Nova geração de máquinas de limpeza de grãos: sistema integrado de visão computacional e inteligência para operação, monitoramento e otimização do processo em limpeza de grãos

Jacson Vargas

Crivum EA69 · DOI 10.67665/crivum.2antx99o · publicada em 05/09/2026

1. Introdução

O processamento e o beneficiamento de grãos exigem equipamentos capazes de operar sob condições variáveis de produto, alimentação e ambiente. No caso das máquinas de limpeza de grãos, essas variações aparecem na quantidade de impurezas, na umidade, no tamanho dos grãos, nos diferentes tipos de cereais, nas condições de alimentação e nos parâmetros de operação. Em máquinas convencionais, o acompanhamento dessas condições depende significativamente da experiência do operador e de inspeções realizadas durante o funcionamento do equipamento.

A Agriaço Metalúrgica atua no desenvolvimento e fabricação de máquinas de limpeza destinadas ao processamento e beneficiamento de produtos agrícolas, com linha de equipamentos em capacidades de 40, 60, 120, 180, 240 e 360 toneladas por hora. A experiência acumulada no desenvolvimento dessas máquinas, associada à comercialização de 865 equipamentos na América Latina, permitiu identificar oportunidades de evolução tecnológica relacionadas à integração de inteligência artificial, automação, visão computacional e uso de dados no desempenho operacional dos equipamentos.

O projeto relatado neste trabalho nasceu da necessidade de aproximar a engenharia tradicional de máquinas das tecnologias digitais. A proposta central foi desenvolver uma máquina capaz de observar e interpretar o próprio processo de limpeza, transformando informações visuais obtidas diretamente no equipamento em dados úteis para acompanhamento, tomada de decisão e otimização operacional.

2. Estado da arte e lacuna tecnológica

A aplicação de visão computacional na agricultura e no processamento de alimentos não é nova. Sistemas de machine vision vêm sendo pesquisados para avaliação de qualidade, identificação, classificação e separação de grãos.

Vithu e Moses (2016) revisaram aplicações de sistemas de visão de máquina para avaliação da qualidade de grãos, mostrando sua utilização em identificação, classificação e operações relacionadas à limpeza e separação. Esses sistemas normalmente combinam aquisição de imagens, iluminação e processamento computacional para extrair características dos produtos.

Velesaca et al. (2021) apresentaram uma revisão abrangente sobre classificação de grãos por visão computacional, abrangendo diferentes estratégias de aquisição de imagens, formação de ground truth e técnicas de classificação. O trabalho demonstra que a classificação visual de grãos constitui um campo consolidado de pesquisa.

Patrício e Rieder (2018), em revisão sistemática sobre visão computacional e inteligência artificial aplicada às principais culturas de grãos, identificaram aplicações relacionadas à qualidade dos grãos, fenotipagem e detecção de doenças, além de oportunidades de utilização de técnicas avançadas de inteligência artificial.

Mais recentemente, Wang (2026) analisou a evolução das aplicações de visão de máquina e deep learning para inspeção da qualidade de grãos, desde técnicas tradicionais baseadas em características de cor, morfologia e textura até redes neurais convolucionais e arquiteturas mais recentes. O trabalho também aponta desafios relacionados à transferência das soluções desenvolvidas em condições controladas para aplicações industriais reais.

Existem igualmente soluções comerciais consolidadas de classificação óptica. A linha SORTEX, da Bühler, por exemplo, utiliza inspeção óptica para classificação por características do produto e remoção de materiais indesejáveis, podendo empregar recursos de machine learning e rastreamento de produto.

Portanto, a originalidade reivindicada neste projeto não está na utilização isolada de câmeras, visão computacional ou inteligência artificial para reconhecer grãos e impurezas.

A lacuna tecnológica explorada pela AgriAço está em utilizar a percepção visual do comportamento macroscópico da camada de produto durante o próprio processo de peneiramento como uma variável de processo de uma máquina de limpeza de alta capacidade, integrando essa informação a sensores e elementos de atuação da máquina.

Enquanto uma classificação óptica tradicional procura decidir, por exemplo, se determinado grão deve ser aceito ou rejeitado, o desenvolvimento aqui apresentado busca responder a outra questão:

“Em que condição operacional encontra-se o processo de peneiramento e como a própria máquina pode responder a essa condição?”

3. Problema e contexto operacional

O produto recebido em uma unidade armazenadora apresenta grande variabilidade. Essa variabilidade pode ocorrer em razão do teor de impurezas, da umidade, do tamanho dos grãos, da variedade dos cereais e das condições de alimentação do equipamento. Em uma máquina convencional, essa mudança contínua não é acompanhada de modo objetivo e permanente pelo próprio equipamento.

A limitação principal está no fato de que a máquina convencional não “enxerga” o próprio processo. A regulagem do fluxo de entrada tende a ser manual, a alimentação é baseada em uma condição geral de recebimento, o operador não acompanha continuamente as peneiras e o comportamento do fluxo não é identificado de modo permanente. Como consequência, podem ocorrer situações de subcarga, sobrecarga ou descarte de grãos bons juntamente com impurezas.

O desafio formulado pela Agriaço pode ser sintetizado na seguinte questão: como manter a capacidade e a eficiência no processo de limpeza de forma contínua e objetiva, permitindo identificar situações operacionais e tomar ações com maior rapidez? A resposta buscada foi utilizar a própria máquina como fonte de informações sobre o processo, incorporando uma camada tecnológica de percepção, interpretação e automação.

4. Hipótese de desenvolvimento

A hipótese do projeto foi que, se fosse possível capturar e interpretar continuamente imagens do processo de limpeza, seria possível aumentar a capacidade e a eficiência da máquina, além de utilizar essas informações para otimizar sua operação. A proposta representou a passagem de uma percepção predominantemente humana para uma percepção inteligente apoiada por câmeras, sensores, visão computacional e inteligência artificial.

Essa hipótese envolveu desafios tecnológicos específicos. Entre eles, destacaram-se: definir onde instalar as câmeras; obter imagens confiáveis durante o funcionamento; lidar com poeira, vibração e variações de iluminação; determinar quais características do produto deveriam ser identificadas; transformar imagens em dados; treinar a inteligência artificial para reconhecer diferentes condições; validar os resultados; e integrar a tecnologia à arquitetura da máquina.

O ciclo adotado no desenvolvimento seguiu uma lógica de hipótese, experimentação, aprendizado, desenvolvimento e validação. Essa sequência permitiu que a solução fosse ajustada a partir do comportamento real do produto e das condições efetivas encontradas em campo.

5. Solução desenvolvida

A solução desenvolvida integra à máquina de limpeza um sistema composto por câmeras, sensores, processamento de imagens, visão computacional, inteligência artificial e automação. As câmeras são instaladas em pontos estratégicos do equipamento para capturar informações visuais relacionadas ao processo. Os sensores acompanham a condição de alimentação na entrada da máquina por meio de inversor de frequência.

As imagens capturadas são processadas por um sistema computacional que utiliza algoritmos de visão computacional e inteligência artificial para identificar padrões previamente definidos. O sistema foi concebido para reconhecer a massa de grãos, gerar informações sobre percentual de grãos, percentual de impurezas e ocupação total, além de apoiar ações como alerta sonoro, envio de e-mail ou comunicação por celular, regulagem automática do fluxo de entrada e regulagem automática da divisão

de grãos nos decks.

A inovação não está apenas na presença de câmeras, mas na integração da percepção visual e dos dados de processo à própria arquitetura da máquina. A máquina deixa de ser apenas um equipamento que executa o processo e passa a atuar como um equipamento que observa, interpreta e pode apoiar o controle do processo.

6. Diferença em relação à máquina convencional

Na máquina convencional, a operação depende de ajustes manuais e da capacidade do operador de observar o comportamento do processo. A alimentação ocorre com base em uma condição geral de recebimento, sem acompanhamento contínuo das peneiras. Essa configuração pode gerar perda de eficiência quando a máquina opera fora da condição adequada, seja por subcarga, sobrecarga ou descarte indevido de grãos bons.

Na máquina inteligente proposta, câmeras monitoram o processo, sensores acompanham a alimentação, informações são processadas, a inteligência artificial interpreta o comportamento observado e a alimentação pode ser controlada. O objetivo é manter o processo em condição mais adequada e ampliar o aproveitamento da área das peneiras.

A evolução tecnológica, portanto, não se limita à melhoria de componentes mecânicos. Ela acrescenta ao equipamento uma camada de percepção e inteligência operacional. Em vez de depender exclusivamente da observação contínua do operador, a máquina passa a capturar informações, interpretar o comportamento do produto e utilizar esses dados para melhorar a operação.

7. Jornada de PDI

Validação em duas configurações reais de máquinas

PROTÓTIPO 01 — SANTA ROSA/RS

Cooperativa Cotrirosa - Unidade Sede ML360 — 360 t/h 6 decks;

6 câmeras — uma por deck;

iluminação dedicada;

sensores de nível;

controle do volume de alimentação;

sensores de temperatura em mancais/rolamentos;

acompanhamento durante a safra de soja;

115 horas de operação acompanhadas presencialmente;

2 profissionais de P&D AgriAço em campo.

PROTÓTIPO 02 — CONDOR/RS

UBS Costa Beber ML180 — 180 t/h 3 decks;

3 câmeras — uma por deck;

iluminação dedicada;

sensores de pressão;

instrumentação do sistema pneumático/câmara de aspiração;

atuador elétrico para controle do ar;

quadro elétrico customizado para experimentação;

aquisição de imagens;

acesso remoto via web/cloud

8. Ecossistema de inovação

Etapa 1 Aquisição de imagens reais As câmeras registram o comportamento do produto durante a operação.

Etapa 2 Rotulagem humana Pessoas treinadas identificam nas imagens:

grão | impureza | ocupação | condição do processo Etapa 3 Construção da base de treinamento As imagens classificadas alimentam o conjunto de dados Etapa 4 Treinamento do algoritmo O sistema aprende padrões associados às diferentes condições observadas.

Etapa 5 Interpretação O algoritmo evolui para identificar automaticamente características do fluxo e gerar indicadores relacionados à ocupação/capacidade da máquina

O desenvolvimento utiliza aprendizado supervisionado baseado em imagens reais do processo. A construção da base de conhecimento ocorre por meio da rotulagem das imagens e do treinamento progressivo do algoritmo para reconhecimento dos padrões observados sobre as peneiras.

A Arquitetura logica da programação, posso citar alguns formatos utilizados:

MySQL | Ruby | C# | VueJS

9. Experimentação e aprendizados

O desenvolvimento foi conduzido de forma experimental. Durante os testes, foram avaliados o posicionamento das câmeras, o campo de visão, a iluminação, as condições de operação, a qualidade das imagens, a presença de poeira, o ambiente com vibração, as diferentes características do produto, a capacidade de identificação dos padrões e a confiabilidade das informações geradas.

A experimentação evidenciou problemas práticos importantes. Entre eles, o material registra a necessidade de troca do tipo de câmera, a necessidade de refazer parte elétrica com isolamento de cabos de sensores e câmera, situações de embuchamento da máquina em operação, embuchamento do elevador de alimentação, indisponibilidade de dados e vídeos em nuvem, testes de conectividade em campo, testes online e reprogramação da lógica de cloud.

Esses aprendizados reforçam uma característica típica de projetos de PDI aplicados a máquinas industriais: mesmo com documentação e planejamento de testes de protótipo, surgem novas condições em campo. A solução precisou ser ajustada diante de aspectos ambientais, operacionais e de integração que só se tornam plenamente visíveis durante a operação real.

10. Indicadores e ganhos potenciais estimados

O material apresenta um placar de resultados com ganhos potenciais estimados para a aplicação da inteligência ao processo. As estimativas foram calculadas para uma máquina ML240 operando com soja a 240 toneladas por hora, jornada de 9 horas por dia, referência salarial do Rio Grande do Sul, perda evitada de 0,01%, produtividade recuperada de 2%, cálculo mensal com 22 dias e semanal com 5 dias. O preço de referência da soja considerado foi de R$ 153,20 por saca de 60 kg no Rio Grande do Sul. O próprio material ressalta que os resultados devem ser validados para cada unidade armazenadora.

O primeiro indicador é a otimização de mão de obra. A operação assistida é estimada como capaz de reduzir de dois para um a necessidade de operador dedicado, com ganho potencial aproximado de R$ 3,6 mil por mês.

O segundo indicador é a redução potencial de perdas. O material estima até 4,75 toneladas por mês de soja boa preservada, associadas a aproximadamente R$ 12,1 mil por mês. A lógica operacional desse ganho está ligada à identificação e ao controle de situações em que grãos bons podem ser descartados juntamente com impurezas.

O terceiro indicador é a recuperação de produtividade. Considerando uma jornada de 9 horas e a hipótese de a máquina deixar de perder produtividade média de 2%, o material estima um potencial de recebimento médio adicional de 216 toneladas por semana, equivalente a 43,2 toneladas por dia.

Esses resultados devem ser lidos como estimativas potenciais, não como validação universal de desempenho. A efetividade dos ganhos depende das condições de cada unidade armazenadora, do tipo de produto, da forma de operação, do nível de variação do produto recebido e da maturidade da integração tecnológica no ambiente produtivo.

11. Propriedade intelectual

O desenvolvimento tecnológico da AgriAço possui relação com conhecimentos e soluções de engenharia previamente desenvolvidos pela organização.

Entre os ativos de propriedade intelectual associados à trajetória tecnológica encontra-se o pedido brasileiro BR 20 2022 024607-1.

Para fins deste trabalho, a existência desse ativo é apresentada como evidência da atividade de desenvolvimento e proteção de conhecimento tecnológico.

A delimitação exata de sua relação com a arquitetura apresentada neste case deve considerar o conteúdo das reivindicações e do relatório descritivo do respectivo pedido, evitando atribuir à proteção um escopo superior ao formalmente reivindicado.

12. Impactos esperados

No plano operacional, o principal impacto é o monitoramento contínuo do comportamento do produto. A máquina passa a gerar informações que antes dependiam de observação manual e descontínua, permitindo melhor acompanhamento do processo.

No plano da produtividade, a solução busca maior aproveitamento da capacidade da máquina e da área das peneiras. Ao identificar condições inadequadas de alimentação ou distribuição, o sistema pode apoiar ajustes que reduzam perdas de capacidade.

No plano da qualidade, a tecnologia cria a possibilidade de manter melhores condições de limpeza diante das variações do produto. Como o produto recebido muda continuamente, a capacidade de perceber essas mudanças em tempo real pode apoiar decisões mais rápidas e consistentes.

No plano de perdas, o sistema atua sobre a identificação de situações em que grãos bons podem ser descartados junto com impurezas. A redução desse descarte indevido é uma das contribuições econômicas centrais do projeto.

No plano energético, o material aponta a possibilidade de operação mais eficiente, evitando condições inadequadas de funcionamento. No plano tecnológico, o projeto cria uma base de tecnologia para futuras máquinas inteligentes da Agriaço, com uso de MySQL, Ruby, C#, VueJS, sensores, câmeras, visão computacional, inteligência artificial e automação.

13. Escala, replicabilidade e próximos passos

A tecnologia foi concebida para aplicação na linha de máquinas de limpeza da Agriaço, contemplando capacidades de 40, 60, 120, 180, 240 e 360 toneladas por hora. O projeto é apresentado como uma primeira aplicação que pode evoluir para uma plataforma de máquinas inteligentes.

Na fase atual, segundo o material, a solução ainda não está em condição comercial. O potencial de evolução inclui diagnóstico, monitoramento, recomendação, otimização contínua, controle automático e comercialização futura.

A replicabilidade não se limita à função específica de uma única máquina. O material indica aplicações futuras em máquinas de limpeza, classificação, movimentação, monitoramento de processos e manutenção baseada em dados. O principal legado é a capacidade tecnológica construída pela Agriaço para incorporar inteligência aos seus equipamentos.

14. Limitações

O caso apresenta limitações importantes. A primeira é que os ganhos econômicos e produtivos são estimativas potenciais, calculadas com base em premissas específicas para a ML240 operando com soja a 240 toneladas por hora. O próprio material informa que os resultados devem ser validados para cada unidade armazenadora.

A segunda limitação está na maturidade comercial. A tecnologia ainda não está em condição comercial no momento descrito, o que indica necessidade de continuidade dos testes, validação operacional, estabilização do sistema e consolidação da integração entre sensores, câmeras, processamento, nuvem e automação.

A terceira limitação decorre das condições de campo. Poeira, vibração, iluminação, conectividade,

embuchamento, qualidade de imagens e interferências elétricas afetaram o desenvolvimento e exigiram ajustes. Esses fatores mostram que a robustez da solução depende de validação contínua em ambientes reais de operação.

A quarta limitação está na ausência, no material apresentado, de uma base quantitativa completa de validação experimental. Há estimativas e aprendizados de campo, mas não são apresentados resultados estatísticos comparativos, séries históricas de desempenho ou métricas detalhadas de acurácia da inteligência artificial. Assim, as conclusões devem ser interpretadas como relato de desenvolvimento tecnológico e potencial de impacto, não como demonstração experimental conclusiva em escala comercial.

15. Conclusão

O projeto da nova geração de máquinas de limpeza de grãos da Agriaço representa a transformação de uma máquina convencional em uma plataforma inteligente de processamento de grãos. A inovação combina engenharia mecânica, sensores, automação, visão computacional, processamento de dados e inteligência artificial para enfrentar um desafio real do beneficiamento agrícola: a grande variabilidade das condições de alimentação e a dificuldade de monitoramento contínuo do processo.

A contribuição central do caso está em deslocar a máquina de uma função puramente executora para uma função também perceptiva e interpretativa. Ao capturar imagens, processar dados e reconhecer padrões, o equipamento passa a fornecer informações para acompanhamento, alertas, tomada de decisão e possíveis estratégias de controle automático.

Os ganhos potenciais estimados indicam oportunidades em mão de obra, redução de perdas, recuperação de produtividade, qualidade operacional e criação de uma base tecnológica para futuras aplicações. No entanto, a consolidação desses ganhos depende de validação em cada unidade armazenadora, avanço da maturidade comercial e continuidade dos testes em campo.

Como case nacional de inovação, o projeto mostra a aplicação de tecnologias digitais ao agronegócio industrial brasileiro, partindo de um problema prático de operação e construindo uma solução integrada ao equipamento. Seu legado mais relevante é a capacidade adquirida de incorporar inteligência aos equipamentos, abrindo caminho para novas aplicações em limpeza, classificação, movimentação, monitoramento de processos e manutenção baseada em dados.