

Nexa Vision

Inteligência Artificial para Agricultura Digital

Como satélites, drones, robôs, índices de vegetação e visão computacional transformam imagens em decisões.



Nexa Vision






APRESENTAÇÃO

Dados agrícolas precisam virar decisões

Um guia visual sobre sensoriamento remoto, visão computacional e inteligência artificial aplicada ao campo.



A agricultura produz um volume crescente de imagens, mapas, leituras meteorológicas e registros operacionais. Isolados, esses dados têm utilidade limitada. Quando são organizados, comparados no tempo e interpretados por modelos de inteligência artificial, passam a revelar padrões que ajudam a priorizar vistorias, compreender a variabilidade da lavoura e documentar decisões.

O Nexa Vision é a plataforma de visão computacional e análise espacial da Convex Robótica. Este e-book apresenta seus fundamentos, o fluxo técnico previsto e exemplos de aplicação. A plataforma encontra-se em desenvolvimento; as telas, indicadores e diagnósticos mostrados aqui são representações conceituais do produto e de seu roadmap.



SUMÁRIO

01	Agricultura digital	5-10
----	---------------------	------

02	Sensoriamento remoto	11-20
----	----------------------	-------

03	Índices de vegetação	21-31
----	----------------------	-------

04	Inteligência artificial	32-43
----	-------------------------	-------



SUMÁRIO

05	Plataforma Nexa Vision	44-57
06	Aplicações por cultura e diagnóstico	58-67
07	Futuro da agricultura autônoma	68
08	Glossário, referências e Convex	69-70



01

AGRICULTURA DIGITAL


Antes dos modelos e dos mapas existe uma pergunta fundamental: como transformar observação em decisão agronômica?



1.1

Uma nova camada de inteligência sobre a lavoura

A transformação não começa com o algoritmo, mas com a capacidade de observar melhor e agir no momento correto



A mecanização ampliou a capacidade física da agricultura. A digitalização amplia sua capacidade de percepção. Câmeras, satélites, sensores e máquinas conectadas registram diferenças de vigor, temperatura, umidade, população de plantas e qualidade operacional em uma escala impossível de acompanhar apenas por inspeção manual.

A inteligência artificial não substitui o conhecimento agrônomo. Ela funciona como uma camada de triagem e análise: encontra padrões, organiza evidências e indica onde a atenção humana pode gerar maior valor. O resultado esperado é uma gestão mais rastreável, com decisões apoiadas por mapas, séries temporais e registros georreferenciados.



1.2

Os desafios que pressionam o campo

Custos, clima, mão de obra e variabilidade espacial exigem uma gestão mais rápida e precisa.

CUSTO

Priorizar intervenções onde o retorno é maior.

CLIMA

Acompanhar mudanças e estresse ao longo do ciclo.

MÃO DE OBRA

Direcionar equipes para pontos críticos.

ESCALA

Observar grandes áreas de forma consistente.

RASTREABILIDADE

Registrar evidências e decisões.

TEMPO

Reduzir o intervalo entre sinal e ação.

Uma mesma propriedade reúne solos, relevo, histórico de manejo e respostas fisiológicas diferentes. Tratar toda a área como homogênea pode esconder perdas localizadas e elevar o consumo de insumos. Ao mesmo tempo, janelas operacionais curtas e eventos climáticos intensos reduzem o tempo disponível para detectar e corrigir problemas.


O monitoramento digital procura responder quatro perguntas: onde existe uma anomalia, quando ela surgiu, como está evoluindo e qual evidência deve orientar a vistoria. O ganho não está apenas em gerar um mapa, mas em conectar o mapa à rotina de campo.



1.3

Agricultura de precisão e agricultura digital

A precisão organiza a variabilidade; o digital conecta dados, pessoas e processos.



Agricultura de precisão utiliza coordenadas, sensores e mapas para reconhecer que a lavoura não responde de maneira uniforme. Agricultura digital amplia esse conceito ao integrar plataformas, históricos, automação, conectividade e inteligência artificial.


Na prática, as duas abordagens são complementares. Um mapa de vigor pode indicar uma região diferente do restante do talhão. Dados de solo, clima, imagens de alta resolução e histórico de produtividade ajudam a investigar a causa. O Nexa Vision foi pensado para atuar justamente nessa etapa de integração e interpretação.



1.4

O ciclo do dado agrícola

Uma captura só gera valor quando percorre um fluxo confiável até a decisão.



O ciclo começa na aquisição: uma imagem de satélite, um voo de drone, uma câmera instalada em robô ou uma leitura meteorológica. Em seguida vêm organização, correção, georreferenciamento e controle de qualidade. Somente depois os modelos calculam índices, detectam objetos ou segmentam regiões.


A saída técnica precisa ser traduzida em produto: mapas individuais, indicadores, alertas e relatórios. O ciclo se fecha com a confirmação em campo. Essa confirmação melhora a interpretação agrônômica e, quando incorporada ao dataset, também pode melhorar futuras versões dos modelos.



1.5

Integração é mais importante que quantidade

Muitas camadas desconectadas aumentam complexidade; camadas comparáveis aumentam entendimento.



Um NDVI isolado mostra variabilidade de biomassa, mas não explica sozinho a causa. Uma imagem RGB detalhada pode mostrar sintomas visuais, mas não revela toda a dinâmica temporal. Uma estação meteorológica registra o ambiente, porém não indica automaticamente como cada parte do talhão respondeu.

O valor surge ao alinhar essas evidências no espaço e no tempo. A arquitetura do Nexa Vision prevê combinar imagens, índices, clima, metadados da missão e histórico do talhão em uma interface única, reduzindo o esforço necessário para transformar sinais dispersos em hipóteses de manejo.



02

SENSORIAMENTO REMOTO


Diferentes sensores observam diferentes propriedades da lavoura. Escala, resolução e protocolo definem o que pode ser inferido.



2.1

Como os sensores enxergam a lavoura

Cada sensor registra uma parte diferente da interação entre luz, planta e ambiente.



O olho humano percebe principalmente o espectro visível. Sensores agrícolas podem registrar também infravermelho próximo, red edge, infravermelho de ondas curtas e radiação térmica. Essas bandas respondem de forma diferente à clorofila, estrutura foliar, água, solo e temperatura.


Nenhuma banda é universalmente superior. A escolha depende da pergunta. RGB oferece interpretação intuitiva e alta resolução; NIR e red edge ampliam a leitura da vegetação; termografia ajuda a investigar temperatura de dossel e possíveis sinais de estresse. O Nexa Vision organiza essas fontes como camadas complementares.



2.2

O espectro eletromagnético

A planta absorve, transmite e reflete energia em proporções que mudam conforme sua estrutura e condição.



A região visível está associada às cores percebidas pelo olho humano. A clorofila absorve fortemente parte da luz vermelha e azul, enquanto a estrutura interna das folhas reflete uma parcela relevante do infravermelho próximo. Essa diferença sustenta vários índices de vegetação.


Red edge ocupa a transição entre o vermelho e o NIR e pode ser útil em situações de dossel mais desenvolvido. SWIR responde à presença de água em tecidos e solo, enquanto sensores térmicos medem radiação relacionada à temperatura aparente da superfície.



2.3

Reflectância: a assinatura dos alvos

Vegetação saudável, vegetação sob estresse, solo e água apresentam curvas espectrais distintas.



Reflectância é a proporção da energia incidente que retorna ao sensor. Em uma folha saudável, a absorção no vermelho tende a ser alta e a reflectância no NIR, elevada. Quando a estrutura ou a fisiologia da planta muda, a curva também pode mudar.


A interpretação deve considerar iluminação, atmosfera, ângulo de aquisição, umidade, estágio fenológico e calibração. Por isso, comparar valores absolutos entre sensores ou datas sem padronização pode produzir conclusões incorretas. O Nexa Vision deve registrar metadados e aplicar rotinas de qualidade antes da análise.



2.4

Satélites: escala e recorrência

A visão orbital permite acompanhar grandes áreas e construir séries temporais consistentes.






2.5

Drones: detalhe sob demanda

O voo aproxima o sensor da lavoura e permite capturas em resolução centimétrica ou milimétrica, conforme altura e câmera.



Drones oferecem flexibilidade de horário, área e sensor. Com planejamento adequado, as imagens são transformadas em ortomosaicos, modelos de superfície e mapas multiespectrais. Sobreposição, velocidade, luz, vento e calibração influenciam diretamente o resultado.


Em vez de substituir o satélite, o drone pode aprofundar a investigação. O satélite aponta a região; o drone revela padrões finos; a câmera próxima registra sintomas foliares. Esse encadeamento reduz o custo de observar tudo com o sensor mais detalhado.



2.6

Sensoriamento proximal e o robô Axis

A proximidade permite registrar folhas, lesões e estruturas com um nível de detalhe muito superior ao orbital.



Câmeras embarcadas no Axis podem percorrer a lavoura a aproximadamente um metro da cultura, capturando imagens RGB, NIR ou térmicas. Essa distância favorece a identificação de sintomas pequenos, desde que foco, iluminação e velocidade estejam controlados.


O sensoriamento proximal também reduz a dependência de nuvens e pode repetir rotas. A contrapartida é o volume de dados: milhares de imagens exigem seleção, inferência eficiente e associação precisa com posição e horário. O Nexa Vision é o componente responsável por organizar e interpretar esse fluxo.



2.7

Estações meteorológicas e sensores IoT

O contexto ambiental ajuda a interpretar por que uma anomalia apareceu ou evoluiu.



Temperatura, umidade relativa, chuva, radiação, vento, molhamento foliar e umidade do solo podem alterar o risco de doenças e a resposta fisiológica da cultura. Esses dados não devem ser usados como diagnóstico isolado, mas como contexto para imagens e séries temporais.


A integração prevista permite associar leituras ao talhão e à janela de captura. Assim, um hotspot térmico pode ser analisado junto da demanda atmosférica; uma mudança de vigor pode ser comparada com chuva e histórico de irrigação.



2.8

GSD: quanto do campo cabe em um pixel

A resolução em megapixels não determina sozinha o detalhe observado.



O Ground Sample Distance representa o tamanho do terreno coberto por um pixel. Ele depende da distância até o alvo, do tamanho físico do sensor, da distância focal e da resolução em pixels. Em uma câmera a cerca de um metro da planta, configurações comuns podem atingir frações de milímetro por pixel.


Um GSD menor aumenta o detalhe, mas também o volume de arquivos e a sensibilidade a desfoque. Para detecção, o tamanho do sintoma em pixels é mais importante que o número total de megapixels. O projeto da câmera deve equilibrar campo de visão, velocidade, luz e menor objeto de interesse.



2.9

Qualidade de captura antes da inteligência artificial

Modelos avançados não compensam imagens desfocadas, mal expostas ou sem referência espacial.



A qualidade começa no protocolo: altura ou distância constante, foco travado, tempo de exposição adequado, sobreposição planejada e calibração quando necessária. Mudanças bruscas de iluminação devem ser registradas, principalmente em sensores multiespectrais.

Também é importante preservar metadados, identificar missão, cultura, talhão, data, operador e sensor. O Nexa Vision deve executar verificações automáticas e sinalizar imagens que podem comprometer o mapa ou a inferência.



03

ÍNDICES DE VEGETAÇÃO

Índices espectrais são ferramentas de comparação. Eles mostram contraste e tendência, mas não substituem a investigação de causa.



3.1

NDVI: uma medida de contraste espectral

O índice destaca diferenças entre a reflectância no infravermelho próximo e no vermelho.

NDVI

$$(NIR - Red) / (NIR + Red)$$

faixa típica de cálculo: -1 a +1

O NDVI é calculado por $(NIR - Red) / (NIR + Red)$. Valores maiores costumam estar associados a maior presença e vigor de vegetação verde, enquanto valores baixos podem indicar solo exposto, baixa cobertura ou menor atividade vegetal.


O índice é uma medida relativa e não um diagnóstico. Duas áreas podem apresentar NDVI semelhante por razões distintas. A análise deve considerar estágio da cultura, variedade, solo, umidade e condições da imagem.



3.2

Como o NDVI transforma duas bandas em um mapa

Cada pixel recebe um valor, e a escala de cores torna a variabilidade espacial visível.



Primeiro, as bandas são alinhadas e corrigidas. Depois, a fórmula é aplicada pixel a pixel. O resultado é uma matriz numérica que pode ser representada por uma paleta contínua ou por classes de vigor.


Uma boa legenda informa limites, data e método de classificação. Escalas automáticas realçam diferenças dentro do talhão, mas podem dificultar a comparação entre datas. Para séries temporais, o Nexa Vision deve oferecer escalas fixas e normalizadas, além de estatísticas por zona.



3.3

Interpretar não é apenas olhar a cor

Vermelho no mapa significa prioridade de investigação, não necessariamente doença.



Áreas de baixo índice podem estar associadas a falhas de plantio, sombra, solo exposto, compactação, déficit hídrico, dano por praga, deficiência nutricional ou diferença de estágio. A imagem indica onde existe contraste; a causa precisa ser investigada.

A interpretação melhora quando o mapa é comparado com RGB, relevo, solo, clima e histórico. O Nexa Vision foi concebido para apresentar essas camadas lado a lado e registrar a confirmação de campo.



3.4

NDRE: sensibilidade em dosséis desenvolvidos

A banda red edge pode preservar contraste quando o NDVI começa a saturar.

NDRE

$$(NIR - RedEdge) / (NIR + RedEdge)$$

faixa típica de cálculo: -1 a +1

O NDRE combina NIR e red edge. Em culturas com alta biomassa, o NDVI pode perder sensibilidade porque grande parte dos pixels já se aproxima da faixa superior. O red edge responde de modo diferente à clorofila e pode revelar variações em estágios mais avançados.

A utilidade depende do sensor e da cultura. O índice deve ser interpretado com referência local e, quando possível, associado a amostras de campo.



3.5

GNDVI: contraste com a banda verde

Uma alternativa que pode responder a variações de clorofila e vigor em determinadas condições.

GNDVI

$$(NIR - Green) / (NIR + Green)$$

faixa típica de cálculo: -1 a +1

O GNDVI substitui a banda vermelha pela verde. Em alguns estágios e culturas, ele pode aumentar a sensibilidade a mudanças relacionadas à clorofila. Assim como os demais índices, não deve ser tratado como medição direta de nutriente.

O valor prático está na comparação: identificar regiões diferentes, acompanhar tendência e selecionar pontos para amostragem. A plataforma pode exibir NDVI e GNDVI simultaneamente para verificar se o padrão espacial se repete.



3.6

SAVI e MSAVI: reduzindo a influência do solo

Índices ajustados são úteis quando o dossel ainda não cobre completamente o terreno.

SAVI

Ajusta parcialmente o efeito do fundo do solo.

MSAVI

Adapta o ajuste conforme a cobertura vegetal.

NDVI

Referência amplamente utilizada para vigor.

USO

Emergência e cobertura incompleta.

CUIDADO

Solo úmido e sombra ainda afetam o sinal.

COMPARAÇÃO

Escalas consistentes melhoram séries temporais.

No início do ciclo, grande parte do pixel pode conter solo. O SAVI introduz um fator de ajuste para reduzir essa influência. O MSAVI estima esse ajuste de forma dinâmica, sendo uma alternativa para áreas com cobertura esparsa.

Esses índices não eliminam todos os efeitos de brilho e umidade do solo, mas podem oferecer mapas mais estáveis durante a emergência. A escolha deve ser validada para o cenário e sensor utilizados.



3.7

VARI: análise com câmeras RGB

Uma opção para explorar vigor relativo quando não há banda NIR.

VARI

$$(Green - Red) / (Green + Red - Blue)$$

faixa típica de cálculo: relativa à cena

O VARI utiliza verde, vermelho e azul. Por depender apenas de RGB, pode ser calculado com câmeras convencionais, inclusive em imagens proximais. Ele é útil para destacar diferenças visuais, mas tende a ser mais sensível à iluminação, sombra e balanço de branco.

Em imagens próximas, a resolução pode compensar parte da limitação espectral. O Nexa Vision pode combinar VARI, textura e modelos de visão computacional para localizar sintomas e padrões de cobertura.



3.8

CWSI e temperatura do dossel

O estresse hídrico altera a transpiração e pode elevar a temperatura das folhas.

CWSI

$$(T_c - T_{wet}) / (T_{dry} - T_{wet})$$

faixa típica de cálculo: 0 a 1, conforme referência

O Crop Water Stress Index relaciona a temperatura do dossel a referências de condição úmida e seca. A construção correta exige sensor térmico calibrado e contexto meteorológico. Temperatura elevada também pode resultar de solo exposto, ângulo de visão ou baixa cobertura.

Por isso, mapas térmicos devem ser mascarados pela vegetação e comparados com umidade, radiação e horário. A plataforma pode destacar hotspots e registrar sua persistência ao longo do dia ou da safra.



3.9

Qual índice utilizar?

A pergunta agronômica, o estágio da cultura e o sensor disponível orientam a escolha.

NDVI

Vigor e cobertura geral.

NDRE

Dossel mais desenvolvido.

GNDVI

Resposta relativa à banda verde.

SAVI

Cobertura inicial e solo aparente.

VARI

Análise baseada em RGB.

CWSI

Temperatura e estresse hídrico.

Não existe um índice que seja melhor em todas as situações. NDVI é robusto para monitoramento geral; NDRE pode preservar sensibilidade em dossel denso; SAVI e MSAVI ajudam com solo aparente; VARI amplia o uso de RGB; CWSI exige termografia e contexto climático.


O Nexa Vision deve evitar apresentar dezenas de índices sem orientação. A interface precisa explicar o que cada camada destaca, suas limitações e quando a comparação é apropriada.



3.10

Limitações e boas práticas

Índices são indicadores de contraste, não laudos automáticos.



Nuvens, sombras, atmosfera, horários diferentes, saturação, mistura de solo e mudança de sensor podem alterar os valores. Comparações confiáveis exigem controle de qualidade, máscaras e metadados.

A recomendação é trabalhar em três níveis: detectar anomalias no mapa, comparar com outras camadas e confirmar em campo. O relatório deve distinguir evidência observada, hipótese e recomendação de vistoria. Essa separação aumenta a transparência e reduz interpretações excessivas.



04

INTELIGÊNCIA ARTIFICIAL


Visão computacional organiza pixels em classes, objetos e regiões. O valor surge quando o resultado é validado e integrado ao contexto.



4.1

O que é visão computacional

É o conjunto de técnicas que transforma pixels em classes, objetos, regiões e medidas.



Uma imagem digital é uma matriz de valores. Modelos de visão aprendem padrões recorrentes de forma, cor, textura e contexto. Na agricultura, esses padrões podem representar folhas, plantas, falhas, lesões, frutos, animais ou componentes de máquinas.


O desempenho depende da qualidade e diversidade dos exemplos usados no treinamento. Uma IA treinada apenas em uma variedade, iluminação ou estágio pode falhar quando encontra outra condição. O desenvolvimento do Nexa Vision prioriza datasets documentados e validação em cenários reais.



4.2

Dos pixels às características

As primeiras camadas identificam padrões locais; as seguintes combinam esses padrões em representações mais abstratas.



Bordas, transições de cor e texturas são sinais simples. Ao longo da rede, eles são combinados em estruturas mais complexas, como nervuras, manchas, folhas e copas. O modelo não memoriza uma fotografia como uma pessoa; ele ajusta milhões de parâmetros para responder a regularidades nos dados.


Embeddings são representações numéricas compactas. Imagens visualmente ou semanticamente semelhantes tendem a ocupar regiões próximas nesse espaço, permitindo busca, agrupamento e detecção de anomalias.



4.3

Redes neurais e aprendizado supervisionado

Treinar significa ajustar parâmetros para reduzir o erro entre a previsão e a anotação.



No aprendizado supervisionado, especialistas ou anotadores fornecem rótulos: classe da imagem, caixa ao redor do objeto ou máscara por pixel. O modelo faz uma previsão, calcula a diferença e atualiza seus pesos por retropropagação.


O processo se repete por épocas, mas repetir as imagens não significa observar exatamente o mesmo exemplo. Aumentos de dados alteram recorte, cor, escala e orientação, ampliando a robustez. Validação separada ajuda a identificar sobreajuste.



4.4

Classificação, detecção e segmentação

A saída correta depende do nível de detalhe exigido pela aplicação.



Classificação responde qual classe predomina na imagem. Detecção localiza objetos com caixas e fornece classe e confiança. Segmentação atribui uma categoria a cada pixel, permitindo medir área e contorno.


Para doenças foliares, detecção pode localizar lesões; segmentação mede severidade; classificação resume a condição da amostra. O Nexa Vision pode combinar tarefas em um pipeline, em vez de depender de um único modelo.



4.5

YOLO: detecção rápida e eficiente

Arquiteturas de uma etapa são adequadas para grande volume de imagens e inferência em tempo real.



Modelos da família YOLO estimam caixas e classes em uma única passagem. São conhecidos pela relação favorável entre velocidade e precisão, o que os torna úteis em edge devices, drones e robôs.

No Nexa Vision, YOLO pode atender tarefas de contagem, detecção de frutos, falhas, animais ou objetos bem definidos. A escolha final depende de benchmark no dataset específico, não apenas de resultados gerais.



4.6

RT-DETR: detecção com transformers

O modelo utiliza atenção para relacionar regiões da imagem e produzir um conjunto direto de detecções.



DETR reformulou a detecção como previsão de conjuntos. Versões em tempo real, como RT-DETR, combinam eficiência e modelagem global da cena. Essa abordagem pode ser interessante quando há objetos sobrepostos, escalas variadas e contexto espacial importante.


O protótipo do Nexa Vision utiliza RT-DETR em experimentos com imagens agrícolas. Métricas, velocidade e robustez precisam ser avaliadas por cultura e tarefa antes da implantação.



4.7

SAM e modelos de segmentação

Modelos fundacionais podem acelerar a criação de máscaras e apoiar análises por área.



Segment Anything permite gerar máscaras a partir de pontos, caixas ou prompts. Em agricultura, isso pode reduzir o trabalho de delinear folhas, copas, manchas ou parcelas, mas ainda exige revisão quando o contraste é baixo ou há sobreposição intensa.


O uso mais seguro é como ferramenta assistiva: o modelo propõe, o especialista corrige e a máscara revisada entra no dataset. Essa interação aumenta a velocidade sem eliminar o controle de qualidade.



4.8

Modelos multimodais

Imagem, texto, clima e histórico podem ser interpretados em conjunto.



Um modelo visual localiza uma anomalia. Um modelo de linguagem organiza o contexto, explica limitações e gera um resumo. Dados meteorológicos ajudam a avaliar hipóteses. A multimodalidade conecta essas fontes em uma resposta mais útil.


Isso não significa permitir que o modelo invente diagnóstico. O sistema deve citar evidências, apresentar confiança e manter regras agronômicas. No Nexa Vision, a camada multimodal é planejada como interface de interpretação e geração de relatórios.



4.9

Dataset: a base do desempenho

Mais imagens ajudam somente quando aumentam diversidade, qualidade e representatividade.



Um dataset agrícola deve registrar cultura, variedade, estágio, local, clima, sensor e condição visual. Classes desequilibradas podem fazer o modelo ignorar sintomas raros. Anotações inconsistentes criam um limite de desempenho que hardware mais potente não resolve.


A evolução do Nexa Vision prevê um ciclo de versionamento: novas amostras são revisadas, incorporadas e comparadas com benchmarks anteriores. Checkpoints e configurações precisam ser preservados para garantir reprodutibilidade.



4.10

Métricas: como avaliar um detector

Precisão, recall e mAP respondem perguntas diferentes e devem ser analisados junto dos erros reais.



Precisão indica a proporção de detecções que estavam corretas. Recall indica quantos objetos verdadeiros foram encontrados. mAP resume o desempenho em diferentes classes e critérios de sobreposição.


Em monitoramento agrícola, o custo do erro importa. Perder uma doença crítica pode ser pior que gerar uma vistoria adicional. Por isso, o limiar de confiança deve ser ajustado ao uso e acompanhado de matriz de confusão, exemplos de falso positivo e falso negativo.



4.11

Humano no circuito

A IA prioriza e organiza; o agrônomo confirma causa e decisão.



Sistemas confiáveis registram o que foi previsto, quem revisou e qual conclusão foi tomada. Esse histórico permite auditar o resultado e aprender com divergências.

Quando o usuário confirma ou corrige uma análise, a informação pode alimentar uma fila de revisão de dataset. Assim, o produto melhora com uso real sem executar aprendizado automático descontrolado. A evolução permanece versionada e validada.



05

PLATAFORMA NEXA VISION


Uma arquitetura modular para ingestão, análise, mapas, alertas, histórico e relatórios.



5.1

O que é o Nexa Vision

Uma plataforma para transformar imagens e sensores em mapas, alertas e relatórios acionáveis.



O Nexa Vision é o núcleo de visão computacional da Convex Robótica. Seu objetivo é receber dados de diferentes plataformas, executar pipelines de análise e apresentar resultados em uma interface geoespacial.

A proposta combina sensoriamento remoto, modelos de detecção e segmentação, índices de vegetação, análise temporal e geração assistida de relatórios. O produto está em desenvolvimento e será ampliado por módulos conforme os modelos forem validados.



5.2

Arquitetura modular

Cada camada pode evoluir sem exigir a reconstrução completa da plataforma.



Fontes de dados entram por upload, API ou integração. Serviços de ingestão validam arquivos e metadados. O motor analítico seleciona modelos, calcula índices e consolida resultados. A API entrega mapas, estatísticas, alertas e documentos ao dashboard.


Essa separação facilita substituir um detector, adicionar um novo sensor ou escalar processamento em nuvem. Também permite executar parte do pipeline no edge quando conectividade e latência forem críticas.



5.3

Pipeline completo de análise

Da captura ao relatório, cada etapa deixa um registro rastreável.



Uma missão é criada com talhão, cultura, data, sensor e operador. Os arquivos passam por controle de qualidade e georreferenciamento. Em seguida, modelos e índices produzem camadas intermediárias.


O motor analítico combina resultados e gera um resumo com evidências, incertezas e prioridades. O usuário revisa, adiciona observações de campo e exporta o relatório. Cada versão permanece associada à missão original.



5.4

Fontes de dados suportadas pelo conceito

O mesmo talhão pode ser observado de escalas e perspectivas diferentes.



A arquitetura prevê imagens Sentinel e outras fontes orbitais, ortomosaicos de drone, fotografias RGB, câmeras multiespectrais e térmicas, vídeos, sensores IoT e estações meteorológicas. Integrações específicas dependem de disponibilidade técnica e licenciamento.


O sistema registra origem e resolução para evitar comparações inadequadas. Uma imagem de satélite não deve ser interpretada como se tivesse o detalhe de uma câmera a um metro da folha.



5.5

Uma biblioteca de mapas individuais

Cada camada responde a uma pergunta e deve poder ser aberta separadamente.



O relatório não deve condensar toda a análise em uma única imagem. O usuário precisa acessar RGB, NDVI, NDRE, VARI, térmico, hotspots, severidade, cobertura, população e outras camadas disponíveis.


Cada mapa deve incluir legenda, escala, data, resolução, estatísticas e limitações. A comparação lado a lado e o controle de transparência ajudam a verificar correspondências espaciais.



5.6

Dashboard orientado à decisão

A interface resume o cenário sem esconder o acesso aos dados brutos.



Indicadores mostram área processada, percentual por classe, número de alertas e tendência temporal. O mapa permanece como elemento central. Filtros por fazenda, talhão, cultura, missão e data reduzem o ruído.


O dashboard deve permitir navegar do resumo até a amostra original: selecionar uma região, abrir imagens correspondentes e verificar as detecções. Essa rastreabilidade é essencial para confiança.



5.7

Relatórios automáticos e editáveis

A automação reduz trabalho repetitivo; a revisão humana preserva responsabilidade técnica.



O relatório reúne resumo executivo, metodologia, mapas individuais, estatísticas, hotspots, evidências e recomendações de vistoria. O sistema pode preencher automaticamente os campos objetivos e sugerir uma interpretação.

Antes da emissão, o usuário autorizado revisa textos e seleciona as páginas relevantes. A versão final recebe data, responsável, origem dos dados e aviso sobre limitações. Exportações em PDF e formatos geoespaciais ampliam o uso em reuniões e operação.



5.8

Alertas por mudança e prioridade

Nem toda variação exige notificação; regras claras evitam fadiga de alerta.

**Possível estresse hídrico**
Setor nordeste

ALTA

**Queda de vigor**
Talhão 12

MÉDIA

**Nova imagem disponível**
Talhão 03

INFO

Um alerta pode ser disparado por queda persistente de índice, hotspot novo, aumento de área afetada ou detecção acima de um limiar. Severidade combina confiança do modelo, extensão espacial e relevância agrônômica.

A plataforma deve permitir configurar culturas, estágios e responsáveis. Alertas críticos geram tarefa de campo; informativos apenas registram que uma nova camada está disponível.



5.9

Histórico temporal

O comportamento ao longo do tempo é frequentemente mais informativo que uma única data.



Séries temporais ajudam a distinguir uma sombra momentânea de uma mancha persistente. O usuário pode comparar mapas, gráficos e fotografias em datas diferentes, observando expansão, recuperação ou estabilidade.


O histórico também permite correlacionar intervenções. Uma aplicação, irrigação ou correção de solo pode ser marcada na linha do tempo e comparada com a resposta posterior da vegetação.



5.10

Integrações e interoperabilidade

A plataforma deve conversar com o ecossistema já utilizado pela fazenda.



APIs REST, webhooks e formatos como GeoTIFF, Shapefile, GeoJSON e CSV permitem troca de dados com GIS, ERP e sistemas de gestão agrícola. Integrações com provedores de mapas e processamento devem respeitar termos de uso e custos.


A estratégia é evitar aprisionar o cliente. Dados exportáveis e documentação de API tornam o Nexa Vision uma camada de inteligência conectável, não uma ilha.



5.11

Edge AI e processamento em nuvem

O melhor local de inferência depende de latência, conectividade, custo e privacidade.



No edge, o robô pode detectar eventos durante a missão e reduzir o volume enviado. Na nuvem, GPUs processam ortomosaicos e grandes lotes com maior flexibilidade. Um desenho híbrido permite resposta local e análise aprofundada posterior.


O sistema deve sincronizar resultados quando a conexão retornar, preservando identificação e versão do modelo. Logs de execução ajudam a comparar desempenho entre dispositivos.



5.12

Segurança, governança e propriedade dos dados

Confiança depende tanto do modelo quanto do controle de acesso e da rastreabilidade.



A arquitetura deve adotar autenticação, permissões por organização, criptografia em trânsito, backup e logs de auditoria. Dados de uma fazenda não devem ficar visíveis para outra.


Modelos, datasets e relatórios precisam de versionamento. O cliente deve saber quais dados enviou, como foram processados e quais exportações estão disponíveis. Políticas claras também definem o uso de amostras para melhoria do sistema.



5.13

Do protótipo à plataforma

O roadmap separa capacidades demonstráveis de recursos ainda planejados.



A primeira fase concentra ingestão, inferência, mapas básicos e relatório. Pilotos adicionam integrações, validação agrônômica e experiência multiusuário. A escala exige observabilidade, filas de processamento e automação de qualidade.

A visão de longo prazo conecta o Nexa Vision ao Axis: o mesmo sistema que identifica uma anomalia pode gerar uma missão de inspeção e, futuramente, apoiar uma intervenção localizada. Cada avanço depende de testes e segurança operacional.



06

APLICAÇÕES NO CAMPO


Os mesmos fundamentos são adaptados a culturas, estágios e perguntas agronômicas diferentes.



6.1

Cana-de-açúcar

Monitoramento de vigor, falhas, reboleiras e sintomas visuais em diferentes escalas.



Em canaviais, imagens orbitais ajudam a acompanhar variabilidade e evolução dos talhões. Drones e câmeras proximais aprofundam a investigação de falhas, plantas daninhas, danos e doenças foliares.

O Nexa Vision pode organizar mapas por corte, variedade e idade, permitindo comparar áreas equivalentes. Detecções devem ser confirmadas em campo e associadas ao contexto de solo, clima e manejo.



6.2

Soja

Uma cultura adequada para séries temporais, mapas de cobertura e inspeção de manchas.



Durante a emergência, mapas de cobertura e falhas ajudam a localizar problemas de estabelecimento. Ao longo do ciclo, índices e RGB revelam diferenças de vigor, fechamento de linhas e reboleiras.

Modelos de visão podem apoiar contagem em parcelas, identificação de plantas daninhas e classificação de sintomas. A plataforma relaciona essas evidências com datas de plantio, chuva e intervenções.



6.3

Milho

População, uniformidade e eventos localizados podem ser acompanhados da emergência ao enchimento.



A estrutura em linhas facilita medir falhas e irregularidade inicial. Em fases posteriores, mapas de vigor e temperatura podem destacar regiões que merecem vistoria.

O uso de câmeras próximas permite detectar folhas danificadas e alguns sintomas visuais, desde que o dataset represente híbridos, estágios e condições de iluminação. Resultados devem ser apresentados como triagem.



6.4

Café e citros

Culturas perenes exigem considerar copa, sombra, arquitetura e histórico de longo prazo.



Em café e citros, segmentar copas permite estimar cobertura, falhas e variações de volume. Imagens RGB de alta resolução ajudam a localizar frutos, ramos secos e sintomas visíveis. Termografia pode apoiar estudos de estresse quando o protocolo é controlado.

Como o ciclo é longo, o histórico do talhão ganha importância. O Nexa Vision pode comparar safras e registrar podas, irrigação, colheita e inspeções.



6.5

Florestas, hortaliças e fruticultura

A arquitetura modular permite adaptar modelos e métricas a diferentes sistemas produtivos.

MÚLTIPLAS CULTURAS

ANÁLISES

vigor • falhas • hotspots
doenças • população

Em florestas, interessa segmentar copas, falhas, mortalidade e danos. Em hortaliças, alta resolução permite contar plantas, medir cobertura e identificar padrões de desuniformidade. Na fruticultura, detecção de frutos pode apoiar amostragem e estimativas.


Cada cultura exige um protocolo. O mesmo modelo não deve ser aplicado indiscriminadamente. O Nexa Vision organiza pipelines especializados dentro de uma plataforma comum.



6.6

Deficiência nutricional e estresse hídrico

Sintomas semelhantes podem ter causas diferentes; a análise combina espectro, clima e inspeção.



Clorose, redução de crescimento e mudança de temperatura podem surgir por deficiência, excesso de água, compactação, dano radicular ou doença. A IA pode localizar áreas e comparar padrões, mas não substituir análise de solo, tecido e avaliação agrônômica.


O relatório deve sugerir pontos de amostragem e listar hipóteses compatíveis com as evidências. Esse formato é mais útil e seguro do que emitir uma causa única sem confirmação.



6.7

Pragas, doenças e plantas daninhas

Visão computacional transforma imagens detalhadas em localização, contagem e severidade estimada.



Deteção localiza indivíduos ou lesões; segmentação mede área; classificação organiza amostras. Para plantas daninhas, o desafio inclui sobreposição, diversidade e estágios pequenos. Para doenças, sintomas visuais podem se confundir com dano mecânico ou deficiência.


A plataforma registra confiança e exemplos que sustentam a previsão. Casos incertos podem ser enviados para revisão, evitando que a automação esconda dúvida.



6.8

Falhas de plantio e estimativa de produtividade

Medidas precoces ajudam a quantificar estabelecimento; previsões de rendimento exigem dados de várias fontes.



Falhas podem ser estimadas por segmentação de linha, contagem e distância entre plantas. O resultado deve considerar área não plantável, bordaduras e qualidade do mosaico.


Produtividade não pode ser inferida apenas por um índice. Modelos mais robustos combinam histórico, clima, fenologia, população, vigor e dados de colheita. O Nexa Vision pode fornecer variáveis e tendências, com intervalos de incerteza.



6.9

Zonas de manejo e taxa variável

Camadas históricas permitem separar padrões persistentes de eventos temporários.



Uma zona de manejo reúne áreas com comportamento semelhante ao longo de várias safras. NDVI, produtividade, solo, relevo e condutividade podem ser combinados para delinear regiões de maior e menor potencial.


O mapa de prescrição exige recomendação agrônômica e compatibilidade com o equipamento. O Nexa Vision pode exportar zonas e apoiar a análise, mas a dose final deve seguir critérios técnicos e legais.



7.1

Da percepção à agricultura autônoma

O próximo passo é conectar detecção, decisão e ação com segurança e rastreabilidade.



Robôs agrícolas poderão repetir missões, comparar plantas individualmente e realizar intervenções localizadas. Edge AI reduz latência; modelos multimodais integram contexto; gêmeos digitais organizam histórico e simulação.


A Convex imagina o Nexa Vision como o sistema perceptivo dessa operação. O Axis observa o mundo físico; o Nexa interpreta; o Synapse Control coordena a missão. A autonomia não elimina supervisão: amplia a capacidade humana de operar com precisão.



8.1

Glossário e referências essenciais

Conceitos para continuar explorando agricultura digital e visão computacional.



GSD: tamanho do terreno representado por um pixel. Reflectância: proporção da energia incidente refletida por uma superfície. Inferência: execução de um modelo treinado sobre novos dados. mAP: métrica agregada de detecção. Segmentação: atribuição de classe por pixel. Edge AI: processamento de IA próximo ao sensor.

Referências de base: Rouse et al. sobre NDVI; literatura de sensoriamento remoto aplicada à vegetação; Redmon et al. e versões posteriores da família YOLO; Carion et al. sobre DETR; Kirillov et al. sobre Segment Anything; documentação do programa Copernicus/Sentinel; materiais técnicos de agricultura digital e o e-book de NDVI utilizado como referência editorial para este projeto.



Inteligência para o mundo físico.

A Convex Robótica desenvolve sistemas de percepção, inteligência artificial e automação para agricultura, pecuária, indústria e robótica. O Nexa Vision é a camada que interpreta imagens e dados; o Axis leva sensores e atuação ao campo; o Synapse Control coordena missões e telemetria.

Nexa Vision

Plataforma em desenvolvimento pela Convex Robótica

convex-robotica.com