



Detecção automática e classificação de trincas em pelotas de minério de ferro

Como otimizar o processo de detecção de trincas em pelotas de ferro?

A empresa enfrenta dificuldades em: identificar, classificar e quantificar trincas nas pelotas de minério. Hoje, esse processo é feito de maneira manual, com auxílio de microscopia visual. Essa limitação causa impactos diretos:

- detecção tardia de problemas no processo produtivo;
- baixa representatividade das amostras, que não refletem a variabilidade real do processo;
- incapacidade de identificar tendências em tempo real;
- variabilidade humana na análise;
- ausência de massa de dados para modelagem preditiva;
- riscos operacionais decorrentes de ajustes reativos

Sendo assim, a ausência de um método automatizado e contínuo de inspeção é um fator crítico que compromete produtividade, estabilidade do processo e desempenho de mercado.



Buscamos uma solução capaz de: identificar, classificar e quantificar trincas em pelotas queimadas de forma automática, contínua e representativa, reduzindo a dependência de análises laboratoriais manuais e permitindo ajustes rápidos no processo de forno e manuseio. Devido as restrições de prazo e riscos de instalação em campo, a **POC deverá priorizar validações em bancada (laboratório)** usando amostras menores para validar o protótipo e sua acurácia. Após obter resultados preliminares e um conceito de infraestrutura, a solução poderá evoluir para um protótipo em campo (amostrador ou em linha) como fase subsequente.

Em termos práticos, **estamos em busca de uma tecnologia que seja capaz de:**

- Operar inicialmente em ambiente de bancada/laboratorial para validação do protótipo e coleta de resultados preliminares.
- Fornecer um conceito de infraestrutura (projeto conceitual) para futura instalação em linha ou no amostrador.
- Identificar trincas em amostras controladas com alta confiabilidade.
- Classificar o tipo de trinca (térmica ou de resiliência).
- Fornecer indicadores que suportem validação técnica e decisões de evolução para campo.
- Aumentar a representatividade e a velocidade da análise em relação ao método manual.
- Gerar um dataset estruturado, fundamental para evoluções futuras com modelos preditivos.
- Contribuir diretamente para a melhoria de finos, CCS, tamboramento e permeabilidade no cliente.

Hipóteses:

Hipótese 1 – Confiabilidade na detecção e classificação das trincas

Se o desafio estiver sendo mitigado, então a solução deverá identificar e classificar trincas térmicas e de resiliência com acurácia superior a 70% em relação ao diagnóstico laboratorial manual, medida em amostras representativas.

Hipótese 2 – Redução do tempo de resposta para ajustes de processo

Se o desafio estiver sendo mitigado, então o tempo entre o surgimento das trincas e a identificação do problema será reduzido em pelo menos 70%, permitindo ações corretivas antes que lotes inteiros sejam comprometidos.

Hipótese 3 – Aumento da representatividade das análises de qualidade

Se o desafio estiver sendo mitigado, então a quantidade de pelotas analisadas por ciclo será pelo menos 10 vezes maior do que o volume avaliado no método manual, resultando em maior representatividade e menor variabilidade estatística.

Hipótese 4 – Previsibilidade e estabilidade operacional

Se o desafio estiver sendo mitigado, então haverá redução da variabilidade nos indicadores de qualidade quando comparados ao histórico do período anterior, conforme análise mensal.

Hipótese 5 – Detecção precoce de instabilidade térmica ou de manuseio

Se o desafio estiver sendo mitigado, então serão identificadas variações anormais na incidência de trincas antes que essas variações apareçam nos indicadores finais (finos, CCS e tamboramento), com antecedência mínima definida pela equipe de processo.

Riscos:

- **Baixa acurácia na detecção e classificação:**

Se a tecnologia proposta não alcançar acurácia necessária, trincas poderão passar de maneira despercebida ou ser classificadas de forma incorreta. Isso tornará a tomada de decisão lenta e imprecisa, prejudicando a estabilidade do processo térmico e a qualidade final das pelotas.

- **Dificuldade de diferenciar trincas térmicas e de resiliência**

As características visuais e físicas de cada tipo de trinca podem ser sutis. Caso a solução não seja capaz de distinguir ambas com clareza, perderemos a capacidade de identificar a causa raiz e de definir ajustes específicos no forno ou no manuseio.

- **Falta de representatividade do dataset coletado**

Se a coleta de imagens ou leituras não abranger um volume suficiente de pelotas ou diferentes cenários operacionais, o modelo poderá se tornar pouco confiável, prejudicando análises avançadas ou modelos preditivos futuros.

- **Sobrecarga de dados e dificuldades na gestão do dataset**

A geração contínua de imagens ou leituras pode criar volumes de dados muito altos. Sem boa governança, armazenamento e padronização, isso pode dificultar análises futuras e elevar custos de TI.

Riscos:

- **Resistência ou dificuldade de adaptação da equipe operacional**

A introdução de um sistema automatizado pode gerar dúvidas, resistência ou mau uso por parte das equipes. Caso não haja treinamento efetivo ou clareza dos benefícios, a solução pode não ser utilizada conforme projetado, reduzindo a eficácia operacional.

- **Dependência de infraestrutura adicional ou não disponível**

Algumas tecnologias podem demandar espaço físico, energia elétrica, pontos específicos de instalação ou sistemas de proteção não previstos. Caso a infraestrutura atual não suporte a solução, isso pode ampliar custos ou inviabilizar a implantação.

- **Divergência entre leitura automatizada e leitura laboratorial**


Se os resultados da solução não convergirem de forma consistente com os resultados do laboratório, pode haver perda de confiança do time técnico e dificuldades na adoção da solução como referência oficial.

- **Falhas na captura contínua da linha ou do amostrador**

Problemas operacionais como desalinhamento, vibração, sujeira no sensor ou falhas de comunicação podem interromper a coleta contínua, gerando lacunas na análise e comprometendo a confiabilidade do sistema.

FINDESLAB3.

 @findeslab

 (27) 99722-3953

 findeslab.com.br

 findeslab@findes.org.br