



IDENTIFICAÇÃO DE CICLOS OPERACIONAIS EM EXPLORAÇÃO DE PEDREIRAS COM RECURSO A SENSORES MEMS PARA OTIMIZAÇÃO DE CARGA E TRANSPORTE

JOSÉ AMARAL LOURENÇO MANUEL

Setembro de 2025

**IDENTIFICAÇÃO DE CICLOS OPERACIONAIS EM EXPLORAÇÃO DE
PEDREIRAS COM RECURSO A SENSORES MEMS PARA
OTIMIZAÇÃO DE CARGA E TRANSPORTE**

**MEMS SENSORS-DRIVEN CYCLE IDENTIFICATION IN QUARRY EXPLOITATION
FOR LOAD-AND-HAUL OPTIMIZATION**

José Amaral Lourenço Manuel

**Dissertação para obtenção do Grau de Mestre em
Engenharia Geotécnica e Geoambiente**

Orientador: Professor João Paulo Meixedo

Júri

Presidente

Helder Gil Iglésias de Oliveira Chaminé, Professor Coordenador com Agregação, Instituto Superior de Engenharia do Porto

Vogais

João Paulo Meixedo dos Santos Silva, Professor Coordenador, Instituto Superior de Engenharia do Porto

Luís Carlos Correia Ramos, Professor Adjunto Convidado, Instituto Superior de Engenharia do Porto

Porto, setembro de 2025

[página propositadamente em branco]

Dedicatória

Dedico esta dissertação aos meus pais, Sá Manuel e Marlene Manuel, que sempre deram tudo de si para que eu me tornasse quem sou hoje. O seu amor, sacrifício e perseverança foram os alicerces da minha caminhada. Apesar de não terem tido a oportunidade de alcançar este grau académico, nunca deixaram que isso fosse uma limitação: pelo contrário, abriram-me o caminho e proporcionaram-me, como primeiro filho, a possibilidade de ser, pelo menos que fique em registo, o primeiro da família a atingir este nível de formação.

Aos meus avós, que permanecem em vida e aos que já partiram, mas que continuam a olhar por mim de onde quer que estejam, deixo a minha eterna gratidão. Neles encontro as raízes e a força que sustentaram cada passo até aqui.

Aos meus irmãos, companheiros desta jornada de vida, dedico também este trabalho, com a esperança de que encontrem nele uma inspiração para perseguirem sempre os seus próprios sonhos. Este trabalho é, em essência, um reflexo do amor, da união e da força que recebi da minha família.

[página propositadamente em branco]

Resumo

Esta dissertação aborda a otimização das operações de carga e transporte em mineração a céu aberto, em particular em pedreiras, por meio da análise de sinais obtidos com sensores microeletromecânicos (MEMS) de smartphones. Propõe-se um fluxo de processamento que integra sincronização temporal entre aceleração e estado do equipamento, limpeza e filtragem de ruído, extração de descritores no domínio do tempo e da frequência com FFT (Transformada rápida de Fourier), e regras de decisão para segmentar automaticamente ciclos e subciclos operacionais. O método identifica estados como deslocamento, paragem, carregamento e descarga, estimando métricas de desempenho como tempo médio de ciclo, número de ciclos por turno e distribuição dos estados. O estudo de caso foi realizado numa pedreira de granito em Portugal com uma escavadora hidráulica e um camião articulado, num conjunto de dados com aproximadamente 663 569 medições a cerca de 51 Hz. Os resultados demonstram a viabilidade de uma instrumentação de baixo custo, não intrusiva e replicável, capaz de aumentar a visibilidade operacional e apoiar decisões de planeamento. Discutem-se limitações práticas, incluindo a sensibilidade à fixação do dispositivo e à variabilidade de padrões de operação, e apresentam-se recomendações para calibração e validação futuras. O trabalho disponibiliza um enquadramento em Python passível de adoção em contextos industriais.

Palavras-chave: Pedreira, mineração, ciclo operacional, acelerómetro, segmentação, carga e transporte

[página propositadamente em branco]

Abstract

This dissertation addresses the optimization of load and haul operations in open-pit mining, particularly in quarries, through signal analysis using smartphone-based MEMS (micro-electromechanical systems) sensors. We propose a processing pipeline that combines time synchronization between acceleration and equipment state, noise cleaning and filtering, feature extraction in both time and frequency domains using the FFT (Fast Fourier Transform), and decision rules to segment operational cycles and sub-cycles automatically. The method detects states such as travel, idle, loading, and dumping, and computes performance metrics including average cycle time, cycle count per shift, and state distribution. The case study was conducted in a Portuguese granite quarry with a hydraulic excavator and an articulated dump truck, using a dataset of approximately 663,569 samples at around 51 Hz. Results demonstrate the feasibility of a low-cost, non-intrusive, and replicable instrumentation approach that enhances operational visibility and supports informed planning decisions. Practical limitations are discussed, namely sensitivity to device mounting and variability of operating patterns, and recommendations are provided for calibration and future validation. The work delivers a Python-based framework suitable for industrial adoption.

Keywords: Quarry, mining, operational cycle, accelerometer, segmentation, load and haul.

[página propositadamente em branco]

Agradecimentos

A realização desta dissertação não seria possível sem o contributo, direto ou indireto, de muitas pessoas e instituições que marcaram o meu percurso.

Em primeiro lugar, agradeço profundamente aos meus pais, Sá Manuel e Marlene Manuel, pelo amor incondicional, pelo sacrifício e pelo apoio incansável em todas as fases da minha vida. Aos meus irmãos, pela companhia e incentivo constantes, deixo também a minha gratidão.

Estendo o meu reconhecimento a todos os docentes que me acompanharam ao longo da formação: desde os tempos no Colégio Júlio Verne, Colégio Emiraís, Complexo Escolar Girassol, no ISPTec, até ao ISEP, tanto na licenciatura como no mestrado. Cada um, de forma voluntária ou não, contribuiu para a minha formação académica e pessoal, moldando quem sou hoje.

Agradeço de forma especial à minha namorada, pelo suporte contínuo e pela presença firme nos momentos de maior exigência. Aos meus parentes e amigos, que sempre desempenharam um papel fundamental na minha vida, agradeço pelo estímulo, pela compreensão e pela motivação para seguir em frente e aspirar a novos horizontes.

Ao meu orientador, Professor João Paulo Meixedo, manifesto sincera gratidão pela orientação, paciência e rigor científico que muito acrescentaram a este trabalho. No lado empresarial, agradeço ao Vinicius Miranda, pela supervisão e proximidade desde o início do projeto e pelo muito que aprendi com a sua experiência. Ao pessoal da O-Pitblast, agradeço pelo ambiente corporativo desafiante e inovador que me permitiu transformar este projeto em realidade académica e profissional.

Por fim, sinto-me realizado por não ter desistido e por persistir na busca dos meus sonhos. Este ciclo representa mais do que uma conquista académica: é também uma vitória interna, a superação de desafios pessoais e a consolidação de uma versão melhor de mim próprio.

[página propositadamente em branco]

Índice

1. ENQUADRAMENTO.....	2
1.1. INTRODUÇÃO	2
1.2. IMPORTÂNCIA DO TEMA	3
1.3. OBJETIVO GERAL E OBJETIVOS ESPECÍFICOS	4
1.4. METODOLOGIA.....	4
1.5. ESTRUTURA DA DISSERTAÇÃO	5
1.6. O-PITBLAST	5
2. ESTADO DE ARTE: BREVE SÍNTESE	9
2.1. A INDÚSTRIA EXTRATIVA E OS CUSTOS OPERACIONAIS	9
2.2. CICLOS OPERACIONAIS	11
2.2.1. <i>Ciclo de Carga</i>	11
2.2.2. <i>Ciclo de Transporte</i>	14
2.3. A RELEVÂNCIA DO CONTROLO DOS TEMPOS DE CICLO	17
2.3.1. <i>Métodos de Controlo de Tempos de Ciclo nas Operações de Carga e Transporte</i>	17
2.3.2. <i>Desafios na Implementação e Eficiência dos Métodos de Controlo</i>	20
2.4. ALGORITMOS E TÉCNICAS DE SEGMENTAÇÃO DE CICLOS PRODUTIVOS	23
2.4.1. <i>Técnicas baseadas em limiares e lógica de eventos</i>	23
2.4.2. <i>Técnicas de processamento de sinais e transformadas</i>	24
2.4.3. <i>Abordagens com algoritmos de aprendizagem automática</i>	24
2.4.4. <i>Uso de dados complementares</i>	25
3. MATERIAIS E METODOLOGIAS.....	29
3.1. EQUIPAMENTOS MONITORIZADOS	29
3.1.1. <i>Escavadora Hidráulica: Caterpillar 336 GC</i>	29
3.1.2. <i>Camiões Articulados: Volvo A40D</i>	30
3.2. SENSORES UTILIZADOS E PARÂMETROS ANALIZADOS	32
3.3. INTRODUÇÃO AO PYTHON PARA ANÁLISE DE DADOS	33
3.4. PRÉ-PROCESSAMENTO DOS DADOS.....	35
4. DESENVOLVIMENTO DO ALGORITMO PARA IDENTIFICAÇÃO DE CICLOS OPERACIONAIS... 39	39
4.1. ESTRUTURA GERAL DO ALGORITMO	39
4.2. VARIÁVEIS DE ENTRADA E PRÉ-PROCESSAMENTO	42
4.2.1. <i>Dados de Aceleração</i>	42
4.2.2. <i>Dados de Estado do Veículo</i>	43
4.2.3. <i>Sincronização Temporal</i>	43
4.2.4. <i>Filtragem e Remoção de Ruído</i>	43
4.2.5. <i>Normalização</i>	44
4.3. ANÁLISE ESPECTRAL DOS SINAIS.....	45
4.4. DETEÇÃO DE ESTADOS OPERACIONAIS	47
4.4.1. <i>Segmentação Movimento/Parado via Velocidade</i>	47
4.4.2. <i>Identificação de Eventos de Carregamento em Paragens</i>	48
4.4.3. <i>Identificação de Eventos de Descarga no Britador</i>	49
4.5. CONSTRUÇÃO DA CRONOLOGIA FINAL	50
4.6. PARÂMETROS, EFICIÊNCIA E LIMITAÇÕES	52
4.6.1. <i>Parâmetros de Calibração do Algoritmo</i>	52
4.6.2. <i>Eficiência e Precisão da Identificação</i>	53
4.7. ENQUADRAMENTO PARA OS RESULTADOS	54
5. ESTUDO DE CASO E APLICAÇÃO DO ALGORITMO	57
5.1. ENQUADRAMENTO GEOGRÁFICO E GEOLÓGICO DA ÁREA DE ESTUDO	57
5.2. CONTEXTUALIZAÇÃO OPERACIONAL DA CAMPANHA DE RECOLHA DE DADOS	59

5.3.	APLICAÇÃO DO ALGORITMO E GERAÇÃO DE CRONOLOGIAS OPERACIONAIS	60
5.3.1.	<i>Reconstrução Cronológica</i>	60
5.3.2.	<i>Duração e Estrutura dos Ciclos</i>	63
5.3.3.	<i>Variações Operacionais</i>	66
5.3.4.	<i>Integração com Dados Espaciais</i>	68
6.	ANÁLISE DE RESULTADOS E CONSIDERAÇÕES FINAIS	72
6.1.	INTERPRETAÇÃO GERAL DOS RESULTADOS OBTIDOS	72
6.2.	EFICIÊNCIA DO ALGORITMO E ROBUSTEZ DAS HEURÍSTICAS	73
6.3.	LIMITAÇÕES DOS DADOS E DESAFIOS DE SEGMENTAÇÃO	74
6.4.	RECOMENDAÇÕES DE MELHORIA E TRABALHOS FUTUROS	75
6.5.	CONCLUSÕES FINAIS	76
7.	REFERÊNCIAS	79

[página propositadamente em branco]

Lista de figuras

Figura 1- Software O-PitSurface.	6
Figura 2 - Conjunto de operações consubstanciadas no processo de produção de agregados, que vão desde o maciço rochoso (georrecurso) até à obtenção de um produto rochoso final (agregado britado). Adaptado de Galiza et al. (2011).....	11
Figura 3 – Esquema de um ciclo de carga da escavadora. Nota. Produzido pelo autor com auxílio de IA (OpenAI, 2025).....	14
Figura 4 - Sequência típica de fases no ciclo de transporte de um camião mineiro. Nota. Produzido pelo autor com auxílio de IA (OpenAI, 2025).....	16
Figura 5 - Ciclo Operacional de métodos baseados em aprendizagem de máquina. Adaptado de: GeeksforGeeks (2025)	25
Figura 6 - Escavadora Hidráulica CAT 336 GC. Fonte: Caterpillar, 2020 (https://www.caterpillar.com)	30
Figura 7 - Camião Articulado Volvo A40D. Fonte: Volvo Construction Equipment, 2025. (https://www.volvoce.com/europe/en).....	30
Figura 8 – Registo operacional: (A)- Fixação de smartphone na caçamba do camião para aquisição de dados. (B) Coleta manual para validação dos ciclos operacionais. (Fotos: J. Manuel, 2025).	31
Figura 9 – Fluxograma do Algoritmo Desenvolvido.	41
Figura 10 - Pseudocódigo do módulo opcional que constrói a série binária 0/1 a partir de picos em <code>yFiltered</code> , calcula a FFT e regista as frequências dominantes (diagnóstico da cadência de pazadas; não usado na classificação).....	46
Figura 11 - Pseudocódigo de Regras de classificação de movimento e paragem com correção de transições e fusão de microparagens.	48
Figura 12 – Localização da Pedreira do Estudo (NW de Portugal).....	57
Figura 13 – Geologia na área de estudo (Adaptado de Folha 09-B – Guimarães, 1986).	58
Figura 14 - Representação inicial dos sinais processados.....	61
Figura 15 - Aceleração filtrada ao longo do tempo, evidenciando os ciclos de carga.	61
Figura 16 - Ciclo individual com identificação das pazadas da escavadora	62
Figura 17 - Diagrama de Gantt de 3 dos ciclos operacionais identificados.....	63
Figura 18 - Comparação entre ciclo curto e ciclo longo (com tempos elevados sem atividade).....	67
Figura 19 - Sobreposição da trajetória do camião monitorizado com variação de velocidade (km/h).	68

[página propositadamente em branco]

Lista de tabelas

Tabela 1 - Comparação entre diferentes métodos de monitorização de tempos de ciclo em operações mineiras.....	20
Tabela 2 - Síntese dos principais desafios na monitorização de ciclos operacionais.....	22
Tabela 3 - Principais parâmetros do algoritmo e valores adotados	53
Tabela 4 - Decomposição dos ciclos operacionais.	64

[página propositadamente em branco]

Capítulo I

Enquadramento

1. Enquadramento

1.1. Introdução

Desde os primórdios da Revolução Industrial, a indústria extrativa molda o curso da humanidade através do fornecimento de matérias-primas essenciais ao desenvolvimento tecnológico e económico. Quando nos referimos ao termo “mineração”, muitos imediatamente pensam em diamantes ou ouro, associando a atividade a uma lógica meramente comercial. Contudo, a mineração é muito mais ampla e profundamente enraizada no quotidiano moderno. O computador utilizado para redigir esta dissertação, o dispositivo em que o leitor a consulta, o automóvel que o transporta diariamente e até os utensílios usados no pequeno-almoço dependem, direta ou indiretamente, da extração de recursos minerais.

Longe de perder relevância, a mineração tornou-se ainda mais indispensável no contexto da transição energética e da digitalização. Tecnologias emergentes, vistas muitas vezes como alternativas à exploração mineral, dependem na verdade de novos recursos extraídos do subsolo. Painéis solares, turbinas eólicas, veículos elétricos e sistemas de armazenamento energético requerem minerais como lítio, cobalto, níquel e terras raras. Este cenário reforça a necessidade não apenas de explorar recursos minerais, mas de o fazer de forma cada vez mais eficiente, sustentável e tecnologicamente avançada.

Entre os métodos existentes, a mineração a céu aberto, realizada em minas e pedreiras, é responsável por uma fatia significativa da produção global. Após a remoção da camada superficial não aproveitável, o processo inicia-se com o desmonte do maciço rochoso, frequentemente por via do uso de explosivos. O material resultante é então carregado por escavadoras e transportado por

camhões até ao britador primário, onde se inicia a fase de processamento. Embora esta sequência pareça simples, a sua execução está longe de o ser: trata-se de um sistema integrado de carga e transporte em que a eficiência depende da coordenação entre equipamentos, da regularidade dos fluxos e da minimização de tempos de espera.

O transporte pode assumir a forma contínua, através de correias transportadoras, ou descontínua, com recurso a frotas de camiões e escavadoras. Este último método, foco desta dissertação, é o mais comum pela sua flexibilidade, mas também aquele em que mais frequentemente se verificam ineficiências. Paragens inesperadas, filas de espera e ciclos de carga mal sincronizados podem representar perdas significativas de produtividade e consumo excessivo de combustível.

Neste contexto, torna-se crucial o desenvolvimento de ferramentas que permitam observar e quantificar de forma precisa o desempenho real das operações. Tecnologias baseadas em sensores de baixo custo, como os sensores microeletromecânicos (MEMS) embutidos em smartphones, abrem caminho a sistemas de monitorização acessíveis e versáteis. Através da recolha de sinais de aceleração e ângulo, complementados por dados de GPS, é possível reconstruir a cronologia dos ciclos operacionais de camiões, segmentando automaticamente as fases de carregamento, transporte, inactividade, descarga e retorno.

Foi neste enquadramento que, com suporte de profissionais mais experientes na O-Pitblast, se desenvolveu um algoritmo capaz de interpretar os dados recolhidos e identificar com precisão os ciclos operacionais em curso. Esta abordagem, para além de melhorar a eficiência e a utilização da frota, contribui também para uma mineração mais sustentável, reduzindo desperdícios e permitindo a otimização dos recursos disponíveis.

Assim, o presente estudo visa demonstrar que a aplicação de algoritmos heurísticos sobre dados obtidos por sensores acessíveis pode constituir uma solução prática e robusta para monitorização e otimização de operações de carga e transporte em pedreiras. A investigação insere-se na procura constante por inovação tecnológica no setor mineiro, conciliando a necessidade de maior produtividade com a crescente exigência por práticas ambientalmente responsáveis

1.2. Importância do Tema

A otimização das operações de carga e transporte na mineração desempenha um papel crucial na eficiência e na sustentabilidade das operações mineiras. Estas operações não apenas representam uma parte significativa dos custos operacionais, mas também têm um impacto direto na produtividade e na rentabilidade das empresas mineradoras.

A pressão global por práticas mais sustentáveis reforça a necessidade de tecnologias de monitorização e análise que permitam identificar estrangulamentos, otimizar a coordenação entre equipamentos e reduzir tempos improdutivos. O tema é, portanto, relevante não apenas em termos técnicos, mas também estratégicos, uma vez que contribui para aumentar a competitividade das empresas e responder às exigências ambientais e sociais que marcam a indústria mineira contemporânea.

1.3. Objetivo Geral e Objetivos Específicos

O objetivo geral desta dissertação é desenvolver e aplicar um algoritmo de segmentação capaz de identificar automaticamente os ciclos operacionais de escavadoras e camiões em pedreiras, utilizando dados de sensores MEMS e GPS.

Objetivos específicos:

- Implementar um sistema de recolha de dados com base em sensores MEMS embutidos em dispositivos móveis;
- Processar e tratar os dados de aceleração, ângulo e GPS, de forma a obter séries temporais limpas e comparáveis;
- Desenvolver um algoritmo heurístico para segmentação automática das fases do ciclo operacional;
- Validar os resultados obtidos com observações empíricas em campo, verificando a coerência temporal e espacial;
- Avaliar as limitações do método e propor recomendações para a sua aplicação em operações reais.

1.4. Metodologia

A metodologia seguida nesta investigação está dividida em várias etapas interligadas:

1. **Revisão da literatura:** estudo das tecnologias de monitorização em mineração, com foco na análise de sinais e nos métodos de segmentação de ciclos produtivos em exploração de pedreiras.
2. **Definição do sistema experimental:** seleção e configuração dos sensores MEMS e recolha de dados com recurso a smartphones em ambiente mineiro.

3. **Pré-processamento dos dados:** limpeza, sincronização e normalização das séries temporais para eliminar ruído e alinhar diferentes fontes.
4. **Desenvolvimento do algoritmo:** implementação de heurísticas para identificar carregamento, transporte, descarga, retorno e períodos de inatividade.
5. **Aplicação em caso de estudo:** teste do algoritmo numa pedreira portuguesa, validando os resultados obtidos.
6. **Análise crítica:** comparação dos tempos médios de ciclo com valores de referência da literatura e discussão de variações operacionais.
7. **Síntese e recomendações:** identificação de limitações, propostas de melhoria e perspetivas para aplicação prática e futura investigação.

1.5. Estrutura da dissertação

A dissertação está organizada da seguinte forma:

- **Capítulo 1 – Introdução:** apresenta o enquadramento, importância, objetivos, metodologia e estrutura do trabalho.
- **Capítulo 2 – Estado da Arte:** revê as operações de carga e transporte em mineração, as tecnologias de monitorização disponíveis e as técnicas de análise de sinais relevantes para o estudo.
- **Capítulo 3 – Materiais e Metodologias:** descreve os equipamentos utilizados, sensores, software, metodologia de tratamento de dados e critérios de segmentação.
- **Capítulo 4 – Desenvolvimento do Algoritmo:** apresenta a lógica heurística desenvolvida e as fases de construção do algoritmo de identificação de ciclos.
- **Capítulo 5 – Estudo de Caso e Aplicação:** aplica o algoritmo a dados recolhidos em pedreira, analisando cronologias, variações operacionais e integração com dados espaciais.
- **Capítulo 6 – Análise de Resultados e Considerações Finais:** interpreta os resultados obtidos, avalia a robustez do algoritmo, reconhece limitações, propõe melhorias e apresenta as conclusões finais.

1.6. O-Pitblast

A O-Pitblast é uma empresa portuguesa fundada em 2016, sediada na cidade do Porto, especializada em soluções avançadas para desmonte eficaz de rochas utilizando explosivos.

Reconhecida internacionalmente, a empresa reúne uma equipe altamente qualificada composta por profissionais das áreas de Engenharia de Minas, de Engenharia Geotécnica, da Estatística e da Matemática aplicada à indústria mineira, com vasta experiência global em desmonte de rochas.

A reputação da O-Pitblast cresceu graças à sua inovação no desenvolvimento de software especializado para planeamento e controlo operações de desmonte de rochas com explosivos. Um desses softwares, o O-PitSurface, permite aos engenheiros e técnicos responsáveis pelo dimensionamento e controlo do diagrama de fogo otimizar todas as etapas do processo de desmonte. Integrando dados de topografia, perfuração, carga e temporização dos furos, o O-PitSurface possibilita simulações avançadas de resultados em um único programa

Com o crescimento contínuo, a empresa introduziu novas ferramentas para melhorar ainda mais o planeamento e controlo das operações. Entre elas estão o O-PitApp para dispositivos móveis Android, o site O-PitAnalytics e o O-Pitdev.

O foco principal desta dissertação é o desenvolvimento de um nova solução para a O-Pitblast, destinado a otimizar as operações de carga e transporte em pedreira e minas a céu aberto.

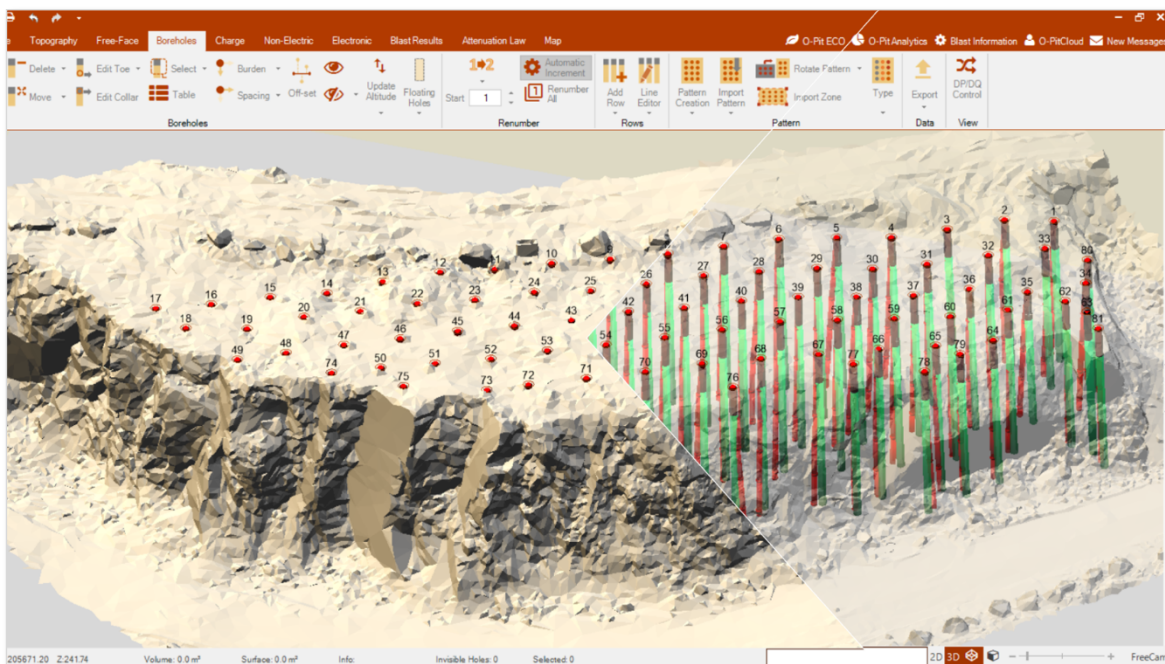


Figura 1- Software O-PitSurface (gentilmente cedido por O-PitBlast).

[página propositadamente em branco]

Capítulo II

Estado de Arte: Breve Síntese

2. Estado de Arte: Breve Síntese

2.1. A Indústria Extrativa e os Custos Operacionais

A indústria extrativa, que abrange a exploração e o processamento de recursos minerais, constitui um pilar fundamental da economia global, fornecendo as matérias-primas indispensáveis para o desenvolvimento de inúmeros setores, desde a construção civil e infraestruturas até à produção de energia, bens de consumo e tecnologias de vanguarda. A sua importância estratégica reside não apenas no valor económico intrínseco dos minerais extraídos, mas também na sua capacidade de impulsionar o crescimento industrial e o progresso tecnológico. Contudo, as operações mineiras, particularmente as realizadas a céu aberto, são empreendimentos de grande complexidade, caracterizados por elevados investimentos de capital e custos operacionais substanciais. Conforme salientado por diversos autores e estudos sectoriais, os custos associados às atividades de carga e transporte de material (minério e estéril) representam, frequentemente, a parcela mais significativa dos custos totais de exploração numa mina a céu aberto. Elijah et al. (2021) destacam que estas operações podem ser responsáveis por mais de 50% dos custos operacionais totais, uma percentagem que sublinha a criticidade da sua gestão eficiente. Trabalhos como os de Leite (1998), ao analisar a transformação de um objeto da indústria extrativa em sistema, e Miranda (1986), ao focar-se nos transportes mineiros, fornecem um enquadramento valioso sobre a magnitude dos desafios logísticos e económicos inerentes à movimentação de grandes volumes de rocha em ambientes mineiros. E, ainda, Meixedo (2005) investiga a dinâmica não-linear de sistemas discretos de carga e transporte. A gestão destes custos é ainda mais complexa devido à natureza dinâmica das frentes de lavra, à variabilidade geológica do material escavado e às longas distâncias de transporte que podem ser necessárias (Both & Dimitrakopoulos, 2020). A otimização contínua destes

processos é, por conseguinte, um imperativo para garantir a viabilidade económica e a competitividade das explorações mineiras num mercado global cada vez mais exigente.

As operações de carga e transporte em mineração a céu aberto são caracterizadas por uma sequência de atividades repetitivas, designadas por ciclos operacionais. Um ciclo operacional pode ser definido como um conjunto de tarefas elementares que se sucedem numa ordem específica e que, uma vez completadas, permitem que o equipamento retorne ao seu estado inicial, pronto para reiniciar a sequência. A análise detalhada destes ciclos e dos seus componentes, os subciclos, é fundamental para a compreensão da dinâmica das operações, a identificação de ineficiências e a implementação de estratégias de otimização. A natureza cíclica destas atividades torna-as particularmente adequadas para estudos de tempos e movimentos e para a aplicação de técnicas de modelação e simulação que visam melhorar a produtividade e reduzir os custos (e.g., Leite, 1998; Miranda, 1986; Meixedo, 2005; Meixedo et al., 2016).

Neste contexto, a Figura 2 ilustra as principais fases do processo produtivo em pedreiras, evidenciando que o ciclo logístico de carga e transporte pode representar aproximadamente 40% dos custos totais, desde a extração do georrecurso até à obtenção do agregado britado. Este dado reforça a importância económica da sua otimização, tornando imprescindível a adoção de abordagens integradas e eficientes na gestão operacional.



Figura 2 - Conjunto de operações consubstanciadas no processo de produção de agregados, que vão desde o maciço rochoso (georrecurso) até à obtenção de um produto rochoso final (agregado britado). Adaptado de Galiza et al. (2011)

Os ciclos operacionais dos equipamentos de carga e dos equipamentos de transporte são interdependentes e o seu desempenho conjunto dita, em grande medida, a eficiência global do sistema de movimentação de materiais. A sincronização inadequada entre estes equipamentos pode levar a tempos de espera excessivos, subutilização de capacidade e, conseqüentemente, a um aumento dos custos unitários de produção. Estudos como os de Meixedo et al. (2016), de Both & Dimitrakopoulos (2020) e de Elijah et al. (2021) enfatizam a importância de uma abordagem sistémica na análise e otimização destes ciclos, considerando as interações e as variabilidades inerentes aos processos. A identificação precisa da duração de cada subciclo e a compreensão dos fatores que a influenciam são passos cruciais para qualquer iniciativa de melhoria contínua nestas operações

2.2. Ciclos Operacionais

2.2.1. Ciclo de Carga

O ciclo de carga, executado por equipamentos como escavadoras hidráulicas ou pás carregadoras de rodas, é uma componente crítica do sistema de produção mineiro, ditando o ritmo de

alimentação dos caminhões de transporte. Este ciclo é tipicamente decomposto em várias fases ou subciclos elementares, cuja duração e eficiência são influenciadas por uma miríade de fatores. De acordo com a literatura técnica (e.g., Leite, 1998; Miranda, 1986; Meixedo, 2005; Meixedo et al., 2016) e observações de campo, um ciclo de carga típico de uma escavadora pode ser descrito da seguinte forma:

1. **Posicionamento da Escavadora e/ou da Colher (Manobra):** Esta fase inicial envolve o movimento da escavadora ou apenas do seu braço e colher para alcançar a frente de desmonte ou a pilha de material a ser carregado. Inclui o ajuste da posição do equipamento para otimizar o ângulo de ataque e a profundidade de escavação. A duração desta fase depende da distância a percorrer, da topografia do terreno e da habilidade do operador em posicionar a máquina eficientemente.
2. **Escavação e Enchimento da Colher (Cavar/Encher):** Corresponde à penetração da colher no material desmontado (ou no banco, em caso de escavação direta) e ao seu enchimento até à capacidade nominal ou ótima. A dificuldade e o tempo desta fase são fortemente influenciados pelas características geomecânicas do material (granulometria, coesão, abrasividade, presença de blocos), pela potência e estado de conservação da escavadora (e.g., desgaste dos dentes da colher), e pela técnica de escavação empregue pelo operador.
3. **Rotação/Elevação com Carga:** Após o enchimento da colher, a superestrutura da escavadora (ou o braço, no caso de pás carregadoras) roda e/ou eleva a colher carregada desde a frente de escavação até à posição de descarga sobre o caminhão. A velocidade de rotação e elevação, o ângulo de giro necessário e a altura de descarga são fatores determinantes para a duração desta fase. A estabilidade do equipamento e a visibilidade do operador também desempenham um papel importante.
4. **Descarga no Camião:** Nesta fase, o operador manobra a colher sobre a caçamba do caminhão e procede à descarga do material. O tempo de descarga depende do tipo de material (pegajoso ou de fluxo livre), do mecanismo de abertura da colher e da perícia do operador em distribuir a carga uniformemente na caçamba do caminhão, minimizando derrames e otimizando o fator de enchimento do caminhão.
5. **Rotação/Descida sem Carga (Giro Vazio):** Após a descarga, a escavadora roda e/ou baixa a colher vazia de volta à posição inicial, preparando-se para o próximo ciclo de escavação. A eficiência desta manobra contribui para a redução do tempo total do ciclo.

Cada um dos subciclos descritos contribui de forma cumulativa para o tempo total do ciclo operacional da escavadora. O objetivo primordial em condições de operação eficientes é manter a escavadora em funcionamento contínuo, reduzindo ao mínimo os períodos de inatividade. A coordenação entre a frente de carga e a frota de transporte assume, assim, um papel determinante na produtividade global do sistema. Idealmente, quando a escavadora conclui o enchimento de um caminhão e se prepara para descarregar a última carga, um novo caminhão já deverá encontrar-se posicionado, pronto para iniciar a carga seguinte. Esta sincronização garante a utilização plena da capacidade da escavadora, que é tipicamente o equipamento de maior custo e importância estratégica no ciclo produtivo.

Quando esta condição não é satisfeita, emergem duas formas de ineficiência amplamente documentadas na literatura. A primeira corresponde ao chamado *shovel hang time*, ou seja, o período em que a escavadora permanece parada por ausência de caminhão disponível para ser carregado. Nestas situações, a máquina encontra-se operacionalmente apta, mas a indisponibilidade de transporte interrompe a continuidade do processo, originando perdas de produção e aumento do custo unitário por tonelada movimentada. Em operações de grande escala, mesmo curtos períodos de *hang time* podem representar centenas de toneladas não movimentadas e impactar significativamente a cadência da lavra.

Por outro lado, verifica-se também o problema inverso: o tempo de espera do caminhão junto à escavadora. Este ocorre quando a escavadora ainda se encontra a concluir o carregamento de outro caminhão ou está temporariamente inativa devido a pequenas interrupções operacionais (ajustes de posição, inspeções rápidas, pausas do operador). Nestes casos, o caminhão encontra-se imobilizado, consumindo combustível sem realizar transporte e contribuindo para a formação de filas na frente de carga. Este tempo de espera traduz-se igualmente em perdas de eficiência, uma vez que o investimento realizado na frota de transporte não se converte em toneladas efetivamente deslocadas.

A análise integrada destes dois fenômenos evidencia a necessidade de um dimensionamento e planejamento adequados da frota. Poucos caminhões resultam em excesso de *shovel hang time*; demasiados caminhões levam a longos tempos de espera. O equilíbrio ótimo é atingido quando a cadência de chegada dos caminhões está ajustada ao ritmo de carregamento da escavadora, garantindo que ambos os recursos operam próximos do seu potencial máximo. Esta relação dinâmica constitui um dos principais focos da engenharia de minas aplicada à gestão de operações de carga e transporte, sendo alvo frequente de simulações e estudos de otimização destinados a maximizar a produtividade e a reduzir custos.




Figura 3 – Esquema de um ciclo de carga da escavadora. Nota. Produzido pelo autor com auxílio de IA (OpenAI, 2025)

Do ponto de vista mecânico, estudos do ciclo em questão mostram que os movimentos de uma escavadora são altamente repetitivos e passíveis de otimização. Por exemplo, ajustar o ângulo de penetração da caçamba e a trajetória de rotação pode reduzir esforços desnecessários e economizar segundos preciosos a cada ciclo. Pequenas economias por ciclo, multiplicadas pelo número de ciclos ao longo de um turno, resultam em aumentos notáveis de produção diária.

2.2.2. Ciclo de Transporte

O ciclo de transporte, efetuado por caminhões mineiros de grande porte, é a operação subsequente ao carga e visa a movimentação do material (minério ou estéril) desde a frente de lavra até aos respetivos destinos, que podem ser o britador primário, as pilhas de stock de minério, ou as escombrelas de estéril. Este ciclo é igualmente composto por um conjunto de fases distintas, cuja duração e eficiência são cruciais para o desempenho global da mina (Leite, 1998; Miranda, 1986; Meixedo, 2005; Meixedo et al., 2016). As principais fases do ciclo de transporte de um caminhão mineiro são:

1. **Espera para Carga:** Esta fase compreende o tempo que o caminhão despense na fila de espera junto à escavadora ou pá carregadora, aguardando a sua vez para ser carregado. A duração desta espera é um indicador chave da sincronização entre as frotas de carga e transporte e pode ser significativamente afetada por desequilíbrios no número de equipamentos, variabilidade nos tempos de ciclo da escavadora, ou interrupções não planeadas.

2. **Manobra e Posicionamento para Carga:** Esta fase compreende as manobras do caminhão para se alinhar corretamente junto ao equipamento de carga. A sua duração depende da perícia do operador e das condições do piso, podendo afetar diretamente a fluidez do processo de carregamento.
3. **Carga:** Corresponde ao tempo durante o qual o caminhão está a ser efetivamente carregado pela escavadora. A duração desta fase depende do número de passadas (baldes/colheradas) da escavadora necessárias para encher a caçamba do caminhão, da capacidade da colher da escavadora, do tipo de material e da eficiência da operação de descarga da escavadora.
4. **Transporte com Carga:** Após a carga completo, o caminhão inicia o percurso desde a frente de lavra até ao ponto de descarga designado. A duração desta fase é a mais variável do ciclo, dependendo criticamente de fatores como a distância de transporte, a velocidade média do caminhão (influenciada pela potência do motor, carga transportada, inclinação e condições das vias de transporte, rampas, curvas, qualidade do piso), e eventuais constrangimentos de tráfego ou interferências com outros veículos.
5. **Manobra e Posicionamento para Descarga:** Ao chegar ao destino, o caminhão realiza as manobras necessárias para se posicionar corretamente na área de descarga. Esta fase pode envolver manobras de marcha-atrás e requer precisão por parte do operador.
6. **Descarga:** Consiste no tempo necessário para o caminhão bascular a sua caçamba e descarregar completamente o material. A duração da descarga pode variar com o tipo de material (materiais pegajosos podem demorar mais a deslizar) e com o mecanismo de basculamento do caminhão.
7. **Transporte Vazio (Retorno):** Após a descarga, o caminhão inicia o percurso de retorno, vazio, desde o ponto de descarga até à frente de lavra para iniciar um novo ciclo. Tal como no transporte com carga, a duração desta fase depende da distância, das condições das vias e da velocidade do caminhão, que geralmente é superior quando está vazio.

Tal como no caso das escavadoras, tempos de ciclo dos caminhões são indicadores-chave de desempenho. A literatura clássica define o tempo de ciclo de um caminhão como o tempo necessário para completar todas as etapas acima mencionadas e voltar ao ponto inicial. Isso inclui tempos produtivos (carregar, transportar, descarregar) e improdutivos (esperas e eventuais atrasos não programados). Um tempo de ciclo médio menor significa maior número de viagens por turno por caminhão, o que, para uma dada distância e carga, incrementa a produção. Por conseguinte, muitas iniciativas de eficiência focam-se em reduzir componentes do tempo de ciclo: melhorando estradas

para aumentar velocidades seguras, implementando sistemas de despacho dinâmico para direcionar camiões a frentes sem fila, treinando operadores para reduzir tempos de manobra, etc.




Figura 4 - Sequência típica de fases no ciclo de transporte de um camião mineiro. Nota. Produzido pelo autor com auxílio de IA (OpenAI, 2025)

Um desafio específico nos ciclos de transporte reside nas diversas fontes de variabilidade operacional. Entre os principais fatores destacam-se o tráfego nas vias internas da mina, onde é comum que camiões fiquem retidos atrás de outros veículos em rampas de inclinação acentuada, as condições meteorológicas adversas, como chuva intensa ou lama que provocam a redução da velocidade de deslocação, e ainda interrupções operacionais pontuais, como paragens para verificações de segurança, necessidade de cruzamento com outros equipamentos ou pequenas manobras imprevistas ao longo do percurso. Estas variabilidades fazem com que, mesmo sob condições de planeamento considerado ótimo, os tempos de ciclo não se mantenham constantes. Em vez disso, seguem distribuições estatísticas, frequentemente aproximadas a distribuições lognormais ou exponenciais, conforme evidenciado em estudos de simulação operacional. Esta natureza estocástica foi aprofundada por investigadores portugueses, como Meixedo (2005), que ao modelar a dinâmica dos sistemas de carga e transporte identificou padrões de comportamento não linear e, em alguns casos, tendências caóticas nas durações dos ciclos e nas interações entre equipamentos. Na prática, isto significa que pequenas perturbações, como um ligeiro atraso na chegada de um camião, podem propagar-se e amplificar-se ao longo do sistema, gerando flutuações imprevisíveis na produtividade instantânea.

Pode-se afirmar, portanto, que o ciclo de transporte do camião concentra uma parcela significativa tanto dos custos como do tempo total da operação mineira. A monitorização detalhada de cada fase do ciclo, preferencialmente através de sistemas de registo automático, é fundamental para

identificar os principais pontos críticos, como tempos excessivos de espera ou deslocação, e, a partir dessa análise, implementar medidas concretas de otimização.

2.3. A Relevância do Controlo dos Tempos de Ciclo

O controlo rigoroso e a minimização dos tempos de ciclo nas operações de carga e transporte são de importância crítica para a produtividade global, a eficiência operacional e a rentabilidade de uma exploração mineira. Dada a elevada proporção que estas operações representam nos custos totais, qualquer redução nos tempos de ciclo, por menor que seja, pode traduzir-se em economias substanciais e num aumento significativo da produção ao longo do tempo. A variabilidade excessiva nos tempos de ciclo e a ocorrência frequente de tempos de espera não produtivos são dos principais entraves à otimização, gerando estrangulamentos, subutilização de equipamentos e um aumento do custo unitário por tonelada movimentada (Elijah et al., 2021).

A relevância do controlo dos tempos de ciclo reside em múltiplos aspetos. Primeiramente, permite uma melhor correspondência entre a capacidade de carga e a capacidade de transporte, minimizando as filas de espera de camiões junto às escavadoras ou, inversamente, a ociosidade das escavadoras por falta de camiões disponíveis. Em segundo lugar, um conhecimento preciso dos tempos de ciclo reais, em detrimento de estimativas ou valores teóricos, possibilita um planeamento de produção mais realista e a definição de metas alcançáveis. Terceiro, a monitorização contínua dos tempos de ciclo permite a deteção precoce de desvios ou problemas operacionais, como avarias em equipamentos, deterioração das condições das vias de transporte, ou práticas de trabalho ineficientes, possibilitando a tomada de ações corretivas em tempo útil. Finalmente, a análise histórica dos tempos de ciclo e dos fatores que os influenciam fornece uma base de dados valiosa para a simulação de cenários de melhoria, a avaliação do impacto de novas tecnologias ou métodos de trabalho, e a tomada de decisões estratégicas relativas ao dimensionamento de frotas e à configuração das operações.

Diversos estudos têm demonstrado os benefícios tangíveis da otimização dos tempos de ciclo. Elijah et al. (2021), por exemplo, aplicam a teoria das filas para otimizar o sistema pá-camião, mostrando como a redução dos tempos de espera e a melhoria da sincronização podem levar a ganhos de produtividade significativos. A capacidade de identificar e quantificar cada componente do ciclo operacional é, portanto, o primeiro passo para desbloquear este potencial de otimização e alcançar uma operação mineira mais eficiente e competitiva.

2.3.1. Métodos de Controlo de Tempos de Ciclo nas Operações de Carga e Transporte

E como se medem os tempos de ciclo? A monitorização dos tempos de ciclo em operações mineiras evoluiu ao longo do tempo, refletindo avanços tecnológicos e as necessidades práticas das explorações. Historicamente, diferentes métodos foram adotados, podendo ser agrupados em três grandes categorias: a monitorização manual, os sistemas eletrónicos de gestão de frotas (FMS) e as abordagens baseadas em sensores embarcados ou distribuídos.

O método mais tradicional consiste na observação direta em campo. Neste modelo, engenheiros ou técnicos registam manualmente as etapas dos ciclos através de cronometragens simples, utilizando relógios ou cronómetros para medir a duração de atividades como o tempo de deslocação entre pontos predefinidos ou o número de passos necessários para carregar um camião. Registos manuais em folhas de campo ou comunicações por rádio também são comuns, como quando o operador reporta verbalmente eventos relevantes, por exemplo, “camião X carregado às 10:32”. Apesar da sua simplicidade e baixo custo, este método apresenta limitações evidentes. A quantidade de ciclos que um técnico consegue acompanhar é reduzida e os registos estão sujeitos a lapsos, esquecimentos e erros de leitura. Além disso, como se baseia em amostragem descontínua, oferece apenas uma visão parcial do desempenho operacional. Ainda assim, foi este o método responsável por sustentar grande parte dos estudos clássicos em engenharia mineira, servindo como base para o desenvolvimento das primeiras teorias de dimensionamento de frotas e estimativas de produtividade ao longo do século XX.

A partir dos anos 2000, a generalização da computação móvel e das redes sem fios promoveu a adoção dos sistemas eletrónicos de gestão de frotas. Estas soluções, conhecidas como FMS (*Fleet Management Systems*), são frequentemente disponibilizadas pelos próprios fabricantes de equipamentos, com exemplos notórios como o Modular Dispatch, o Caterpillar MineStar (VIMS), o Komatsu KOMTRAX ou o Wenco FleetControl. Nestes casos, cada equipamento é equipado com um computador de bordo, GPS e um conjunto de sensores que comunicam em tempo real com uma central de despacho. Eventos operacionais, como a carga ou a descarga, são identificados automaticamente através da leitura de variáveis como pressão hidráulica, aceleração ou inclinação do chassis. Desta forma, o sistema regista informações detalhadas com precisão temporal, incluindo o instante exato em que o camião iniciou a carga, terminou, chegou ao britador, descarregou e retornou ao ponto de carga. O resultado é uma monitorização contínua, precisa e praticamente em tempo real.

Os sistemas de gestão de frotas oferecem múltiplas vantagens. Permitem o rastreio completo das operações, geram relatórios automáticos de produtividade, identificam paragens prolongadas e auxiliam na tomada de decisão operacional. Empresas como a APS, a Wenco e outras especializadas

oferecem versões completas destas plataformas, incluindo interfaces tácteis para os operadores e funcionalidades que eliminam por completo o recurso a registos em papel. Contudo, apesar da sua eficácia operacional, a adoção destes sistemas envolve custos significativos. O investimento inicial inclui o fornecimento e instalação de hardware especializado em cada equipamento, licenciamento do software, infraestrutura de comunicação e formação dos operadores. Este conjunto de requisitos torna o FMS pouco acessível para operações de pequena e média escala, sobretudo em ambientes com restrições orçamentais ou limitações infraestruturais. Adicionalmente, a maioria das soluções comerciais apresenta carácter proprietário, o que implica dependência tecnológica para atualizações e manutenções futuras.

Em alternativa aos métodos anteriores, destaca-se uma abordagem emergente com potencial para democratizar a monitorização de ciclos. Com o avanço da miniaturização dos sensores e a popularização de dispositivos móveis robustecidos, tornou-se possível utilizar smartphones, tablets ou sensores individuais para recolher dados diretamente nas máquinas. A premissa é simples: as atividades operacionais geram “assinaturas” detetáveis nos sinais de aceleração, inclinação ou vibração captados pelos dispositivos. A aceleração durante a marcha, o impacto durante a descarga ou o padrão vibratório durante a escavação refletem-se em variações identificáveis nos sensores.

Estudos recentes validaram a aplicabilidade desta abordagem. Mathur et al. (2015) instalaram um smartphone numa escavadora hidráulica e, através de algoritmos de aprendizagem automática, conseguiram identificar automaticamente as fases do ciclo operacional, incluindo movimentos específicos como a rotação da torre e a movimentação da lança, com mais de 70% de precisão. Dewangan et al. (2024) desenvolveram metodologias semelhantes aplicadas a camiões de transporte, utilizando redes neurais convolucionais para distinguir automaticamente entre deslocação, carregamento e descarga, correlacionando estes eventos com atrasos operacionais e variações de produtividade.

Estas soluções baseadas em sensores acessíveis oferecem diversas vantagens. A implementação é simples, não requer alterações no sistema original da máquina e permite um grau elevado de flexibilidade e personalização por parte da própria equipa da mina. Em muitos casos, a simples instalação de um smartphone fixado ao banco do operador já é suficiente para recolher dados úteis. Porém, existem desafios associados, principalmente relacionados com a calibração dos sensores, a filtragem do ruído inerente aos dispositivos de baixo custo e a gestão de grandes volumes de dados em operações contínuas. Outro desafio relevante consiste na necessidade de desenvolver algoritmos robustos, capazes de minimizar falsos positivos e interpretar corretamente os sinais em ambientes operacionais dinâmicos.

A Tabela 1 sintetiza as principais características dos métodos de monitorização de tempos de ciclo, reunindo as respetivas vantagens e limitações em função dos recursos requeridos e da precisão obtida. Esta comparação facilita a identificação da solução mais adequada a cada realidade operacional, permitindo equilibrar custos, complexidade de implementação e nível de detalhe pretendido.

Tabela 1 - Comparação entre diferentes métodos de monitorização de tempos de ciclo em operações mineiras.

Método	Vantagens	Desvantagens
Cronometragem Manual	Simplicidade, baixo custo inicial.	Mão-de-obra intensiva, sujeito a erros humanos, amostragem limitada (não contínuo).
Registo por Operadores	Aproveita presença dos operadores. barato.	Dados muitas vezes imprecisos ou incompletos, depende da disciplina/ relatório do operador.
FMS Comercial (Dispatch)	Automático e em tempo real; integração com gestão; alta precisão	Custo de implementação e manutenção elevado, requer infraestrutura (GPS, rede), dependência de fornecedor.
Sistemas Customizados (sensores)	Custo relativamente baixo, flexível/adaptável; possível integrar sensores de baixo custo (smartphones, acelerómetros).	Necessita desenvolvimento/validação interna; robustez e calibração dos sensores podem ser limitantes; desafios de processamento de dados brutos.

No âmbito da presente investigação, o foco incide sobre a quarta abordagem, nomeadamente o uso de sensores acessíveis, com particular atenção aos acelerómetros. Esta estratégia apresenta-se como uma solução pragmática e economicamente viável, capaz de expandir o acesso à monitorização contínua de tempos de ciclo, mesmo em contextos de operação onde a adoção de FMS comerciais não é possível. Com o correto tratamento de dados e o desenvolvimento de algoritmos adequados, é possível criar uma base objetiva de informação que apoie a tomada de decisão operacional e promova melhorias progressivas de eficiência na movimentação de materiais.

2.3.2. Desafios na Implementação e Eficiência dos Métodos de Controlo

Apesar dos avanços tecnológicos verificados nos últimos anos, é imprescindível adotar uma perspetiva crítica sobre as limitações associadas à monitorização de ciclos operacionais em ambientes mineiros.

Um dos principais constrangimentos relaciona-se com o investimento necessário e o retorno económico expectável. A adoção de soluções automatizadas, sejam elas baseadas em sistemas comerciais de gestão de frotas (FMS) ou em sensores customizados, implica custos relevantes de aquisição, instalação e manutenção. Em operações de pequena escala, o ganho marginal obtido com a automatização pode não justificar o investimento inicial, conduzindo a uma preferência por métodos convencionais baseados em observação direta ou coordenação por rádio. Por oposição, explorações mineiras de maior envergadura evidenciam frequentemente retornos positivos após alguns anos de implementação, com benefícios claros em termos de eficiência operacional e redução de custos unitários. Torna-se assim fundamental adaptar a tecnologia à realidade específica da mina, considerando a escala, o volume de produção e as prioridades estratégicas.

As condições ambientais características das minas constituem um desafio adicional incontornável. A presença de poeiras finas com elevado teor condutivo, vibrações constantes durante o funcionamento das máquinas e variações extremas de temperatura comprometem a durabilidade e a fiabilidade de equipamentos eletrónicos. Os sistemas comerciais FMS mitigam parte destes efeitos através do uso de hardware com especificações industriais robustas. Já os sensores MEMS, como os integrados em smartphones, foram desenhados para ambientes menos agressivos e podem apresentar limitações significativas no longo prazo (Kim et al., 2022). Persistem incertezas consideráveis sobre a capacidade destes dispositivos operarem de forma estável em ambientes de alta trepidação e oscilações térmicas típicas de operações a céu aberto.

A qualidade dos dados recolhidos emerge igualmente como fator crítico. Sensores MEMS apresentam erros determinísticos, como desvios de escala e offset, e erros estocásticos, incluindo ruído branco e *drift*, afetando diretamente a precisão dos registos (Kim et al., 2022). Para garantir a fiabilidade da informação é necessária uma calibragem rigorosa, que pode ser alcançada através da comparação com posições conhecidas ou pela aplicação de filtros estatísticos, como o filtro de Kalman. A ausência de calibragem adequada resulta frequentemente em leituras erróneas, onde pequenos desvios de offset podem levar a interpretações incorretas do estado operacional.

Outro desafio prende-se com a diferenciação entre eventos operacionais. Enquanto certos momentos, como a descarga do camião, são expectáveis de gerar padrões vibratórios característicos e em teoria facilmente identificáveis, outros intervalos, como o tempo de deslocação em velocidade reduzida ou o tempo de espera, podem apresentar assinaturas muito semelhantes no sinal acelerométrico. Essa dificuldade exige abordagens complementares, muitas vezes combinando sensores de diferentes naturezas, como acelerómetros e módulos de posicionamento por GPS (Dewangan et al., 2024). No entanto, o próprio sinal GPS apresenta

limitações, sobretudo em ambientes com obstrução da linha de visão aos satélites, como em zonas de lavra profundas ou áreas subterrâneas.

A integração dos sistemas de monitorização com as plataformas legadas de cada mina representa outro obstáculo prático. Muitas explorações já utilizam soluções básicas de telemetria, e a introdução de novos sensores pode resultar em redundância de informação ou em fragmentação dos fluxos de dados. A coexistência de múltiplas interfaces aumenta a complexidade operacional e pode ser mal recebida pelas equipas técnicas. Assim, a integração eficiente deve priorizar a compatibilidade com os sistemas existentes, recorrendo a dashboards unificados, protocolos abertos e formatos de exportação comuns às ferramentas de gestão da mina (Hustrulid et al., 2013).

Para além das limitações técnicas, existem desafios humanos e organizacionais que não devem ser subestimados. A introdução de monitorização contínua pode ser interpretada como uma ferramenta de controlo, gerando resistências, sobretudo em ambientes onde predomina uma cultura operacional baseada em experiência empírica. Operadores podem manifestar reservas quanto ao uso dos dados recolhidos, temendo consequências em termos de avaliações de desempenho ou possíveis reduções de pessoal (Baiden et al., 2014). A eficácia da adoção tecnológica depende, em grande medida, da sensibilização e formação prévia das equipas envolvidas, promovendo uma transição gradual para uma cultura orientada por dados.

Finalmente, a segurança digital e a privacidade dos dados constituem preocupações transversais. Em operações onde são utilizados dispositivos pessoais, ou em casos onde as localizações exatas da frota são registadas, emergem riscos associados à cibersegurança. A adoção de arquiteturas de rede seguras, com sistemas isolados da internet pública e a implementação de protocolos de comunicação cifrada, são elementos fundamentais para garantir a integridade da informação sensível (Kim et al., 2022).

Em síntese, a monitorização inteligente dos ciclos operacionais revela um elevado potencial de ganhos operacionais, mas enfrenta barreiras relevantes de natureza técnica, económica e organizacional. A mitigação destes desafios requer uma seleção criteriosa das ferramentas tecnológicas, o desenvolvimento de metodologias adequadas para o processamento dos dados e uma abordagem participativa junto das equipas operacionais, elementos que serão aprofundados nos capítulos seguintes.

Tabela 2 - Síntese dos principais desafios na monitorização de ciclos operacionais.

Desafio	Descrição	Implicações
---------	-----------	-------------

Custos e ROI	Investimento inicial elevado em sistemas automatizados	Nem todas as minas justificam o custo; solução deve ser dimensionada
Ambiente Mineiro Hostil	Poeiras, vibração, temperaturas extremas afetam sensores e equipamentos	Pode comprometer durabilidade e confiabilidade
Qualidade e Calibração dos Dados	Ruídos e desvios em sensores MEMS exigem filtros e calibragem	Dados incorretos levam a interpretações erradas
Diferenciação de Eventos	Eventos similares no sinal acelerométrico podem dificultar a segmentação	Pode exigir múltiplos sensores e algoritmos mais sofisticados
Integração com Sistemas Existentes	Dificuldade em combinar novos sensores com infraestruturas legadas	Requer dashboards unificados e exportação compatível
Limitações Humanas e Organizacionais	Resistência cultural, falta de formação ou receios sindicais	Necessidade de envolvimento e treino contínuo
Segurança de Dados e Privacidade	Riscos associados ao uso de dispositivos pessoais ou exposição de dados sensíveis	Exige redes seguras, controlo de acesso e protocolos apropriados

2.4. Algoritmos e técnicas de segmentação de ciclos produtivos

A crescente disponibilidade de dados provenientes de sensores embarcados em equipamentos mineiros tem impulsionado o desenvolvimento de algoritmos especializados para segmentação automática dos ciclos produtivos. Estes algoritmos visam identificar, com precisão e de forma automatizada, as etapas constituintes do ciclo operacional, tais com a carga, deslocamento carregado, descarga e retorno vazio (Krot et al., 2020; Gawelski et al., 2021). A segmentação eficiente destes ciclos é fundamental para a obtenção de indicadores-chave de desempenho (KPIs), reduzindo a dependência de apontamentos manuais, que frequentemente são sujeitos a erros humanos (Skoczylas et al., 2023).

2.4.1. Técnicas baseadas em limiares e lógica de eventos

Os métodos mais clássicos e amplamente utilizados para segmentação de ciclos produtivos baseiam-se em regras determinísticas, por meio da definição de limiares (thresholds) e condições lógicas associadas a variáveis monitorizadas (Krot et al., 2020). Estes métodos partem do princípio de que certos parâmetros operacionais exibem comportamentos característicos durante diferentes fases do ciclo. Por exemplo, o sinal da pressão hidráulica da caçamba apresenta picos bem definidos durante a carga e a descarga, permitindo a sua utilização como indicador para detecção automática destes eventos (Stachowiak et al., 2014).

A lógica de eventos combina variáveis como pressão hidráulica, marcha engatada, velocidade do veículo, rotação do motor e pressão dos travões para inferir o estado operacional do equipamento. A partir destas variáveis, são criados “sensores virtuais”, que classificam o estado do veículo em categorias como “em carregamento”, “transporte cheio”, “em descarga” ou “transporte vazio” (Krot et al., 2020).

Estas abordagens são reconhecidas pela sua simplicidade de implementação e facilidade de interpretação pelos engenheiros de minas. No entanto, apresentam limitações importantes, como a necessidade de calibração manual dos limiares, suscetibilidade a erros em condições de operação atípicas e baixa adaptabilidade a diferentes equipamentos e ambientes.

2.4.2. Técnicas de processamento de sinais e transformadas

Com o intuito de superar as limitações dos métodos baseados apenas em limiares, diversos estudos exploraram técnicas de processamento de sinais, como a Transformada Rápida de Fourier (FFT) e filtros digitais. A FFT é utilizada para decompor sinais no domínio da frequência, facilitando a identificação de padrões periódicos associados aos ciclos produtivos. Embora o ciclo de operação não seja estritamente periódico, a FFT pode ser útil para distinguir estados operacionais pela distribuição espectral do sinal (Markham et al., 2022).

Outra técnica explorada é a convolução do sinal com funções matemáticas específicas, como degraus unitários invertidos, o que permite realçar transições de estado, facilitando a detecção de eventos como início e fim de carregamento.

Estudos demonstram que estas abordagens apresentam resultados robustos em ambientes controlados, com grau de exatidão superiores a 90% para a detecção de fases do ciclo em camiões, embora com desempenho mais modesto em pás-carregadoras devido à maior complexidade do seu ciclo operacional (Skoczylas et al., 2023).

2.4.3. Abordagens com algoritmos de aprendizagem automática

Com os avanços em poder computacional e acesso a grandes volumes de dados, métodos baseados em aprendizagem de máquina “*machine learning*” (Figura 5) ganharam espaço na segmentação de ciclos produtivos. Técnicas como Máquinas de Vetores de Suporte (SVM), agrupamento por densidade (DBSCAN), modelos probabilísticos como cadeias de Markov e redes neurais convolucionais têm sido exploradas com resultados promissores (Gawelski et al., 2021; Skoczylas et al., 2023).

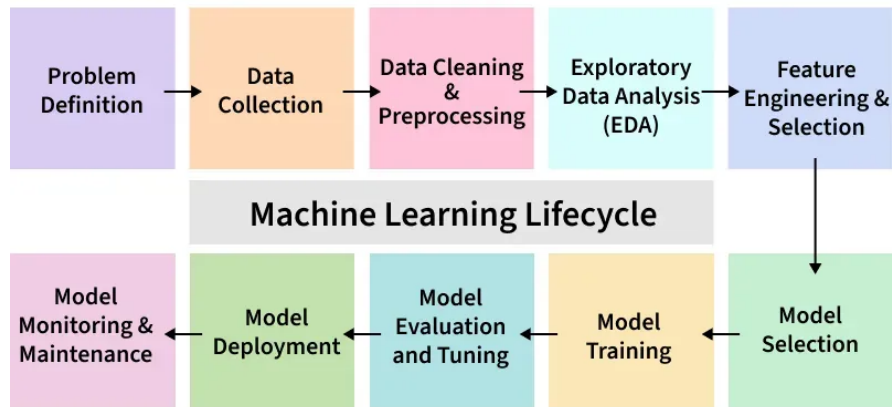


Figura 5 - Ciclo Operacional de métodos baseados em aprendizagem de máquina. Adaptado de: GeeksforGeeks (2025)

Estas técnicas têm a vantagem de capturar relações complexas entre múltiplas variáveis, dispensando a necessidade de definição manual de limiares. Adicionalmente, apresentam maior capacidade de adaptação a diferentes ambientes operacionais quando comparadas aos métodos determinísticos tradicionais (Markham et al., 2022).

Contudo, enfrentam desafios relacionados à necessidade de grandes volumes de dados rotulados para treino, menor interpretabilidade e maior complexidade de implementação. Ademais, estudos apontam que a transferência de modelos entre minas distintas permanece uma limitação prática, sendo frequentemente necessária re-calibração ou re-treinamento (Skoczylas et al., 2023)

2.4.4. Uso de dados complementares

Algumas investigações têm procurado complementar as variáveis internas do equipamento com dados externos, como a localização GPS, sinais de vibração ou mesmo imagens de câmaras de vigilância. A incorporação de dados espaciais permite identificar com maior precisão as zonas de carregamento e descarga, explorando a proximidade geográfica como critério de segmentação, enquanto os sinais de vibração oferecem um nível adicional de sensibilidade na distinção entre

deslocamentos carregados e vazios. Em contextos experimentais, a utilização conjunta destes dados tem revelado melhorias na capacidade de detecção de estados operacionais e na redução de erros associados à simples análise de variáveis internas.

Apesar do seu potencial, estas soluções apresentam limitações práticas significativas. A implementação de sensores adicionais implica custos mais elevados, tanto de aquisição como de manutenção, além de exigir maior complexidade tecnológica na calibração, transmissão e armazenamento dos dados. Tais requisitos acabam por restringir a sua aplicação sobretudo a operações de grande escala ou a equipamentos modernos, enquanto frotas mais antigas ou contextos de menor dimensão dificilmente justificam esse investimento.

Neste enquadramento, a evolução dos algoritmos para segmentação de ciclos produtivos tem desempenhado um papel central na monitorização e optimização das operações mineiras. Embora os métodos baseados em lógica e limiares continuem a ser predominantes devido à simplicidade e ao baixo custo, observa-se uma clara tendência de migração para abordagens híbridas que combinam processamento de sinais com técnicas de aprendizagem automática. Esta integração oferece maior robustez e capacidade de adaptação a diferentes contextos, representando uma direcção promissora para o futuro da análise operacional em mineração (Skoczylas et al., 2023)

[página propositadamente em branco]

Capítulo III

Materiais e Metodologias

3. Materiais e Metodologias

3.1. Equipamentos Monitorizados

Compreender o ciclo produtivo em mineração exige mais do que conhecer máquinas. É necessário observar como estas interagem, no tempo e no espaço, com a lógica da operação. Neste estudo, dois equipamentos essenciais à fase de carga e transporte foram monitorizados com sensores: uma escavadora hidráulica e dois caminhões articulados. Através desta instrumentação simples, mas estratégica, foi possível captar os ritmos da operação tal como eles acontecem em campo.

3.1.1. Escavadora Hidráulica: Caterpillar 336 GC

A escavadora monitorizada foi o modelo Caterpillar 336 GC, amplamente usado em operações de escavação pesada. Com um balde de 1.88 m³, operando sempre com a mesma configuração, a máquina executava sequências repetitivas e bem marcadas de escavação e descarga.

Durante os turnos de monitorização, a escavadora manteve uma cadência estável. Aproximava-se do material fragmentado, preenchia o balde, girava sobre a base e descarregava o conteúdo no caminhão. Cada pazada não era apenas uma unidade de produção. Era também uma assinatura de movimento, um padrão de aceleração e tempo que os sensores gravavam com fidelidade.

O objetivo não era apenas contar pazadas, mas entender como se estrutura um ciclo completo. Esses padrões, uma vez identificados, tornaram-se a base para métodos de segmentação automática, reduzindo a dependência de observações manuais.




Figura 6 - Escavadora Hidráulica CAT 336 GC. Fonte: Caterpillar, 2020 (<https://www.caterpillar.com>)

3.1.2. Camiões Articulados: Volvo A40D

Do lado do transporte, dois camiões articulados Volvo A40D foram envolvidos. Embora tecnicamente idênticos, apresentavam capacidades distintas: 19 m³ no camião identificado como 94/900 e 23 m³ no 94/897. Essa diferença foi suficiente para gerar variações no número de pazadas por ciclo e, por consequência, no comportamento dinâmico da caçamba, sobretudo na fase final de descarga.

O primeiro camião foi utilizado nos testes iniciais, onde se comparou o registo manual dos ciclos com os dados captados por sensores. Foi nesse ponto que se confirmou, na prática, o valor da abordagem automatizada. O segundo camião, com maior volume, serviu para alargar a base de observações e testar a consistência do método em cenários mais exigentes.




Figura 7 - Camião Articulado Volvo A40D. Fonte: Volvo Construction Equipment, 2025. (<https://www.volvoce.com/europe/en>)

Os sensores, smartphones estrategicamente colocados na parte traseira da caçamba, registavam a aceleração, o movimento e, de forma indireta, a inclinação do conjunto. Esta inclinação, visível nos momentos de descarga no britador, tornou-se uma referência importante para delimitar fases do ciclo com precisão temporal.

A operação decorreu numa pedreira de granito, com frente de lavra em bancada simples. O trajeto até ao britador incluía trechos planos e rampas, exigindo dos camiões mudanças de esforço e padrão de condução. A alternância de operadores ao longo dos dois dias de testes permitiu captar variações naturais no comportamento das máquinas, refletindo a realidade do campo.

Sem sistemas de telemetria instalados, os únicos dados operacionais disponíveis até então eram os consumos de combustível por ciclo, anotados manualmente pelos operadores. A introdução dos sensores trouxe, assim, um novo olhar. Não apenas mais dados, mas uma nova forma de ver o que antes passava despercebido.

Com frequência de amostragem na ordem dos **50 Hz**, os sensores capturavam cada variação com detalhe suficiente para reconstruir o tempo operativo em camadas. Do ciclo total aos seus microeventos.




Figura 8 – Registo operacional: (A)- Fixação de smartphone na caçamba do camião para aquisição de dados. (B) Coleta manual para validação dos ciclos operacionais. (Fotos: J. Manuel, 2025).

3.2. Sensores Utilizados e Parâmetros Analizados

Captar o ritmo de uma operação de carga e transporte requer mais do que observação. Exige escuta ativa da própria máquina. Neste estudo, essa escuta foi feita através de smartphones Samsung Galaxy A22 5G (Figura 8-A), posicionados como sensores discretos, mas eficazes, no coração da operação. Trata-se de um modelo de entrada, com recursos limitados face a dispositivo topo de gama, mas que cumpre de forma fiável as exigências de aquisição de dados. Com um custo de aquisição de aproximadamente 100 euros, estes equipamentos mostraram ser uma solução acessível e tecnicamente suficiente para o objetivo proposto.

Equipados com acelerómetros MEMS triaxiais embutidos, os smartphones registaram com boa estabilidade os padrões vibratórios e os movimentos característicos dos equipamentos monitorizados. Foram utilizados os mesmos dispositivos em todas as fases da campanha, assegurando homogeneidade nos resultados e reduzindo variáveis externas na análise.

A aplicação desenvolvida para o projeto permitiu a recolha automática dos dados e a sua exportação em ficheiros .csv. Cada linha continha um timestamp (em milissegundos), os valores de aceleração nos eixos X, Y e Z, a aceleração resultante e as coordenadas geográficas correspondentes (latitude e longitude). Esses dados, organizados cronologicamente, revelavam o comportamento cinemático dos equipamentos ao longo do tempo operativo.

Ao observar as três componentes da aceleração, foi possível inferir movimentos e inclinações. Cada arranque, cada paragem, cada descarga deixava um padrão identificável. Ao todo, foram recolhidas 663.569 medições, com uma frequência média de 51 Hz (aproximadamente 20 milissegundos entre leituras) e um desvio padrão de cerca de 3,5 ms. Essa densidade de amostragem foi suficiente para captar variações rápidas e momentos de transição importantes nos ciclos de trabalho.

Durante a fase inicial, realizou-se uma comparação entre os dados recolhidos automaticamente pelos sensores e os registos manuais obtidos em campo (Figura 8-B). Esta comparação serviu para validar a abordagem adotada. Verificou-se que os sensores integrados nos smartphones eram capazes de identificar, com elevada precisão, os mesmos marcos operacionais registados pelos observadores humanos. Além disso, mostraram-se mais consistentes e menos sujeitos a erros de omissão.

Os dispositivos foram estrategicamente colocados na parte traseira da caçamba dos camiões (Figura 8-A), onde os efeitos das mudanças de inclinação e vibração são mais visíveis. Esta

localização foi particularmente útil para detetar o momento exato da descarga no britador, permitindo marcar com precisão essa fase crítica do ciclo.

Importa sublinhar que os dados registados não passaram por qualquer pré-processamento automático. A sua interpretação, limpeza e tratamento foram realizados no âmbito desta dissertação. É nesse ponto que se encontra o contributo metodológico do trabalho: transformar dados crus em conhecimento operativo, através de algoritmos desenvolvidos especificamente para identificar, segmentar e compreender os ciclos produtivos.

3.3. Introdução ao Python para Análise de Dados

A escolha do ambiente de desenvolvimento e das ferramentas computacionais desempenha um papel decisivo na estruturação de qualquer trabalho de análise de dados. Nesta dissertação, optou-se por conduzir a análise através do editor de código Visual Studio Code, utilizando o formato de Jupyter Notebook como interface principal. Este enquadramento proporcionou uma experiência fluida, iterativa e documentada, ideal para o tipo de exploração técnica e científica que o projeto exigia.

A linguagem de programação Python revelou-se a escolha mais adequada para o tratamento e interpretação dos dados registados. Trata-se de uma linguagem de alto nível, com uma curva de aprendizagem relativamente baixa, o que facilita a sua adoção por parte de engenheiros e investigadores que não tenham necessariamente formação avançada em programação. Mas o mais relevante é a sua versatilidade. Python é hoje amplamente utilizado em contextos académicos e industriais, desde projetos de investigação científica até à produção de sistemas complexos de aprendizagem automática, passando por tarefas do quotidiano de análise de dados.

Uma das grandes forças do Python reside na sua extensa coleção de bibliotecas. Estas bibliotecas são conjuntos de ferramentas e funcionalidades previamente desenvolvidas por outros programadores, organizadas em pacotes reutilizáveis, que permitem acelerar o desenvolvimento de soluções. Ao invés de programar tudo do zero, o utilizador pode recorrer a estas bibliotecas para realizar tarefas comuns como leitura de ficheiros, análise estatística, visualização gráfica ou transformações matemáticas.

No presente trabalho, bibliotecas como pandas foram essenciais para a manipulação de dados tabulares, permitindo organizar os registos em estruturas de fácil leitura e filtragem. A numpy deu suporte ao tratamento eficiente de arrays numéricos e a scipy forneceu os recursos necessários para análises no domínio do tempo e da frequência, bem como testes estatísticos fundamentais

para a robustez das conclusões. Na componente visual, recorreram-se a matplotlib e seaborn para gráficos estáticos, e a plotly para visualizações interativas, o que permitiu observar com nitidez os padrões presentes nas séries temporais. A leitura e manipulação de ficheiros em formato Excel foi feita com o auxílio da biblioteca openpyxl.

O uso do Jupyter Notebook foi particularmente estratégico. Este ambiente de desenvolvimento interativo permite a divisão do raciocínio em células executáveis, onde o código é acompanhado por texto explicativo, equações matemáticas, gráficos e outputs dinâmicos. Esta dinâmica iterativa entre codificação, visualização e interpretação dos resultados revelou-se essencial para ajustar parâmetros, testar hipóteses e documentar de forma rigorosa todo o processo. A própria estrutura dos notebooks facilita a reprodutibilidade e a colaboração, pois permite a qualquer leitor seguir passo a passo a lógica da análise (Kluyver et al., 2016).

A natureza exploratória da análise de sinais exige precisamente esta flexibilidade. Em diversas fases, foi necessário ajustar a estratégia de tratamento de dados em função das tendências observadas, testar diferentes janelas de tempo, validar eventos suspeitos ou simplesmente visualizar novamente um ciclo à luz de uma nova hipótese. O Jupyter Notebook, nesse contexto, não foi apenas um ambiente técnico. Tornou-se uma ferramenta de raciocínio ativo, onde cada bloco de código serviu para confirmar ou refutar ideias, apoiar interpretações ou guiar decisões futuras.

Importa ainda referir que esta escolha tecnológica não implicou custos adicionais. Todas as bibliotecas e ferramentas utilizadas são de código aberto, amplamente documentadas e com comunidade ativa. Isso reforça a relevância prática da metodologia seguida, permitindo que, futuramente, qualquer empresa ou instituição com interesse na replicação deste trabalho o possa fazer sem entraves técnicos ou financeiros.

Por fim, a escolha por um ambiente local como o Visual Studio Code, ao invés de plataformas online, garantiu maior controlo sobre as dependências e os ficheiros utilizados. Este software leve, gratuito e extensível apresenta suporte nativo a múltiplas linguagens e integra-se com Jupyter de forma fluida, tornando-se uma opção estratégica para quem procura aliar produtividade e robustez num ambiente técnico (Microsoft, 2023).

Assim, a combinação entre Python, os notebooks Jupyter e o ambiente do Visual Studio Code constituiu a base tecnológica sobre a qual se desenvolveu todo o trabalho analítico desta dissertação. A coerência entre ferramentas, linguagem e objetivos metodológicos foi decisiva para a solidez dos resultados alcançados.

3.4. Pré-processamento dos Dados

A análise de dados brutos provenientes de sensores, como os acelerómetros embutidos em smartphones, exige uma etapa prévia de preparação meticulosa: o pré-processamento. Esta fase é mais do que um mero passo técnico. É uma fundação crítica sobre a qual se constrói toda a robustez, precisão e utilidade das análises subsequentes. Sem esta base sólida, os algoritmos perdem fiabilidade, as interpretações tornam-se enviesadas e as conclusões, frágeis.

Na prática, os dados recolhidos em campo são tudo menos perfeitos. Vibrações espúrias, pequenos atrasos na aquisição, movimentos involuntários dos dispositivos e até interrupções de registo são comuns. Por isso, o primeiro contacto com os dados deve ser cuidadoso. Começa-se pela limpeza, não uma limpeza qualquer, mas uma triagem científica dos elementos que não pertencem ao sinal real. Ruídos e outliers são, aqui, os primeiros alvos. Técnicas estatísticas como o desvio interquartil (IQR) e o z-score oferecem critérios objetivos para identificar valores que se desviam fortemente da tendência central da distribuição (Aggarwal, 2015). Esses desvios, quando ignorados, podem distorcer médias, inflacionar variâncias e sabotar a deteção de padrões.

Outra etapa essencial é a sincronização temporal. Quando lidamos com múltiplos sensores, como num camião articulado e numa escavadora hidráulica, cada dispositivo opera de forma independente, com seu próprio relógio interno. Um atraso de poucos segundos pode significar o registo de eventos em momentos distintos, mesmo quando aparentemente simultâneos. Para garantir coerência temporal, é necessário alinhar os dados através de timestamps padronizados, ajustando as latências naturais que surgem entre sensores. Esse alinhamento é crucial para análises comparativas, correlação entre eventos e segmentações de ciclos operacionais.

A transformação dos dados entra em cena como um mecanismo de tradução. Os sensores captam acelerações em três eixos (x, y, z), mas o que interessa ao analista é compreender o comportamento global do equipamento. Por isso, calcula-se a aceleração resultante, combinando os três eixos através da raiz da soma dos quadrados. Essa métrica unificada traduz o movimento total do corpo, destacando oscilações intensas, choques e transições abruptas. Outras métricas derivadas incluem a velocidade, obtida por integração da aceleração ao longo do tempo, ou a inclinação, inferida a partir da orientação vetorial do sensor em repouso. Cada transformação adiciona uma camada de leitura e aproxima os dados da realidade física que representam.

Em contextos com séries temporais captadas em diferentes escalas, a normalização dos dados torna-se igualmente relevante. Este processo ajusta os dados para uma escala comum, sem alterar a forma da distribuição. A padronização por z-score transforma os dados para uma média nula e

desvio padrão unitário, enquanto a normalização min-max redistribui os valores para um intervalo entre 0 e 1. Estas técnicas são fundamentais em algoritmos de classificação ou clustering, nos quais diferenças de escala podem induzir interpretações errôneas (Han et al., 2012).

Outro recurso valioso nesta fase é a aplicação da Transformada Rápida de Fourier (FFT). A FFT permite reescrever um sinal no domínio da frequência, revelando a assinatura espectral do movimento. Vibrações cíclicas, oscilações recorrentes e padrões ocultos tornam-se visíveis quando se observa a distribuição de frequências presentes num determinado período. Isto é particularmente útil para distinguir fases operacionais como o deslocamento contínuo do caminhão, as paragens, ou as pazadas da escavadora (Smith, 2003). Em vez de analisar apenas quando algo acontece, a FFT mostra com que ritmo e intensidade algo acontece.

A compreensão do tipo de distribuição estatística dos dados complementa esta etapa, permitindo a seleção criteriosa de ferramentas de análise. É importante perceber se os dados seguem uma distribuição normal, ou se apresentam assimetrias, picos, ou múltiplos modos. Testes como Shapiro-Wilk ou Kolmogorov-Smirnov (Pallant, 2020) ajudam a obter esta resposta. Visualizações como histogramas, boxplots e gráficos de densidade também se revelam úteis nesta fase exploratória. Saber a forma da distribuição permite, por exemplo, decidir entre técnicas paramétricas ou não paramétricas, ajustar limiares de segmentação e escolher filtros apropriados.

O pré-processamento, portanto, não é uma formalidade. É o ato de escutar os dados antes de lhes fazer perguntas mais complexas. É onde o ruído se separa do padrão e o caos se transforma em informação útil. Ao realizar esta etapa com critério e sensibilidade técnica, garante-se que os algoritmos que serão descritos no próximo capítulo não operam sobre suposições frágeis, mas sobre uma representação coerente, limpa e fiel da realidade captada pelos sensores.

[página propositadamente em branco]

Capítulo IV

Desenvolvimento do Algoritmo para Identificação de Ciclos Operacionais

4. Desenvolvimento do Algoritmo para Identificação de Ciclos Operacionais

4.1. Estrutura Geral do Algoritmo

O algoritmo desenvolvido foi concebido para identificar de forma automática os ciclos operacionais de um camião de transporte mineiro, a partir da análise de dados provenientes de sensores inerciais e variáveis de estado do veículo. O seu objetivo central é segmentar o funcionamento do equipamento em estados distintos, nomeadamente: carregamento; transporte; descarga e retorno; permitindo a reconstrução cronológica do ciclo produtivo.

A conceção do algoritmo seguiu uma lógica modular, organizada em fases encadeadas, desde o pré-processamento dos dados até à geração de métricas de desempenho. A Figura 9 representa o fluxograma geral, onde se destacam os principais blocos funcionais:

1. Aquisição e Pré-processamento dos Dados

Nesta fase inicial, procede-se à leitura dos ficheiros .CSV contendo registos de aceleração triaxial e variáveis de estado do veículo (velocidade e ângulo da caçamba de carga). Os datasets são sincronizados temporalmente, garantindo um referencial comum de análise, e submetidos a etapas de filtragem, normalização e remoção de ruído. Técnicas como filtros passa-baixa e passa-alta de Butterworth foram consideradas para atenuar ruídos de alta frequência e corrigir deriva lenta nos sinais, complementadas pela aplicação de limiares mínimos de deteção (SciPy, 2023).

2. Segmentação Inicial (Movimento/Paragem)

Utilizando a velocidade como variável discriminatória, o algoritmo classifica intervalos de tempo em “movimento” ou “parado”. Seguindo práticas correntes na literatura, adotou-se um limiar baixo, próximo de 1 km/h, como critério para identificar estados de paragem (Wei et al., 2024). Pequenas flutuações ou microparagens inferiores a cinco segundos são fundidas no estado de movimento, evitando a criação de intervalos espúrios.

3. Detecção de Eventos Específicos

Dentro dos períodos classificados como “parado”, o algoritmo procura padrões característicos de carga e de descarga. A carga é inferida através da aceleração vertical (eixo y): picos de amplitude superiores a um limiar empírico ($\sim 0,1$ g) indicam impactos do material na caçamba do camião. A descarga é identificada pelo ângulo da caçamba de carga: valores superiores a 20° correspondem inequivocamente a uma operação de despejo (Mnzool et al., 2024).

4. Refinamento da Cronologia Operacional

Os intervalos obtidos são combinados de forma lógica, distinguindo-se estados como *Loading* (carregamento), *Crushing* (descarga no britador), *MovingGo* (transporte carregado), *MovingBack* (retorno vazio) e *Idle* (paragem sem operação). Os estados de transporte e de espera são inferidos pelo contexto: movimentos imediatamente após um carregamento são classificados como transporte carregado, enquanto deslocamentos após a descarga são interpretados como retorno (Miranda, 1986).

5. Cálculo de Métricas Operacionais

Com a cronologia final estabelecida, o algoritmo calcula indicadores quantitativos do desempenho, como a duração média de ciclo, tempos médios de carregamento e de descarga, e número de ciclos por unidade de tempo. Estes parâmetros constituem ferramentas essenciais para a análise de eficiência e identificação de estrangulamentos no processo produtivo (Elijah et al., 2021).

De forma simplificada, o fluxo do algoritmo pode ser representado da seguinte forma:

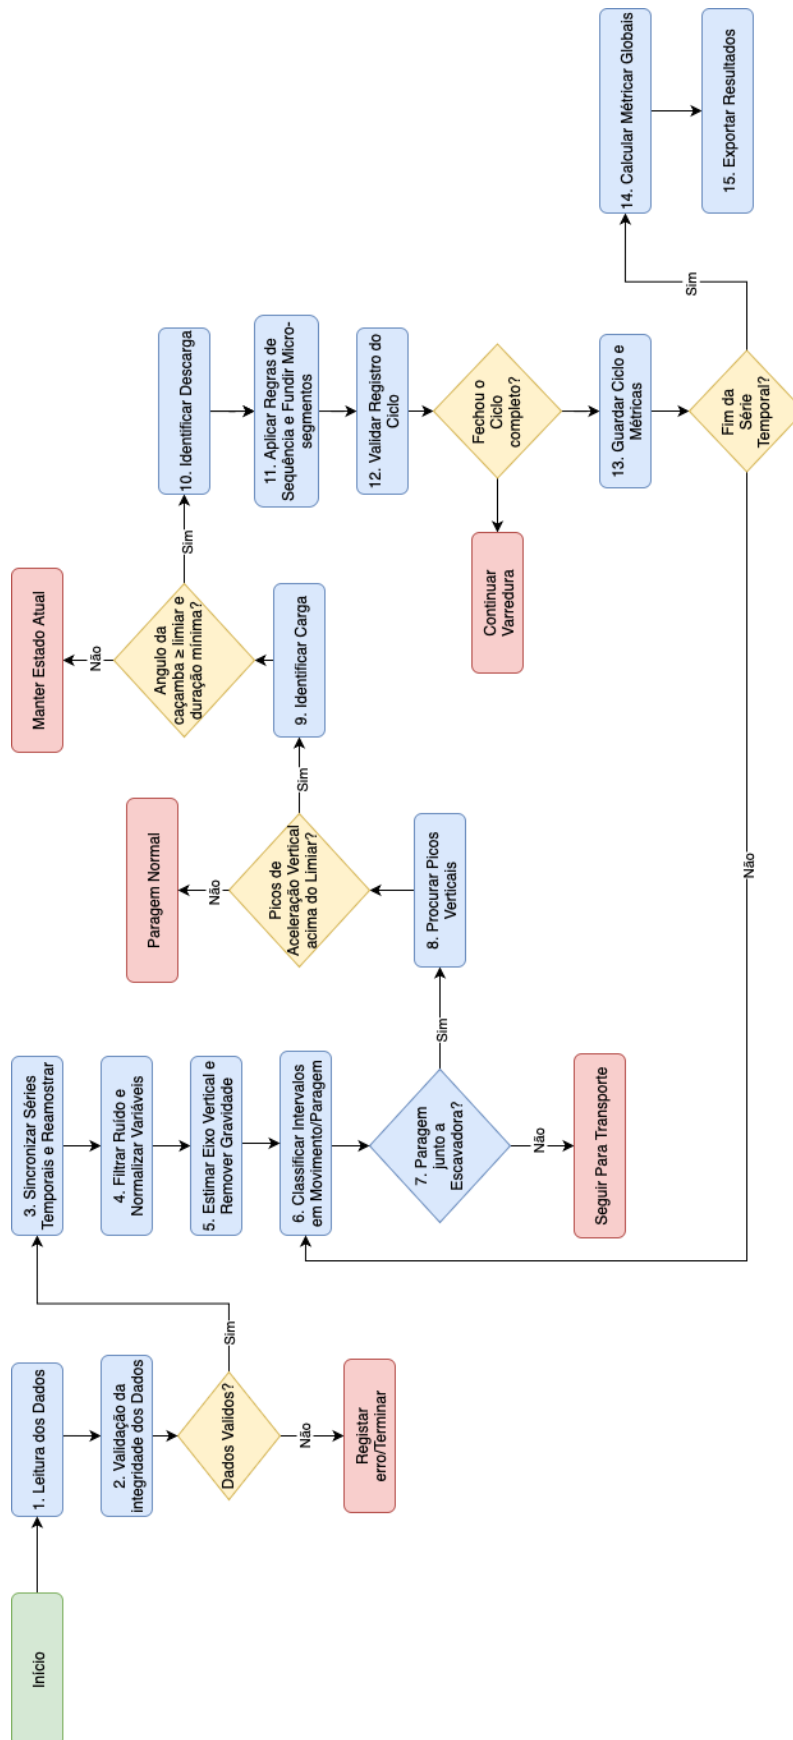


Figura 9 – Fluxograma do Algoritmo Desenvolvido.

Esta estrutura garante uma abordagem transparente, em que cada etapa pode ser validada individualmente, e fornece um pipeline robusto para a monitorização automática de operações mineiras

4.2. Variáveis de Entrada e Pré-processamento

O algoritmo desenvolvido opera sobre dois conjuntos principais de dados de entrada:

1. Registos de aceleração triaxial
2. Variáveis de estado do veículo.

Ambos foram adquiridos a partir de sensores instalados no camião e disponibilizados em ficheiros CSV. Antes da aplicação de qualquer lógica de deteção de eventos, foi necessário proceder a um pré-processamento sistemático para garantir consistência temporal, eliminar ruídos e escalonar as variáveis em intervalos comparáveis.

4.2.1. Dados de Aceleração

Os registos de aceleração constituíram a principal fonte de informação para a construção do algoritmo de segmentação de ciclos. Estes foram obtidos a partir de acelerómetros MEMS embutidos em dispositivos móveis de uso corrente, fixados de forma estável na estrutura do veículo de transporte. A escolha de sensores deste tipo deveu-se à sua elevada disponibilidade, baixo custo e facilidade de integração em operações mineiras, permitindo uma abordagem não intrusiva e escalável para a monitorização do desempenho operacional.

As medições realizadas incluíram as três componentes da aceleração nos eixos ortogonais x, y e z, registadas de forma contínua e acompanhadas de um timestamp associado. Este registo temporal uniforme foi essencial para a sincronização subsequente com outras variáveis do veículo, permitindo correlacionar variações de aceleração com eventos operacionais específicos.

Embora todas as componentes tenham sido analisadas, verificou-se que a aceleração vertical (eixo y) se destacou como a mais informativa para a deteção de eventos relevantes. Isto deve-se ao facto de, durante a operação do camião, fenómenos como o impacto do material ao ser despejado na caixa de carga, as vibrações associadas ao processo de carregamento pela escavadora, ou ainda as oscilações abruptas durante a descarga, se manifestarem predominantemente nesta direção. Assim, picos acentuados na aceleração vertical puderam ser diretamente relacionados com fases críticas do ciclo, em particular o carregamento e a descarga (e.g., Muduli & Yegulalp, 1996; Mnzool et al., 2024).

Adicionalmente, as componentes horizontais (x e z) foram consideradas complementares. Apesar de apresentarem maior variabilidade devido às irregularidades do piso e às manobras do veículo, fornecem indícios úteis sobre movimentos de deslocação e estabilidade direcional. Desta forma, a análise conjunta dos três eixos permitiu não apenas reforçar a deteção de eventos, mas também aumentar a robustez do algoritmo perante variações ambientais e operacionais, como terrenos inclinados ou superfícies irregulares.

4.2.2. Dados de Estado do Veículo

O segundo conjunto de dados incluía variáveis como a velocidade, o ângulo médio da caçamba de carga e, em alguns casos, coordenadas GPS (latitude, longitude e altitude). Para a segmentação inicial, a velocidade foi a principal variável considerada, após conversão de m/s para km/h, uma vez que esta unidade se revelou mais intuitiva para definir limiares de paragem e movimento (Wei et al., 2024). O ângulo da caçamba foi igualmente utilizado, dado que valores acima de 20° foram identificados como um critério robusto para detetar eventos de descarga (Miranda, 1986).

4.2.3. Sincronização Temporal

Como os ficheiros provenientes dos diferentes sensores tinham tempos de início distintos, foi necessário alinhar ambos os conjuntos de dados num mesmo referencial temporal. Para tal, determinou-se o menor timestamp global e subtraiu-se este valor de todas as séries, criando assim um tempo relativo comum (SciPy, 2023). Além disso, os datasets foram truncados de forma a cobrir exatamente o mesmo intervalo de tempo, garantindo consistência entre as variáveis.

4.2.4. Filtragem e Remoção de Ruído

Os dados brutos apresentavam variações espúrias que poderiam comprometer a deteção fiável de eventos. Para mitigar esse problema, aplicaram-se técnicas de filtragem e remoção de tendência:

- **Filtros Butterworth** de 9ª ordem foram considerados, tanto em configuração passa-baixa (para remover ruídos de alta frequência) como passa-alta (para eliminar deriva lenta). A escolha deste filtro deve-se à sua resposta plana em frequência, sem ondulações, característica adequada para manter a forma global do sinal (SciPy, 2023).
- **Remoção de tendência local (drift)** foi realizada por meio da subtração de médias móveis em janelas de 5 segundos ao sinal da aceleração vertical. Esta técnica atua como um filtro passa-alta com corte em aproximadamente 0,2 Hz, centralizando o sinal em torno de zero e realçando variações rápidas associadas a eventos (Elijah et al., 2021).

- **Aplicação de limiar mínimo de detecção:** valores de aceleração vertical inferiores a 0,01 g foram truncados para zero, permitindo distinguir oscilações relevantes de ruído residual. Esta simplificação binarizou o sinal em “ativo” versus “inativo”, garantindo maior clareza na fase de segmentação subsequente (Mnzool et al., 2024).

Para uma melhor visualização, o pseudocódigo abaixo descreve a sequência do pré-processamento aplicado:

```

Entradas
  y_raw, x_raw, z_raw      sinais de aceleração bruto
  [g]
  t_raw                    tempo original [s]

Parâmetros
  fs_target                frequência de referência
  opcional
  filt_type ∈ {lowpass, highpass}
  butter_order = 9
  fc_lowpass, fc_highpass  frequências de corte [Hz]
  win_drift = 5 s          janela média móvel para
  remoção de tendência
  y_activity_thr = 0.01 g

Saídas
  yFiltered                aceleração vertical filtrada
  yFiltered_norm           aceleração vertical filtrada
  e normalizada

Passos
  1. alinhar e, se necessário, reamostrar {t_raw, y_raw} para
  grelha uniforme
  2. se filt_type = lowpass aplicar Butterworth ordem 9 com
  fc_lowpass
  se filt_type = highpass aplicar Butterworth ordem 9 com
  fc_highpass
  3. remover tendência local
  y_drift = média_móvel(y_filtrado, janela = win_drift)
  y_hp = y_filtrado - y_drift
  4. aplicar limiar mínimo de atividade
  y_act = onde |y_hp| < y_activity_thr então 0 senão
  y_hp
  5. normalização min max para intervalo [-1, 1]
  y_min, y_max = min(y_act), max(y_act)
  yFiltered_norm = 2 · (y_act - y_min) / (y_max - y_min)
  - 1
  6. devolver yFiltered = y_hp e yFiltered_norm

```

4.2.5. Normalização

Finalmente, os sinais foram normalizados para o intervalo [-1, 1], recorrendo à normalização min-max. Esta escolha, em vez de uma escala [0, 1], permitiu recentrar os sinais em torno de zero, tornando-os mais compatíveis com fenómenos oscilatórios típicos da aceleração (SciPy, 2023).

Ao término do pré-processamento, estavam disponíveis três variáveis principais para a fase seguinte do algoritmo:

- **yFiltered_norm**: aceleração vertical filtrada e normalizada;
- **speedFiltered_norm**: velocidade filtrada e normalizada;
- **average_angle**: ângulo médio da caçamba (em graus).

Estas constituíram a base para a segmentação e detecção de eventos operacionais.

4.3. Análise Espectral dos Sinais

Este módulo implementa uma verificação espectral da cadência de carregamento a partir de uma série binária de eventos e não interfere na lógica de classificação ou na segmentação do ciclo. O objetivo é disponibilizar um mecanismo de diagnóstico para análise futura da periodicidade das pazadas, podendo ser ativado ou desativado por configuração; os artefactos produzidos destinam-se apenas a consulta posterior.

Os eventos de carga são inferidos a partir de picos detetados no sinal de aceleração vertical filtrado (yFiltered). Cada pico representa a ocorrência de uma pazada e é registado como instante temporal (em segundos) no vetor changeStatus.

A partir desses instantes constrói-se uma série binária 0/1 sobre uma grelha temporal regular com passo de 20 ms (frequência-alvo \approx 50 Hz): atribui-se o valor 1 nos instantes coincidentes com os eventos e 0 em todos os restantes pontos da grelha. Este trem de impulsos sintetiza a ocorrência das pazadas num formato adequado à análise no domínio da frequência.

O procedimento inicia-se com a detecção de picos em yFiltered, gerando changeStatus. Define-se a janela temporal de análise entre o primeiro e o último evento e cria-se a grelha regular com passo de 1/50 s, sobre a qual se projeta a sequência 0/1. Para melhorar a leitura espectral, remove-se a componente DC da série binária, recentrando-a em torno de zero.

Calcula-se então a transformada de Fourier (FFT real), obtendo o espetro de magnitude e o vetor de frequências associado; as componentes dominantes são identificadas por ordenação das amplitudes em ordem decrescente.

A frequência de maior energia é guardada como estimativa da cadência fundamental das pazadas, juntamente com as restantes frequências proeminentes. A verificação é chamada após a detecção das mudanças de estado de carregamento e antes da síntese final de métricas; não altera rótulos,

estados ou contagens, limitando-se a produzir artefactos de diagnóstico (frequências, amplitudes e candidata a frequência fundamental).

O pseudocódigo da Figura 10 resume o módulo: deteta picos em `yFiltered` para criar `changeStatus`, projeta esses eventos numa grelha a 50 Hz formando uma série 0/1, remove a componente DC e calcula a FFT real para identificar as frequências dominantes, registando `f0` e restantes picos apenas como diagnóstico, sem impactar a classificação.

```

pseudocódigo VerificacaoEspectralEventos(yFiltered, fs_alvo=50,
N_picos=5):
    # 0) Detecção de eventos de carregamento (picos em yFiltered)
    # Saída: changeStatus = [τ1, τ2, ..., τM] em segundos (um por
    pazada)
    changeStatus ← DetectaPicos(yFiltered)
    se vazio(changeStatus):
        retornar [], indefinido

    # 1) Janela temporal e grelha regular (passo de 20 ms)
    t0 ← mínimo(changeStatus)
    t1 ← máximo(changeStatus)
    t ← sequência(t0, t1, passo = 1/fs_alvo)      # ~50 Hz
    x ← zeros(tamanho(t))                          # série binária 0/1

    # 2) Projeção dos eventos na grelha 0/1
    para cada τ em changeStatus:
        k ← arred( (τ - t0) * fs_alvo )
        se 0 ≤ k < tamanho(x):
            x[k] ← 1

    # 3) Pré-processamento leve para leitura espectral
    x ← x - média(x)                                # remove componente
    DC
    # (opcional) w ← janela_hann(tamanho(x)); x ← x * w

    # 4) FFT real e espectro de magnitude
    X ← FFT_real(x)
    f ← freq_FFT_real(tamanho(x), 1/fs_alvo)      # frequências (Hz)
    A ← módulo(X); A[0] ← 0                        # ignorar DC

    # 5) Extração de frequências dominantes (diagnóstico futuro)
    idx_ord ← ordenar_indices_por(A, ordem = "desc")
    f_picos ← f[idx_ord][0:N_picos]
    f0_est ← f_picos[0]                            # cadência estimada
    (pazadas/s)

    # 6) Persistência dos artefactos (não usados na classificação)
    guardar("diagnostics/fft_events_freq.npy", f)
    guardar("diagnostics/fft_events_amp.npy", A)
    guardar("diagnostics/fft_events_top.npy", f_picos)
    guardar("diagnostics/fft_events_f0.txt", f0_est)

    retornar f_picos, f0_est

```

Figura 10 - Pseudocódigo do módulo opcional que constrói a série binária 0/1 a partir de picos em `yFiltered`, calcula a FFT e regista as frequências dominantes (diagnóstico da cadência de pazadas; não usado na classificação)

4.4. Deteção de Estados Operacionais

4.4.1. Segmentação Movimento/Parado via Velocidade

A primeira etapa da deteção de estados operacionais consiste em distinguir os intervalos em que o veículo se encontra em movimento daqueles em que permanece parado. Esta distinção é fundamental para estruturar os ciclos produtivos, uma vez que operações críticas, como a carga e a descarga, apenas ocorrem em condições de paragem estável. Além disso, a segmentação inicial em movimento/paragem fornece um quadro de referência robusto para a identificação de eventos subsequentes, reduzindo a complexidade na análise de sinais ruidosos e permitindo que etapas posteriores do algoritmo se concentrem apenas nas transições operacionais relevantes. Em termos práticos, este primeiro filtro atua como uma camada de simplificação, transformando séries temporais complexas em sequências binárias mais fáceis de interpretar e validar.

A variável principal utilizada nesta segmentação foi a **velocidade do camião**, previamente filtrada e convertida para km/h, uma vez que representa de forma direta o estado cinemático do veículo. A utilização da velocidade, em detrimento exclusivo da aceleração, deve-se à sua maior robustez para identificar imobilizações prolongadas, já que a aceleração pode oscilar em torno de zero mesmo quando o veículo está parado, originando falsos positivos.

Com base em recomendações da literatura, adotou-se um **limiar de 1 km/h** para discriminar o estado de paragem. Assim, sempre que a velocidade se manteve abaixo deste valor, o camião foi considerado parado; acima desse valor, foi considerado em movimento. Este critério é consistente com estudos de deteção de paragens em veículos pesados, que apontam a necessidade de limiares baixos para evitar a classificação errada de desacelerações momentâneas, oscilações de GPS ou ruído de medição como paragens efetivas (Elijah et al., 2021). A escolha de 1 km/h, em particular, procura encontrar um equilíbrio entre sensibilidade e especificidade: suficientemente baixo para não confundir desacelerações normais com paragens, mas suficientemente alto para filtrar pequenas variações residuais no sinal de velocidade.

Para reforçar a consistência dos resultados, o algoritmo incorporou dois mecanismos adicionais:

- **Correção de transições espúrias:** quando se verificava que a velocidade de um instante era igual a zero, mas o instante seguinte já correspondia a movimento, o estado atual era também classificado como movimento. Este ajuste evita a criação de paragens artificiais de curta duração.

- **Fusão de microparagens:** todas as paragens com duração inferior a cinco segundos foram reclassificadas como movimento. Esta regra reflete que paragens tão breves não correspondem a atividades operacionais relevantes, sendo antes resultantes de oscilações momentâneas de velocidade (Mnzool et al., 2024).

```

Entradas
v(t)          velocidade filtrada [km/h]
t(t)          tempo alinhado [s]

Parâmetros
speed_stop_thr = 1.0 km/h
short_stop_max = 5 s

Saídas
state_mov(t) ∈ {moving, stopped}
intervals = lista de intervalos contínuos com rótulo

Passos
1. classificar ponto a ponto
   state_mov[i] = stopped se v[i] ≤ speed_stop_thr
                 moving caso contrário
2. correção de transição espúria de 1 amostra
   se state_mov[i] = stopped e state_mov[i+1] = moving
então state_mov[i] = moving
3. fundir microparagens
   detetar runs de stopped com duração < short_stop_max
   reclassificar esses runs como moving
4. extrair intervalos contínuos de moving e stopped
   intervals = run_length_encode(state_mov, t)
5. devolver state mov e intervals

```

Figura 11 - Pseudocódigo de Regras de classificação de movimento e paragem com correção de transições e fusão de microparagens.

O resultado final desta etapa foi uma série temporal binária, distinguindo períodos de *moving* e *stopped*. A partir desta série, o algoritmo construiu um primeiro conjunto de intervalos contínuos, cada um definido por tempo inicial, tempo final e estado associado. Estes intervalos constituem a base para a deteção subsequente de eventos específicos, com a cargas e descargas, dentro dos segmentos classificados como paragem.

4.4.2. Identificação de Eventos de Carregamento em Paragens

Após a segmentação entre movimento e paragem, torna-se necessário distinguir quais das paragens correspondem efetivamente a operações de carregamento. Nem toda paragem implica atividade produtiva; algumas resultam apenas de esperas ou de interrupções momentâneas do ciclo. Para resolver esta ambiguidade, o algoritmo recorreu à análise da aceleração vertical (y) registada pelo acelerómetro.

Durante a carga, cada despejo de material na caçamba do caminhão gera um impacto que provoca picos acentuados de aceleração vertical. Este padrão vibratório é suficientemente distinto para diferenciar um carregamento ativo de uma simples espera, onde as oscilações do sinal tendem a ser mínimas (Mnzool et al., 2024). Assim, a presença de picos sucessivos de elevada amplitude foi considerada a assinatura principal para confirmar que o veículo estava a ser carregado.

A estratégia implementada baseou-se em três etapas:

1. **Seleção de paragens candidatas:** apenas paragens com duração igual ou superior a 180 segundos foram consideradas como potenciais eventos de carregamento. Este limiar foi definido com base em observações práticas, refletindo o tempo mínimo necessário para completar a carga de um caminhão através de várias passadas da escavadora (Elijah et al., 2021).
2. **Deteção de picos de aceleração vertical:** para cada paragem candidata, o algoritmo procurou o instante em que a aceleração vertical ultrapassava um limiar empírico de $\sim 0,1$ g. Este valor foi calibrado de modo a excluir vibrações menores (motor ao ralenti, movimentações externas) e a captar apenas os impactos de maior magnitude característicos do despejo de rocha (Miranda, 1986).
3. **Ajuste do intervalo de paragem:** uma vez identificado o primeiro pico relevante, o início do intervalo de paragem foi ajustado para esse instante, eliminando o tempo inicial de espera sem atividade. Caso, após este ajuste, a duração total do intervalo ficasse abaixo dos 180 segundos, a paragem era descartada como evento de carregamento.

O resultado deste processo foi um conjunto refinado de intervalos classificados como *loading*, representando a duração integral da operação de enchimento do caminhão. É importante destacar que o algoritmo não separou cada passada individual da escavadora, mas considerou o período completo de carregamento como uma única fase. Embora seja possível, em futuras versões, identificar o número de passadas através da contagem de picos de aceleração, tal nível de detalhe não foi incluído nesta fase do estudo.

Esta abordagem garantiu a exclusão de falsas classificações, restringindo a categoria de carregamento a paragens prolongadas com evidência clara de atividade operacional.

4.4.3. Identificação de Eventos de Descarga no Britador

A descarga do material no britador constitui a etapa final de cada ciclo de transporte. Diferentemente da carga, que se caracteriza por impactos sucessivos registados no acelerómetro,

a descarga é um processo contínuo e mais facilmente identificado através do ângulo da caçamba de carga.

Durante o transporte e a carga, a caçamba permanece praticamente horizontal, com valores de inclinação próximos de 0° . No momento da descarga, o acionamento do sistema hidráulico provoca a elevação da caçamba, atingindo inclinações superiores a 20° . Este valor foi estabelecido como limiar empírico, por se tratar de um ponto seguro para distinguir oscilações normais do veículo ($5\text{--}10^\circ$) de um basculamento efetivo para despejo de material (Wei et al., 2024).

O algoritmo monitorizou continuamente a variável **average_angle**, extraída dos dados de estado do veículo, e classificou como evento de *crushing* qualquer intervalo em que o ângulo ultrapassasse o limiar definido. Para garantir que todo o processo fosse incluído, a detecção foi expandida retroativamente até ao início da elevação da caçamba (fase ascendente) e progressivamente até ao seu retorno à posição horizontal (fase descendente). Com este procedimento, cada evento de descarga foi registado como um único intervalo contínuo.

Os resultados confirmaram a elevada robustez desta abordagem: em todos os casos observados, o aumento do ângulo acima de 20° correspondeu inequivocamente a uma operação de descarga. Este método revelou-se, portanto, praticamente isento de falsos positivos, ao contrário da análise exclusiva de aceleração, que poderia confundir vibrações de terreno com eventos de descarga (Mnzool et al., 2024).

Assim, a detecção da descarga baseou-se em três princípios fundamentais:

- o ângulo da caçamba como indicador primário, dada a sua fiabilidade;
- a definição de um limiar conservador de 20° para excluir ruídos operacionais;
- a marcação de todo o intervalo de inclinação, desde o início do basculamento até ao retorno da caçamba, como um único evento de descarga.

Este processo assegurou a identificação precisa de cada fase de descarga no britador, permitindo integrar estes eventos na cronologia final do ciclo operacional.

4.5. Construção da Cronologia Final

Uma vez identificados os eventos de carregamento e de descarga, o algoritmo procede à integração destes com os segmentos de movimento e paragem previamente segmentados, de modo a construir uma cronologia completa dos ciclos operacionais. O objetivo é que cada instante da série temporal seja classificado de forma consistente em um dos estados operacionais definidos: *Loading*

(carregamento), *MovingGo* (transporte carregado), *Crushing* (descarga no britador), *MovingBack* (retorno vazio) ou *Idle* (paragem sem atividade).

O processo de construção da cronologia final desenvolveu-se em quatro etapas principais:

1. **Combinação inicial de eventos identificados**

Os intervalos de carregamento e de descarga foram reunidos num único conjunto de dados, ordenados cronologicamente. Os períodos inicialmente classificados como *stopped* e validados com a carga foram reclassificados como *loading*. Os intervalos com ângulo de caçamba acima de 20° foram rotulados como *crushing* (Wei et al., 2024).

2. **Identificação de movimentos de transporte e retorno**

Entre o final de um carregamento e o início de uma descarga seguinte, inseriu-se automaticamente um intervalo de transporte carregado (*movingGo*). De forma análoga, entre o fim de uma descarga e a carga subsequente, foi criado um intervalo de retorno vazio (*movingBack*). Esta inferência baseia-se no pressuposto de que, no ciclo típico de operação, cada evento de carregamento é necessariamente seguido de transporte e subsequente descarga (Miranda, 1986).

3. **Inserção de períodos de espera (*idle*)**

Quando foram detetadas lacunas temporais não explicadas por carregamento, transporte ou descarga, estas foram classificadas como *idle*. Este estado representa paragens curtas em que o camião permaneceu inativo, aguardando por condições operacionais, como disponibilidade da escavadora ou do britador (Elijah et al., 2021).

4. **Consolidação da cronologia final**

Após a inserção dos intervalos inferidos, a sequência foi reordenada e indexada, produzindo a cronologia final (*dfFinalResult*). Esta estrutura fornece a duração de cada evento, bem como a sequência temporal completa dos estados do veículo ao longo da operação.

O resultado final é uma representação estruturada dos ciclos operacionais, permitindo identificar de forma clara as transições entre carregamento, transporte, descarga, retorno e períodos de espera. Além disso, esta cronologia serviu como base para o cálculo de métricas de desempenho, abordado na secção seguinte.

4.6. Parâmetros, Eficiência e Limitações

4.6.1. Parâmetros de Calibração do Algoritmo

A eficácia do algoritmo desenvolvido dependeu da definição criteriosa de um conjunto de parâmetros de calibração. Estes parâmetros funcionam como limiares operacionais que permitem distinguir entre sinais de ruído e eventos efetivos, bem como estabelecer fronteiras temporais mínimas para a classificação de estados. A sua determinação baseou-se numa combinação de observações empíricas realizadas durante a campanha de recolha de dados e em recomendações disponíveis na literatura técnica e científica.

Limiar de atividade do acelerómetro (*y_activity_thr*): Para eliminar flutuações de baixa amplitude, foi definido um limiar mínimo de 0,01 g na aceleração vertical (*y*). Valores inferiores foram truncados para zero, reduzindo a interferência de vibrações residuais provenientes do motor ao ralenti ou de pequenas oscilações estruturais do veículo. Este procedimento assegura que apenas variações com significado operacional sejam consideradas. Estudos prévios sublinham a utilidade desta prática para diferenciar entre ruído de fundo e impactos reais registados em operações de carga (Mnzool et al., 2024).

Limiar de velocidade para deteção de paragem (*speed_stop_thr*): A velocidade constitui a variável primária para distinguir movimento de paragem. O valor de 1 km/h foi adotado como limiar, em consonância com trabalhos sobre monitorização de veículos pesados por GPS que indicam a necessidade de limiares baixos para evitar classificações falsas de paragens durante desacelerações (Wei et al., 2024). Este valor mostrou-se adequado para os dados em análise, permitindo captar paragens efetivas sem perder eventos curtos de baixa velocidade.

Limiar de ângulo da caçamba para deteção de descarga (*angle_crush_thr*): No caso da descarga no britador, a variável decisiva foi o ângulo de inclinação da caçamba de carga. Um valor de 20° foi considerado suficiente para distinguir movimentos normais de oscilação do veículo (habitualmente inferiores a 10°) de um basculamento real para despejo de material. Esta escolha resultou da inspeção direta dos dados, corroborada por referências que descrevem valores semelhantes em estudos de operações de transporte em minas a céu aberto (Elijah et al., 2021).

Duração mínima de carregamento (*loading_duration_min*): Para validar uma paragem com a carga, estabeleceu-se uma duração mínima de 180 segundos. Este valor reflete a necessidade de tempo prolongado para completar o enchimento de um camião por meio de múltiplas passadas da escavadora. Intervalos inferiores foram interpretados como paragens de espera ou interrupções

momentâneas. A adoção deste parâmetro garante que apenas operações completas são contabilizadas como *loading*, aumentando a robustez da segmentação.

Duração máxima de microparagens (*short_stop_max*): De modo a evitar a fragmentação excessiva da série temporal, paragens inferiores a 5 segundos foram fundidas em segmentos de movimento. Este procedimento tem fundamento prático, dado que paragens tão curtas raramente correspondem a eventos operacionais relevantes, mas sim a pequenas hesitações do condutor ou oscilações de sinal (Mnzool et al., 2024).

A Tabela 3 resume os principais parâmetros e os respetivos valores adotados.

Tabela 3 - Principais parâmetros do algoritmo e valores adotados

Parâmetro	Descrição	Valor adotado
<i>y_activity_thr</i>	Limiar de atividade no acelerómetro vertical	0,01 g
<i>speed_stop_thr</i>	Velocidade máxima para estado “parado”	1 km/h
<i>angle_crush_thr</i>	Ângulo mínimo da caçamba para detetar descarga	20°
<i>loading_duration_min</i>	Duração mínima de uma paragem para validação com a carga	180 s
<i>short_stop_max</i>	Duração máxima de microparagens a fundir em movimento	5 s

Estes parâmetros revelaram-se adequados para o conjunto de dados utilizado. No entanto, é importante destacar que a sua aplicabilidade poderá variar consoante as características do equipamento monitorizado, a natureza do material transportado e as condições específicas da operação mineira.

4.6.2. Eficiência e Precisão da Identificação

A análise da eficiência do algoritmo revelou um desempenho robusto na identificação dos principais eventos que estruturam o ciclo operacional. No caso da carga, a utilização da aceleração vertical como variável de referência mostrou-se altamente fiável: todos os intervalos observados em campo foram corretamente reconhecidos pelo algoritmo, sem ocorrência de falsos positivos. Os picos de aceleração superiores a 0,1 g corresponderam inequivocamente ao impacto do material na caçamba, confirmando que a filtragem e o limiar estabelecidos foram adequados para discriminar eventos reais de ruído de fundo (Mnzool et al., 2024).

De igual modo, a deteção das descargas baseou-se no ângulo da caçamba de carga, que se revelou praticamente infalível. Sempre que a inclinação ultrapassou o limiar de 20°, verificou-se um

basculamento real para despejo no britador. Ao considerar todo o processo de inclinação, desde o início da elevação até ao retorno da caçamba à posição horizontal, o algoritmo garantiu que cada descarga fosse registada como um único evento, evitando fragmentações e melhorando a clareza da cronologia (Wei et al., 2024).

A segmentação entre estados de movimento e paragem também demonstrou elevada consistência. O limiar de 1 km/h permitiu distinguir eficazmente as paragens produtivas das flutuações normais de velocidade, enquanto a fusão de paragens muito curtas eliminou microsegmentos que poderiam introduzir ruído na análise. O resultado foi uma série temporal simplificada e fiel ao comportamento observado em operações reais (Elijah et al., 2021).

De forma resumida, a eficiência do algoritmo reside na combinação de dois indicadores independentes, mas complementares: a aceleração vertical, fiável para reconhecer a carga, e o ângulo da caçamba, robusto na deteção da descarga. Esta integração reduziu a probabilidade de classificações erradas e produziu uma reconstrução cronológica precisa do ciclo operacional, confirmando a utilidade do método como ferramenta de monitorização automática.

4.7. Enquadramento para os Resultados

O algoritmo descrito neste capítulo fornece a base metodológica para a identificação automática de ciclos operacionais em operações de carga e transporte. A sua estrutura modular, assente em fases de pré-processamento, deteção de eventos e construção de uma cronologia sequencial, permitiu criar um procedimento robusto e replicável. Os parâmetros de calibração definidos garantiram uma segmentação adequada dos dados, e os primeiros testes confirmaram a sua capacidade de reconhecer os principais estados operacionais.

Neste ponto, importa sublinhar que o foco do presente capítulo se centrou na descrição e fundamentação técnica do algoritmo, deixando a análise crítica da sua eficiência, das limitações encontradas e das implicações práticas para o capítulo 6, onde os resultados serão discutidos em maior detalhe. Esta divisão permite manter a clareza entre a apresentação metodológica e a avaliação global do contributo científico da investigação.

O código completo do algoritmo encontra-se incluído em anexo digital. Foi desenvolvido especificamente para este trabalho, no âmbito de uma dissertação em engenharia, pelo que poderá não apresentar o nível de organização ou a padronização que seria expectável em software profissional. No entanto, cumpre integralmente o seu propósito: é funcional, transparente e garante a rastreabilidade das etapas de processamento e análise dos dados.

[página propositadamente em branco]

Capítulo V

Estudo de Caso e Aplicação do Algoritmo

5. Estudo de Caso e Aplicação do Algoritmo

5.1. Enquadramento geográfico e geológico da área de estudo

Por indicação da entidade proprietária, a identidade da pedreira não é divulgada. Para contextualização espacial, apresenta-se uma imagem de localização aproximada na Região Norte de Portugal (Figura 12), em que a área de estudo surge destacada de forma não identificável a nível parcelar, garantindo a confidencialidade do sítio. A envolvente imediata encontra-se bem servida por acessos rodoviários e serviços (restauração, comércio e oferta habitacional), refletindo a integração da atividade extractiva num território com ocupação antrópica consolidada. Importa notar que a operação decorre há mais de duas décadas, o que, ainda que não possa ser quantificado neste estudo, poderá ter contribuído positivamente para a empregabilidade local e para a dinâmica económica da região, quer pela criação direta de postos de trabalho, quer pelos efeitos indiretos em cadeias de fornecimento e serviços associados.



Figura 12 – Localização da Pedreira do Estudo (NW de Portugal).

De acordo com a geologia regional, a pedra analisada encontra-se inserida na unidade litológica designada por Ym1 (Ver Figura 13), correspondente aos Granitos de Airão, Aves e Roriz. Esta unidade geológica é composta por monzogranitos de grão médio e tendência porfiróide, constituídos por duas micas (moscovite e biotite), com predomínio de biotite (Pereira, 1992). É frequente a observação de textura equigranular ou levemente porfiróide com megacristsais de feldspato potássico (Pereira, 1992).

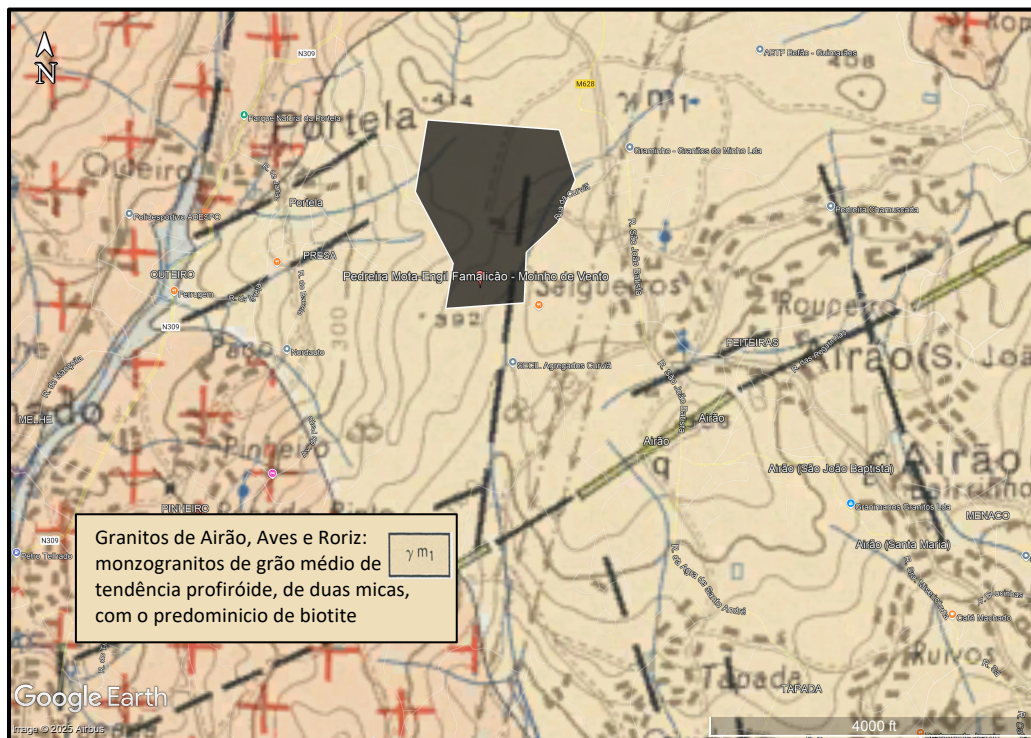


Figura 13 – Geologia na área de estudo (Adaptado de Folha 09-B – Guimarães, 1986).

Estes granitos são considerados tardi a pós-tectónicos no contexto do ciclo varisco e integram um conjunto litológico amplamente representado no norte de Portugal (Pereira, 1992), frequentemente alvo de exploração industrial para produção de agregados. A unidade Ym1 caracteriza-se ainda por apresentar baixo grau de alteração superficial, fraturação espaçada e resistência mecânica compatível com operações de desmonte por explosivos, sendo particularmente adequada à extração escalonada em bancadas.

A caracterização geológica aqui apresentada serve de base para a análise das operações de carga e transporte que se seguem, bem como para a compreensão das condições do maciço rochoso no que diz respeito à escavação, estabilidade dos taludes, fragmentação e desempenho dos equipamentos operacionais utilizados na pedra.

5.2. Contextualização Operacional da Campanha de Recolha de Dados

A campanha de recolha de dados decorreu numa pedreira de granito em plena atividade, sendo esta a única unidade industrial disponível para a realização do estudo. As operações monitorizadas ocorreram após a execução de um desmonte, envolvendo a escavação, carga e transporte do material fragmentado até ao britador primário. O trajeto percorrido pelos camiões incluía trechos planos e rampas de inclinação variável, o que influenciava diretamente os padrões de aceleração e velocidade registados.

Durante o período de observação em campo, verificou-se que todo o processo de carregamento era assegurado por uma única escavadora hidráulica, que operava em diferentes configurações de frota consoante a disponibilidade de camiões e operadores. Foram registadas três combinações principais:

- escavadora com 1 camião;
- escavadora com 2 camiões;
- escavadora com 3 camiões.

A afetação da frota não seguia critérios de planeamento estruturado, dependendo sobretudo da disponibilidade momentânea de equipamentos e recursos humanos. Essa abordagem gerava variações significativas no fluxo de trabalho. Em particular, a utilização de três camiões revelou-se contraproducente: a escavadora não dispunha de tempo suficiente para reposicionar a pilha entre ciclos, o que originava tempos de espera e sobreposição de manobras. Adicionalmente, a curta distância entre a frente de lavra e o britador reduzia o intervalo disponível entre viagens, acentuando os congestionamentos. Este resultado é consistente com a evidência de que sobredimensionar a frota tende a elevar esperas e alongar ciclos, pelo que a seleção deve ser feita conjuntamente com a unidade de carga e com as condições do traçado e da via (Meixedo, 2005; Meixedo et al., 2016)

Estas observações confirmam que a simples adição de camiões não garante ganhos de produtividade, podendo até provocar o efeito inverso. Estudos de dimensionamento de frotas já destacaram que a produtividade depende do equilíbrio entre o ritmo da escavadora, o tempo de transporte e a capacidade de descarga, sendo comum que excessos na frota conduzam a desperdícios operacionais.

Para efeitos de análise detalhada, este estudo considerou como cenário de referência a configuração menos favorável, a escavadora a operar com apenas um camião. Esta opção permitiu identificar com maior clareza a estrutura dos ciclos, os tempos médios de operação e os principais estrangulamentos, fornecendo uma base sólida para avaliar a aplicabilidade do algoritmo desenvolvido.

5.3. Aplicação do Algoritmo e Geração de Cronologias Operacionais

Após a definição metodológica do Capítulo 4, o algoritmo foi aplicado ao conjunto de dados recolhido na campanha experimental. O objetivo não foi apenas validar a implementação computacional, mas verificar a capacidade do método em segmentar ciclos operacionais de forma fiável e coerente com a realidade observada em contexto não controlado. Esta estratégia é apropriada para sistemas de carga e transporte com dinâmica não linear, onde pequenas alterações de parâmetros ou condições iniciais podem induzir respostas qualitativamente distintas (Meixedo, 2005; Meixedo et al., 2016).

O ciclo operacional de um camião mineiro, apesar de teoricamente bem definido, apresenta na prática elevada variabilidade em função da disponibilidade de equipamentos, do estilo de condução, da fluidez das operações de carga e descarga e até das condições do terreno. Neste sentido, a aplicação do algoritmo a dados reais constitui uma etapa crítica, pois permite demonstrar a sua robustez em condições não controladas, típicas de pedreiras em funcionamento contínuo.

O procedimento adotado consistiu em processar os registos de aceleração triaxial, velocidade e ângulo da caçamba, de acordo com as heurísticas definidas no desenvolvimento do algoritmo. A partir destes dados foi possível identificar as fases elementares do ciclo produtivo e organizá-las numa cronologia contínua, que traduz o funcionamento do sistema de transporte durante todo o período monitorizado.

5.3.1. Reconstrução Cronológica

A execução do algoritmo sobre os dados recolhidos produziu um conjunto de sinais que, uma vez visualizados, permitiram acompanhar a sequência das operações com elevado grau de detalhe. A primeira abordagem consistiu em representar simultaneamente as variáveis processadas de aceleração, velocidade e ângulo da caçamba. A Figura 14 mostra esta visualização inicial, onde se encontram sobrepostos diferentes registos. Apesar da complexidade gráfica, este tipo de plot foi fundamental para verificar a coerência interna do algoritmo. Mesmo sem tratamento adicional, já

era possível identificar a repetição de ciclos operacionais ao longo da série temporal, refletindo a alternância entre momentos de carga, transporte, descarga e retorno.




Figura 14 - Representação inicial dos sinais processados

Embora esta primeira representação seja tecnicamente completa, a sobreposição de variáveis dificulta a interpretação imediata. Assim, optou-se por retirar momentaneamente as componentes de velocidade e ângulo (“*speedFiltered*” e “*average_angle_original*”), mantendo apenas a aceleração filtrada como variável central de análise. A Figura 15 ilustra este resultado, no qual os ciclos surgem de forma mais clara. Nesta configuração, o padrão repetitivo da operação mineira fica evidente, com alternâncias regulares de picos e períodos de relativa estabilidade que correspondem, respetivamente, os ciclos de carregamento do camião.




Figura 15 - Aceleração filtrada ao longo do tempo, evidenciando os ciclos de carga.

Este passo demonstrou que, mesmo reduzindo a análise a uma única variável, a estrutura do processo produtivo podia ser identificada com precisão. De facto, a repetição de padrões não apenas refletiu a lógica teórica do ciclo mineiro, mas também confirmou aquilo que fora observado em campo: um ritmo contínuo, embora irregular, de carga, transporte e descarga. A utilização de aceleração vertical como indicador dominante encontra suporte na literatura, onde se destaca a sua sensibilidade para captar variações abruptas e impulsos associados a eventos físicos distintos (Mnzool et al., 2024).

Num momento seguinte, reintroduziu-se a variável velocidade para verificar se os intervalos previamente segmentados correspondiam efetivamente a deslocamentos do camião. Esta correlação mostrou-se essencial para validar que os períodos assinalados como transporte coincidiam com velocidades relativamente constantes, enquanto as fases de carga e descarga se associavam a reduções significativas ou mesmo a paragens. A integração destas variáveis ofereceu uma confirmação cruzada de que os estados inferidos pelo algoritmo correspondiam a comportamentos reais do equipamento.

O grau de detalhe dos registos permitiu ainda uma análise mais fina de um ciclo isolado. Ao ampliar a fase de carregamento, foi possível identificar cada passada individual da escavadora, visível sob a forma de picos sucessivos na aceleração. A Figura 16 ilustra este fenómeno, mostrando como cada descarga parcial de material no interior da caçamba gera um impulso distinto. Esta observação tem particular relevância porque demonstra a capacidade do método não apenas para identificar as fases macro do ciclo, mas também microeventos dentro de uma única operação. Embora a presente investigação não tenha explorado este nível de detalhe como métrica de produtividade, ele constitui uma linha de desenvolvimento futura promissora, alinhada com estudos que procuram relacionar a cadência da escavadora com o tempo total de carregamento (Elijah et al.,2021).




Figura 16 - Ciclo individual com identificação das passadas da escavadora

A progressão das visualizações conduziu inevitavelmente à necessidade de uma representação mais sintética, capaz de resumir a informação de forma acessível sem perder rigor. Embora os gráficos de aceleração e velocidade permitam reconhecer padrões, a sua interpretação exige experiência e tempo de análise. Para responder a esta limitação, optou-se por representar a sequência dos estados num diagrama de Gantt, apresentado na Figura 17 Nesta visualização, cada estado operacional surge como um bloco colorido e a alternância entre eles reflete diretamente a cronologia da operação.




Figura 17 - Diagrama de Gantt de 3 dos ciclos operacionais identificados.

A clareza deste diagrama é notável. O que no terreno se traduz numa sucessão aparentemente caótica de movimentos, em que o camião se aproxima, é carregado, parte carregado, descarrega e regressa, surge aqui ordenado e quantificável. A visualização permite não apenas confirmar a segmentação correta dos ciclos, mas também identificar imediatamente onde se concentram os maiores tempos de inatividade, quais as fases mais demoradas e como se distribuem os diferentes eventos ao longo do turno.

Em termos metodológicos, este percurso analítico mostrou a importância de não apresentar apenas o resultado final. O processo de construção, desde a leitura inicial dos sinais até à representação final em Gantt, confere transparência ao trabalho desenvolvido e demonstra que as decisões foram fundamentadas em observações sucessivas e consistentes. Do ponto de vista da prática mineira, este tipo de abordagem tem ainda outra virtude: aproxima a linguagem técnica dos engenheiros de campo, que reconhecem nos gráficos não apenas linhas e blocos de cor, mas uma tradução fiel do que acontece diariamente na operação.

Assim, a reconstrução cronológica não se limita a validar o algoritmo. Ela estabelece uma ponte entre os dados digitais e a realidade operacional, permitindo que a análise científica dialogue diretamente com a experiência empírica. Ao tornar visíveis tanto a macroestrutura do ciclo como os microeventos que o compõem, abre caminho a aplicações futuras que vão desde o dimensionamento ótimo da frota até ao acompanhamento em tempo real da produtividade.

5.3.2. Duração e Estrutura dos Ciclos

A análise da cronologia gerada pelo algoritmo permitiu quantificar a duração média de cada fase operacional, fornecendo uma visão detalhada da estrutura dos ciclos. Esta informação é essencial não apenas para validar a segmentação automática, mas também para compreender como o tempo é distribuído entre as diferentes etapas do processo produtivo.

Para materializar a cronologia em métricas objetivas, apresenta-se na Tabela 4 a decomposição ciclo a ciclo dos estados identificados pelo algoritmo (loading, movingGo, crushing, movingBack, idle). Cada linha corresponde a um segmento contínuo, com registo de instante inicial, final e duração; a primeira linha de cada ciclo inclui o tempo total do ciclo em minutos.

Tabela 4 - Decomposição dos ciclos operacionais.

Cycle number	initial	final	status	duration	Duration (min)	Total
1	395,163	670,102	loading	274,939	4,58	13,796
	670,102	912,182	movingGo	242,08	4,03	
	912,182	965,282	crushing	53,1	0,89	
	965,282	1096,302	movingBack	131,02	2,18	
	1096,302	1140,302	idle	44	0,73	
	1140,302	1222,923	movingBack	82,621	1,38	
2	1222,923	1540,822	loading	317,899	5,30	29,80
	1540,822	1702,082	movingGo	161,26	2,69	
	1702,082	2154,242	idle	452,16	7,54	
	2154,242	2252,261	movingGo	98,019	1,63	
	2252,261	2692,362	crushing	440,101	7,34	
	2692,362	2825,441	movingBack	133,079	2,22	
	2825,441	2923,542	idle	98,101	1,64	
2923,542	3010,922	movingBack	87,38	1,46		
3	3010,922	3354,542	loading	343,62	5,73	15,41
	3354,542	3598,801	movingGo	244,259	4,07	
	3598,801	3640,802	crushing	42,001	0,70	
	3640,802	3754,842	movingBack	114,04	1,90	
	3754,842	3777,842	idle	23	0,38	
3777,842	3935,583	movingBack	157,741	2,63		
4	3935,583	4212,861	loading	277,278	4,62	13,61
	4212,861	4456,881	movingGo	244,02	4,07	
	4456,881	4523,081	crushing	66,2	1,10	
	4523,081	4645,201	movingBack	122,12	2,04	
	4645,201	4677,202	idle	32,001	0,53	
4677,202	4751,903	movingBack	74,701	1,25		
5	4751,903	5100,461	loading	348,558	5,81	12,16
	5100,461	5111,461	movingGo	11	0,18	
	5111,461	5185,482	idle	74,021	1,23	
	5185,482	5417,582	movingGo	232,1	3,87	
5417,582	5481,582	crushing	64	1,07		

Os resultados obtidos indicaram que a carga constituiu a fase mais longa do ciclo, com tempos médios em torno de cinco minutos. Este valor reflete a cadência da escavadora hidráulica, que necessita de várias pazadas para encher a caçamba do camião. Embora a variabilidade entre ciclos seja considerável, dependendo da posição da pilha, do ângulo de ataque e até da experiência do operador, a consistência do tempo médio confirma a fiabilidade do algoritmo. Estudos anteriores apontam para tempos de carregamento entre 2,5 e 4 minutos em pedreiras de médio porte, valores que estão ligeiramente abaixo em relação ao observado neste caso (Elijah et al., 2021).

A descarga no britador revelou-se mais breve, com duração próxima de um minuto. Esta fase é limitada pelo tempo de basculamento da caçamba e pela necessidade de aguardar a estabilização do material no equipamento de britagem. Em alguns ciclos, registaram-se descargas mais rápidas, inferiores a 40 segundos, quando a caçamba estava corretamente posicionada e não havia congestionamento na zona de descarga. Em outros casos, o processo prolongou-se devido a pequenas manobras de alinhamento ou tempos de espera pela disponibilidade do britador. Esta oscilação mostra como fatores aparentemente secundários, como a organização da zona de descarga, podem influenciar significativamente o ciclo.

As fases de transporte carregado (MovingGo) e de retorno vazio (MovingBack) apresentaram durações mais variáveis, entre um e dois minutos cada. O transporte carregado, como esperado, foi mais lento, resultado do peso adicional e do maior esforço do motor, enquanto o retorno vazio ocorreu em média com velocidades superiores. A curta distância entre a frente de lavra e o britador explica a brevidade destas fases, mas também reforça que pequenas ineficiências, como manobras adicionais ou tempos de espera, têm impacto proporcionalmente maior no ciclo total.

Um aspeto relevante identificado pela cronologia foi a ocorrência de períodos de paragem intermédia (Idle). Embora nem sempre presentes, estes intervalos chegaram a representar mais de 15% da duração de alguns ciclos. A sua origem esteve frequentemente associada à espera do camião pela escavadora, quando esta necessitava de reposicionar a pilha, ou a pequenas filas junto ao britador. Este tipo de inatividade, frequentemente negligenciado em análises tradicionais, surge aqui claramente quantificado, oferecendo evidência objetiva da necessidade de melhor coordenação entre equipamentos.

No conjunto, a duração média de um ciclo completo situou-se entre cinco e seis minutos. Este valor encontra-se em linha com a literatura e com observações empíricas em pedreiras europeias de dimensão semelhante, onde os ciclos variam normalmente entre quatro e sete minutos (e.g., Miranda, 1986; Muduli & Yegulalp, 1996; Mnzool et al., 2024). A proximidade destes números não apenas valida o algoritmo, mas também reforça a representatividade da operação monitorizada.

Para além da média, a análise revelou uma dispersão significativa, com ciclos mínimos em torno de quatro minutos e máximos superiores a oito minutos. Este intervalo demonstra a forte influência de fatores externos ao desempenho mecânico, como a disponibilidade dos equipamentos e a coordenação entre escavadora e camiões. A capacidade do algoritmo em capturar esta variabilidade constitui um dos seus pontos fortes, pois permite diferenciar entre um desempenho ideal e situações de ineficiência.

Do ponto de vista prático, esta informação assume relevância direta para o planeamento da frota. Se, por um lado, a média de cinco a seis minutos permite estimar produtividades globais, por outro a identificação de ciclos alongados por períodos de espera destaca oportunidades de otimização. A redução destes tempos improdutivos poderia, por si só, equivaler a ganhos operacionais superiores ao que se conseguiria apenas com o aumento da frota de transporte.

5.3.3. Variações Operacionais

A análise das variações operacionais foi possível a partir da cronologia representada no diagrama de Gantt apresentado anteriormente. Esta visualização, ao sintetizar em blocos discretos a sucessão de estados de cada ciclo, permitiu observar de forma clara não apenas a sequência lógica das fases, mas também as diferenças na sua duração relativa. Assim, a discussão que se segue é subsequente à reconstrução cronológica, constituindo um aprofundamento interpretativo do resultado já mostrado.

Embora a estrutura básica do ciclo seja repetitiva e relativamente estável, a análise detalhada revelou variações significativas entre viagens sucessivas. Esta variabilidade é um reflexo da própria natureza das operações mineiras, onde múltiplos fatores externos, desde as condições do terreno até à disponibilidade de equipamentos, influenciam diretamente a duração e a fluidez do processo.

Uma das primeiras diferenças observadas diz respeito à fase de carregamento. Em ciclos mais curtos, o material encontrava-se bem posicionado, permitindo à escavadora realizar passadas rápidas e consecutivas, com enchimento uniforme da caçamba. Já em ciclos mais longos, verificou-se a necessidade de reposicionamento da pilha, manobras adicionais da escavadora ou pequenas interrupções para corrigir a distribuição da carga. Estas diferenças, subtis na observação em campo, tornam-se evidentes nos registos de aceleração, onde o ritmo cadenciado das passadas é interrompido por períodos mais extensos de inatividade, em linha com a distinção entre ciclo mínimo e ciclo efetivo e com a incorporação de tempos de espera no tempo total de ciclo (Meixedo, 2005; Meixedo et al., 2016).

No transporte carregado, a variabilidade foi igualmente notória. O percurso curto entre a frente de lavra e o britador deveria, em teoria, garantir tempos homogêneos; contudo, registaram-se variações superiores a um minuto em alguns ciclos. As discrepâncias estiveram associadas a cruzamentos com outros veículos, diferenças de estilo de condução e alterações de velocidade em função do estado da via. Estes condicionantes operacionais e de via afetam diretamente o tempo de viagem e, por consequência, o tempo total de ciclo do camião.

As maiores variações, porém, ocorreram nas paragens intermédias (Idle). Em alguns ciclos, estas paragens foram residuais, noutros, representaram uma fração significativa do tempo total por vezes superior a 15%. Esta disparidade esteve associada principalmente a dois cenários: a espera do camião pela escavadora, quando esta necessitava de reorganizar a pilha antes de prosseguir a carga, e a acumulação de veículos junto ao britador, que provocava pequenas filas de espera para a descarga. Este padrão é coerente com a mobilidade de filas entre os nós de carga e descarga descrita para sistemas de carga-transporte em operação contínua (Meixedo, 2005; Meixedo et al., 2016)

A Figura 9 ilustra a comparação entre dois ciclos contrastantes: um exemplo de ciclo curto e eficiente, com tempos mínimos de espera, e um ciclo mais longo, onde as paragens intermédias representaram um gargalo significativo. A visualização mostra como, apesar de a sequência dos estados ser idêntica, a duração relativa de cada fase pode alterar de forma substancial o tempo total de ciclo.




Figura 18 - Comparação entre ciclo curto e ciclo longo (com tempos elevados sem atividade)

Estas variações revelam a importância de não analisar apenas médias, mas também a dispersão e a estrutura interna dos ciclos. Enquanto a média de cinco a seis minutos fornece uma visão global da produtividade, a análise de casos extremos permite identificar oportunidades concretas de melhoria. Se os ciclos mais eficientes representam o potencial máximo da operação, os ciclos mais longos denunciam constrangimentos específicos que podem ser alvo de intervenção.

Do ponto de vista operacional, a identificação destas variações oferece informações valiosas. Permite, por exemplo, avaliar se os tempos de espera se concentram sistematicamente em determinada fase ou se surgem de forma aleatória. No caso estudado, a tendência foi de acumulação de paragens em momentos críticos de interação entre equipamentos, destacando a relevância de uma melhor coordenação entre escavadora e frota de camiões. Esta constatação,

além de reforçar a validade do algoritmo, demonstra a utilidade prática da análise para o planeamento e gestão de operações em pedreiras.

5.3.4. Integração com Dados Espaciais

A análise cronológica dos ciclos ganha uma dimensão adicional quando os dados temporais são correlacionados com a posição espacial dos camiões no interior da pedreira. Esta integração permite validar a coerência dos estados identificados e, ao mesmo tempo, compreender melhor como a geografia do espaço de trabalho influencia a operação.

A Figura 19 apresenta a trajetória registada por GPS sobreposta sobre uma imagem de satélite usando como recurso o apple Maps, onde a variação de velocidade é representada por uma escala de cores. O traçado mostra de forma clara os deslocamentos entre a frente de lavra e o britador, bem como os pontos de paragem associados a carga e à descarga. Os segmentos de velocidade mais elevada correspondem ao retorno vazio, enquanto os trechos mais lentos representam o transporte carregado. Os pontos estáticos, destacados pela ausência de deslocamento, coincidem com os períodos classificados pelo algoritmo como *Loading* e *Crushing*.



Figura 19 - Sobreposição da trajetória do camião monitorizado com variação de velocidade (km/h).

Esta correspondência entre os estados cronológicos e a posição espacial confirma a consistência da segmentação. De facto, a análise espacial não revelou discrepâncias relevantes: sempre que o algoritmo identificou uma paragem para carregamento, a localização correspondia à frente de lavra, e quando identificou uma descarga, o ponto coincidiu com a zona do britador. Este alinhamento entre sinais e georreferenciação reforça a robustez do método e demonstra que a

lógica implementada não se limita a padrões matemáticos, mas traduz fielmente a realidade operacional.

Para além da validação, a integração dos dados espaciais oferece informações complementares sobre a operação. A curta distância entre a frente de lavra e o britador explica a brevidade das fases de transporte, ao mesmo tempo que amplifica o impacto de pequenas ineficiências. Manobras adicionais para alinhar o camião junto à escavadora ou para posicionar a caçamba no britador tornam-se relativamente mais significativas quando o trajeto principal é reduzido. Neste contexto, o mapeamento espacial evidencia a importância do ordenamento físico do espaço de trabalho na produtividade global.

A análise da trajetória também revelou variações de estilo de condução entre ciclos, visíveis nas diferenças de velocidade ao longo do mesmo percurso. Estas discrepâncias, associadas à experiência do operador ou ao tráfego local, contribuíram para a dispersão observada nos tempos de transporte. Assim, os dados espaciais não apenas validam a segmentação temporal, mas também ajudam a interpretar a origem das variações, ligando-as diretamente à geografia e à dinâmica da pedreira.

Pode-se assim dizer que a integração com dados de GPS demonstra que a operação não deve ser entendida apenas como uma sequência temporal, mas como uma interação entre tempo, espaço e recursos disponíveis. A sobreposição destas dimensões fornece uma visão mais completa do ciclo produtivo e cria oportunidades para análises futuras, como a otimização de rotas, o planeamento de acessos ou a avaliação do impacto do tráfego interno na eficiência global

[página propositadamente em branco]

Capítulo VI

Análise de Resultados e Considerações Finais

6. Análise de Resultados e Considerações Finais

6.1. Interpretação Geral dos Resultados Obtidos

A aplicação prática do algoritmo desenvolvido permitiu comprovar a sua capacidade para transformar dados brutos de sensores em informação estruturada e útil para a análise de operações de carga e transporte em pedreiras. A cronologia gerada demonstrou de forma clara que é possível identificar, com consistência, as fases fundamentais do ciclo produtivo: carregamento, transporte carregado, descarga, retorno vazio e períodos de inatividade.

O cruzamento entre a análise temporal e a validação espacial mostrou uma coerência notável. Os intervalos classificados como *Loading* coincidiram com as localizações da frente de lavra, enquanto os eventos de *Crushing* corresponderam à área do britador. A correspondência entre os resultados algorítmicos e as observações empíricas em campo reforça a robustez do método, que se revelou capaz de captar a dinâmica real da operação com elevado grau de fiabilidade.

Os tempos médios obtidos alinharam-se com referências da literatura e com as expectativas práticas para pedreiras de médio porte. A carga, com duração média de 5 minutos, e a descarga, com cerca de um minuto, enquadraram-se em valores reportados em estudos prévios. Da mesma forma, o ciclo completo apresentou média entre cinco e seis minutos, intervalo amplamente documentado em análises de sistemas de transporte semelhantes. Esta convergência não apenas valida o algoritmo, mas também atesta a representatividade do caso estudado face a cenários operacionais comparáveis.

Um aspeto relevante observado foi a variabilidade entre ciclos sucessivos. Embora a estrutura global seja estável, cada viagem apresentou pequenas diferenças na duração das fases, sobretudo na carga e nas paragens intermédias. Esta variação reflete a natureza dinâmica da operação mineira e confirma que a análise de médias deve ser complementada pela investigação de dispersões e

casos extremos. O algoritmo mostrou-se adequado para este fim, documentando tanto os ciclos mais eficientes como os mais penalizados por tempos de espera.

A interpretação global dos resultados permite, assim, concluir que o método desenvolvido cumpre o objetivo principal: oferecer uma ferramenta acessível e fiável para monitorizar ciclos de transporte em tempo quase real. Para além da validação científica, o valor desta abordagem reside no seu potencial de aplicação prática. A simplicidade dos sensores utilizados, combinada com a clareza das visualizações produzidas, torna a metodologia uma opção viável para operações de pequena e média escala que não dispõem de sistemas avançados de monitorização.

6.2. Eficiência do Algoritmo e Robustez das Heurísticas

A eficiência do algoritmo foi avaliada a partir da sua capacidade de identificar corretamente os estados operacionais e de reconstruir, sem omissões ou redundâncias, a sequência completa dos ciclos de transporte. Os resultados obtidos mostraram que a lógica implementada foi eficaz, tanto na deteção de eventos críticos como no encadeamento das fases, o que se refletiu numa elevada taxa de correspondência entre os dados processados e a realidade observada no terreno.

A identificação da carga, baseada na aceleração vertical, apresentou um desempenho consistente. Todos os episódios de enchimento registados em campo foram corretamente reconhecidos pelo algoritmo, sem ocorrência de falsos positivos. O padrão repetitivo das pazadas da escavadora, visível nos sinais de aceleração, reforçou a fiabilidade desta heurística, que se mostrou sensível o suficiente para captar tanto a macroestrutura da fase de *Loading* como os microeventos internos.

A fase de descarga, por sua vez, foi segmentada com base no ângulo da caçamba do camião. Esta decisão revelou-se adequada, já que todos os episódios de basculamento foram identificados sem fragmentação ou duplicação de eventos. A robustez desta heurística confirmou-se pela clareza com que o sinal angular distingue o movimento da caçamba relativamente a oscilações normais do veículo.

A distinção entre estados de movimento e paragem demonstrou também elevada precisão. O limiar de velocidade definido para classificar o estado de *Idle* mostrou-se suficientemente baixo para evitar confundir desacelerações com paragens reais, ao mesmo tempo que captou de forma adequada os períodos de inatividade junto à escavadora ou ao britador. O recurso a uma duração mínima para validar a carga e a fusão de paragens muito curtas contribuíram para reduzir a fragmentação do sinal, garantindo maior estabilidade à cronologia final.

Em termos globais, o algoritmo demonstrou elevada sensibilidade e especificidade. Por um lado, foi capaz de detetar todos os eventos relevantes registados durante a campanha experimental. Por outro, evitou criar estados artificiais ou interpretar como eventos produtivos sinais residuais e oscilações sem significado operacional. Esta combinação confere-lhe uma elevada fiabilidade prática, uma vez que os resultados produzidos são robustos o suficiente para apoiar decisões de gestão.

A robustez das heurísticas utilizadas é reforçada pelo facto de se basearem em variáveis simples, mas fortemente representativas da operação. Ao privilegiar grandezas como aceleração vertical, velocidade e ângulo da caçamba, o algoritmo minimizou a dependência de cálculos complexos ou parâmetros de difícil calibração. Esta escolha assegura a replicabilidade do método e a sua aplicabilidade em diferentes contextos, desde que sejam respeitadas as condições mínimas de monitorização.

Em síntese, a eficiência do algoritmo não se traduz apenas na sua capacidade de segmentar corretamente os ciclos, mas também na estabilidade das heurísticas utilizadas. A simplicidade metodológica revelou-se um fator de robustez, tornando o modelo menos vulnerável a falhas pontuais dos sensores e mais adaptável a cenários reais de operação.

6.3. Limitações dos Dados e Desafios de Segmentação

Apesar dos resultados positivos obtidos, a aplicação do algoritmo revelou algumas limitações que importa destacar. Estas não invalidam a validade da abordagem, mas devem ser reconhecidas como condicionantes da sua generalização e como pontos de atenção para futuras aplicações.

A primeira limitação está relacionada com a natureza dos dados disponíveis. A frequência de amostragem dos sensores utilizados foi suficiente para captar as macroestruturas do ciclo, mas revelou-se limitada para o registo de eventos de curta duração. Pequenas manobras de posicionamento ou microparagens inferiores a alguns segundos foram frequentemente suavizadas pelo algoritmo ou incorporadas em estados mais longos. Este aspeto não comprometeu a análise global, mas reduziu a granularidade dos resultados.

Outra restrição importante foi a dependência de limiares fixos para distinguir estados. Valores como 1 km/h para definir paragem ou 20° para identificar a descarga mostraram-se adequados no caso estudado, mas podem não ser universalmente aplicáveis. Em contextos distintos, com diferentes equipamentos ou condições de operação, seria necessária a recalibração destes

parâmetros. Esta rigidez representa um desafio, pois limita a transferibilidade imediata do algoritmo sem ajustes adicionais.

Do ponto de vista espacial, a curta distância entre a frente de lavra e o britador, embora favorável a ciclos curtos e repetitivos, reduziu a diversidade de cenários de transporte analisados. Este fator significa que algumas complexidades típicas de minas de maior escala, como trajetos longos, rampas acentuadas ou múltiplas frentes de lavra, não foram contempladas. Assim, embora os resultados sejam robustos para o caso em estudo, não podem ser extrapolados diretamente para operações de maior dimensão sem validação adicional.

Também se verificou uma limitação metodológica quanto à classificação de estados intermediários. Operações de manobra, como reposicionamento do caminhão junto à escavadora ou alinhamento no britador, foram absorvidas nas categorias de movimento ou paragem, sem distinção própria. Esta simplificação, embora prática, pode ocultar potenciais estrangulamentos, especialmente em ambientes onde as manobras consomem uma parte significativa do tempo de ciclo.

Finalmente, importa salientar a ausência de validação independente em larga escala. A correspondência entre os resultados do algoritmo e as observações em campo reforça a sua fiabilidade, mas uma validação sistemática, com recurso a cronometragem manual ou sensores adicionais de alta resolução, aumentaria a confiança científica no método.

Em conjunto, estas limitações não diminuem o mérito do algoritmo, mas apontam para desafios a considerar em futuras aplicações. Reconhecê-las é essencial para situar o contributo deste trabalho no contexto da investigação em engenharia mineira e para delinear estratégias de melhoria nos capítulos seguintes.

6.4. Recomendações de Melhoria e Trabalhos Futuros

A aplicação do algoritmo evidenciou o seu potencial, mas também apontou caminhos claros de evolução. Em primeiro lugar, recomenda-se a introdução de mecanismos adaptativos para calibrar automaticamente limiares como velocidade e ângulo de descarga, aumentando a precisão e a aplicabilidade em diferentes contextos. Em segundo lugar, a integração de dados adicionais, nomeadamente GPS combinado com aceleração, poderá enriquecer a análise, permitindo estudar rotas, distâncias percorridas e efeitos da topografia. A utilização de sensores complementares, como giroscópios ou sensores hidráulicos, poderá ainda reduzir ambiguidades. Adicionalmente, foi iniciada uma avaliação preliminar para estimar a cadência de pazadas diretamente a partir do sinal contínuo de aceleração, sem recorrer à série binária de eventos. Os

resultados foram inconclusivos nesta versão, mas abrem caminho a abordagens futuras como envelope-FFT e autocorrelação do envelope, aplicadas a janelas puras de carregamento. O notebook completo com esta exploração encontra-se disponível como anexo digital apenas para referência.

Outra linha de melhoria passa pelo recurso a técnicas de aprendizagem automática, capazes de reconhecer padrões mais complexos e distinguir estados atualmente agregados, como manobras de posicionamento. Este avanço aumentaria a granularidade e a adaptabilidade do modelo. Por fim, recomenda-se a realização de campanhas de validação em diferentes contextos mineiros e a exploração de uma aplicação em tempo quase real, integrada em plataformas de monitorização, permitindo apoiar decisões operacionais com indicadores contínuos. Em síntese, estas melhorias visam consolidar o algoritmo como uma solução escalável e prática, com contributo direto para a eficiência e sustentabilidade das operações mineiras.

6.5. Conclusões Finais

O presente trabalho teve como objetivo desenvolver e aplicar um algoritmo capaz de identificar automaticamente os ciclos operacionais de camiões em pedreiras a partir de dados recolhidos por sensores de baixo custo. Esse objetivo foi alcançado, demonstrando-se que uma abordagem baseada em heurísticas simples pode transformar sinais brutos em informação operacional útil e fiável.

A dissertação contribui em dois planos distintos. No plano científico, confirma a viabilidade do uso de sensores acessíveis para monitorizar operações mineiras, reforçando a literatura sobre métodos alternativos de análise de ciclos produtivos. No plano prático, oferece às empresas uma solução de baixo custo que pode apoiar a gestão diária, permitindo identificar estrangulamentos, reduzir tempos de espera e melhorar a coordenação entre escavadora e frota de transporte.

Apesar das limitações identificadas, nomeadamente a dependência de limiares fixos e a necessidade de maior granularidade em eventos de curta duração, o trabalho provou que é possível construir uma ferramenta robusta e replicável. As recomendações de melhoria apontam para a integração de dados adicionais, técnicas adaptativas e aplicações em contextos mais complexos.

Em síntese, a investigação demonstrou que a simplicidade metodológica pode ser aliada da eficácia, abrindo caminho para o desenvolvimento de soluções escaláveis que conciliem acessibilidade tecnológica com ganhos reais de eficiência e sustentabilidade no setor mineiro.

[página propositadamente em branco]

Capítulo VII

Referências

7.Referências

Aggarwal C.C. (2015). *Outlier analysis*. 2nd ed.. Springer.

Both C., & Dimitrakopoulos R. (2020). Joint stochastic short-term production scheduling and fleet management optimization for mining complexes. *Optimization and Engineering*, 21, 1717–1743.

Dewangan N., Mohanty A.R., & Kumar R. (2024). Dump truck activity recognition using vibration signal and convolutional neural network. *Automation in Construction*, 165, 105495.

Elijah K., Joseph G., Samuel M., & Mauti D. (2021). Optimisation of shovel-truck haulage system in an open pit using queuing approach. *Arabian Journal of Geosciences*, 14(11), 973.

Galiza A.C., Ramos L., Fonseca L., & Chaminé H.I. (2011). Geotecnia mineira de maciços rochosos fracturados para o controlo da qualidade do desmonte. *Revista Ingenium da Ordem dos Engenheiros*, 124 (Jul/Agos): 76-80.

Gawelski D., Jachnik B., Stefaniak P., & Skoczylas A. (2020). Haul Truck Cycle Identification Using Support Vector Machine and DBSCAN Models. In: *Advances in Computational Collective Intelligence (ICCCI 2020)*, Springer, 338–350.

Han J., Kamber M., & Pei J. (2012). *Data mining: concepts and techniques*. 3rd ed., Morgan Kaufmann.

Kim H., Lee, W.-H., Lee, C.-H., & Kim, S.-M. (2022). Development of Monitoring Technology for Mine Haulage Road through Sensor-Connected Digital Device and Smartphone Application. *Applied Sciences*, 12(23), 12166. <https://doi.org/10.3390/app122312166>

Kluyver T., Ragan-Kelley B., Pérez F., Granger B.E., Bussonnier M., Frederic J., & Willing C. (2016). Jupyter Notebooks – a publishing format for reproducible computational workflows. In: Loizides F., Schmidt B. (Eds.), *Positioning and Power in Academic Publishing: Players, Agents and Agendas* (pp. 87–90). IOS Press.

Leite A.J.M. (1998). *Transformação de um Objecto da Indústria Extractiva em Sistema. Algumas Consequências*. Departamento de Minas, Faculdade de Engenharia da Universidade do Porto, Porto, Portugal. (Tese de Doutoramento)

Markham G., Seiler K.M., Balamurali M., Hill A.J. (2022). Load-haul cycle segmentation with hidden semi-Markov models. In: *IEEE 18th International Conference on Automation Science and Engineering (CASE)*, 447–454.

Meixedo J.P. (2005). *Em torno da dinâmica não-linear de sistemas discretos de carga e transporte*. Departamento de Minas, Faculdade de Engenharia da Universidade do Porto, Porto, Portugal. (Tese de Doutoramento).

Meixedo J.P., Madureira C.M., Leite A.J.M., & Miranda H.S.B. (2016). Contributos para a criação de um modelo de simulação de sistemas de carga e transporte em explorações mineiras a céu aberto: uma perspectiva sistémica. In: H.I. Chaminé, M.J. Afonso, A.C. Galiza (eds.), *Eduardo Gomes (1931-2008): Engenheiro, Docente, Empreendedor - Uma Homenagem*. Coleção LABCARGA-Geo|2, Laboratório de

Cartografia e Geologia Aplicada & Departamento de Engenharia Geotécnica, Instituto Superior de Engenharia do Porto, Porto. p. 177 – 189.

Miranda H.S.B. (1986). Transportes mineiros: efeitos peculiares da disciplina de fecho do relevo. Departamento de Minas, Faculdade de Engenharia da Universidade do Porto, Porto, Portugal. (Tese de Doutoramento).

Mnzool C., Shaba H., Phiri W., & Nyirenda M. (2024). Performance evaluation of truck and shovel haulage systems in surface mining. *Mining Technology*, 133(1):45–60.

Muduli P.K. & Yegulalp T.M. (1996). Modeling truck-shovel systems as closed queuing network with multiple job classes. *International Transactions in Operational Research*, 3: 89–98.

Oppenheim A.V., & Schafer R.W. (2010). *Discrete-time signal processing*. 3rd ed., Upper Saddle River, NJ: Prentice Hall.

Pallant J. (2020). *SPSS survival manual*. 7th ed.. McGraw-Hill Education.

Pereira E. (1992). Notícia Explicativa da Carta Geológica de Portugal, escala 1/200.000, Folha 1. Serviços Geológicos de Portugal, Lisboa.

Smith S.W. (2003). *The scientist and engineer's guide to digital signal processing*. 2nd ed., California Technical Publishing.

Wei L., Sun H., Zhang Y., & Li C. (2024). Identifying truck activity from GPS data in mining operations. *Transportation Research Record*, 2678(2):112–123.

Zimroz R., Michalak A., Śliwiński P., & Kaniewski T. (2019). An algorithm for determining unloading cycles in dump truck. *IOP Conference Series: Earth and Environmental Science*, 362, 012111.

Ligações de internet (consultadas de Junho a Agosto de 2025)

GeeksforGeeks (2025): <https://www.geeksforgeeks.org/blogs/top-new-technology-trends/> (acedido em Junho de 2025)

Microsoft (2023). *Visual Studio Code – Documentation*. Disponível em: <https://code.visualstudio.com/docs> (acedido em Julho de 2025)

SciPy (2023). Butterworth filter design (scipy.signal.butter) — SciPy v1.16.2 Reference Guide. Disponível em: <https://docs.scipy.org/doc/scipy/reference/generated/scipy.signal.butter.html> (acedido em Julho de 2025)

Ferramentas de Inteligência Artificial (IA)

OpenAI (2025). ChatGPT (Aug 15 version) [Large language model]: <https://chat.openai.com/chat> (consultado em 14 de Agosto de 2025).

[página propositadamente em branco]

DECLARAÇÃO DE INTEGRIDADE

DECLARAÇÃO DE INTEGRIDADE

Eu, **JOSÉ AMARAL LOURENÇO MANUEL**, N.º CC: **32148451**,

Declaro ter conduzido e desenvolvido este trabalho académico com integridade e ética. Não plagiei ou apliquei qualquer forma de uso indevido de informações ou falsificação de resultados ao longo do processo que levou à elaboração da dissertação/projeto/estágio.

Declaro ainda que pontualmente recorri a ferramentas de inteligência artificial (IA) — texto, imagem, vídeo ou outro formato — apenas para fins académicos de pesquisa avançada de tópico específico e ainda fiz a devida citação deste recurso sem colocar em causa os direitos de autor ou uso indevido de informações ou falsificação de conteúdos.

Declaro que o trabalho apresentado neste documento é original e de minha autoria, não tendo sido utilizado anteriormente para nenhum outro fim.

Declaro ainda que tenho pleno conhecimento do Código de Conduta Ética do P.PORTO.

ISEP, Porto, 22 de Setembro de 2025.

JOSÉ AMARAL LOURENÇO MANUEL