6%

Fonte: os autores.

A distribuição da contagem de *lean score* propostas para cada um dos *inputs* estão representadas pela Figura 3. Devido a análise no *Power BI*, as regras foram redistribuídas, a fim de melhor representar a distribuição do *lean score* de acordo com os quatro *inputs*. Com isso, foi alocado os quantitativos iniciais e finais referentes a cada função de pertinência, de forma a melhor representar o indicador de forma mais coerente. Além do mais, é percebido que todos os *inputs* apresentam a mesma distribuição, uma vez que cada *input* neste caso foi alocado com o mesmo peso e grau de importância ao resultado do índice.

Figura 3: Contagem de *lean score* proposta e de acordo com o Estágio (à esquerda acima), Complexidade (à direita acima), Tempo (à esquerda abaixo) e Presença (à direita abaixo)

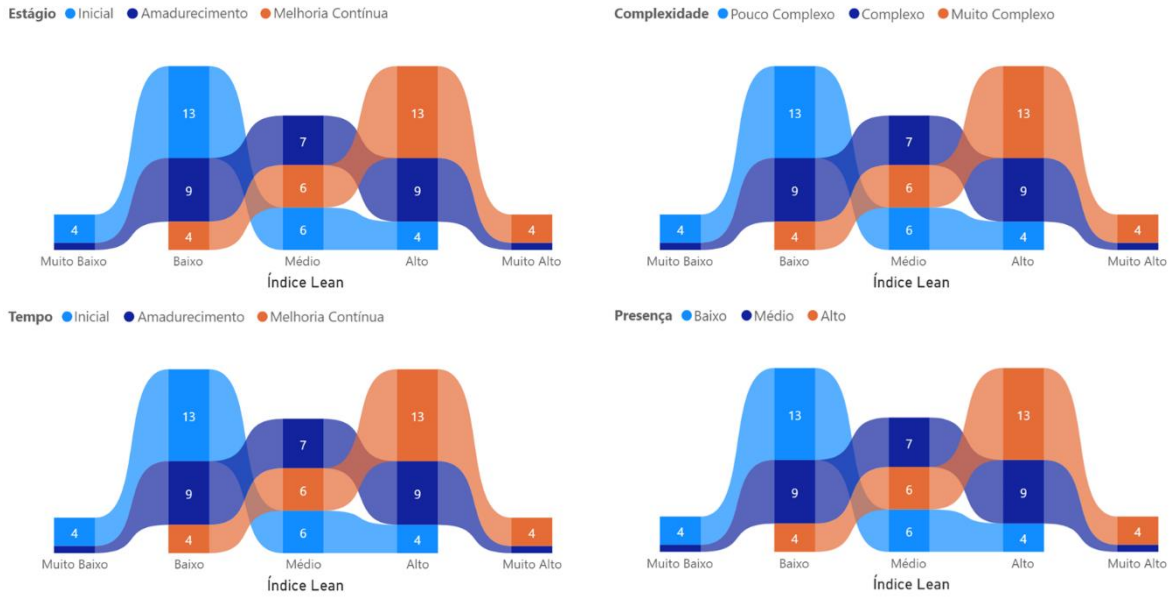

Fonte: os autores.

O Quadro 1 faz referência às sete principais regras de ambas as distribuições, ou seja, as que apresentaram as maiores divergências entre si. Dessa forma, é identificado que no modelo anterior há uma tendência nos resultados, fazendo com que o principal influenciador seja o *input* da presença. Enquanto isso, na distribuição proposta foi possível identificar esse viés por meio do *Power BI*, fazendo com que as regras sejam locadas igualmente para cada uma das variáveis apresentadas, sem que haja nenhum peso ou grau de importância predefinido.

Quadro 1: Principais regras propostas e de Camargo Filho (2017)

Presença	Complexidade	Tempo	Estágio	Lean Score	
				Proposta	Camargo Filho (2017)
Baixo	Complexo	Amadurecimento	Melhoria Contínua	Médio	Muito Baixo
Baixo	Complexo	Melhoria Contínua	Amadurecimento	Médio	Muito Baixo
Baixo	Muito Complexo	Amadurecimento	Amadurecimento	Médio	Muito Baixo
Baixo	Muito Complexo	Melhoria Contínua	Amadurecimento	Alto	Baixo
Médio	Pouco Complexo	Amadurecimento	Melhoria Contínua	Médio	Muito Baixo
Alto	Pouco Complexo	Inicial	Inicial	Baixo	Muito Alto
Alto	Complexo	Amadurecimento	Inicial	Médio	Muito Alto

Fonte: os autores.

CONCLUSÃO

A principal contribuição deste trabalho foi analisar as regras FIS, a partir de uma ferramenta de BI, para um sistema destinado ao cálculo do *lean score* proposto por [5]. A partir da plataforma desenvolvida para o tratamento de dados no Power BI, foi possível identificar a definição das regras em quatro *inputs* destinados ao cálculo do *lean score*.

A variável de presença foi a que apresentou o maior viés, pois a ferramenta conseguiu identificar que a função de pertinência *alto* estava toda destinada a um *lean score muito alto*. Além do mais, as interações entre os demais *inputs* apresentaram vieses otimistas e pessimistas, uma vez que 63% das regras haviam se concentrado nas extremidades da classificação do *lean score*.

Dessa forma, a ferramenta do *Power BI* possibilitou realizar análises interativas entre as quatro variáveis de entrada do modelo, de forma a apresentar os gráficos em conjunto. Esta análise permitiu identificar quais foram as regras que necessitavam ser alteradas, de acordo com as locações dos *inputs*. Portanto, a plataforma desenvolvida na ferramenta BI apresentou um resultado promissor na análise da distribuição das regras *fuzzy*.

As limitações da pesquisa estão relacionadas à quantidade de análises realizadas, visto que foi discutido as regras propostas por um modelo. Além do mais, é possível apresentar um método de desenvolvimento de regras *fuzzy* usando a média ponderada, atribuindo pesos de acordo com o grau de importância da variável. Pesquisas futuras podem ser destinadas a aplicação da ferramenta em outros modelos fuzzy, com regras e *inputs* diferentes, a fim de consolidar o seu uso.

REFERÊNCIAS

[1] KOSKELA, L. Lean Production in Construction. In: ANNUAL INTERNATIONAL SYMPOSIUM ON AUTOMATION AND ROBOTICS IN CONSTRUCTION, 10., 1993, Houston. **Proceedings [...]** Houston: The International Association for Automation and Robotics in Construction, 1993, p.47-54. DOI: https://doi.org/10.22260/ISARC1993/0007

[2] MOSSMAN, A. What Is Lean Construction: Another Look - 2018. In: ANNUAL CONFERENCE INTERNATIONAL GROUP FOR LEAN CONSTRUCTION, 26., 2018, Chennai. **Proceedings [...]** Chennai: IGLC, 2018, p 1229-1239. DOI: https://doi.org/10.24928/2018/0309

[3] ETGES, B. M. B. S.; SAURIN, T. A.; BULHÕES, I. R. A Protocol for Assessing the Use of Lean Construction Practices. In: ANNUAL CONFERENCE INTERNATIONAL GROUP FOR LEAN CONSTRUCTION, 21., 2013, Fortaleza. **Proceedings [...]** Fortaleza: IGLC, 2013, p 93-101.

[4] WOMACK, J. P.; JONES, D. T. Beyond Toyota: how to root out waste and pursue perfection. **Harvard business review**, v.74, n.5, p. 140, 1996

[5] CAMARGO FILHO, C. A. B. **LCAT: ferramenta de avaliação da implementação da construção enxuta**. 2017. 143 f. Dissertação (Mestrado em Geotecnia, Estruturas e Construção Civil) - Universidade Federal de Goiás, Goiânia, 2017.

[6] ZADEH L. A. Fuzzy sets. **Information and Control**. v.8, n.3, p. 338–353, 1965.

[7] PETROVIĆ, D.; TANASIJEVIĆ, M.; MILIĆ, V.; LILIC, N.; STOJADINOVIĆ, S.; SVRKOTA, I. Risk assessment model of mining equipment failure based on fuzzy logic. **Expert Systems with Applications**. v.41, n.18, p. 8157–8164, 2014. DOI: https://doi.org/10.1016/j.eswa.2014.06.042

[8] BOJADZIEV, G.; BOJADZIEV, M. **Fuzzy logic for business, finance, and management**. 2nd ed. Singapore: World Scientific, 2007. 252 p.

[9] ROY, A.; CHENG, M.; WU, Y. Time dependent evolutionary fuzzy support vector machine inference model for predicting diaphragm wall deflection. **Neural Network World**. v.24, p.193-210, 2014.

[10] KO, C. H. **Evolutionary Fuzzy Neural Inference Model (EFNIM) for Decision-Making in Construction Management**. 2002. Ph.D. Thesis, Department of Construction Engineering, National Taiwan University of Science and Technology, Taipei, Taiwan, 2002.

[11] CHEN, H; CHIANG, R. H.; STOREY V. C. Business Intelligence and Analytics: From Big Data to Big Impact. **MIS Quarterly**. v.36, n.4, p.1165–88, 2012. DOI: https://doi.org/10.2307/41703503

[12] GAOL, F.; ABDILLAH, L.; MATSUO, T. Adoption of Business Intelligence to Support Cost Accounting Based Financial Systems — Case Study of XYZ Company. **Open Engineering**. v. 11, n. 1, 2021, p. 14-28, 2021. DOI: https://doi.org/10.1515/eng-2021-0002

[13] VICENTE, P. O uso de simulação como metodologia de pesquisa em ciências sociais. **Cadernos EBAPE.BR**, Rio de Janeiro, v. 3, n. 1, p. 01-09, Mar. 2005. Disponível em: http://dx.doi.org/10.1590/S1679-39512005000100008

[14] CALDINI, V.; VARELA, E. Uso de *Business Intelligence* para gerenciamento processos pós-obra. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 18., 2020, Porto Alegre. **Anais...** Porto Alegre: ANTAC, 2020.

[15] LOPES, A. B. **Aplicações analíticas na construção civil: investigações e um estudo de caso na gestão de custos**. 2020. 102 f. Dissertação (Mestrado em Tecnologias, Gestão e Sustentabilidade) - Universidade Estadual do Oeste do Paraná, Foz do Iguaçu, 2020.