

**ARTHUR ARAÚJO SILVA**

**TECNOLOGIAS DIGITAIS APLICADAS NA GESTÃO DO CORTE FLORESTAL  
COM *HARVESTER***

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Doctor Scientiae*.

Orientador: Carlos Cardoso Machado

**VIÇOSA - MINAS GERAIS  
2021**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade  
Federal de Viçosa - Campus Viçosa**

T

S586t                   Silva, Arthur Araújo, 1989-  
2021                    Tecnologias digitais aplicadas na gestão do corte florestal  
com harvester / Arthur Araújo Silva. – Viçosa, MG, 2021.  
1 tese eletrônica (80 f.): il.

Inclui anexos.

Orientador: Carlos Cardoso Machado.

Tese (doutorado) - Universidade Federal de Viçosa,  
Departamento de Engenharia Florestal, 2021.

Referências bibliográficas: f. 70-78.

DOI: <https://doi.org/10.47328/ufvbbt.2021.188>

Modo de acesso: World Wide Web.

1. Corte (árvores). 2. Madeira - Exploração - Processamento de dados. 3. Processamento eletrônico de dados. 4. Sistemas de transmissão de dados. 5. Power BI (Software). I. Machado, Carlos Cardoso, 1951-. II. Universidade Federal de Viçosa. Departamento de Engenharia Florestal. Programa de Pós-graduação em Ciência Florestal. III. Título.

CDO adapt. CDD 634.9614

Bibliotecário(a) responsável: Renata de Fátima Alves CRB6/2578

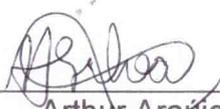
**ARTHUR ARAÚJO SILVA**

**TECNOLOGIAS DIGITAIS APLICADAS NA GESTÃO DO CORTE FLORESTAL  
COM HARVESTER**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Doctor Scientiae*.

APROVADA: 28 de setembro de 2021.

Assentimento:



---

Arthur Araújo Silva  
Autor



---

Carlos Cardoso Machado  
Orientador

## **AGRADECIMENTOS**

Primeiramente agradeço a Deus pelo dom da vida e a Nossa Senhora Aparecida por guiar meus passos durante esta jornada.

À minha mãezinha Nilcea Silva pelo seu esforço, sempre visando meu crescimento e, sendo assim a principal responsável por mais esta vitória.

À toda minha família, em especial minha avó Maria Antônia da Silva, pelas valiosas colaborações ao longo deste caminho.

Aos professores Hélio Garcia Leite, Sebastião Renato Valverde, Luciano José Minette e Raiane Ribeiro Machado Gomes pelos conhecimentos transmitidos. Em especial, ao professor e orientador, Carlos Cardoso Machado, por ter abraçado minha ideia e acreditado em minha capacidade, sendo fundamental para a concretização deste trabalho.

À Angelita e aos amigos estrangeiros que fizeram parte desta história.

Aos funcionários do Departamento de Engenharia Florestal - DEF, em especial aos amigos Alexandre e Dilson e à amiga Julien, por sempre estarem dispostos a ajudar na resolução das pendências ao longo deste caminho.

Ao Professor e amigo Wagner L. Araújo por ter sido como um “pai” para mim durante esta caminhada, fica o agradecimento pelas dicas oportunas.

A todos os amigos da Engenharia Florestal 2009, principalmente os companheiros do Boca Seca Jrs. pela parceria de sempre.

Aos estudantes da disciplina ENF 446, pelas palavras de apoio.

À SIF por todo aprendizado ao longo do último ano de doutorado.

À Universidade Federal de Viçosa, que me proporcionou a realização de um grande objetivo da minha vida.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de estudos.

## BIOGRAFIA

Arthur Araújo Silva, filho de Nilcea Silva, nasceu em 26 de outubro de 1989, em Florestal, Minas Gerais. Em 2007 se tornou Técnico em Agropecuária, tendo realizado este curso concomitantemente com o Ensino Médio na antiga CEDAF (Central de Ensino e Desenvolvimento Agrário de Florestal), atualmente UFV - Campus Florestal.

Em 2009, iniciou o curso de Engenharia Florestal, na Universidade Federal de Viçosa, sendo o mesmo concluído em dezembro de 2014. Em julho de 2017, concluiu o curso de Mestrado em Ciência Florestal na mesma instituição, obtendo o título de *Magister Scientiae* sob orientação do Professor Carlos Cardoso Machado.

Em agosto do mesmo ano, iniciou seus estudos no curso de Doutorado em Ciência Florestal, na mesma instituição, submetendo-se à defesa de tese para obtenção do título de *Doctor Scientiae* em setembro de 2021.

*“Se você pode sonhar, você pode realizar”.*

(Walt Disney)

## RESUMO

SILVA, Arthur Araújo, D.Sc., Universidade Federal de Viçosa, setembro de 2021.  
**Tecnologias digitais aplicadas na gestão do corte florestal com harvester.**  
Orientador: Carlos Cardoso Machado.

A operação de corte florestal com *harvester* deve seguir exigências de um mundo corporativo ágil e conectado, sendo que a mensuração e transmissão de dados em tempo real garantem informações em menor tempo e redução nos custos da operação. Neste contexto, o objetivo geral deste estudo foi analisar a aplicação de tecnologias digitais na gestão do corte florestal com *harvester*. Como objetivos específicos, descreveu-se as variáveis que influenciam o desempenho do *harvester*, analisando as opções de coleta automática e transmissão em tempo real dos dados; descreveu-se o funcionamento e as vantagens da utilização do *software* Microsoft Power BI na análise diagnóstica dos dados da operação; e avaliou-se a aplicação da tecnologia gêmeo digital para análise preditiva e antecipação de ocorrências na operação de corte florestal com *harvester*. Os dados utilizados no estudo foram obtidos entre os anos de 2015 e 2019 durante operações de corte florestal com *harvester* em plantios comerciais de *Eucalyptus* pertencentes a empresas do setor florestal situadas nos estados da Bahia e Espírito Santo. Utilizou-se os softwares Microsoft Excel, Power BI e RStudio para análises diagnóstica, estatística e preditiva dos modelos utilizados. Comprovou-se a influência de variáveis relacionadas às características da floresta, do ambiente, da máquina, das condições humanas e da organização da operação. A produtividade média do *harvester* foi de  $18,42 \text{ m}^3.\text{he}^{-1}$ , para um volume médio individual (VMI) de  $0,162 \text{ m}^3$  encontrado. Esta produtividade pode ser considerada baixa, justamente explicada pelo baixo VMI. Indicou-se a coleta automatizada dos dados através de sensores e apontamento eletrônico pelos operadores. Identificou-se diferentes opções de transmitir os dados da operação em tempo real, como comunicação satelital, rádio frequência (LoRa), telefonia móvel, WiFi e sistema de coletores (M2M). A escolha da tecnologia de transmissão de dados depende de diversos fatores, como localização da máquina e custo envolvido, portanto, para cada situação em campo deve-se ter uma solução personalizada. Concluiu-se que o Power BI pode ser utilizado como ferramenta estratégica para as tomadas de decisão na operação devido às suas diversas características, que

permitem: fácil implementação e maneabilidade; integração com diversos sistemas e fontes de dados; agilidade na modelagem de dados através do Power Query, Power Pivot e linguagem DAX; interface e visualização intuitiva através das ferramentas do Power View; acompanhamento da localização em tempo real das máquinas através da ferramenta “ArcGis for Maps”; atualização automática. Realizadas as análises descritiva e diagnóstica, surge como oportunidade otimizar a operação de corte florestal com *harvester* através da antecipação de ocorrências. Concluiu-se que, utilizando diversas tecnologias, tais como *Big Data*, *Business Intelligence*, Internet das Coisas, sensores, computação em nuvem, simulações, entre outras, é possível criar um gêmeo digital do *harvester*, aplicando nas seguintes etapas: elaboração de equipe técnica multidisciplinar, coleta de dados automatizada, transmissão dos dados em tempo real, armazenamento dos dados em nuvem, criação dos modelos, análise das informações geradas e gestão da tecnologia. O estudo possibilitou a predição da produtividade através do modelo *Random Forest* baseado em diversas variáveis explicativas e a predição do abastecimento de combustível e ocorrência de falhas baseado em séries temporais através do modelo de suavização exponencial simples (SESM – *Simple Exponential Smoothing Model*). Estas análises preditivas proporcionaram controle mais efetivo e antecipação de ocorrências na operação. Trabalhos como este são de grande importância para a evolução da operação de corte florestal com *harvester*, e consequentemente do setor florestal brasileiro, apresentando soluções inovadoras que podem ser utilizadas em outras operações pertencentes a um projeto florestal.

Palavras-chave: Dados. Indicadores de desempenho. Power BI. Gêmeo digital.

## ABSTRACT

SILVA, Arthur Araújo, D.Sc., Universidade Federal de Viçosa, September, 2021.  
**Digital technologies applied to timber cutting management with a harvester.**  
Adviser: Carlos Cardoso Machado.

The timber cutting with a harvester must follow the requirements of an agile and connected corporate world, and the measurement and transmission of data in real time guarantee information in less time and a reduction in operation costs. In this context, the general objective of this study was to analyze the application of digital technologies in the management of timber cutting with a harvester. As specific objectives, the variables that influence the harvester's performance were described, analyzing the options for automatic collection and real-time data transmission; the functioning and advantages of using the Microsoft Power BI software in the diagnostic analysis of the operation data were described; and the application of digital twin technology for predictive analysis and anticipation of occurrences in the timber cutting operation with a harvester was evaluated. The data used in the study were obtained between 2015 and 2019 during timber cutting with a harvester in commercial Eucalyptus plantations belonging to companies in the forest sector located in the states of Bahia, Espírito Santo and Minas Gerais. Microsoft Excel, Power BI and R Studio software were used for diagnostic, predictive and statistical analysis of the models used. The influence of variables related to the characteristics of the forest, the environment, the machine, human conditions and the organization of the operation was proven. The average harvester productivity was  $18.42 \text{ m}^3 \cdot \text{he}^{-1}$ , for an mean tree volume (MTV) of  $0.162 \text{ m}^3$  found. This productivity can be considered low, precisely explained by the low MTV. Automated data collection through sensors and electronic notes by operators was indicated. Different ways of transmitting operation data in real time were identified, such as satellite communication, radio frequency (LoRa), mobile telephony, WiFi and collector system (M2M). The choice of data transmission technology depends on several factors, such as the location of the machine and the cost involved, therefore, for each situation in the field, a customized solution must be provided. It was concluded that Power BI can be used as a strategic tool for decision making in the operation due to its several characteristics, which allow: easy implementation and manageability; integration with diverse systems and data sources; agility in data modeling through

Power Query, Power Pivot and DAX language; intuitive interface and visualization through Power View tools; real-time location monitoring of machines through the “ArcGis for Maps” tool; Automatic Update. After performing descriptive and diagnostic analysis, it appears as an opportunity to optimize the timber cutting operation with a harvester by anticipating occurrences. It was concluded that, using several technologies, such as Big Data, Business Intelligence, Internet of Things, sensors, cloud computing, simulations, among others, it is possible to create a harvester digital twin, applying in the following steps: preparation of a technical team multidisciplinary, automated data collection, real-time data transmission, cloud data storage, model creation, analysis of generated information and technology management. The study enabled the prediction of productivity through the Random Forest model based on several explanatory variables and the prediction of fuel supply and failure occurrence based on time series through the Simple Exponential Smoothing Model (SESM). These predictive analytics was provided more effective control and anticipation of occurrences in the operation. Works like this are of great importance for the evolution of timber cutting with a harvester, and consequently of the Brazilian forest sector, presenting innovative solutions that can be used in other operations belonging to a forestry project.

Keywords: Data. Performance indicators. Power BI. Digital twin.

## LISTA DE ILUSTRAÇÕES

Figura 1: Componentes do software Power BI (Karpinski, 2020).....	19
Figura 2: Etapas - Criação de dashboards no Power BI (Karpinski, 2020). ....	19
Figura 3: Abas pertencentes ao software Microsoft Power BI.....	21
Figura 4: Exemplos de fórmulas DAX utilizadas no estudo.....	22
Figura 5: Cinco dimensões propostas para criação do gêmeo digital do harvester no corte florestal mecanizado (Tao et al. 2018). ....	26
Figura 6: Valores de produtividade do harvester em função do volume médio individual .....	31
Figura 7: Produtividade do harvester em função da condição do plantio. ....	32
Figura 8: Produtividade do harvester em função da inclinação do terreno.....	33
Figura 9: Produtividade do harvester em função da idade da máquina (anos). ....	34
Figura 10: Produtividade do harvester em função do tempo de experiência do operador .....	35
Figura 11: Produtividade do harvester em função do tipo de fornecimento de serviço. ....	37
Figura 12: Exemplo de cabeçote de harvester visto frontalmente (A), distância entre os rolos (B) e a serra (C).....	39
Figura 13: Opções de transmissão de dados e comunicação mais utilizadas na colheita florestal (Fonte: Aiko Digital, 2021) .....	40
Figura 14: Principal dashboard criado no estudo relacionado à eficiência global da operação – EGMF. Onde DM – Disponibilidade Mecânica; EO – Eficiência Operacional; TC – Taxa de Consumo de Combustível; TQ – Taxa de Qualidade dos parâmetros da operação. ....	44
Figura 15: Dashboard - Acompanhamento da localização das máquinas.....	45
Figura 16: Dashboard – Controle dos indicadores de qualidade da operação de corte florestal com harvester. ....	46
Figura 17: Tecnologias habilitadoras relacionadas à criação de um gêmeo digital do harvester no corte florestal mecanizado.....	50
Figura 18: Ferramentas de modelagem para construção de um gêmeo digital do harvester (Adaptado de Qi et al. 2019) .....	53
Figura 19: Dispersão dos valores de produtividade estimados pelo modelo de predição utilizado – Random Forest em relação aos valores observados. ....	54
Figura 20: Análises preditivas para a operação de corte florestal com harvester no Power BI.....	56
Figura 21: Análises preditivas para ocorrências de danos à mangueira hidráulica do cabeçote do harvester .....	58

## LISTA DE TABELAS

Tabela 1: Modelos e características dos <i>harvesters</i> analisados .....	16
Tabela 2: Classificação das variáveis influentes no desempenho do <i>harvester</i> no corte florestal mecanizado .....	30
Tabela 3: Etapas, Estratégias e Tecnologias utilizadas para construção do gêmeo digital do <i>harvester</i> .....	51
Tabela 4: Erros relacionados à análise preditiva das variáveis analisadas.....	57
Tabela 5: Dimensões <i>Big Data</i> e características para a realidade do <i>harvester</i> .....	59

## SUMÁRIO

1. INTRODUÇÃO .....	13
1.1.Contextualização .....	13
1.2.Objetivo Geral.....	15
1.3. Objetivos Específicos.....	15
1.4. Hipótese .....	15
2. MATERIAIS E MÉTODOS.....	16
2.1.Parte 1 – Análise das variáveis influentes no desempenho do harvester na operação de corte florestal mecanizado.....	16
2.2.Parte 2 – Gestão da operação de corte florestal com harvester através do software Microsoft Power BI.....	18
2.3.Parte 3 – Criação de um gêmeo digital do harvester na operação de corte florestal.....	25
3. RESULTADOS E DISCUSSÃO.....	29
3.1.Variáveis influentes no desempenho do harvester.....	29
3.1.1. Características da floresta.....	31
3.1.2. Características do ambiente.....	32
3.1.3. Especificações e propriedades da máquina.....	33
3.1.4. Características e condições humanas.....	34
3.1.5. Organização da operação.....	35
3.2. Coleta automática dos dados em tempo real.....	37
3.3. Transmissão e Armazenamento dos dados.....	40
3.4. Gestão dos dados da operação de corte florestal com harvester através do software Microsoft Power BI.....	41
3.5. Criação de um gêmeo digital do harvester no corte florestal.....	50
3.6. Ganhos operacionais obtidos através da construção do gêmeo digital do harvester .....	61
3.7. Desafios e perspectivas da aplicação da tecnologia gêmeo digital para o harvester no corte florestal .....	64
4. CONCLUSÕES .....	67
5. RECOMENDAÇÕES E SUGESTÕES PARA TRABALHOS FUTUROS.....	69
REFERÊNCIAS.....	70
ANEXOS .....	79

## 1. INTRODUÇÃO

### 1.1. Contextualização

A operação de corte florestal com *harvester*, com custo significativo no processo de produção de madeira, deve ter suas atividades otimizadas, seguindo exigências de um mundo corporativo ágil e conectado. Portanto, a automatização da transmissão e gestão dos dados e geração de informações em menor tempo garantem ganhos na qualidade e no desempenho da operação, reduzindo os custos do processo (Silva et al. 2014; Carmo et al. 2015). Diversas são as variáveis que interferem no desempenho operacional do *harvester*, sendo assim, é necessário o conhecimento da influência destas variáveis, assim como as formas de coletar, transmitir e gerir os dados desta operação.

Neste sentido, Segundo Campos (2021), o setor florestal atualmente passa por um novo tipo de inovação: o de dados, informações e serviços digitais. Campos (2021) ainda questiona: “Se começamos a pensar em como os dados florestais podem nos ajudar a nos tornarmos mais produtivos e eficientes, devemos começar com uma perspectiva ampla. Em que partes da cadeia de suprimento de madeira os dados são gerados, onde eles são armazenados e como podem ser extraídos?”. A partir disso, surge a necessidade de refletir também sobre “o que fazer com tantos dados e como eles podem auxiliar na tomada de decisão?”. Dessa forma, estudos voltados à aplicação de tecnologias digitais na gestão dos dados das operações florestais se justificam, na busca por soluções inovadoras para monitoramento e gestão digital destas operações.

Os conceitos e tecnologias habilitadoras da “Indústria 4.0” têm o potencial para promover estas mudanças nos modelos vigentes na operação de corte florestal, tanto no que se refere às técnicas empregadas na produção, quanto na gestão dos dados. Estas tecnologias interligadas podem promover uma operação embasada em processos produtivos inteligentes, digitais, interoperáveis, descentralizados, caracterizados pela modularidade e que permitam, de maneira dinâmica, a coleta, análise e consolidação de informações (Kagermann et al. 2013; Hermann, 2015).

Dentre estas tecnologias estão aquelas relacionadas ao termo “*Business intelligence*” (Inteligência de Negócios), com capacidade de extrair e integrar informações estratégicas para as organizações a partir de diferentes bancos de dados, possibilitando a interpretação de forma contextualizada (Baldwin et al. 2015). Por sua vez, estas informações são convertidas em conhecimento útil, refletindo em decisões devidamente fundamentadas (Borges, Cardozo e Filho, 2018).

Dentre os sistemas de informação existentes, o Microsoft Power BI vem se destacando no mercado nos últimos tempos, sendo líder do “Quadrante Mágico” em plataformas de análise de dados e *Business Intelligence* (Gartner, 2021), apresentando uma visualização intuitiva sobre as demandas do negócio, e obtendo *insights* para identificar as melhores oportunidades de melhoria e crescimento.

A adoção das ferramentas deste *software* para análise dos dados da operação de corte florestal com *harvester* se justifica do ponto de vista tecnológico devido à constante evolução tecnológica destas máquinas, equipadas com sensores e dispositivos para coleta automática de dados em grande volume e heterogeneidade. Do ponto de vista humano, a sua adoção se justifica devido à sua característica *Self-Service* (Ferrari e Russo, 2016), tendência que visa dar autonomia aos utilizadores que não dispõem da formação especializada que os sistemas analíticos exigiam no passado, para executarem determinadas tarefas e tomar certas decisões que até então estavam restritas aos analistas em tecnologia da informação (TI) (Powell, 2018).

Realizadas as análises descritiva e diagnóstica, surge como oportunidade analisar a operação de corte florestal com *harvester* de maneira preditiva e prescritiva, buscando a otimização da operação através da antecipação de ocorrências. As simulações assumem papel importante nesse contexto, sendo parte inerente da recente tecnologia denominada Gêmeo Digital ou *Digital twin* (Singh et al. 2021).

A implementação de um gêmeo digital tem a capacidade de criar uma cópia virtual, a fim de monitorar o andamento da operação ou produção, reconhecer complexidades internas e externas, detectar anormalidades, simular seu comportamento, prever tendências futuras e realizar o direcionamento de esforços conforme a necessidade (Qi e Tao, 2018). A implementação desta tecnologia se baseia em princípios de modelagem geométrica, física, comportamental e de regras.

Enfatiza-se que a aplicação dos conceitos desta tecnologia para a gestão da operação de corte florestal com *harvester* faz muito sentido devido às suas particularidades, entendendo que, a modelagem de comportamento e análise preditiva de ocorrências são fundamentais para início do processo de criação do gêmeo digital. Trabalhos como este são de grande importância para a evolução da operação de corte florestal com *harvester*, e conseqüentemente do setor florestal brasileiro, apresentando soluções inovadoras que podem ser utilizadas em outras operações pertencentes a um projeto florestal.

## **1.2. Objetivo Geral**

Neste contexto, o objetivo geral deste estudo foi analisar a aplicação de tecnologias digitais na gestão do corte florestal com *harvester*.

## **1.3. Objetivos Específicos**

Como objetivos específicos, descreveu-se as variáveis que influenciam o desempenho do *harvester*, analisando as opções de coleta automática e transmissão em tempo real dos dados; descreveu-se o funcionamento e as vantagens da utilização do *software* Microsoft Power BI na análise diagnóstica dos dados da operação; e avaliou-se a aplicação da tecnologia gêmeo digital para análise preditiva e antecipação de ocorrências na operação de corte florestal com *harvester*, discutindo sobre as tecnologias habilitadoras, etapas a seguir no processo, modelos virtuais utilizados e desafios na gestão desta tecnologia.

## **1.4. Hipótese**

A aplicação de ferramentas e tecnologias digitais é uma alternativa para a problemática relacionada à gestão dos dados da operação de corte florestal com *harvester*, contribuindo para geração de informações de valor a partir de grande quantidade e variedade de dados. Estas informações geradas são pilares para uma tomada de decisão mais assertiva, ágil e eficiente, garantindo menor tempo de resposta às variações positivas ou negativas dos indicadores de desempenho do *harvester* na operação de corte florestal.

## 2. MATERIAIS E MÉTODOS

Os dados utilizados no estudo foram obtidos entre os anos de 2015 e 2019 durante operações de corte florestal com *harvester* em plantios comerciais de *Eucalyptus* pertencentes a empresas do setor florestal situadas nos estados da Bahia e Espírito Santo. O tipo de solo predominante na região é o Latossolo Vermelho-Amarelo, e o relevo é plano a suave-ondulado. O clima característico da região é o tropical quente super-úmido (tipo Aw, segundo Köppen), tendo temperatura média anual de 24,4°C. A precipitação média anual é de 1054,9 mm.

O sistema de colheita de toras curtas (*cut-to-length*) foi empregado no estudo, no qual o *harvester* foi responsável pela operação de corte e o *forwarder* pela extração das toras até a margem da estrada. Os dados foram coletados durante os três turnos de trabalho (24 horas por dia), sendo o Turno 1 – 06 às 14 horas, Turno 2 – 14 às 22 horas e Turno 3 – 22 às 06 horas do dia posterior. Para o estudo das variáveis relacionadas à máquina, diferentes conjuntos de máquina base e cabeçotes foram analisados, sendo suas especificações técnicas e propriedades representadas na Tabela 1.

Tabela 1: Modelos e características dos *harvesters* analisados

Modelos de <i>harvesters</i>		Características		
Máquina base	Cabeçote	Tipo de Rodado	Potência (hp)	Peso do cabeçote (kg)
Hyundai R160LC	Komatsu H370E	Esteira	126	1600
Hyundai R220LC	Komatsu H370E	Esteira	155	1600
Komatsu PC200-8	Komatsu H370E	Esteira	155	1600
Komatsu PC200-8	Komatsu V132E	Esteira	155	1302
Komatsu PC200-F	Komatsu H370E	Esteira	155	1600
TigerCat H845C	SP Maskiner 591 LX G2	Esteira	260	1800
Valmet 941 Articulado	Komatsu H370E	Pneus	273	1600
Volvo EC220LC	Ponsse H77Euca	Esteira	167	1300
Volvo EC250DL	SP Maskiner 591 LX G2	Esteira	188	1800

### 2.1. Parte 1 – Análise das variáveis influentes no desempenho do *harvester* na operação de corte florestal mecanizado

A metodologia para o levantamento e classificação das variáveis de influência na atividade de corte florestal com *harvester* se baseou em análises em campo,

revisão de literatura científica e informações transmitidas através de boletins diários técnicos preenchidos pelos operadores e supervisores da operação. Estes boletins técnicos foram base para a elaboração das planilhas analisadas no estudo (em ANEXOS), contendo dados relacionados à produção de madeira (metros cúbicos -  $m^3$ ), horas operadas, volume médio individual, horas em paradas mecânicas e operacionais, entre outros.

O *software* Microsoft Excel foi utilizado para tabulação e análise estatística dos dados, e o Microsoft Power BI foi utilizado para criação de gráficos e *dashboards* para análise visual da influência das variáveis no desempenho do *harvester*. Para análise estatística dos dados de produtividade da operação ( $m^3.he^{-1}$ ) foram consideradas as seguintes variáveis:

- Características da floresta
  - Volume por árvore ( $0,005$  a  $0,350 m^3.ind^{-1}$ )
  - Tortuosidade (ocorrência ou não)
  - Bifurcação (ocorrência ou não)
- Características do ambiente
  - Inclinação do terreno (Plano – até  $25^\circ$ ; Declivoso – acima de  $25^\circ$ )
  - Sub-bosque (ocorrência ou não)
- Características das máquinas
  - Tempo de trabalho (1, 2, 3, 4, 5 anos)
  - Velocidade dos rolos do cabeçote ( $5 m.s^{-1}$ ;  $5,5 m.s^{-1}$ ;  $6 m.s^{-1}$ )
- Características humanas
  - Tempo de experiência (até 1 ano; acima de 1 ano)
  - Conhecimento do processo (em treinamento; conhecimento avançado)
- Organização da operação
  - Fornecimento do serviço (máquina em teste; próprio; terceirizado)
  - Tipo de intervenção (corte raso; desbaste)

A produtividade foi calculada pela razão entre o volume de madeira colhida em metros cúbicos por hora efetiva de trabalho multiplicando-se o número de árvores abatidas ( $N_a$ ) pelo volume médio dos indivíduos (VMI), e dividindo-se pelo número de horas efetivas de trabalho ao longo do período (Equação 1).

$$Prod. Real. = \left( \frac{Na \times VMI}{He} \right) \quad (Eq. 1)$$

Em que:

Prod. Real. = Produtividade realizada da operação ( $m^3_{s/c}.he^{-1}$ );

Na = número de árvores processadas;

VMI = Volume individual por árvore ( $m^3.ind^{-1}$ );

He = Horas efetivas de trabalho.

Os resultados de produtividade da operação em relação às variáveis analisadas foram submetidos à análise de variância a 5% de probabilidade, pelo teste F. Nos casos em que houve diferença estatística significativa, aplicou-se o teste de média de Tukey a 5% de probabilidade ( $p>0,05$ ), na análise qualitativa, por meio da ferramenta “Análise de Dados” do *software* Microsoft Excel.

A análise das opções de coleta automática e transmissão em tempo real dos dados foi realizada através de discussão entre uma equipe multidisciplinar, envolvendo especialistas da área florestal, como supervisores e técnicos de campo, especialistas em manutenção mecânica e sensores.

## **2.2. Parte 2 – Gestão da operação de corte florestal com *harvester* através do software Microsoft Power BI**

O Microsoft Power BI é um *software* de Inteligência Empresarial (“*Business intelligence*”) que vem se destacando no mercado, com capacidade de extrair e integrar informações estratégicas para a organização a partir de diferentes bancos de dados. Este *software* se apresenta de três formas, sendo um aplicativo da área de trabalho do Microsoft Windows chamado Power BI Desktop, um serviço SaaS online (*software* como serviço) chamado Power BI Service e também uma versão para dispositivos móveis chamada Power BI Mobile.

No presente estudo foram utilizadas ferramentas do Power BI Desktop, sendo que, o princípio de funcionamento desta plataforma consiste na união de três suplementos: Power Query, Power Pivot e Power View (Karpinski, 2020) (Figura 1).

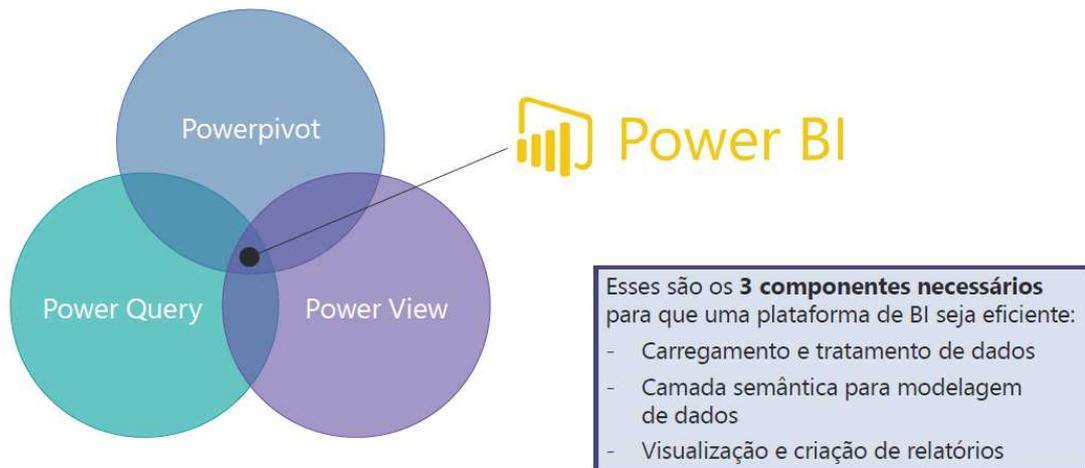


Figura 1: Componentes do *software* Power BI (Karpinski, 2020).

Primeiramente, utilizou-se a ferramenta Power Query para processamento, estruturação e unificação dos dados de entrada no modelo; o Power Pivot foi utilizado para criação de relacionamentos entre tabelas, colunas calculadas (colunas com fórmulas) e medidas (campos com fórmulas) usando a linguagem DAX (modelagem e cálculos); já o Power View foi utilizado para visualização dos dashboards e relatórios obtidos no estudo através de um painel interativo, que podem ser distribuídos de maneira automatizada aos interessados. Estes três suplementos estão interconectados entre si através das três abas de visualização do Power BI Desktop: relatório, dados e modelo (Karpinski, 2020) (Figura 2).

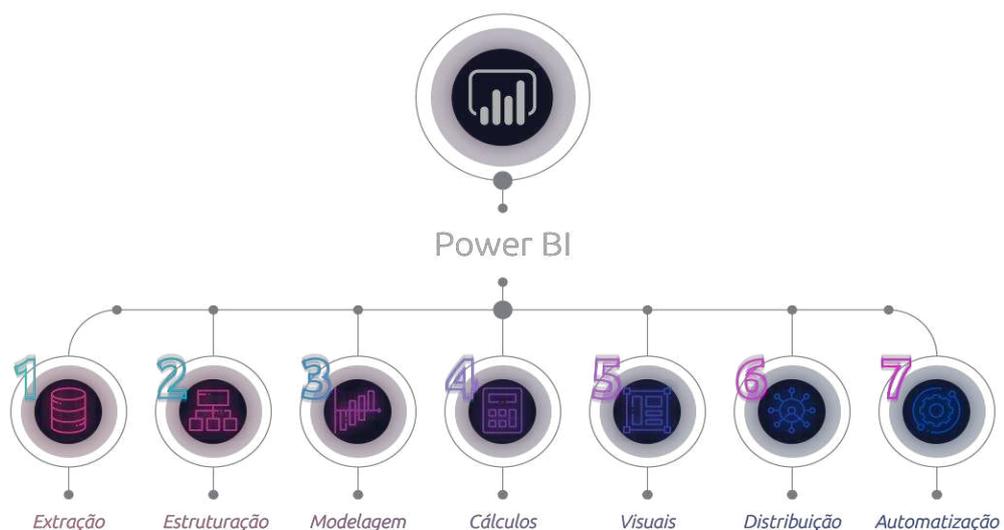


Figura 2: Etapas - Criação de *dashboards* no Power BI (Karpinski, 2020).

Na aba relatório - Power View (Figura 3 - A), é possível observar na seção “Campos” os conjuntos de dados trabalhados, com cada linha representando uma coluna dos dados importados da planilha de Excel, além das medidas criadas. Ao lado, à esquerda da seção “Campos” se encontra a seção de “Visualizações” com vários ícones visíveis, cada um representando uma opção de visualização. À esquerda há um grande espaço aberto onde as visualizações do estudo foram exibidas em forma de tabelas e gráficos visuais (Lyon, 2019).

Na aba dados (Figura 3 - B), pode-se observar as tabelas usadas como base do modelo associado ao relatório criado no estudo: Consumo – dados de consumo de combustível do *harvester*; Desempenho – análise da produção de madeira (m<sup>3</sup>) e paradas da operação (horas); Qualidade – dados dos parâmetros de qualidade da operação (altura do toco; condição do toco; diâmetro mínimo; comprimento das toras; qualidade do descascamento). É também onde observamos transformações a serem realizadas nos dados para melhor uso nos relatórios através do Power Query. Dentre as transformações realizadas no estudo, cita-se “adicionar colunas”, “filtros”, entre outras.

Na aba modelo (Figura 3 - C), estabeleceu-se o relacionamento entre as planilhas trabalhadas, ou seja, dados iguais de planilhas diferentes são conectados através de chaves de relacionamento. No presente estudo, diversas colunas foram conectadas, sendo utilizadas as tabelas “Datas” e “Operadores” como “tabelas dimensão”, ou seja, dados descritivos como base para análise dos dados das colunas das tabelas fato, sendo as tabelas “combustível”, “desempenho” e “qualidade”.

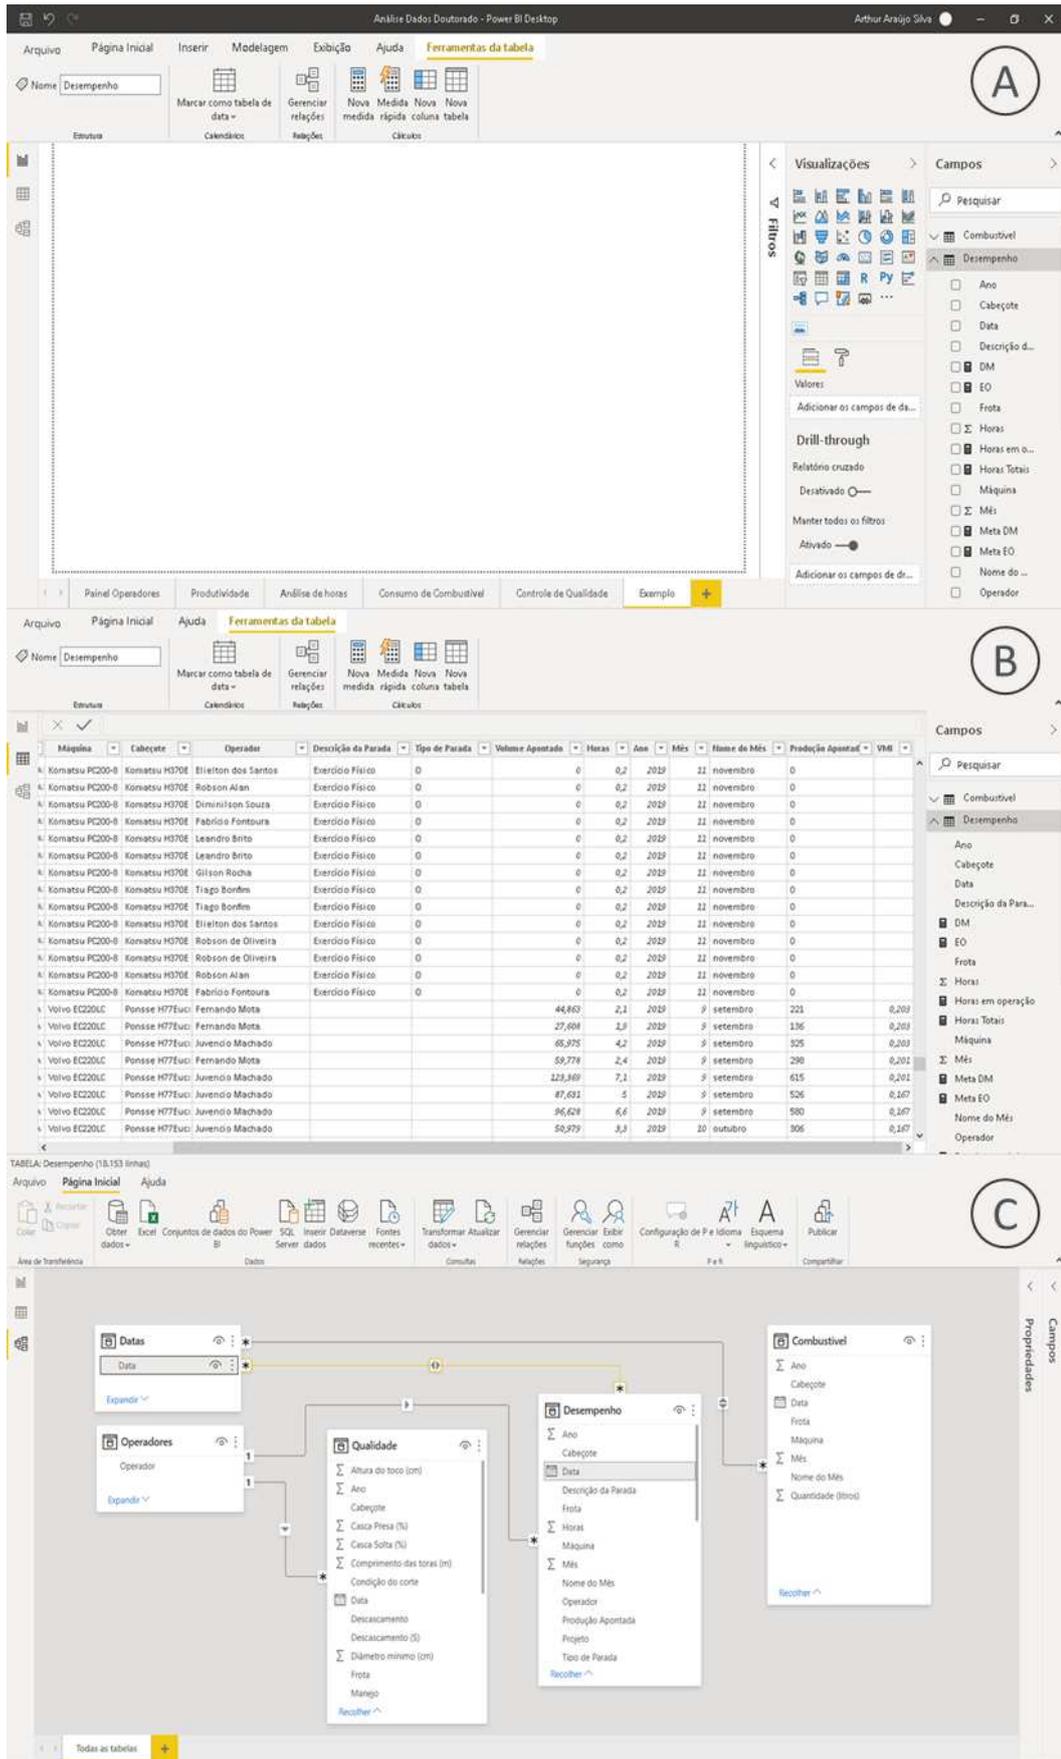


Figura 3: Abas pertencentes ao software Microsoft Power BI

Os resultados foram apresentados em forma de *dashboards* e relatórios, em que podem ser visualizados os indicadores de desempenho (KPI's – *Key Performance Indicators*) da operação de corte florestal com *harvester*. A escolha das métricas tratadas como indicadores-chave (KPI's) no estudo foi baseada na experiência do autor e revisão de literatura científica (Silva, 2017).

Para a criação de fórmulas e indicadores utilizou-se funções da linguagem DAX (*Data Analysis Expressions*) através das ferramentas “Nova medida”, “Coluna calculada” e “Tabela calculada”. Por ser composta de funções analíticas que podem ser alinhadas conforme a necessidade do usuário, a linguagem DAX se assemelha muito às funções do Excel. Utilizou-se diversas funções no presente estudo, com destaque à expressão CALCULATE (<expressão>;<filtro1>;<filtro2>;...), função que avalia um contexto que pode ser mudado por filtros específicos, como a avaliação das paradas mecânicas e posterior cálculo da disponibilidade mecânica do *harvester* (Figura 4).

```
Paradas mecânicas = CALCULATE(SUM(Desempenho[Horas]),Desempenho[Tipo de Parada]="M")
Horas Totais = [Horas em operação]+[Paradas mecânicas]+[Paradas operacionais]+[Paradas para refeição]
DM = 1-([Paradas mecânicas]/[Horas Totais])
```

Figura 4: Exemplos de fórmulas DAX utilizadas no estudo.

Foram elaboradas cinco páginas, com informações relativas à produtividade da operação de corte florestal com *harvester* (Equação 2), consumo de combustível das máquinas (Equações 3 e 4), análise de paradas mecânicas e operacionais (disponibilidade mecânica e eficiência operacional - Equações 5 e 6), análise dos parâmetros de qualidade da operação (Equação 7) e “Eficiência Global de Máquinas Florestais - EGMF” (Silva, 2017) (Equação 8), esta última baseada em outro indicador bastante conhecido na literatura internacional, o OEE – *Overall Equipment Effectiveness* (Chiaradia, 2004).

$$TP (\%) = \left( \frac{Prod. Real.}{Prod. Plan.} \right) \times 100 \quad (Eq. 2)$$

Em que:

TP (%) = Taxa de produtividade alcançada em relação ao planejado;

Prod. Real. = Produtividade realizada da operação ( $m^3_{s/c}.h^{-1}$ );

Prod. Plan. = Produtividade planejada de acordo com os valores de VMI ( $m^3.h^{-1}$ ).

$$Cons. hor. = \left( \frac{Q_{Abast.}}{He} \right) \quad (Eq. 3)$$

Em que:

Cons. hor. = Consumo horário de óleo diesel ( $l.h^{-1}$ );

$Q_{Abast.}$  = quantidade de combustível depositada no equipamento (litros);

He = Horas efetivas de trabalho a partir do depósito de combustível.

$$TC (\%) = 200 - \left( \left( \frac{Cons. Hor.}{Cons. Plan.} \right) \times 100 \right) \quad (Eq. 4)$$

Em que:

TC = Taxa de Consumo alcançado em relação à meta estipulada (%);

Cons. Hor. = Consumo horário de óleo diesel ( $l/h$ );

Cons. Plan. = Consumo horário planejado de óleo diesel ( $l/h$ );

$$DM (\%) = \left( 1 - \left( \frac{H_m}{H_t} \right) \right) \times 100 \quad (Eq. 5)$$

Em que:

DM = Disponibilidade mecânica (%);

$H_m$  = tempo de paradas para manutenção e reparos (horas);

$H_t$  = tempo de trabalho programado (horas).

$$EO (\%) = 1 - \left( \left( \frac{H_m + H_o}{H_t} \right) * 100 \right) \quad (Eq. 6)$$

Em que:

EO = Eficiência operacional (%);

H<sub>o</sub> = tempo de paradas operacionais (horas).

$$TQ (\%) = \left( \frac{N_c}{N_t} \right) x 100 \quad (Eq. 7)$$

Em que:

TQ. = Qualidade da operação (%);

N<sub>c</sub> = Número de amostras em conformidade com as normas;

N<sub>t</sub> = Número total de amostras avaliadas.

$$EGMF (\%) = \frac{3 x TP (\%) + 3 x TC (\%) + 3 x EO (\%) + TQ (\%)}{10} \quad (Eq. 8)$$

Em que:

EGMF = Eficiência Global de Máquinas Florestais (%).

A análise e discussão em relação às vantagens da utilização do Microsoft Power BI na análise e gestão dos dados do corte florestal com *harvester* se baseou através da experiência obtida pelo autor no estudo e entrevistas com especialistas da área.

### 2.3. Parte 3 – Criação de um gêmeo digital do *harvester* na operação de corte florestal

O gêmeo digital é visto como uma ferramenta importante para aumentar a produtividade na era industrial da digitalização, sendo uma cópia virtual que representa os sistemas físicos e que é abastecida por dados reais de maneira automática, visando a otimização de tais sistemas e o retorno de respostas, instruções ou comandos com certo grau de autonomia. Esta otimização se dá através da integração entre processos e tecnologias.

Diversas são as maneiras de se criar um gêmeo digital, sendo que a escolha das etapas a seguir na construção do mesmo irá depender do ativo trabalhado (produto, processo ou serviço). Com base no modelo de gêmeo digital proposto Tao et al. (2018) e adaptado de Grieves (2014), propusemos um modelo de cinco dimensões para promover aplicações da tecnologia em mais campos de pesquisa e atuação, sendo baseado em:

$$M_{GD} = (EF, MV, SS, DD, CN)$$

Onde EF são entidades físicas, MV são modelos virtuais, SS são serviços, DD são dados disponíveis, e CN são as conexões (Figura 5). No caso da operação de corte florestal, considerou-se neste estudo estas cinco dimensões como sendo:

- Entidades físicas (EF) - *harvesters* utilizados na operação de corte florestal mecanizado.
- Modelos virtuais (MV) - réplicas fiéis dos *harvesters*, que reproduzem suas características físicas e comportamentos através da inteligência artificial.
- Serviços (SS) - diagnóstico, verificação, monitoramento e otimização da operação em tempo real através de aplicativos e plataformas digitais.
- Dados disponíveis (DD) - dados de campo obtidos através do apontamento eletrônico e telemetria, manuseados através dos sistemas de gestão.
- Conexões (CN) - contato entre os dados oriundos do campo apontados através de sensores, o computador de bordo das máquinas, aplicativos e o sistema de gestão empresarial.

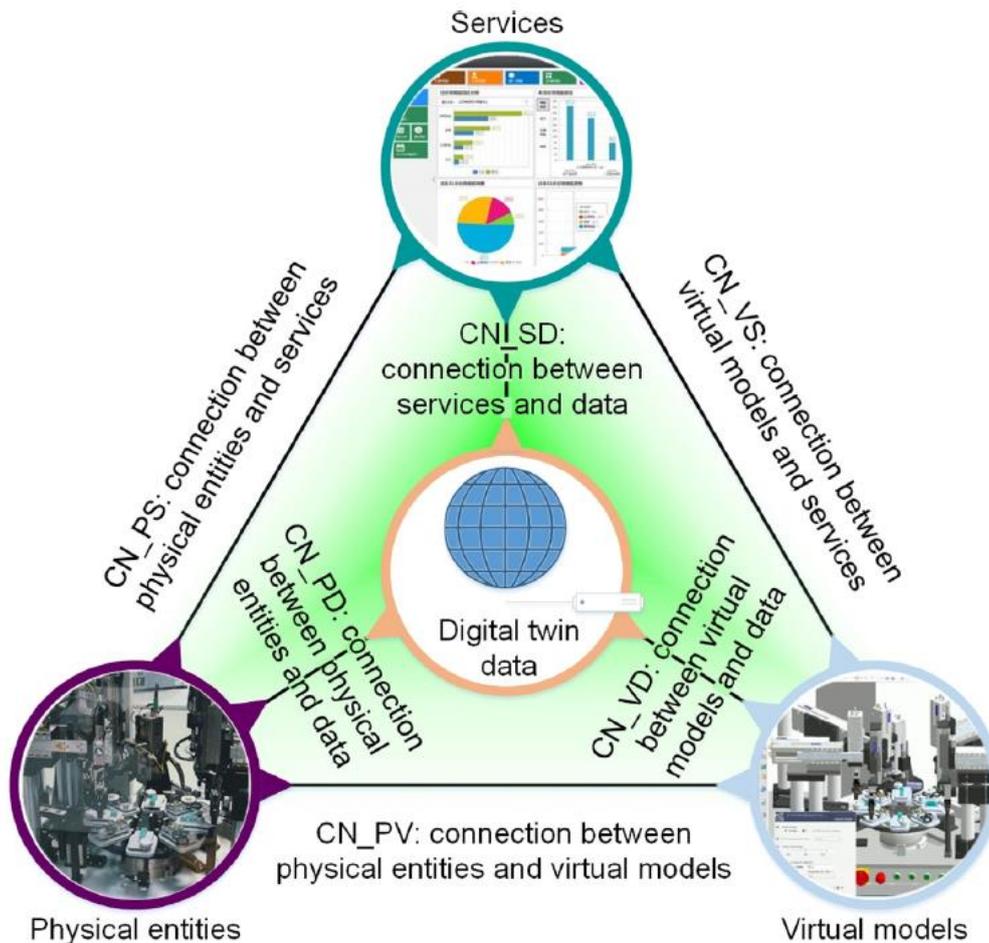


Figura 5: Cinco dimensões propostas para criação do gêmeo digital do *harvester* no corte florestal mecanizado (Tao et al. 2018).

Indicou-se opções de *softwares* e ferramentas disponíveis para criação de um gêmeo digital do *harvester* na operação de corte florestal mecanizado, entendendo que esta operação possui suas particularidades e diversos tipos de variáveis, qualitativas ou quantitativas, discretas ou contínuas, dependentes ou independentes.

Para análise preditiva da produtividade do *harvester* utilizou-se uma técnica de Aprendizado de Máquina (AM) que vem sendo muito utilizada no setor florestal, conhecida como *Random forest* ou florestas aleatórias (Silva, 2015; Friedrichs, 2016). As *Random forests* são árvores de tomada de decisão baseadas na divisão binária das variáveis de entrada. Cada galho da árvore é denominado de nó, que treinado objetiva formar outros nós, resultando em estimativas da variável dependente em função da sua correlação com o banco de dados (Schikowski, 2016). A estimativa final é dada pela média de todas as árvores de decisão criadas durante esse processo.

As variáveis de entrada utilizadas para a estimativa se basearam na escolha de algumas daquelas influentes no desempenho do *harvester*, sendo: volume médio individual (0,005 a 0,350 m<sup>3</sup>.ind<sup>-1</sup>); inclinação do terreno (plano – até 25° ou declivoso – acima de 25°); ocorrência de tortuosidade ou bifurcação (sim ou não); presença de sub-bosque (sim ou não); tempo de experiência do operador (até 1 ano ou mais de 1 ano) e fornecimento do serviço (em teste, próprio ou terceirizado).

Os dados foram aplicados em dois conjuntos, sendo um conjunto para treinamento (70% do volume de dados) e outro para validação (30% do volume de dados). Os dados pertencentes a cada conjunto de dados foram definidos aleatoriamente na base de dados inicial (100% dos dados) e aplicados sistematicamente, sendo utilizado o número de árvores de decisão (ntree) igual a 500 e número de variáveis por nível (mtry) igual a 4. Utilizou-se o software RStudio para estas análises.

Para a análise preditiva das variáveis classificadas como “*time dependent*”, ou seja, que apresentam um histórico temporal, utilizou-se o método de séries temporais. A previsão em séries temporais tem como objetivo prever ocorrências futuras tendo como base um modelo de análise ao histórico da variável a prever, partindo do pressuposto de que o histórico se repetirá no futuro com algumas semelhanças (Pinheiro, 2020). Entre as variáveis temporais que influenciam o desempenho do *harvester* e foram consideradas no modelo, cita-se: parada para abastecimento de combustível, e manutenções corretiva e preventiva (troca de material de corte, lubrificação, lavagem da máquina)

Realizou-se uma análise preditiva (simulação virtual) da operação através da ferramenta “Previsão - *Forecast*” do *software Power BI*. Esta ferramenta se baseia no modelo de suavização exponencial simples (SESM – *Simple Exponential Smoothing Model*), sendo atribuído um peso exponencialmente menor às observações mais antigas. As fórmulas principais utilizadas no SESM – *Simple Exponential Smoothing Model* são as seguintes (Equação 9) (Equação 10):

$$St = \alpha At + (1 - \alpha) St - 1 \quad (9)$$

$$\hat{A}t + 1 = St \quad (10)$$

Onde:

- $St$  representa o nível ou uma média ponderada dos valores alisados da série temporal no momento  $t$ ;
- $\alpha$  corresponde ao parâmetro/fator/constante de alisamento, isto é, representa o peso médio que é atribuído às observações;
- $At$  corresponde ao valor observado no momento  $t$ ;
- $\hat{A}t + 1$  é o valor previsto no momento  $t + 1$  que se assume que seja sempre igual a  $St$  (Evans, 2016; Hyndman e Athanapoulos, 2018; Brownlee, 2020).

Para avaliar a precisão dos modelos de previsão acima descritos, utilizou-se critérios estatísticos como: erro quadrático médio absoluto e relativo da variável estimada (Equação 11), correlação de Pearson entre os dados estimados e observados (Equação 12), resíduos percentuais das estimativas (Equação 13) e análise gráfica de resíduos e ajustes.

$$RMSE\% = \frac{100}{\bar{y}} * \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_I)^2}{n}} \quad (11)$$

Onde: RMSE% - erro quadrático médio;  $\bar{Y}$  - média observada;  $Y_i$  - valores observados;  $\hat{Y}_I$  - valores estimados;  $n$  - número de observações.

$$r = \frac{cov(Y, \hat{Y})}{\sqrt{S^2(Y) S^2(\hat{Y})}} \quad (12)$$

Onde:  $r$  - correlação de *Pearson*;  $cov(Y, \hat{Y})$  - covariância.  $S^2$  - variância.

$$Erro\% = \frac{(\hat{Y} - Y)}{Y} * 100 \quad (13)$$

Onde: Erro% - erro médio;  $Y$  - valores observados;  $\hat{Y}$  - valores estimados.

### **3. RESULTADOS E DISCUSSÃO**

#### **3.1. Variáveis influentes no desempenho do *harvester***

Através de análises em campo, discussão entre especialistas da área e operadores das máquinas e revisão de literatura científica, classificamos as variáveis de influência no desempenho do *harvester* no corte florestal mecanizado em cinco categorias, sendo: características da floresta; características do ambiente; especificações e propriedades da máquina; condições humanas; e organização da operação (Tabela 2).

Tabela 2: Classificação das variáveis influentes no desempenho do *harvester* no corte florestal mecanizado

Características da floresta	Especificações e propriedades da máquina	Características do ambiente	Características e condições humanas	Organização da operação
Espécie	Tempo de trabalho	Inclinação do terreno	Idade do operador	Tipo de intervenção
Clone	Modelo	Tipo de solo	Tempo de experiência	Turno do trabalho
Espaçamento	Tipo de rodado	Pedregosidade	Conhecimento	Política e qualidade de manutenção
Volume por árvore	Ergonomia	Presença de sub-bosque	Personalidade	Fornecimento do serviço
Volume por hectare	Campo visual	Clima	Motivação	Parâmetros exigidos
Diâmetro da base	Potência do motor	Obstáculos		<ul style="list-style-type: none"> <li>• Sortimento</li> </ul>
Peso da árvore	Alcance da grua			<ul style="list-style-type: none"> <li>• Diâmetro mínimo</li> </ul>
Altura total	Velocidade da grua			<ul style="list-style-type: none"> <li>• Altura das cepas</li> </ul>
Altura comercial	Peso do cabeçote			<ul style="list-style-type: none"> <li>• Descascamento</li> </ul>
Tortuosidade	Velocidade dos rolos			
Bifurcação	Velocidade de giro da corrente da serra			
Ciclo do povoamento	Afiação da corrente			
Tipo de casca	Afiação das facas			
Umidade da madeira	Velocidade de resposta aos comandos			

### 3.1.1. Características da floresta

Dentre as variáveis relacionadas às características da floresta, observou-se que o volume por árvore é uma das variáveis mais influentes na produtividade alcançada pelo *harvester*, de maneira que o rendimento da operação acompanha proporcionalmente o volume individual das árvores, sendo explicado em 78,9 % ( $R^2 = 0,789$ ) dos resultados (Figura 6). Este resultado é semelhante ao que foi encontrado em outros estudos (Nakagawa et al. 2010; Burla et al. 2012; Zhang et al. 2016).

Em termos gerais, a média de produtividade do *harvester* no estudo foi de  $18,42 \text{ m}^3 \cdot \text{he}^{-1}$ , para um volume médio individual de  $0,162 \text{ m}^3$  encontrado. Esta produtividade pode ser considerada baixa, justamente explicada pelo baixo valor de VMI, fato que vem sendo observado em algumas regiões do Brasil nos últimos anos, podendo ser justificado por diversos fatores como edafoclimáticos (déficit hídrico, características dos solos), pragas e doenças, fatores operacionais, entre outros. Diversos estudos têm sido realizados neste sentido (Condé, 2019; Rodrigues et al. 2019).

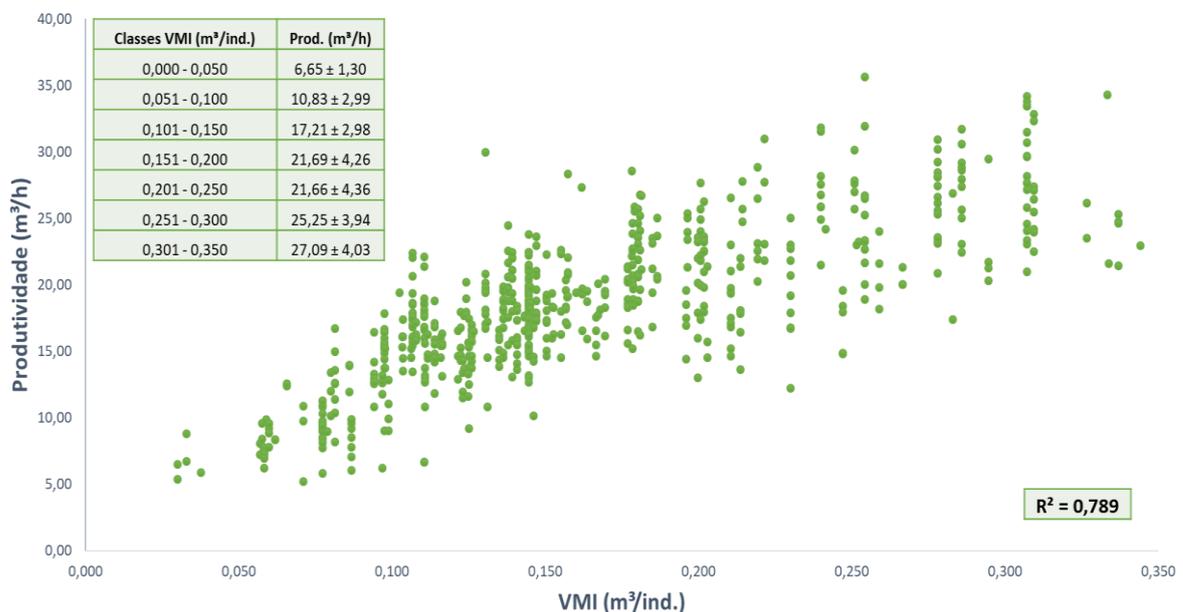


Figura 6: Valores de produtividade do *harvester* em função do volume médio individual

Diversos fatores influenciam no crescimento das espécies florestais, podendo citar condições edafoclimáticas, tratos silviculturais, entre outros. No Brasil, tem se

observado nos últimos anos uma grande incidência de áreas denominadas “distúrbios”, com perda de dominância apical, indivíduos de baixo volume individual, fustes tortuosos, alto número de galhos e casca rígida, conforme ilustrado na Figura 7 (Silva et al. 2010; Rodrigues, 2020). Observou-se neste estudo uma diminuição de produtividade do *harvester* em até 33 %, em operação nestas áreas (Figura 7). No presente estudo, operadores relataram que esta redução ocorre devido principalmente à dificuldade no processamento da madeira colhida, relato também encontrado em outros estudos (Puttock, 2005; Eriksson e Lindroos, 2014; Strandgard et al. 2014).

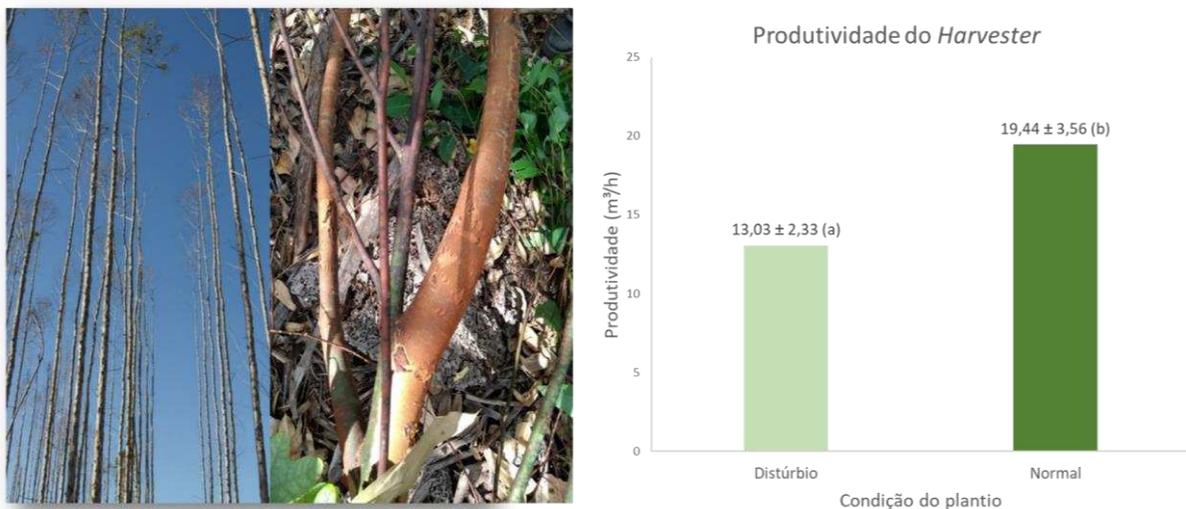


Figura 7: Produtividade do *harvester* em função da condição do plantio.

### 3.1.2. Características do ambiente

Em relação às características do ambiente, cita-se a inclinação do terreno como sendo uma variável influente na produtividade do *harvester*, sendo que, neste estudo, observou-se uma diminuição de produtividade em até 17,5 % na operação em áreas declivosas - acima de 25° de inclinação (Figura 8). No estudo de Leite et al. (2013), operadores de *harvester* relataram que a inclinação do terreno acima de 25° influencia na produtividade da operação devido às restrições do campo visual e ao desconforto gerado pela angulação restrita do acento na cabine, que acaba interferindo também na estabilidade da máquina. Portanto, enfatiza-se que a atividade de corte florestal em áreas acidentadas exige alto nível de planejamento e detalhamento (Leite et al. 2014). Entre as adaptações realizadas na operação em áreas declivosas, cita-se a

utilização de guinchos auxiliares de tração, articulação e grua com maior alcance (Félix, 2015; Robert *et al.* 2013).

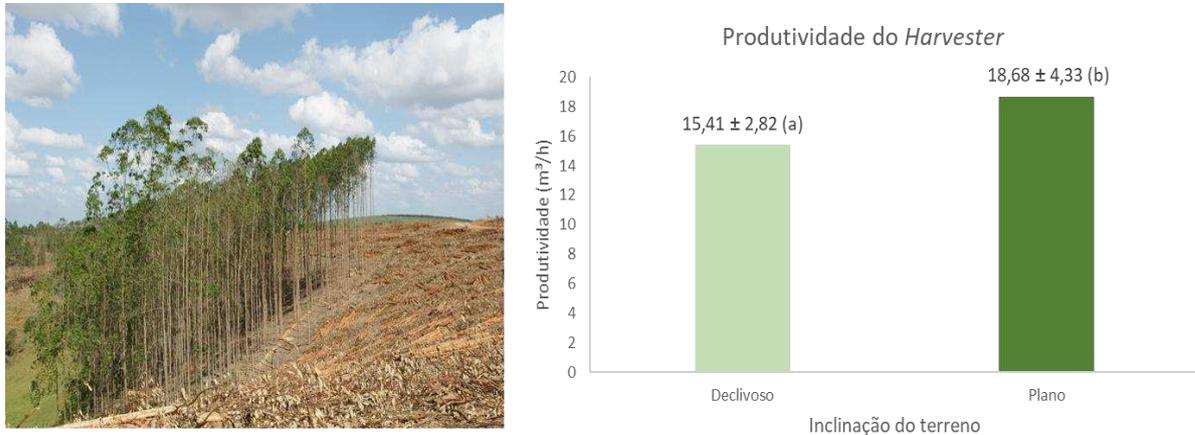


Figura 8: Produtividade do *harvester* em função da inclinação do terreno.

Outras condições do ambiente também foram relatadas pelos operadores como influentes na produtividade da operação, podendo citar: presença de sub-bosque, que diminui a visibilidade e dificulta o processamento das árvores; clima, sendo que a incidência de chuva e ventos demanda maior atenção por parte dos operadores. Neste estudo, observou-se diminuição de até 53,4 % na produtividade do *harvester* em áreas com presença de sub-bosque, plantas trepadeiras, entre outros obstáculos.

### 3.1.3. Especificações e propriedades da máquina

Em relação à máquina e suas propriedades, primeiramente é válido comentar sobre a influência do tempo de trabalho do *harvester* na sua produtividade e custos. Observou-se neste estudo uma diminuição de até 10,69 % em produtividade do *harvester*, quando comparado do primeiro ao quinto ano de trabalho (Figura 9). Santos *et al.* (2017), avaliando os custos do *harvester* no abate e processamento de madeira de eucalipto, concluíram que a máquina deveria operar somente até o quinto ano de trabalho, pois, a partir deste momento, a produtividade caía consideravelmente, fazendo com que os custos de produção da madeira aumentassem.

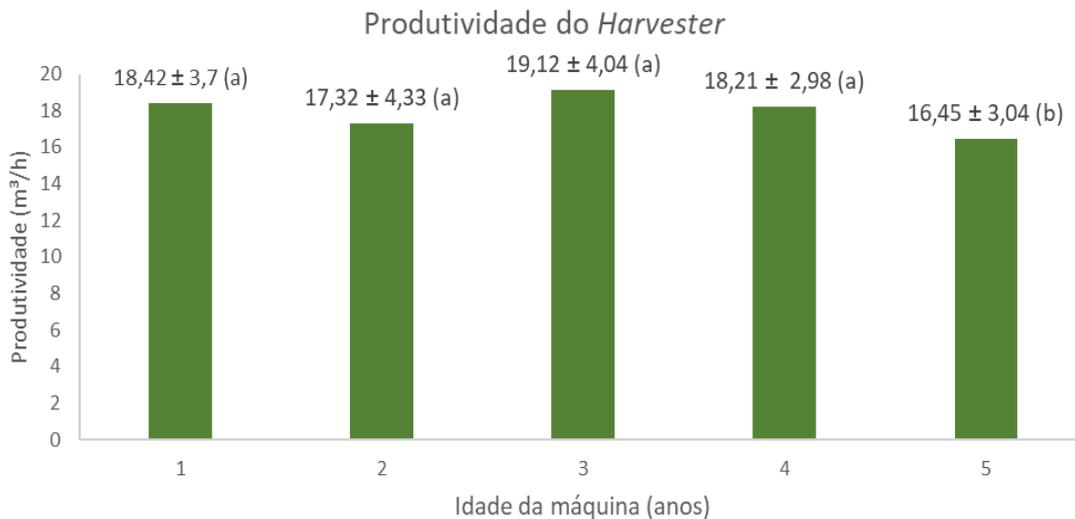


Figura 9: Produtividade do *harvester* em função da idade da máquina (anos).

Para a realização de cada uma das subetapas do corte florestal com *harvester*, é necessário o acionamento de partes da máquina, principalmente àquelas relacionadas à grua e ao cabeçote. Por exemplo, dentro do ciclo operacional do *harvester*, o aumento no tempo efetivamente produtivo é influenciado pela velocidade na busca e derrubada das árvores, sendo esta influenciada pelo alcance e velocidade da grua do *harvester*. Já o ganho de produtividade no desgalhamento e descascamento está diretamente relacionado à velocidade dos rolos de tração do cabeçote de corte, à qualidade de afiação das facas, além das características naturais da árvore, tais como a qualidade da desrama natural e homogeneidade dos fustes. A continuação, o ganho de produtividade no traçamento está relacionado com a velocidade de giro da corrente e com a qualidade da afiação (Burla, 2012).

Em resumo, configurações do maquinário empregado na operação de corte florestal é outra variável que influencia na produtividade do *harvester*. Neste estudo, observou-se um acréscimo de até 17,28 % em produtividade do *harvester*, quando utilizou-se a velocidade dos rolos do cabeçote de 6,0m/s, em comparação à 5,0 m/s.

#### 3.1.4. Características e condições humanas

Em relação às características humanas, os resultados deste estudo demonstraram um acréscimo de 12,83% em produtividade ( $\text{m}^3 \cdot \text{he}^{-1}$ ) da operação, quando se comparado operadores que possuem mais de um ano de experiência

conduzindo a operação em relação àqueles com até um ano de experiência (Figura 10). Embora a experiência possa ser uma indicação do seu desempenho, Purfürst (2010) e Lopes e Pagnussat (2017) observaram que a duração da curva de aprendizado inicial para os operadores de *harvester* era de aproximadamente 8 meses, sendo que, a partir deste período, estabilizaram ou até mesmo diminuíram sua produtividade. Este resultado destacou a importância do processo de reciclagem operacional, com treinamentos constantes de aprendizado.

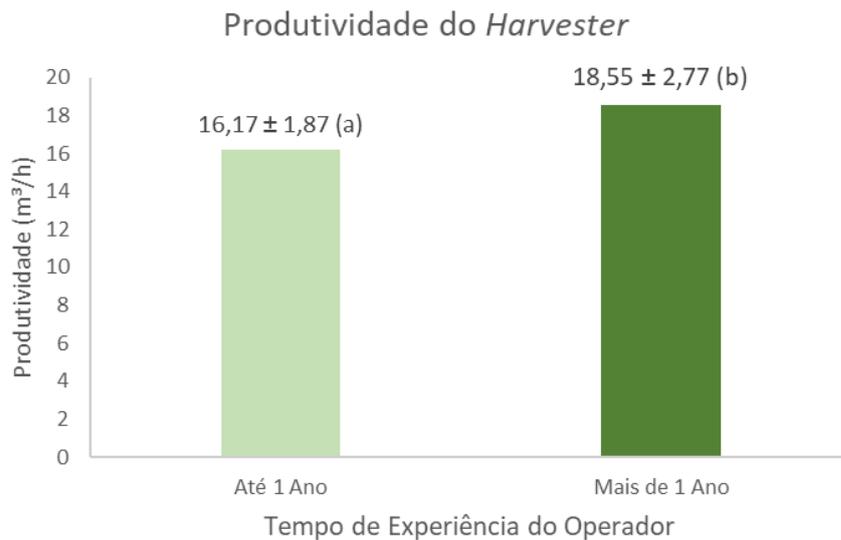


Figura 10: Produtividade do *harvester* em função do tempo de experiência do operador

Strandgard et al. (2014) consideram que, após o volume da árvore, o fator mais significativo que afeta a produtividade do *harvester* é o desempenho do operador. Embora a mecanização do corte florestal tenha sido aprimorada por meio da tecnologia, o maior desafio encontrado pelas empresas florestais brasileiras é a escassez de operadores de máquinas qualificados (Pagnussat et al. 2014). Portanto, para aumentar a produtividade do *harvester* no corte florestal, torna-se crucial ter operadores com conhecimento da operação, além de combinar personalidade e fatores motivacionais (Harstela, 2004; Volodina et al. 2015).

### 3.1.5. Organização da operação

Em relação ao planejamento da atividade de corte florestal, o tipo de intervenção realizada pode ser o corte raso (corte de todos indivíduos) ou desbaste (corte de

alguns indivíduos previamente selecionados). Neste estudo, observou-se uma produtividade média de  $4,03 \text{ m}^3 \cdot \text{he}^{-1}$  em operação de desbaste, uma diminuição de 482,38% quando se comparado à operação de corte raso dos indivíduos. Diversos estudos comprovam que a produtividade do *harvester* é diminuída quando se trabalha no regime de desbaste, principalmente pela dificuldade de mobilidade da máquina no interior do povoamento e necessidade de produção de toras com diferentes sortimentos (Spinelli e Nati, 2009; Lopes et al. 2017). Em algumas situações, indica-se realizar o corte através do método semimecanizado (motosserra) em detrimento ao método mecanizado com *harvester*, devido aos custos da operação.

Outro fator a depender do planejamento da empresa e do uso final da madeira refere-se à inclusão do descascamento da madeira. Esta variável influencia a produtividade do *harvester* devido ao tempo para executá-lo representar uma parte significativa do ciclo operacional (Burla et al. 2012). Vale ressaltar as vantagens do descascamento em campo pelo *harvester*: redução do peso de madeira transportada e a diminuição da exportação de nutrientes do solo (Machado, 2014).

Outra questão que cabe discussão no planejamento da operação de corte florestal com *harvester* é a influência dos turnos de trabalho na produtividade da máquina, ou seja, a relação entre o trabalho durante o dia e noite. Porém, neste estudo não foi observada diferença significativa de produtividade do *harvester* quando comparada a operação nos dois turnos. Tal fato pode ser explicado devido à evolução do nível de tecnologia das máquinas, como sensores e principalmente melhorias na qualidade e potência de luminosidade dos faróis. Outros trabalhos já inferem que o agendamento de turnos é um fator que não deve ser ignorado (Häggström e Lindroos, 2016; Rossit et al. 2019).

Considerando-se todas outras variáveis de influência na produtividade do *harvester* semelhantes, analisamos o fornecimento do serviço, encontrando resultado de produtividade superiores quando se realiza o corte florestal com fornecimento de serviço próprio, comparado às máquinas em teste e serviço terceirizado de mão-de-obra (Figura 11). Este resultado encontrado foi semelhante ao estudo de Lacerda (2017), que ainda obteve resultado de disponibilidade mecânica e eficiência operacional superiores quando o fornecimento de serviço é próprio, comparado ao terceirizado.

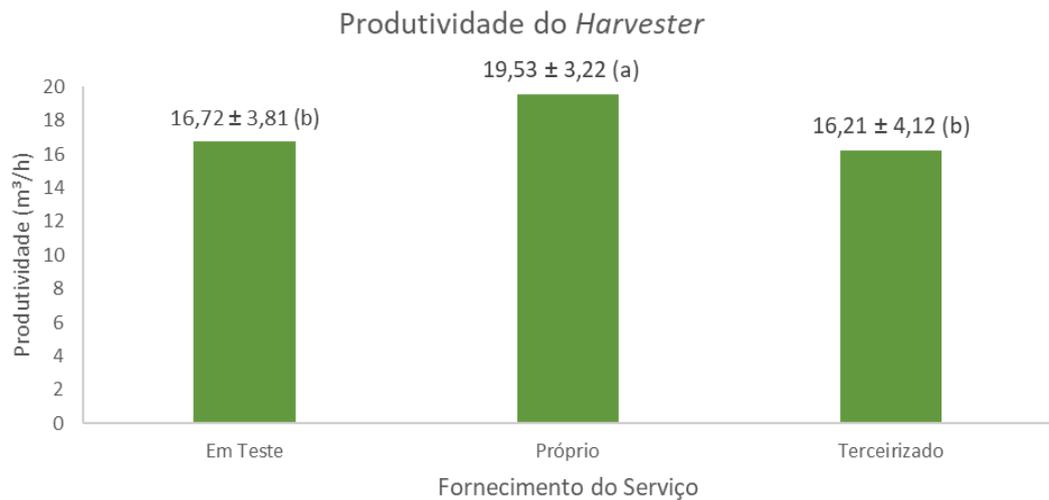


Figura 11: Produtividade do *harvester* em função do tipo de fornecimento de serviço.

### 3.2. Coleta automática dos dados em tempo real

Conhecendo as variáveis de influência no desempenho do *harvester*, tem-se a base para a gestão digital da operação. Na construção de um gêmeo digital é essencial decidir quais tipos de dados serão coletados, sabendo que dados ausentes ou incorretos podem distorcer o resultado final (Tao e Qi, 2019). Sugeriu-se neste estudo a coleta e conhecimento das seguintes variáveis:

- Ciclo de operação da máquina – os recursos de monitoramento dos *harvesters* através do apontamento eletrônico, permitem acompanhar a situação das máquinas, tais como “em operação”, “aguardando manutenção”, “ancorada em abastecimento”, entre outros.
- Características da floresta – através de sensores acoplados ao cabeçote do *harvester* (base, rolos, facas, serra) é possível mensurar características das árvores processadas, como diâmetro, comprimento das toras, altura das cepas, diâmetro mínimo de corte na ponteira, número e comprimento das toras processadas, altura comercial, entre outros.
- Características do terreno – através da instalação de sensores e sistema *GPS* acoplados às máquinas, permite-se aos operadores identificar as características da área em sua volta, como a inclinação do terreno, obstáculos, estradas, áreas de conservação, corpos hídricos, entre

outros. Isto permite um planejamento do deslocamento mais ágil, assertivo e seguro (Leite et al. 2013).

- Características da máquina – em razão das características da floresta e do terreno, o *harvester* responde de diferentes maneiras. Esta resposta ocorre de uma maneira mais ágil a partir do momento em que os dados relativos às características externas se encontrem no sistema da máquina. Como exemplo podemos citar a velocidade dos rolos e da serra do cabeçote, que pode ser otimizada em razão das características da floresta, buscando-se maior produtividade e menor consumo de combustível. Através destes dados se criam informações para que o sistema de trabalho homem-máquina-ambiente seja otimizado.
- Produtividade da operação – com base nos dados das características da floresta e qualidade da operação trazidos pelos sensores acoplados ao cabeçote do *harvester* e enviados ao sistema, calcula-se a volumetria de madeira (m<sup>3</sup>) e número de árvores processadas por hora, por turno, por dia, por máquina, por operador, entre outros, conforme as exigências da gestão dos indicadores da empresa.
- Registros categóricos – através do computador de bordo da máquina, conectado ao sistema de gestão da empresa, se adicionam outras informações importantes, tais como, espécie, clone, espaçamento, turno, operador.

Algumas destas características que influenciam o desempenho do *harvester* são qualitativas e normalmente conhecidas pelos operadores, técnicos e especialistas da operação. Neste sentido, indica-se a utilização do apontamento eletrônico, estratégia utilizada por algumas empresas nos últimos anos, tornando mais fácil e eficiente a gestão da operação. Outros dados que podem ser apontados eletronicamente são a produtividade, paradas operacionais e de manutenção, registros de abastecimento e horímetro das máquinas florestais (Silva e Robert, 2019). De acordo com Alvarenga (2017), os dados coletados através do apontamento eletrônico, além da maior confiabilidade elimina os riscos de extravio, atraso e desfragmentação das informações.

Porém, a base para o apontamento e acompanhamento em tempo real de alguns destes dados, é a sua coleta. Neste sentido, entra em cena a tecnologia dos sensores, capazes de realizar a medição de dados importantes para gestão da operação, sendo base para a tecnologia chamada telemetria, ou seja, acompanhamento e monitoramento das máquinas em tempo real sem interferência ou manipulação humana (Abreu et al. 2019).

Neste estudo, indicou-se que sensores posicionados próximos aos rolos (Figura 12 - B), facas e serra (Figura 12 - C) do cabeçote do *harvester* tenham a capacidade de medição de dados importantes como diâmetro e comprimento das árvores e toras processadas. Através da tomada destes dados calcula-se o volume processado de madeira ( $m^3$ ) e a produtividade da operação ( $m^3.he^{-1}$ ). A quantidade e posição destes sensores deve ser otimizada, visto o custo envolvido na aquisição e manutenção destes instrumentos. Enfatiza-se a necessidade de calibragem periódica dos sensores, visto a importância de se obter dados precisos, ou seja, que realmente representa as condições analisadas (Tao e Qi, 2019).



Figura 12: Exemplo de cabeçote de *harvester* visto frontalmente (A), distância entre os rolos (B) e a serra (C).

### 3.3. Transmissão e Armazenamento dos dados

Após coletados, estes dados devem ser transmitidos em tempo real e armazenados nos sistemas da empresa. As tecnologias de transmissão de dados incluem transmissões por fio e sem fio, sendo que esta última pode ocorrer a curta e longa distância. Algumas tecnologias de curto alcance amplamente utilizadas são *bluetooth*, *WiFi*, banda ultra-larga (UWB) e comunicação por campo de proximidade (NFC). Já tecnologias de longa distância incluem GPRS/CDMA, rádio digital, bridges wireless (ponte sem fio), comunicação via satélite, entre outras (Lei, 2018). Neste estudo, focou-se nas particularidades daquelas mais utilizadas atualmente na colheita florestal, como comunicação via satélite, via rádio digital, rede de telefonia móvel e sistema de coletores (Figura 13), entendendo que cada situação em campo deve ter uma solução personalizada.

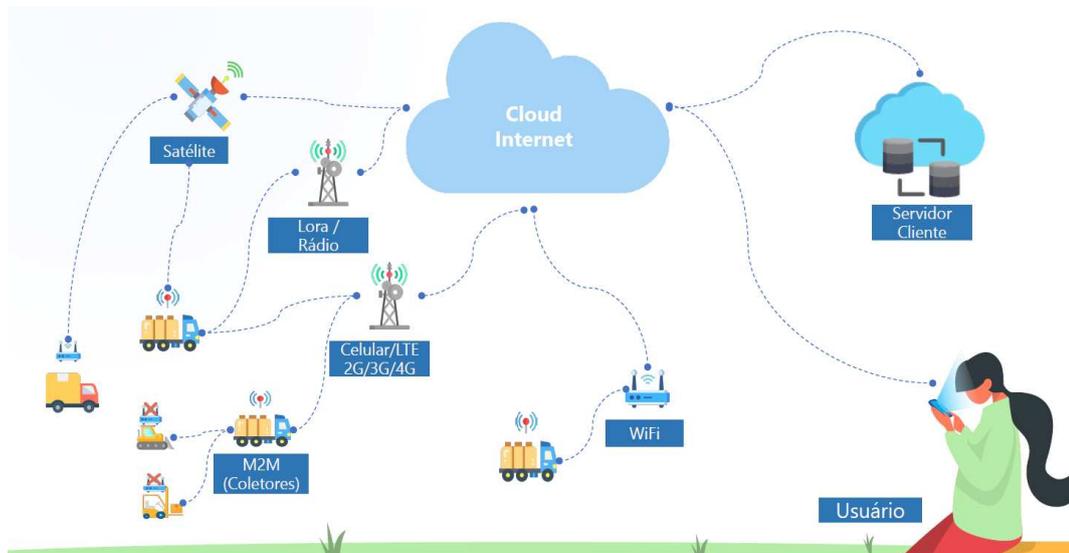


Figura 13: Opções de transmissão de dados e comunicação mais utilizadas na colheita florestal (Fonte: Aiko Digital, 2021)

A comunicação via satélite se apresenta como uma solução interessante do ponto de vista que independe da localização da máquina em campo, porém, ainda apresenta um custo elevado para um tráfego de grande quantidade de informações (Ribeiro e Fernandes, 2021). Outra opção seria a comunicação através de rádio frequência, como por exemplo a tecnologia LoRa, porém, com investimento alto para cobrir uma grande área florestal. Surge como opção de menor custo utilizar rede de telefonia móvel (2G/3G/4G), porém são poucas áreas florestais que possuem acesso

a este recurso. Acredita-se que, com a disseminação e consolidação do sinal 5G, poderemos solucionar este gargalo (Campos, 2021). Através da tecnologia WiFi se consegue trafegar uma grande quantidade de informações, porém a um alcance curto, sendo mais utilizada como ponto de descarga de informações em módulos fixos. O sistema de coletores (M2M) tem sido bastante utilizado, sendo um veículo de apoio que movimenta a área coletando dados das máquinas, e posteriormente, descarregando na nuvem quando se encontra em área com acesso à alguma opção de comunicação, seja telefonia móvel, WiFi ou outro meio.

Após coletados e transmitidos, sugeriu-se que estes dados sejam armazenados em plataformas que forneçam recursos avançados de tecnologia da informação, tendo como solução a computação em nuvem, uma rede de servidores remotos que tem a propriedade de compartilhar e armazenar dados na internet. Esta tecnologia apresenta como vantagens a fácil implementação e acesso por parte dos interessados, porém, são necessários cuidados em relação à privacidade e segurança destes dados (Au, 2016).

#### **3.4. Gestão dos dados da operação de corte florestal com *harvester* através do software Microsoft Power BI**

Em relação aos resultados gerados para gestão da operação de corte florestal com *harvester* através do software Power BI, as informações obtidas permitiram tanto uma análise ampla do desempenho dos operadores, assim como informações pontuais e específicas, permitindo aos gestores da operação obterem *insights* para agirem nos desvios observados. A análise satisfatória dos indicadores (KPI's) da operação foi possível devido às mais diversas características e vantagens das ferramentas e etapas do processo de criação de visuais para geração de informações corretas e intuitivas através do Power BI. Em um cenário em que é preciso aumentar a velocidade e a assertividade da tomada de decisão, o funcionamento do Power BI se mostrou chave para o sucesso da gestão da operação, ampliando vantagem competitiva de mercado (Morais, 2019).

Dentre as etapas do processo, primeiramente, comenta-se a diversidade de fonte de dados utilizadas na etapa de extração, com planilhas de Excel, endereços virtuais e dados de posição geográfica servindo como base para o estudo. Durante a

etapa de estruturação dos dados, as ferramentas do Power Query permitiram uma transformação ágil e simples dos dados a partir da utilização de diversas funções, como filtragens, remoções, agrupamentos, mesclas. (Raviv, 2018).

Nas posteriores etapas de modelagem dos dados e cálculos, as funções do Power Pivot e linguagem DAX permitiram rapidez e dinamicidade na criação de relacionamentos entre as colunas estudadas, assim como na criação de cálculos complexos envolvendo os mais diversos tipos de dados extraídos da operação de corte florestal.

Na etapa “Criação de Visuais”, diversas formas de visualização foram utilizadas, sendo necessário destacar algumas. A visualização “Segmentação de dados” permitiu uma análise rápida em relação aos operadores de *harvester* e data da operação avaliados no estudo. A visualização “*Simple image*”, com capacidade de fornecer imagens dinâmicas no dashboard através do endereço virtual de uma página ou *website* (URL - *Uniform Resource Locator*), possibilitou em nosso estudo visualizar o rosto dos operadores analisados (Conroe, 2018). Esta forma de visualização é considerada importante devido à maior habilidade de algumas pessoas em relação à memória visual.

O gráfico de colunas empilhadas possibilitou a análise diária das horas em operação, assim como em paradas mecânicas ou operacionais. Atrelado à esta forma de visualização, destaca-se neste estudo a utilização da ferramenta “*Tooltip*”, basicamente um gráfico secundário que traz valores específicos quando se posiciona o mouse em um gráfico principal do relatório, proporcionando uma análise abrangente e efeito visual muito interessante. No nosso caso, avaliando a eficiência operacional dos *harvesters* em estudo, o gráfico secundário trouxe a informação do “tipo de parada” realizada (Figura 14).

A visualização *Scroller*, um gráfico dinâmico que movimenta os resultados da “direita pra esquerda”, proporcionou visualizar informações importantes do dashboard principal, enquanto se analisa outros dados. Por se tratar de um gráfico frequentemente utilizado para análise de valores em percentual, optou-se por visualizar no estudo o indicador EGMF dos operadores, assim como a diferença encontrada em relação à meta estabelecida em termos percentuais (Figura 14).

A visualização “Indicador” permitiu analisar os valores encontrados em relação às metas estipuladas, com mudança interativa de cores baseado no alcance das mesmas. Neste estudo, foi a visualização mais utilizada, haja visto a necessidade de avaliar diversos indicadores importantes para a gestão do corte florestal com *harvester* e que são base para analisar a eficiência global da operação (Silva, 2017) (Figura 14).

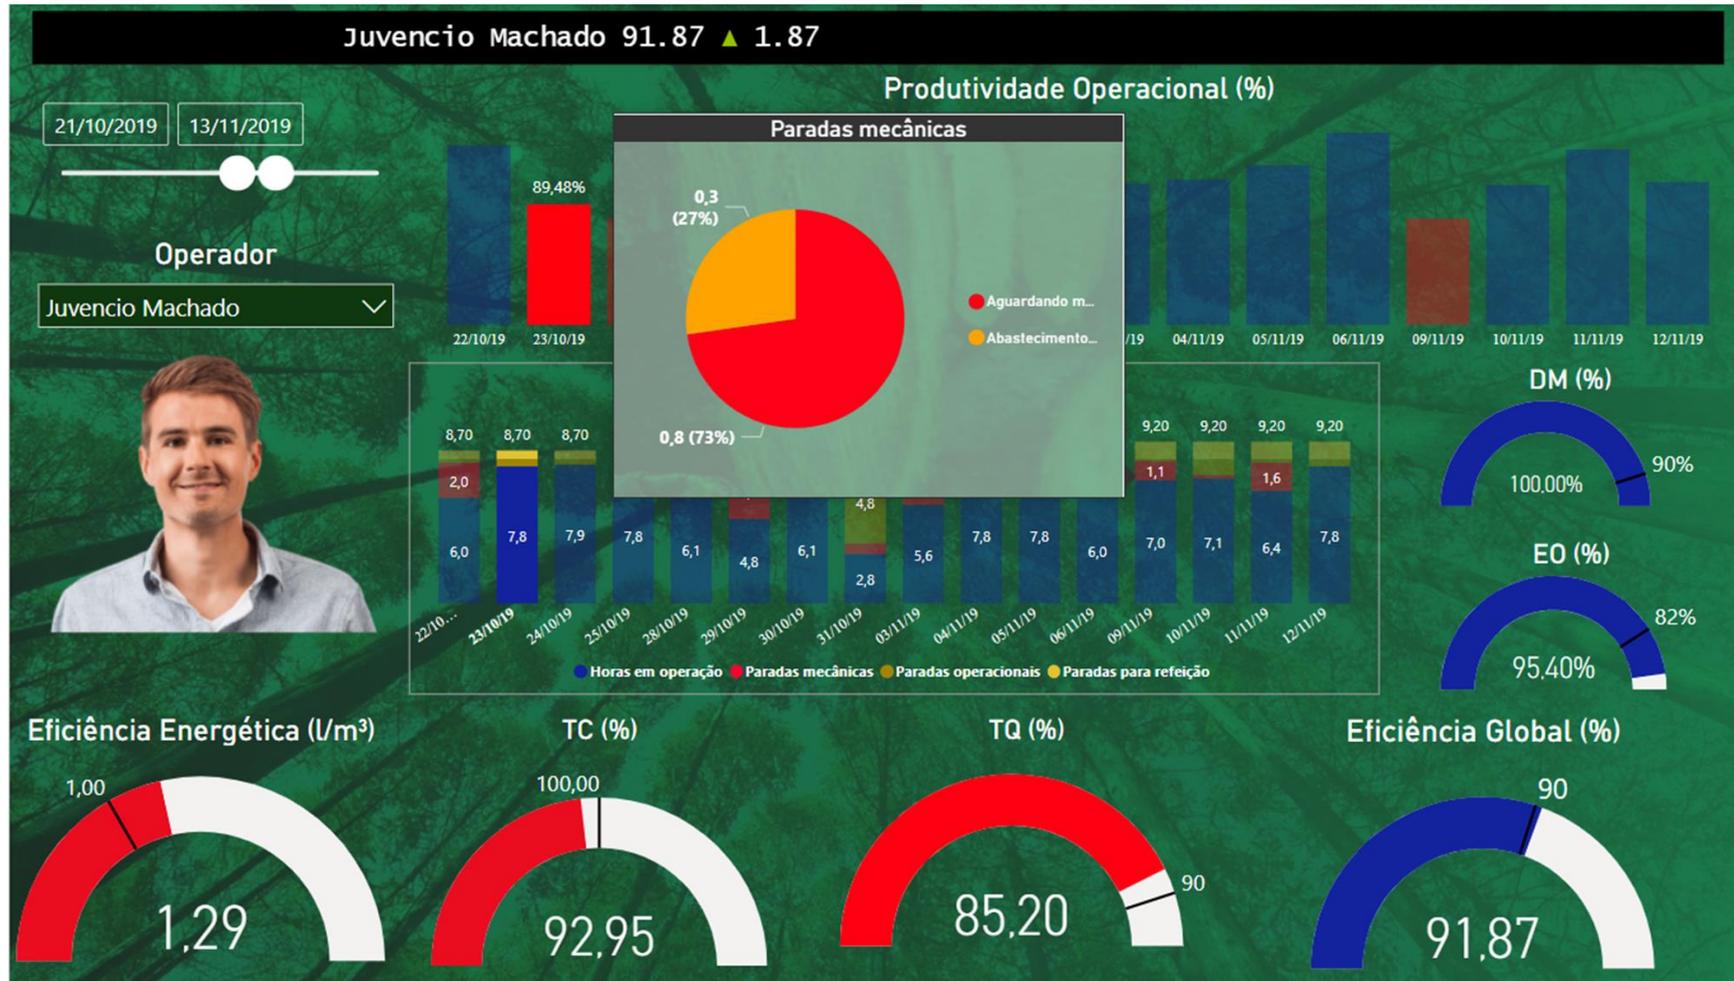


Figura 14: Principal dashboard criado no estudo relacionado à eficiência global da operação – EGMF. Onde DM – Disponibilidade Mecânica; EO – Eficiência Operacional; TC – Taxa de Consumo de Combustível; TQ – Taxa de Qualidade dos parâmetros da operação.

As visualizações “Mapa” ou “ArcGis for Maps”, com a capacidade de fornecer a localização correta das máquinas em campo através dos dados de latitude e longitude, se mostrou muito importante para planejamento da rota dos operadores e equipe de manutenção em campo, diminuindo o tempo de movimentação e espera da máquina para manutenção (Brown, 2017) (Figura 15).

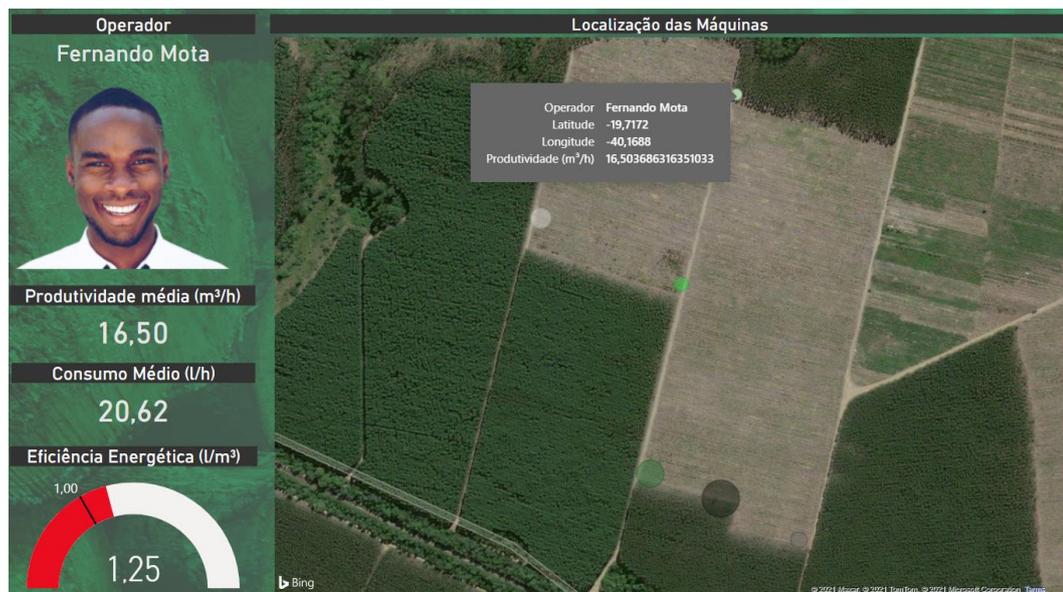


Figura 15: *Dashboard* - Acompanhamento da localização das máquinas.

Através de diversas formas de visualização, avaliou-se no estudo os parâmetros relacionados ao controle de qualidade da operação, como altura de toco, comprimento de toras, diâmetro mínimo e descascamento (Figura 16). O acompanhamento destes parâmetros em tempo real é importante para reduzir desperdícios de madeira, além de gerar uma mentalidade focada na busca da qualidade total (Trindade, 2017). Este fato resultará em impactos significativos tanto à curto quanto à médio prazo na redução dos custos da operação de corte florestal com *harvester*.

Todas formas de visualização descritas são integradas, proporcionando uma interatividade com efeitos visuais interessantes e fornecendo informações pontuais para uma tomada de decisão rápida e assertiva (Pirnal et al. 2017). Esta é uma das vantagens oferecidas pela utilização do Power BI na gestão da operação de corte florestal com *harvester*, sendo as demais descritas posteriormente.



Figura 16: *Dashboard* – Controle dos indicadores de qualidade da operação de corte florestal com *harvester*.

### 3.4.1. Vantagens da utilização do Power BI na gestão do corte florestal

Em relação às vantagens da utilização do Microsoft Power BI na gestão da operação de corte florestal com *harvester*, podemos citar aquelas relacionadas à disponibilidade do *software*, integração com outros sistemas e fontes de dados, agilidade na transformação e modelagem dos dados, atualizações automáticas, fácil manuseabilidade, versatilidade, visualização intuitiva, publicação de relatórios, entre outros, conforme descrito abaixo:

- **Fácil implementação e manuseabilidade**

Como primeira vantagem, é importante comentar a facilidade de obtenção do *software* (*download* gratuito), assim como em manejá-lo, ajudando a impulsionar as organizações para uma cultura baseada em dados. Com poderosas habilidades *self-service*, os usuários corporativos não dependem mais da área da tecnologia de informação (TI) para coletar, transformar e analisar dados. Do ponto de vista da colheita florestal, esta facilidade tem contribuído na comunicação entre as equipes de trabalho, e, com isso, dando suporte à uma tomada de decisão assertiva (Lennerholt et al. 2018).

- **Integração com diversos sistemas e fontes de dados**

Uma outra vantagem é a relação com a manipulação de dados, garantindo conectividade com diversas fontes, não importando qual é a origem do arquivo (Borges et al. 2018). Assim sendo, é possível apresentar um único relatório, mesclando diversas fontes de dados. Dentro da realidade da colheita florestal, tem-se utilizado bastante as plataformas de gestão empresarial SAP ERP e SGF – Sistema de Gestão Florestal para extração dos dados de forma direta, com ganhos operacionais relacionais ao tempo de trabalho. Para realização de análises avançadas, o Power BI ainda apresenta integração com outras linguagens, como a linguagem R (Sonna, 2018).

- **Agilidade na transformação e modelagem de dados**

Neste sentido, o Power BI permite a criação de modelos de dados de uma forma muito simples, a partir de relações entre diferentes tabelas e colunas em sua ferramenta Power Pivot. Esta solução tornou possível superar várias barreiras de uma

análise tradicional, como dados não estruturados, fórmulas grandes, longo prazo de preparação de relatórios analíticos, entre outros. A criação destes relacionamentos permite uma integração simples, rápida e intuitiva (Sonna, 2018).

- **Interface e visualização intuitiva.**

Através das diversas visualizações fornecidas em seu componente “Power View”, o Power BI também apresenta como vantagem sua variedade de elementos visuais, permitindo gerar informações coerentes e intuitivas. Do ponto de vista da operação de corte florestal com *harvester*, este fácil entendimento das informações geradas a partir da análise dos dashboards criados é muito importante, haja visto a diversidade de público envolvida na operação, envolvendo operadores em campo, mecânicos, técnicos, supervisores da operação, coordenadores, gestores, entre outros.

- **Análise do panorama geral e específico**

Os gestores têm a possibilidade de resposta imediata a qualquer desvio negativo ou positivo dos resultados demonstrados através do painel de controle *dashboard*, sendo que as decisões são tomadas com maior clareza, precisão e eficácia, direcionando sua atenção ao que realmente é necessário, gerando assim um melhor desempenho de sua equipe em relação às metas da operação. Para a operação de corte florestal, é muito importante uma análise geral dos KPI's por parte dos gestores da operação, assim como uma análise específica por parte dos supervisores e operadores de *harvester* (Silva, 2017). Enfatiza-se ainda, que, estas informações podem estar disponíveis em diversos dispositivos, desde telemóveis, tablets, computadores (Ferrari e Russo, 2016).

- **Diversidade de utilização e versatilidade**

Para a gestão do corte florestal com *harvester*, diversas outras análises podem ser realizadas, podendo citar: controle do estoque de peças, já que uma correta mensuração de peças para reposição se torna essencial para garantir o funcionamento das máquinas; análise da influência de diversas variáveis sobre o desempenho do *harvester*; pesquisas de satisfação com os colaboradores da empresa; entre outros. O valor e domínio que o Power BI apresenta reside na

diversidade de utilização e versatilidade que oferece para servir e melhorar o desempenho de diversas funções dentro de uma dada organização, maximizando a sua eficiência (Blast, 2019).

- **Acompanhamento da localização das máquinas em tempo real**

Além de todas as vantagens comentadas em relação à análise de dados, o Power BI oferece ainda conexão direto com o Arc GIS Maps, possibilitando acompanhamento em tempo real da localização das máquinas em campo. Esta análise espacial, combinada aos demais indicadores analisados, fornece aos supervisores da operação e manutenção em campo uma visão mais assertiva para a tomada de decisão (Brown, 2017).

- **Sistema de publicação dos relatórios**

O sistema de publicação dos relatórios é outra vantagem, sendo que, por meio do serviço em nuvem do Power BI Service, é possível acessar relatórios de qualquer lugar via web ou aplicativo. Essa praticidade permite a obtenção de *insights* em qualquer momento, pois, com o acesso facilitado de qualquer lugar, evita-se a concentração de recursos. Comenta-se ainda, a possibilidade de exportar os relatórios diretamente para o *Power Point*, o que facilita bastante as apresentações em reuniões ou eventos.

- **Atualizações automáticas**

Esta particularidade permite que o relatório seja montado apenas uma vez, e a partir disso, programar as atualizações automáticas para análise dos indicadores (Karpinski, 2020). Atualmente, para a realidade da “colheita florestal 4.0”, com geração de grande quantidade e diversidade de dados em um espaço curto de tempo, as empresas têm utilizado atualização automática em intervalos de até 1 hora. Esta vantagem permite rápida tomada de decisão por parte dos gestores e supervisores da operação, mesmo estando em campo, devido ao acesso ao Power BI Mobile.

### 3.5. Criação de um gêmeo digital do *harvester* no corte florestal

Como primeiro passo para aplicação da tecnologia gêmeo digital no monitoramento e gestão do corte florestal mecanizado com *harvester*, entendeu-se que é necessária a integração entre três pilares, sendo o pilar humano (pessoal envolvido), tecnologia (máquinas e sistemas desenvolvidos) e processos. Somente com uma gestão satisfatória e integrada entre estes três pilares é possível alcançar os resultados esperados.

Em relação às tecnologias habilitadoras para a construção de um gêmeo digital do *harvester*, baseado na ideia das tecnologias da chamada “Indústria 4.0” (Carbone, 2017), identificou-se onze principais, relacionadas às áreas de ciência de dados, sistemas de informação, conectividade no campo, autonomia da operação, entre outras (Figura 17). Estas tecnologias habilitadoras estiveram presentes nas etapas de construção do gêmeo digital.

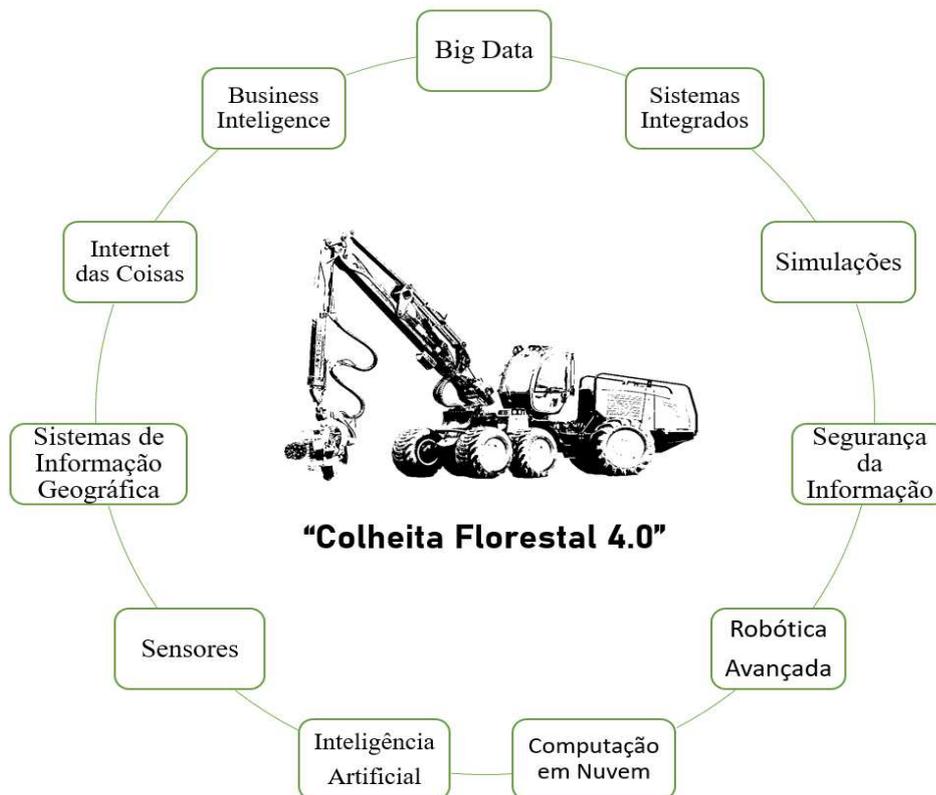


Figura 17: Tecnologias habilitadoras relacionadas à criação de um gêmeo digital do *harvester* no corte florestal mecanizado.

As etapas de construção de um gêmeo digital se combinam em um processo evolutivo dinâmico que constrói gradualmente o gêmeo digital (Parmar et al. 2019). Adaptado de outros estudos (Parmar et al. 2019; Tao e Qi, 2019), as etapas técnicas imprescindíveis na construção de um gêmeo digital para a realidade da operação de corte florestal com *harvester*, e as estratégias e ferramentas utilizadas em cada etapa foram compiladas na Tabela 3.

Tabela 3: Etapas, Estratégias e Tecnologias utilizadas para construção do gêmeo digital do *harvester*

<b>Etapas para construção do gêmeo digital do <i>harvester</i></b>	<b>Estratégias e/ou tecnologias habilitadoras utilizadas por etapa</b>
1). Elaboração da equipe técnica	Multidisciplinaridade; Treinamentos.
2). Coleta dos dados	Sensores; Mecânica; Automação; Sistemas de Informação Geográfica.
3). Transmissão e armazenamento dos dados	Internet das Coisas; Big Data; Computação em Nuvem; Segurança da Informação.
4). Criação dos modelos	Inteligência Artificial; Sistemas Integrados; Simulações.
5). Análise dos dados e informações geradas	<i>Business Intelligence</i> .
6). Gestão da tecnologia de gêmeo digital	Ferramentas de qualidade; monitoramento; verificação; otimização; educação digital.

Para a aplicação e funcionamento do gêmeo digital da operação de corte florestal mecanizado com *harvester*, é necessário, relatar a importância da criação de uma equipe técnica multidisciplinar formada por especialistas nas diferentes áreas e etapas, entendendo que ninguém sabe cada detalhe de todo o processo.

Sugeriu-se a presença de especialistas da área florestal que conheçam as variáveis de entrada no modelo (analistas, doutores, engenheiros, professores, pesquisadores), profissionais na área de mecânica e manutenção (técnicos, engenheiros), especialistas em criação e desenvolvimento de sensores específicos para a operação, profissionais de tecnologia e informação (TI) para criação de

modelos, simulações, *hardwares* e *softwares*, que sejam robustos e realistas, e, por fim, analistas financeiros para avaliação dos custos de implantação e manutenção da tecnologia em funcionamento.

Sendo uma equipe multidisciplinar, faz-se necessário entender e respeitar as diferenças, sendo fundamental customizar as soluções para atendimento aos diferentes profissionais. Com isso, para a construção do gêmeo digital do *harvester*, além do alinhamento tecnológico, o exercício da criatividade e da inovação para racionalizar ao máximo os recursos humanos e as soluções para as dificuldades operacionais encontradas são indispensáveis (Oliveira, 2017).

Em relação à coleta automática e transmissão dos dados, entram em cena os sensores, capazes de realizar a medição de dados importantes para gestão da operação, sendo base para a tecnologia chamada telemetria, ou seja, acompanhamento e monitoramento das máquinas em tempo real sem interferência ou manipulação humana (Abreu et al. 2019). Quando os sensores coletam e transmitem dados de um dispositivo conectado, estes podem ser usados para atualizar sua cópia virtualizada em tempo real (Haag e Anderl, 2018). Neste sentido, o gêmeo digital torna-se atualizado e uma cópia precisa das propriedades do objeto físico, em nosso caso o *harvester*, incluindo forma, posição, gesto, status e movimento. Neste processo, enfatiza-se ainda a importância das tecnologias “Internet das Coisas” (*Internet of things - IoT*) e “computação em nuvem” (*Cloud Computing*), que fazem parte do conceito da “Indústria 4.0” (Botkina et al. 2018) e facilitam a criação de uma cópia virtualizada da operação de corte florestal com *harvester*.

Para construir um gêmeo digital de um ativo físico, em nosso caso o *harvester*, é necessário um modelo digital do ativo. O modelo deve ser leve, robusto, caracterizado por apresentar alta padronização e modularização, e calibrado para corresponder com precisão ao ativo físico específico (Tao et al. 2019). A precisão do modelo virtual afeta diretamente a eficácia do gêmeo digital, portanto, o modelo deve ser validado e verificado.

Através de várias tecnologias de digitalização, comportamentos e relações no mundo físico são digitalizados holisticamente para criar modelos virtuais de alta fidelidade (Tuegel et al. 2011; Glaessgen e Stargel, 2012). Tais modelos virtuais

dependem de dados do mundo físico para formular seus parâmetros em tempo real, levando a uma reflexão mais representativa das entidades físicas correspondentes (Grieves, 2014).

Para o modelo virtual, várias tecnologias de modelagem são essenciais. A modelagem relacionada à criação de um gêmeo digital envolve modelagem geométrica, modelagem física, modelagem comportamental e modelagem de regras. Portanto, as ferramentas para modelagem de um gêmeo digital incluem ferramentas de modelagem geométrica, física, de comportamento e de regras. Do ponto de vista da criação de um gêmeo digital do *harvester*, sugeriu-se neste estudo algumas ferramentas e softwares que podem ser utilizados (Figura 18).

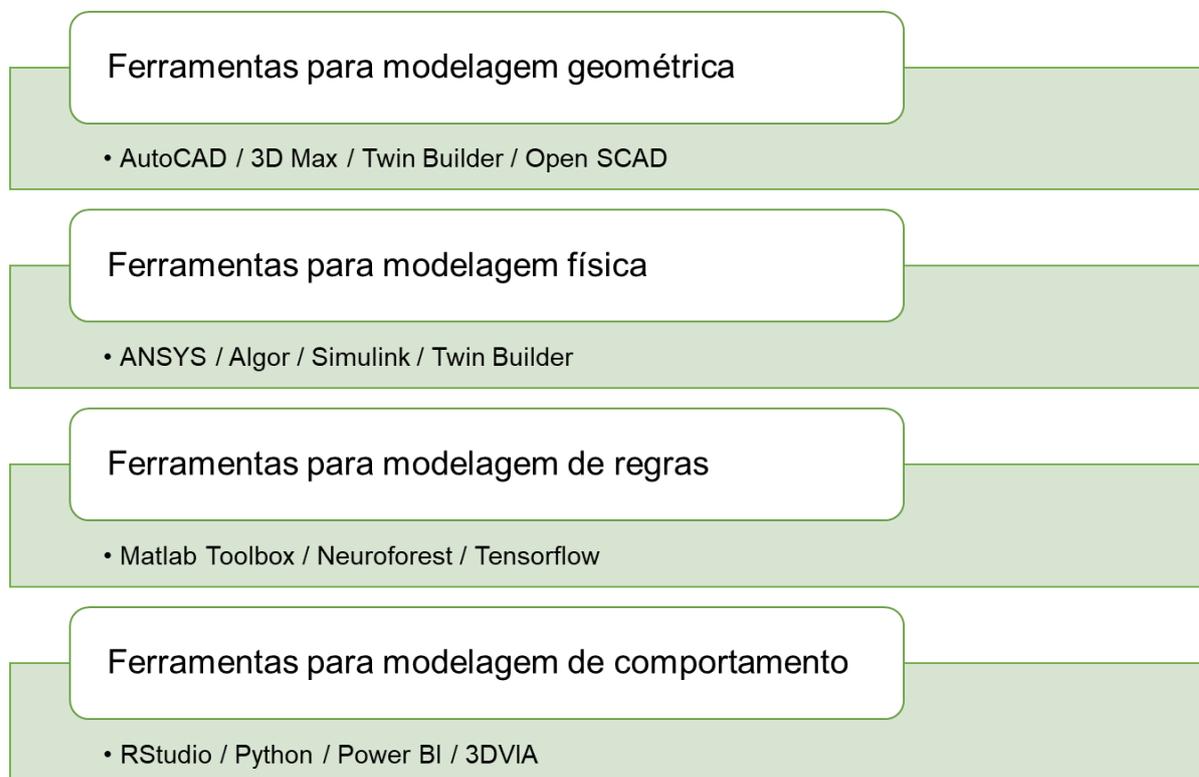


Figura 18: Ferramentas de modelagem para construção de um gêmeo digital do *harvester* (Adaptado de Qi et al. 2019)

Para a análise preditiva da produtividade do *harvester*, conclui-se que a técnica *Random Forest* apresentou qualidade estatística do algoritmo para estimativas da produtividade em relação aos valores observados (Figura 19).

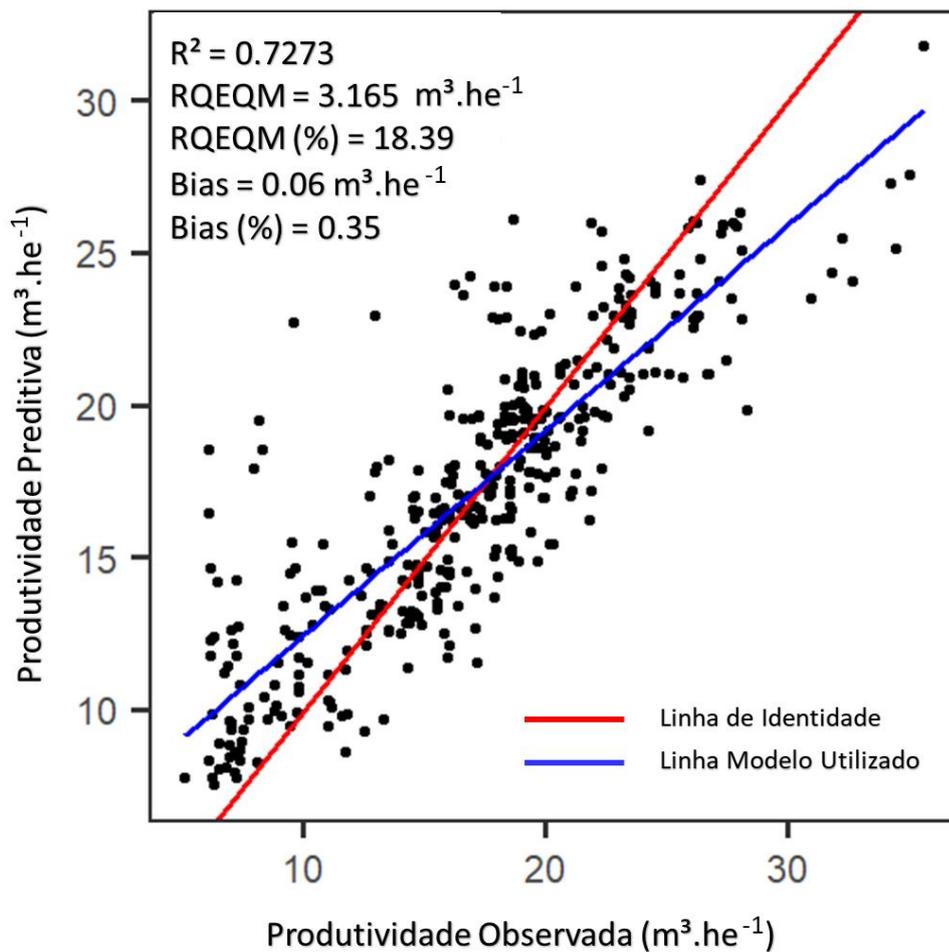


Figura 19: Dispersão dos valores de produtividade estimados pelo modelo de predição utilizado – *Random Forest* em relação aos valores observados.

Relacionando-se os resultados à qualidade estatística das estimativas, entendeu-se que os resultados de RQEQM absoluto/relativo foram satisfatórios, assim como as bias que apresentaram tendência próximo a zero. Porém, observou-se uma tendência de predição de valores menores aos observados a partir da classe de produtividade no valor de  $30 \text{ m}^3 \cdot \text{he}^{-1}$ . Com isso, pode-se concluir que o modelo poderia ser ainda mais assertivo englobando valores de produtividade até esta classe. Isto pode ser explicado devido às limitações da máquina para alcançar valores de produtividade maiores que  $30 \text{ m}^3 \cdot \text{he}^{-1}$ , mesmo em florestas com boas condições de volume médio individual e relevo plano.

Portanto, conclui-se que o modelo *Random Forest* pode servir como base para a criação de um gêmeo digital do *harvester*, direcionando esforços com base na

predição da produtividade em relação às variáveis influentes no desempenho da máquina.

Para a análise preditiva de séries temporais, identificou-se quatro parâmetros ou *inputs* principais que visam otimizar a performance do modelo e algoritmo, sendo: Horizonte temporal de previsão (*Forecast Length*) (HT/FL); Ignorar último (Ignore Last/Hindcast) (IU/IL); Intervalo de Confiança (Confidence Interval (IC)) e Sazonalidade (Seasonality) (*FluentPro*, 2019). Após diferentes cenários de simulação, para a realidade da operação de corte florestal com *harvester*, a configuração mais assertiva utilizada foi a seguinte: HT - 20; IU - 20; IC - 95%; Sazonalidade - 30. Simulando cenários no filtro de data, identificou-se que, para uma análise preditiva consistente de algumas variáveis, deve-se realizar um mínimo de noventa (90) observações, em nosso estudo de caso, dias de operação do *harvester*.

Partindo para a análise preditiva efetuada, as ferramentas e modelos utilizados no estudo reuniram funcionalidades interessantes, que, em termos gerais, para o contexto da operação com *harvester*, responderam de maneira satisfatória. Para as variáveis abastecimento de combustível (quantidade de litros e número de abastecimentos), troca de material de corte e manutenções preventivas (número de ocorrências e tempo consumido) o modelo e algoritmos apresentaram bom desempenho em relação à previsão de ocorrências. Para a variável abastecimento de combustível, os valores previstos em relação aos valores observados apresentaram em média uma diferença de 13,44% (Figura 20) (Tabela 4). Porém, mais importante que a média global é a análise diária. Neste sentido, em vinte observações (dias de operação), somente em um dia o valor real de abastecimento não esteve contido dentro do intervalo de confiança gerado pelo modelo em relação aos valores previstos.

Para a variável manutenção corretiva (número de ocorrências) o modelo apresentou erro médio de 48,68 % de ocorrências de manutenção corretiva realizadas em relação às previstas pelo modelo (Figura 20) (Tabela 4). Este valor pode ser explicado pelos seguintes fatores: 1). Número baixo de ocorrências diárias, levando à alta porcentagem quando se calcula a diferença entre os valores observados e previstos; 2). Dificuldade em prever ocorrências de distintos tipos de manutenção corretiva realizadas.

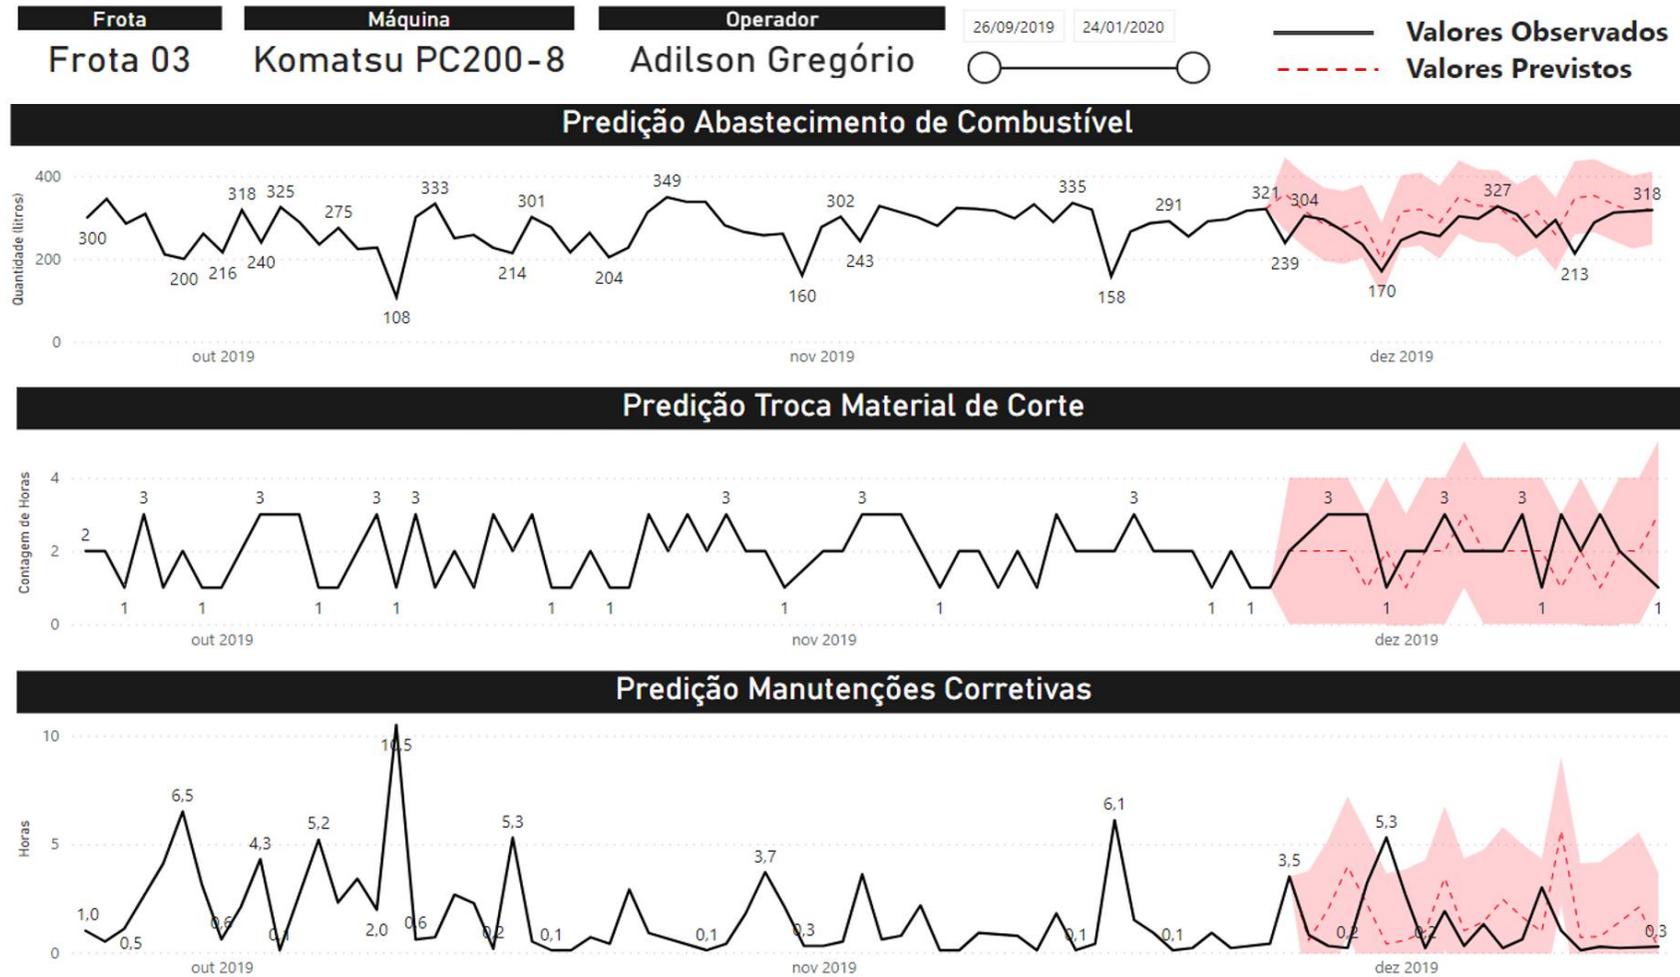


Figura 20: Análises preditivas para a operação de corte florestal com *harvester* no Power BI

Tabela 4: Erros relacionados à análise preditiva das variáveis analisadas

Data	Análise Abastecimento de Combustível (litros)					Análise Manutenção Corretiva (n)				
	Valor observado	Valor esperado	IC Superior	IC Inferior	Erro (%)	Valor observado	Valor esperado	IC Superior	IC Inferior	Erro (%)
24/11/2019	321	321	321	321	0	-	-	-	-	-
25/11/2019	239	357	445	269	-49,37	3	3	3	3	0
26/11/2019	304	316	404	228	-3,95	3	2	4	0	33,33
27/11/2019	295	284	372	196	3,73	2	3	6	2	-50
28/11/2019	268	276	364	188	-2,99	1	4	7	3	-300
29/11/2019	235	291	379	203	-23,83	1	2	5	0	-100
30/11/2019	170	200	288	112	-17,65	3	2	5	0	33,33
01/12/2019	245	314	402	226	-28,16	2	2	5	0	0
02/12/2019	265	320	408	232	-20,75	1	2	5	0	-100
03/12/2019	255	288	376	200	-12,94	4	3	5	0	25
04/12/2019	303	350	438	262	-15,51	1	3	6	1	-200
05/12/2019	297	329	417	241	-10,77	3	4	6	1	-33,33
06/12/2019	327	325	413	237	0,61	1	2	5	0	-100
07/12/2019	308	291	380	203	5,52	2	2	5	0	0
08/12/2019	253	316	404	228	-24,9	2	2	4	0	0
09/12/2019	294	259	348	171	11,9	3	4	6	1	-33,33
10/12/2019	213	347	436	259	-62,91	1	2	6	0	-100
11/12/2019	288	353	441	265	-22,57	2	3	5	0	-50
12/12/2019	312	332	420	244	-6,41	2	2	5	0	0
13/12/2019	314	313	401	225	0,32	0	3	6	0	
14/12/2019	318	323	411	235	-1,57	2	1	4	0	50
<b>Média Geral</b>					<b>-13,44</b>					<b>-48,68</b>

Devido à esta dificuldade em prever ocorrências de diferentes tipos de falhas e manutenções realizadas, sugere-se análises específicas, sendo que, manutenções relacionadas às mangueiras do sistema hidráulico do cabeçote estão entre as mais ocorrentes na operação de corte florestal com *harvester* (Rodrigues et al. 2018) Porém, para esta análise, sugeriu-se diferentes configurações para se chegar a um modelo mais assertivo, como: mínimo de 356 pontos (1 ano de observações); HT - 60; IU - 60; IC - 95%; Sazonalidade - 300.

Após diferentes cenários de simulação, o modelo respondeu satisfatoriamente ao processo, com capacidade de antecipar ocorrências relacionadas à danos na mangueira hidráulica do *harvester* (Figura 21). Aliado à análise preditiva realizada, calculou-se também o tempo médio entre as falhas (TMEF), ou MTBF - *Mean Time Between Failures*, indicador muito utilizado na área de manutenção mecânica. Para este estudo de caso, chegou-se a um resultado de 159,5 horas como tempo médio entre ocorrências relacionadas à danos na mangueira hidráulica do *harvester*.



Figura 21: Análises preditivas para ocorrências de danos à mangueira hidráulica do cabeçote do *harvester*

Estes resultados possibilitam diminuir os tempos de manutenção corretiva no *harvester*, sendo realizadas manutenções preventivas periódicas e sobretudo, manutenções preditivas, antecipando a necessidade de manutenção numa peça específica de uma máquina e aumentando o tempo de disponibilidade das mesmas (Viana, 2014). Enfatiza-se que, estas previsões realizadas no Power BI apresentam a possibilidade de sincronia e integração com outros *softwares*, possibilitando o envio de alertas aos operadores comunicando-os em relação a previsões de falhas ou outras ocorrências, sendo assim, a aplicação de um princípio do gêmeo digital na prática (Pinheiro, 2020).

## Análise dos dados e informações geradas

A capacidade de transmissão, armazenamento e processamento de dados pelos computadores tem aumentado significativamente, facilitando a implantação de sistemas que requerem análises em extensas bases de dados em tempo real. Neste sentido entram em cena os termos *Big Data* e *Business Intelligence*, sendo que, a conexão e integração entre tecnologias envolvendo estes temas fornecem uma nova abordagem para analisar e entender o mundo físico, em nosso caso a operação de corte florestal com *harvester*.

Do ponto de vista do “*Big Data*”, a aplicação desta tecnologia é base para a construção de um gêmeo digital do *harvester* devido à caracterização da operação e dos dados processados. Baseado em Owais e Hussein (2016) e Almeida (2018), enfatiza-se sobre as nove dimensões (9 V's) de um *Big Data* para a realidade da operação de corte florestal com *harvester* (Tabela 5).

Tabela 5: Dimensões *Big Data* e características para a realidade do *harvester*

<b>Dimensões</b>	<b>Características do corte florestal com <i>harvester</i></b>
1). Volume	Grande volume de dados sendo coletados a cada segundo na operação de corte florestal com <i>harvester</i> .
2). Variedade	Dados de diferentes tipos e formatos, envolvendo localização, produtividade, desempenho, qualidade da operação, entre outros.
3). Veracidade	Os dados provenientes de telemetria (sensores) e apontamento eletrônico (humanos) devem refletir verdadeiramente a situação real, sem irregularidades e discrepâncias.
4). Velocidade	As informações devem ser entregues ao usuário ou máquina instantaneamente, em tempo real.
5). Validade	Os dados devem ser corretos e precisos para o uso pretendido, devendo ser validados pelos profissionais envolvidos, como operadores e supervisores.

---

6). Variabilidade	O fluxo de dados pode ser altamente inconsistente com picos periódicos, diários, entendendo que eventos não controláveis podem acontecer na operação do <i>harvester</i> .
7). Volatilidade	Deve-se entender que demandas pontuais podem surgir, sendo que, a plataforma deve estar preparada tratamento de dados específicos da operação.
8). Valor	É importante garantir o retorno sobre o investimento, gerando insights que levem a melhorias na gestão da operação com <i>harvester</i> .
9). Visualização	A apresentação dos dados deve ser intuitiva e atraente graficamente, devendo ser entendido facilmente pelos diversos profissionais envolvidos na operação. Neste sentido, entram em cena as ferramentas de BI – <i>Business Intelligence</i> , como o Power BI.

---

Uma parte importante na análise de dados da operação com *harvester* é a integração e conexão entre diferentes sistemas e tecnologias utilizadas, haja visto a grande diversidade disponível no mercado. Importante comentar também que, a compilação e compartilhamento de informações detalhadas só é possível através do uso de tecnologias de informação e comunicação – TICs. Dentre as TICs utilizadas na gestão do corte florestal com *harvester* estão os dispositivos móveis, como *smartphones* e *tablets*, além dos computadores de bordo das máquinas. Através destes dispositivos é possível o acesso a *softwares* e aplicativos voltados para a gestão e monitoramento dos dados da operação.

Após as fases de coleta, transmissão, análise dos dados e geração das informações, o gêmeo digital sinaliza através de simulações quais as características do comportamento operacional que se desvia do comportamento ideal e tem a capacidade de tomar decisões e “enviar recados” à máquina para que as alterações ocorram em busca dos resultados desejados. Em resumo, o gêmeo digital tem a capacidade de ajustar o mundo físico, principalmente através do controle das operações com base no *feedback* das informações (Rasheed et al. 2019).

## **Gestão da tecnologia de gêmeo digital**

O objetivo final da tecnologia de gêmeo digital é fornecer aos usuários serviços de agregação de valor como monitoramento, simulação, verificação, experimento virtual, otimização, educação digital, entre outros (Cai et al. 2017). Estes serviços devem ser entregues através dos aplicativos móveis.

Conclui-se que a entidade física (*harvester* na operação de corte florestal mecanizado) e modelos virtuais, através de dados e serviços do gêmeo digital, deverão estar interconectados para permitir interações e trocar informações rumo à evolução coletiva.

Com base no princípio do gêmeo digital, é necessário entender o contexto geral, sabendo que pode haver uma rápida mudança no modelo de impacto impulsionado por novas oportunidades ou mudanças externas. A equipe de trabalho e responsáveis pela gestão da tecnologia devem estar atentos às mudanças no mercado, em vez de simplesmente manter e atualizar os mesmos tipos de dados de entrada.

Para uma gestão satisfatória da tecnologia de gêmeo digital, é preciso reunir as ferramentas corretas com uma equipe bem treinada. Para isso, além de serem capazes de analisar adequadamente as informações, esses profissionais também devem conseguir propor soluções e correções que funcionem tanto na versão virtualizada quanto na versão real de qualquer que seja o produto, ou seja, devem apresentar conhecimento aprofundado em relação às metodologias e ferramentas utilizadas (Rasheed et al. 2019).

### **3.6. Ganhos operacionais obtidos através da construção do gêmeo digital do *harvester***

A criação de gêmeos digitais em uma organização agrega valor a partir de três maneiras: produtividade, desempenho e previsibilidade (Parmar et al. 2019). Diante do exposto, comenta-se sobre os ganhos de se aplicar esta tecnologia na operação de corte florestal com *harvester*.

- **Acompanhamento dos parâmetros da operação em tempo real**

O acompanhamento da produtividade da operação e parâmetros de qualidade em tempo real por parte dos operadores através do computador de bordo da máquina e analistas através do sistema de gestão da empresa é uma grande vantagem por propiciar tomadas de decisão mais rápidas e assertivas.

A transmissão dos dados da operação em tempo real para um modelo virtual permite uma resposta instantânea às adversidades encontradas, e, à medida que os dados são atualizados permitem uma previsão baseada em simulação muito mais precisa e confiável, conforme já demonstrado nos resultados deste estudo.

- **Substituição de fichas de apontamento manual**

A substituição das fichas de apontamento manual pelo apontamento eletrônico é de fato um grande avanço na operação de corte florestal com *harvester*, sendo que este sistema simplifica as etapas de coleta, envio e análise das informações.

O apontamento escrito por parte do operador, normalmente realizado em fichas de campo, é posteriormente levado ao escritório, onde é digitalizado. Esta é uma operação cansativa, que pode causar desconforto aos funcionários em relação à posição e movimentos repetitivos na digitalização dos relatórios. Com a automatização da transmissão dos dados este trabalho é evitado, facilitando a gestão da operação e permitindo que os responsáveis pelos processos tenham mais tempo para tratar a qualidade dos produtos finais (Filho, 2016).

- **Previsibilidade de manutenção**

Uma das vantagens que se pode destacar através do uso da tecnologia do gêmeo digital é a previsibilidade. Isto ocorre devido à capacidade da tecnologia em combinar os dados por meio de sistemas digitais, realizar simulações e análises que obtenham informações relevantes sobre uma possibilidade futura.

No caso da manutenção de máquinas e equipamentos florestais, esta previsibilidade é muito importante, visto que o tempo em manutenção reduz o desempenho das máquinas e aumenta os custos da colheita florestal (Santos et al. 2017). Portanto, enfatiza-se a importância da sua utilização na gestão da operação de

corte florestal com *harvester*, devido, principalmente, à redução dos riscos e diminuição dos custos da operação.

- **Previsibilidade de consumo de combustível**

Com base nos dados históricos armazenados no sistema de gestão da empresa e nos modelos matemáticos desenvolvidos, outro fator que pode se prever é o consumo de combustível. Portanto, a previsibilidade deste consumo é importante, visto que esta variável pode representar de 8 a 25% do custo total operacional dos *harvesters* (Leite et al. 2014). Além disso, esta previsibilidade facilita o planejamento do abastecimento das máquinas, sendo realizado nos momentos corretos e com o mínimo de intervenção possível na operação.

- **Correção de erros e falhas momentaneamente**

Outro valor importante entregue por um gêmeo digital são as melhorias na qualidade da operação. Sabe-se que desvios na qualidade da operação se devem aos operadores ou às especificações da máquina (Lopes e Pagnussat, 2017). Esses desvios reduzem a produtividade do corte florestal e das atividades subsequentes, como a extração e transporte florestal, além de gerar perdas econômicas e, por isto, devem ser solucionados. É importante realizar um diagnóstico dos desvios em tempo real, para que a correção seja feita momentaneamente e não haja maiores prejuízos.

- **Novo design do equipamento/máquina**

A obtenção de informações mais detalhadas sobre a máquina e/ou equipamento utilizados na operação de corte florestal pode levar os fornecedores à criação de um design aprimorado.

Além disso, as características e propriedades do ativo trabalhado podem ser avaliadas, comparadas e validadas através de um gêmeo digital sem construir protótipos físicos caros (Tao et al. 2019). Ao executar virtualmente o esquema de design em cenários de produção já conhecidos, a capacidade de produção e todas as funções esperadas da máquina e/ou equipamento podem ser simuladas para verificar se o design atende a todos os requisitos esperados.

No caso da operação de corte florestal com *harvester*, há uma demanda contínua por novas tecnologias e possíveis alterações nas características e

especificações do *harvester* e do cabeçote. Estas alterações são realizadas com o intuito de atingir maior produtividade e qualidade da operação, atreladas a um menor custo de produção.

- **Aumento da produtividade da operação**

O aumento da produtividade irá ocorrer devido a um somatório de vantagens oferecidas pela construção de um gêmeo digital do *harvester* no corte florestal. A partir de uma operação digitalizada, em que a análise dos dados e geração das informações ocorre de maneira mais ágil e eficiente, espera-se ganhos em produtividade e qualidade da operação.

- **Diminuição dos custos de produção**

Por fim, somando-se todas as vantagens proporcionadas pela criação de um gêmeo digital do *harvester* no corte florestal, pode-se afirmar que a utilização desta tecnologia tem a capacidade de diminuir os custos de produção, principalmente pelo fato de identificar, de forma muito rápida, as etapas da produção em que ocorrem gastos desnecessários. Os *softwares* utilizados para a simulação virtual são capazes de apontar mudanças que tornam a operação mais eficiente, o que reduz o custo de produção.

### **3.7. Desafios e perspectivas da aplicação da tecnologia gêmeo digital para o *harvester* no corte florestal**

Antes de considerar como um gêmeo digital cria valor para uma organização, é necessário entender algumas das implicações da construção de um gêmeo digital organizacional. Assim como benefícios, um gêmeo digital também oferece riscos, à medida que aumenta a evidência de que muitas organizações são incapazes de agarrar as oportunidades oferecidas pelos dados (Bean e Davenport, 2019; Tabesh, Mousavidin e Hasani, 2019). Por exemplo, 85% dos projetos relacionados a dados falham enquanto as organizações desconhecem os grandes desafios que acompanham tais projetos (Asay, 2017).

Para a construção de um gêmeo digital do *harvester* na operação de corte florestal mecanizado, surgem diversos desafios, sendo que, seu processo de

construção é multifacetado e não envolve apenas tecnologia, mas representa um processo contínuo de mudar a maneira como uma organização opera. Requer investimentos fundamentais em habilidades de pessoas, projetos, infraestrutura, processos, máquinas, e frequentemente, na limpeza de sistemas digitais existentes (Davenport e Westerman, 2018).

Do ponto de vista da operacionalização da tecnologia, por exemplo, na etapa de transmissão de dados, surge um desafio, que é justamente a conectividade à rede. Diferente de um ambiente industrial, em que, os ativos são fixos e trabalham dentro de um ambiente de fácil monitoramento e controle, o ambiente florestal trabalha com ativos móveis, longe da base administrativa e em ambientes de grau de conectividade baixo (Souza, 2019).

Do ponto de vista humano, é necessário readequar o ensino e a capacitação dos profissionais envolvidos na operação (operadores, mecânicos supervisores, analistas, cientistas de dados, entre outros), preparando-os com habilidades e conhecimento muito diferentes daqueles que até então eram considerados mais valiosos. De encontro a estes fatores comentados anteriormente, Parmar et al. (2019) sugeriram que existem duas principais implicações que precisam ser abordadas para criar com êxito um gêmeo digital, sendo novos desafios organizacionais e novos requisitos de habilidades.

Para a implementação do gêmeo digital e demais ferramentas da Indústria 4.0 em diversas operações, ainda há a necessidade de grandes investimentos (Uriarte et al. 2018), e isto não é diferente na gestão do corte florestal com *harvester*. Porém, sabe-se que este investimento obtém retorno. Um setor digitalizado oferece um enorme potencial econômico, sendo que, somente nas áreas da engenharia mecânica e de instalações, é esperado um aumento cumulativo de produtividade de 30% em 2025 como resultado dos esforços em relação às tecnologias da Indústria 4.0, incluindo o gêmeo digital (Bauer e Ganschar, 2014). Espera-se que estas tecnologias irão criar novas formas que atendam às necessidades existentes e romper a antiga cadeia de valor industrial (Schwab, 2016).

A tecnologia do gêmeo digital tem atraído a atenção da academia e da indústria, sendo que, a Gartner, empresa de consultoria em soluções tecnológicas, classificou

os gêmeos digitais como uma das dez (10) principais tendências tecnológicas com valores estratégicos para os próximos anos. Pesquisas recentes dos gerentes de organização mostraram que gêmeos digitais de objetos físicos estão entrando em uso convencional, com 13% das organizações implementando projetos de IoT (Internet das Coisas) já usando gêmeos digitais e 62% estão em processo de estabelecer o uso de gêmeos digitais (Gartner, 2019). Sendo assim, o setor florestal deve estar atento à esta realidade, pois, o crescimento do setor no futuro começa a partir de uma operação em campo totalmente conectada e digitalizada.

#### 4. CONCLUSÕES

Como base para a gestão digital da operação de corte florestal com *harvester*, comprovou-se a influência de diversas variáveis no desempenho da máquina, sendo relacionadas às características da floresta (volume médio individual, condição do fuste), características do ambiente (inclinação do terreno), especificações e propriedades da máquina (velocidade dos rolos), condições humanas (conhecimento e tempo de experiência do operador), e organização da operação (tipo de intervenção, fornecimento do serviço).

Conhecendo-se as variáveis, identificou-se diferentes opções de coleta automatizada e transmissão dos dados da operação em tempo real, sendo o apontamento eletrônico e coleta através de sensores para a coleta automatizada e comunicação satelital, rádio frequência (LoRa), telefonia móvel (2G/3G/4G/5G), WiFi e sistema de coletores (M2M) opções para transmissão dos dados. A escolha da tecnologia de transmissão de dados depende de diversos fatores, como localização da máquina e custo envolvido, portanto, para cada situação em campo deve-se ter uma solução personalizada.

Como próximo passo, surge a necessidade de gerar informações relevantes através da análise dos dados obtidos. Dito isso, o desenvolvimento deste estudo possibilitou entender que o Power BI pode ser utilizado como ferramenta estratégica para as tomadas de decisão na operação de corte florestal com *harvester*, permitindo superar algumas barreiras da análise tradicional como dados não estruturados e longo período de elaboração de relatórios analíticos.

As informações obtidas permitiram tanto uma análise ampla, assim como pontual, dos indicadores de desempenho (KPI's) da operação, sendo possível devido às mais diversas características e vantagens das ferramentas do Power BI, que permitem: fácil implementação e maneabilidade; integração com diversos sistemas e fontes de dados; agilidade na transformação e modelagem de dados através do Power Query e Power Pivot utilizando a linguagem DAX; interface e visualização intuitiva através das ferramentas do Power View; acompanhamento da localização em tempo real das máquinas através da ferramenta "ArcGis for Maps"; diversidade de utilização;

sistema de publicação dos relatórios através do Power BI Service; atualização automática personalizada a cada situação.

Após as análises descritiva e diagnóstica, surgiu como oportunidade realizar previsões para antecipação de ocorrências na operação de corte florestal mecanizado com *harvester*. Neste sentido, o desenvolvimento deste estudo possibilitou entender que é possível aplicar a tecnologia gêmeo digital na gestão e monitoramento da operação, utilizando diversas ferramentas e tecnologias habilitadoras, podendo citar: *Big Data*, *Business Intelligence*, Internet das Coisas, sensores, computação em nuvem, simulações, entre outras.

O estudo para criação de um gêmeo digital do *harvester* possibilitou a previsão da produtividade através do modelo *Random Forest* baseado em diversas variáveis explicativas e a previsão do abastecimento de combustível e ocorrência de falhas baseado em séries temporais através do modelo de suavização exponencial simples (SESM – *Simple Exponential Smoothing Model*).

A aplicação do conceito de gêmeo digital na gestão do corte florestal mecanizado com *harvester* ofereceu diversos ganhos, como: acompanhamento dos parâmetros da operação em tempo real, substituição de fichas de apontamento manual por eletrônico, correção de erros e falhas momentaneamente, previsibilidade de situações (produtividade, consumo de combustível, manutenção), criação de novo design do equipamento/máquina, aumento da produtividade e diminuição dos custos operacionais.

Porém, o cenário ainda é desafiador, haja visto as diversas dificuldades que podem ser encontradas, tanto operacionais, como a conectividade no campo, assim como humanas, como a falta de experiência e conhecimento do pessoal envolvido para execução das atividades e estratégias para digitalização da operação de corte florestal com *harvester*. Dito isso, ainda é necessário investimento em tecnologias e especialização da mão de obra para alcançar sucesso neste processo, entendendo que o setor florestal deve estar atento à esta realidade, pois, o crescimento do setor no futuro começa a partir de uma operação em campo totalmente conectada e digitalizada.

## 5. RECOMENDAÇÕES E SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestões para trabalhos futuros e complementares no intuito de enriquecer este estudo apresentado, temos:

- Aplicação das ferramentas do software Power BI para análise e gestão dos dados de outras operações florestais.
- Realização de outras análises preditivas, visando a antecipação de outras ocorrências para a operação de corte florestal com *harvester*.
- Criação de um gêmeo digital para outras máquinas de colheita florestal, como *Feller*, *Forwarder* e *Skidder*.

## REFERÊNCIAS

Abreu, A.D. de, Lana, J.A.S. de, Ribeiro, R.N. Aplicação dos conceitos de Floresta 4.0 com a utilização de projeto de telemetria nas atividades de colheita florestal da CENIBRA. Congresso Brasileiro de Instrumentação, Sistemas e Automação, 2019.

Almeida, F. Big Data: Concept, Potentialities and Vulnerabilities. *Emerging Science Journal*, 2(1): 1-10, 2018.

Asay, M. 85% of big data projects fail, but your developers can help yours succeed. TechRepublic. Retrieved from <https://www.techrepublic.com/article/85-of-big-dataprojects-fail-but-your-developers-can-help-yours-succeed/>. 2017.

Au, Regina. To Cloud Compute, or Not to Cloud Compute?. *Innovations in Pharmaceutical Technology*, 32-35, 2016.

Baldwin, T., Bommer, B., Rubin, R. Gerenciando o comportamento organizacional. Rio de Janeiro, Campus, 2015.

Bauer, W.; Ganschar, O. *Industrie 4.0 - Volkswirtschaftliches Potenzial für Deutschland*, BITKOMStudie, 2014.

Bean, R., Davenport, T. H. Companies Are Failing in Their Efforts to Become Data-Driven. *Harvard Business Review Digital Articles*, 2-4, 2019.

Blast. Microsoft Power BI Consulting. Obtido em 10 de 05 de 2020, de Blast: <https://www.blastanalytics.com/power-bi-consulting>, 2019.

Borges, M., Cardozo, C., Filho, O. Dos dados ao conhecimento: Business Intelligence como ferramenta para apoio à tomada de decisão, 2018.

Botkina, D., Hedlind, M., Olsson, B., Henser, J., Lundholm, T. Digital twin of a cutting tool. *Procedia CIRP*, 72: 215-8, 2018.

Brown, R.O., Diniz, C.C.C. Colheita Florestal e Manutenção de Equipamentos Móveis. In: *Semana de Aperfeiçoamento em Engenharia Florestal – SEAFLOR*. Curitiba: UFPR, 01 – 41, 2017.

Brownlee, J. A gentle Introduction to Exponential Smoothing for Time Series Forecasting in Python. Disponível: <https://machinelearningmastery.com/exponential-smoothing-for-time-series-forecasting-in-python/>, 2020.

Burla, E.R. et al. Avaliação técnica e econômica do *harvester* em diferentes condições operacionais. Revista Engenharia Na Agricultura, 20(5): 412-422, 2012.

Cai, Y., Starly, B., Cohen, P., Lee, Y.S. Sensor data and information fusion to construct digital-twins virtual machine tools for cyber-physical manufacturing. Procedia Manuf., 10: 1031-42, 2017.

Campos, F. Serviços Digitais para uma colheita 4.0. Revista Opiniões, 2021. <https://florestal.revistaopinioes.com.br/revista/detalhes/14-servicos-digitais-para-uma-colheita-40/>

Carbone, D. Indústria 4.0 e World Class Manufacturing: punti di contato. Disponível em: Indústria 4.0 e World Class Manufacturing | Smart Factory Blog di NeXT (mynext.it). Castelbellino, Next, 2017.

Carmo, F.C.A., Fiedler, N.C. Minette, L.J., Souza, A.P. Otimização do uso do trator florestal forwarder em função da produtividade, custos e capacidade de carga. Revista Árvore, 39(3): 561-566, 2015.

Chiaradia, A. J. P. Utilização do indicador de eficiência global de equipamentos na gestão e melhoria contínua dos equipamentos: um estudo de caso na indústria automobilística. 2004. 133p. Dissertação Mestrado Profissionalizante em Engenharia – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

Condé, S. A. Biomarcadores fenotípicos para seleção precoce de clones de eucalipto tolerantes à seca de ponteiros associada ao deficit hídrico. Dissertação (mestrado), Universidade Federal de Viçosa, 2019.

Conroe, Z. Simple steps to embed images in Power BI. Disponível: <https://www.bluegranite.com/blog/simple-steps-to-embed-images-in-power-bi>, 2018.

Davenport, T.H., Westerman, G. Why So Many High-Profile Digital Transformations Fail. Harvard Business Review Digital Articles, 2-5, 2018.

Eriksson, M., Lindroos, O. Productivity of harvesters and forwarders in CTL operations in northern Sweden based on large follow-up datasets. *International Journal of Forest Engineering*, 25(3): 179-200, 2014.

Evans, J. R. *Business Analytics: Methods, Models and Decisions*. Pearson, 2016.

Félix, R. Superando desafios da colheita de eucaliptos. *Opiniões*, 12(41): 37-39, 2015.

Ferrari, A., Russo, M. *Introducing Microsoft Power BI*. Microsoft Corporation, 2016.

Filho, L.S.C.C. Fibria investe em tecnologia digital no setor de colheita. [http://www.ciflorestas.com.br/conteudo.php?tit=fibria\\_investe\\_em\\_tecnologia\\_digital\\_no\\_setor\\_de\\_colheita&id=12589](http://www.ciflorestas.com.br/conteudo.php?tit=fibria_investe_em_tecnologia_digital_no_setor_de_colheita&id=12589). 2016.

Gartner Survey Reveals Digital Twins Are Entering Mainstream Use. Acesso: <https://www.gartner.com/en/newsroom/press-releases/2019-02-20-gartner-survey-reveals-digital-twins-are-entering-mai>, 2019.

Gartner. Magic Quadrant for Analytics and Business Intelligence Platforms. Acesso: <https://www.gartner.com/en/documents/3900992/magic-quadrant-for-analytics-and-business-intelligence-p>, 2021.

Glaessgen, E., Stargel, D. The digital twin paradigm for future NASA and US air force vehicles. *Proceedings of the 53rd AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics and Materials Conference 20th AIAA/ASME/AHS Adaptive Structures Conference 14th AIAA*; 23-26, p.1818, 2012.

Grieves, M. *Digital Twin: Manufacturing Excellence through Virtual Factory Replication*, White Paper, 2014.

Grieves, M. *Digital twin: manufacturing excellence through virtual factory replication*. White paper. Melbourne, FL: Florida Institute of Technology, 2014.

Haag, S., Anderl, R. Digital twin – Proof of concept. *Manufacturing Letters*, 15: 64 – 66, 2018.

Häggström, C., Lindroos, O. Human, technology, organization and environment – a human factors perspective on performance in forest harvesting. *International Journal of Forest Engineering*, 27(2): 67-78, 2016.

Harstela, P. The competence of the forest-machine operator and tacit knowledge. In: *The proceedings of development project in forest machine based training*; Joensuu, Finland, 2004.

Hermann, M., Pentek, T. Otto, B. Design Principles for Industrie 4.0 Scenarios: A Literature Review. Working Paper 01, Technische Universität Dortmund, 2015.

Hyndman, R. J., & Athanasopoulos, G. *Forecasting: Principles and Practice*. Disponível em: <https://otexts.com/fpp2/data-methods.html>, 2018.

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

Karpinski, L. *Aprenda Power BI – Torne-se Data Driven*, 2020.

Lacerda, L.C., Fiedler, N.C., Chichorro, J.F., Minette, L.J., Carmo, F. C. de A. do. Analysis of the production capacity from a *harvester* in the forest in own and outsourced modules. *Revista Árvore*, 41(1):410120, 2017.

Leite, E.S., Fernandes, H.C., Minette, L.J., Leite, H.G., Guedes, I.L. Modelagem técnica e de custos do *harvester* no corte de madeira de eucalipto no sistema de toras curtas. *Scientia Forestalis*, 41(98): 205-215, 2013.

Leite, E. S. et al. Desempenho do harvester na colheita de eucalipto em diferentes espaçamentos e declividades. *Revista Árvore*, 38(1): 1-7, 2014.

Lei, S. Design of data acquisition system based on zigbee for wireless sensor networks. *Proceedings of MATEC Web of Conferences* 246, pág. 3036, 2018.

Lennerholt, C., van Laere, J., Söderström, E. Implementation challenges of Self Service Business Intelligence: A literature review. *51st Hawaii International Conference on System Sciences*, USA: IEEE Computer Society, 51: 5055-5063, 2018.

Lopes, E.S., Pagnussat, M.B. Effect of the behavioral profile on operator performance in timber harvesting, *International Journal of Forest Engineering*, 28(3): 134-139, 2017.

Lyon, W. Microsoft Power BI Desktop: A free and user friendly software programme for data visualisations in the Social Sciences. *Historia*, 64: 166-171, 2019.

Machado, C.C. O setor florestal brasileiro. In: Machado, C.C. (Ed.) *Colheita Florestal*, Universidade Federal de Viçosa, 501p., 2014.

Morais, B.C. Sistema integrado de análise e predição de indicadores de desempenho de um processo industrial. Trabalho de Conclusão de Curso – Universidade Federal de Uberlândia – UFU, 91p., 2019.

Nakagawa, M., Hayashi, N., Narushima, T. Effect of tree size on time of each work element and processing productivity using an excavator-based single-grip harvester or processor at a landing. *Journal of Forest Research*, 15(4): 226-233, 2010.

Oliveira, A.J.de. Os segredos de uma colheita florestal. *Revista Opiniões*, 14(47): 6-7, 2017.

Owais, S.S., Hussein, N.S. Extract Five Categories CPIVW from the 9V's Characteristics of the Big Data. (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, 7(3), 2016.

Pagnussat, M.B., Lopes, E.S., Silva, P.C., Diniz, C.C., Watzlawick, L.F. Desempenho de operadores de operadores de diferentes idades no treinamento com simulador virtual *forwarder*. *Enciclopédia Biosfera*, 10: 3842 - 3852, 2014.

Parmar, R., Leiponen, A., Thomas, L.D.W. Building an organizational Digital Twin. *Business Horizons*, 2019.

Pinheiro, S.A.S. Potencialidades do Power BI Desktop na Análise Preditiva. Dissertação - Universidade Católica Portuguesa, Portugal, 122p., 2020.

Powell, B. *Mastering Microsoft Power BI: Expert techniques for effective data analytics and business intelligence*. Packt., 2018.

Purfürst, F.T. Learning curves of harvester operators. *Croatian Journal of Forest Engineering*, 31: 89 - 97, 2010.

Puttock, D., Spinelli, R., Hartsough, B.R. Operational trials of cut-to-length harvesting of poplar in a mixed wood stand. *International Journal of Forest Engineering*, 16: 39-49, 2005.

Qi, Q., Tao, F. Digital twin and big data towards smart manufacturing and industry 4.0: 360-degree comparison. *IEEE* (6): 3585-93, 2018.

Qi, Q., Tao, F., Hu, T., Anwer, N., Liu, A., Wei, Y., Wang, L., Nee, A.Y.C. Enabling technologies and tools for digital twin. *Journal of Manufacturing Systems*, <https://doi.org/10.1016/j.jmsy.2019.10.001>, 2019.

Rasheed, A., San, O., Kvamsdal, T. *Digital Twin: Values, Challenges and Enablers*. 2019.

Raviv, G. *Collect, Combine, and Transform Data Using Power Query in Excel and Power BI*. Microsoft Corporation by: Pearson Education, 368p., 2018.

Ribeiro, R.N., Fernandes, B.R. O impacto do “novo normal” sobre a automação florestal. *Revista Opiniões*, 2021. Disponível em:<https://issuu.com/opinioesbr/docs/opcp62-201222-20h00?fr=sMTY4NjlyMzIzOTk>

Robert, R.C.G, Rocha, M.P. da., Jaeger, D. Análise técnica e econômica de um sistema de colheita mecanizada em plantios de *Eucalyptus* spp. em duas condições de relevo acidentado. Tese (Doutorado em Engenharia Florestal/Ciências Agrárias) – Universidade Federal do Paraná, Curitiba – PR, 2013.

Rodrigues, C.K., Lopes, E.S., Oliveira, D., Sampietro, J.A. Influência do volume das árvores no desempenho do processador florestal harvester em povoamento de Eucalipto. *BIOFIX Scientific Journal*, 3(2): 237-242, 2018.

Rodrigues, B.P., Oliveira, J.T. da S., Rodrigues, V.A., Longue, D. Efeito do distúrbio de crescimento nas variáveis dendrométricas de árvores de *Eucalyptus grandis* x *Eucalyptus urophylla*. IV Congresso Brasileiro de Eucalipto, Salvador - BA, 2019.

Rossit, D.A., Olivera, A., Céspedes, V.V., Broz, D. A Big Data approach to forestry harvesting productivity. *Computers and Electronics in Agriculture*, 161: 29-52, 2019.

Santos, L.N., Fernandes, H.C., Silva, R.M.F., Silva, M.L., Souza, A.P. Evaluation of costs of Harvester in cut and processing of Eucalyptus wood. *Revista Árvore*, 41(5): 1-9, 2017.

Schikowski, A.B. Estimativa do volume e da forma do fuste utilizando técnicas de aprendizado de máquina. Dissertação de Mestrado, Universidade Federal do Paraná, 2016.

Schwab, K. The Fourth Industrial Revolution: what it means, how to respond. World Economic Forum. <https://www.weforum.org/agenda/2016/01/the-fourth-industrialrevolution-what-it-means-and-how-to-respond/>, 2016.

Silva, S.R., Bazani, J.H., Vrechi, A., Gentil, M.S., Zamprogno-Ferreira, K.C., Rosse, L.N. Palestra no “VI Workshop de Melhoramento e XVI Reunião Técnica Científica do Programa Temático de Silvicultura e Manejo – PTSM”. Distúrbios fisiológicos ocasionados pelo estresse hídrico em clones de eucalipto na Veracel: estudo de caso e hipóteses, 2010.

Silva, F. Aplicação de redes neurais artificiais para estimar a produtividade do forwarder na extração de madeira. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, MG, 63p., 2015.

Silva, A.A. Desenvolvimento do indicador de eficiência global de máquinas de colheita florestal (EGMF). Dissertação (Mestrado em Ciência Florestal) - Universidade Federal de Viçosa, Viçosa, 107f. 2017.

Silva, R.A.L.da., Robert, R.C.G. Análise de ferramenta para monitoramento de operações de colheita florestal em tempo real. IUFRO, 2019.

Silva, A.C.P. Perfil de expressão gênica em híbridos de *Eucalyptus grandis* x *Eucalyptus urophylla* afetados pelo distúrbio fisiológico do eucalipto (DFE). Tese (Doutorado - Programa de Pós Graduação em Ciência Florestal), Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, 142p., 2020.

Singh, S., Weeber, M., Birke, K. Advancing digital twin implementation: a toolbox for modelling and simulation. *Procedia CIRP*, v. 99, p. 567-572, 2021.

Sonna, D. Ferramentas de BI: Conheça as ferramentas de BI mais utilizadas no mercado. Disponível: <https://www.sonna.com.br/ferramentas-de-bi-conheca-as-ferramentas-de-bi-mais-utilizadas-no-mercado/>, 2018.

Souza, W. Indústria 4.0: O Futuro Da Manutenção De Maquinas De Colheita Florestal. <https://www.linkedin.com/pulse/ind%C3%BAstria-40-o-futuro-da-manuten%C3%A7%C3%A3o-de-maquinas-colheita-souza/>. 2019.

Spinelli, R., Nati, C. A Low-Investment fully mechanised operation for pure selection thinning of pine plantations. *Croatian Journal of Forest Engineering*, 2(30): 89-97, 2009.

Strandgard, M., Mitchell, R., Acuna, M. General productivity model for single grip harvesters in Australian eucalypt plantations. *Australian Forestry*, 79(2): 108-113, 2014.

Tabesh, P., Mousavidin, E., Hasani, S. Implementing big data strategies: A managerial perspective. *Business Horizons*. doi:<https://doi.org/10.1016/j.bushor.2019.02.001>. 2019.

Tao, F., Zhang, M., Liu, W., Nee, A.Y.C. Digital twin driven prognostics and health management for complex equipment. *CIRP Annals - Manufacturing Technology*: 67, 169-172, 2018.

Tao, F., Liu, W., Zhang, M. Five-dimension digital twin model and its ten applications. *Comput Integr Manuf Syst*, 25(1): 1-18, 2019.

Tao, F., Qi, Q. Make more digital twins. *Nature*, 573: 490-1, 2019.

Tao, F., Liu, W., Zhang, M. Five-dimension digital twin model and its ten applications. *Comput Integr Manuf Syst*, 25(1): 1-18, 2019.

Trindade, C., Jacovine, L.A.G., Rezende, J.L.P., Sartorio, M. L. *Gestão e Controle da Qualidade na Atividade Florestal*. Viçosa: Editora UFV, 2 ed., 273p., 2017.

Tuegel, E.J., Ingrassia, A.R., Eason, T.G., Spottswood, S.M. Reengineering aircraft structural life prediction using a digital twin. *Int J Aerosp Eng*, 1-14, 2011.

Uriarte, A.G.; Ng, A.H.; Moris, M.U. Supporting the lean journey with simulation and optimization in the context of Industry 4.0. *Procedia Manufacturing*, 25: 586–593, 2018.

Viana, H. R. G. *Planejamento e Controle da Manutenção*. Rio de Janeiro, RJ: Qualitymark, 6<sup>a</sup>. ed., 167p., 2014.

Volodina, A., Nagy, G., Köller, O. Success in the first phase of the vocational career: the role of cognitive and scholastic abilities, personality factors, and vocational interests. *J Vocat Behav*, 91: 11 - 22, 2015.

Zhang, F., Johnson, D.M., Wang, J., Yu, C. Cost, energy use and GHG emissions for forest biomass harvesting operations. *Energy*, 114: 1053-1062, 2016.

## ANEXOS

Anexo A – Planilha utilizada para análise de desempenho dos *harvesters* em estudo.

A	B	D	E	G	H	I	J	K	L	M	N
Data	Frota	Máquina	Cabeçote	Descrição da Parada	Tipo de Parada	Produção Apontada	Volume Apont.	Horas	VMI	Prod. (m³/h)	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E			706	143,318	6,9	0,203	20,77072464	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E			0	0	0,4		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E			0	0	0,3		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E			850	172,355	6,8	0,203	25,375	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E			505	102,515	4,8	0,203	21,35729167	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E			0	0	0,6		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E			825	167,475	7,5	0,203	22,33	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E			489	99,267	3,9	0,203	25,45307692	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E			924	187,572	7	0,203	26,796	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E			616	125,048	6,3	0,203	19,84888889	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Inspeção de máquina	O	0	0	0,2		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Troca de material de corte	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Troca de material de corte	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Parada para refeição	R	0	0	1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Exercício Físico	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Troca de turno	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Medição de madeira	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Exercício Físico	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Parada não operacional	O	0	0	0,2		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Troca de material de corte	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Medição de madeira	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Exercício Físico	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Troca de material de corte	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Exercício Físico	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Parada para refeição	R	0	0	0,5		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Exercício Físico	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Troca de material de corte	O	0	0	0,1		0	
28/09/2019	Frota 02	Komatsu PC200-8	Komatsu H370E	Troca de turno	O	0	0	0,1		0	

Anexo B - Planilha utilizada para análise de influência das variáveis no desempenho dos *harvesters* em estudo.

A	B	C	D	E	F	G	H	I	J	K	L
Produtividade (m³/h) Distúrbio		Produtividade (m³/h) Declivoso	Inclinação Terreno Plano	Produtividade (m³/h) Idade Máquina (Anos) 1	5	Produtividade (m³/h) Experiência Operador Até 1 Ano	Mais de 1 Ano	Produtividade (m³/h) Fornecimento Serviço Próprio	Em teste	Terceirizado	
7,21	Não	11,91	20,90	21,36	21,36	7,91	21,36	19,29	5,74	21,36	9,59
8,37		12,51	13,20	14,53	14,53	12,86	14,53	19,67	3,37	14,53	13,78
11,40		12,64	24,65	15,71	15,71	17,51	15,71	16,53	2,97	15,71	13,17
12,17		13,82	34,55	24,91	24,91	16,28	24,91	19,66	18,81	24,91	10,05
14,40		14,09	15,35	17,38	17,38	9,99	17,38	15,97	16,20	17,38	13,47
14,54		14,26	14,62	17,53	17,53	19,33	17,53	19,33	16,44	17,53	11,76
15,98		14,26	11,28	14,64	14,64	15,01	14,64	13,30	13,19	14,64	8,53
16,26		14,28	17,11	15,45	15,45	16,88	15,45	18,34	8,07	15,45	16,76
16,87		14,28	19,41	16,53	16,53	11,04	16,53	15,65	13,36	16,53	11,61
17,03		14,35	11,34	19,29	19,29	17,53	18,98	16,48	14,08	19,29	8,58
11,47		14,40	12,18	19,67	19,67	9,73	18,10	14,28	9,01	19,67	14,00
11,63		14,42	16,96	16,53	16,53	8,83	19,17	11,91	15,25	16,53	12,19
11,91		14,52	18,59	19,66	19,66	8,41	19,03	13,37	15,40	19,66	17,76
12,51		14,53	25,28	15,97	15,97	11,83	19,70	14,54	15,76	15,97	13,98
12,64		14,54	18,52	10,83	10,83	10,62	19,20	20,08	13,04	10,83	9,18
12,88		14,54	17,70	19,33	19,33	15,43	14,65	17,23	8,92	19,33	7,26
12,99		14,60	21,45	13,30	13,30	12,18	12,51	26,78	19,73	13,30	10,04
13,01		14,62	11,34	18,34	18,34	16,57	17,46	16,18	18,89	18,34	11,95
13,08		14,62	6,56	11,63	11,63	18,60	17,34	17,73	19,08	11,63	14,32
13,20		14,63	23,22	15,65	8,41	13,93	13,76	25,17	6,78	5,81	12,85
13,30		14,63	14,40	16,48	9,67	11,23	15,29	24,04	5,32	9,13	8,77
13,37		14,64	16,97	11,47	8,51	11,82	18,38	19,64	7,45	9,29	10,99
13,64		14,65	24,72	14,28	8,98	6,01	13,64	22,61	8,54	7,74	10,23
14,01		14,70	24,00	11,91	15,65	20,09	14,09	19,07	8,27	8,41	11,26
13,62		14,74	15,60	13,37	16,48	20,59	14,74	16,99	5,77	9,67	13,28
11,41		14,80	28,26	14,54	11,47	16,64	15,50	20,17	7,03	8,51	13,49
12,05		14,86	19,73	20,08	14,28	6,97	15,79	18,57	9,63	8,98	12,65

