



# Abordagem de Visão Computacional para Cálculo de Consumo Não Registrado

**Tema:** Recuperação de energia - Perdas não-técnicas

**Autores:** Gabriel Alboretti; Matheus Menezes; Thiago Cazes

**Co-Autores:** Ilana França; Lucas de Paula

**Empresa:** Equatoria Maranhão Distribuidora de Energia S.A.

## Resumo

A regularização e recuperação de receitas provenientes da identificação de furto de energia e/ou irregularidades de consumo caracteriza um dos maiores desafios operacionais do setor de distribuição de energia Brasileiro e na América Latina. O cálculo do consumo não registrado (CNR) provindo dessas situações é um tema complexo e altamente regulado pelas agências de controle. Uma série de procedimentos no manual da ANEEL e nos manuais internos dos distribuidores definem cenários, casos e regras de cálculo do volume de energia e de como deve ser a cobrança nesses casos. Apesar de esforços na detecção do CNR, um dos maiores obstáculos para a recuperação da receita a partir de cálculos do consumo é a conformidade de processos manuais. A não conformidade dos processos durante e após a detecção desses casos pode inviabilizar a cobrança. Esse projeto propõe uma solução baseada em inteligência artificial a partir de modelos de visão computacional com o objetivo de automatizar processos e melhor controlar a conformidade durante o processo de cálculo do CNR. Esses processos incluem a construção de uma plataforma para cálculo automatizado do CNR, e a elaboração automatizada de laudos técnicos. Espera-se que o projeto, uma iniciativa do programa de Pesquisa, Desenvolvimento e Inovação (PDI) ANEEL sob o código PD-00037-0051/2023, auxilie na redução de intervenção manual e aumento da precisão dos resultados, além da agilidade de todo o fluxo operacional.

## 1. Introdução

A gestão e controle do consumo não registrado (CNR) envolve um conjunto de desafios tecnológicos e processuais enfrentado por setores produtivos essenciais como energia, saneamento e gás. O CNR refere-se a recursos ou serviços que não são devidamente medidos, faturados, ou apropriadamente reportados às empresas (EQUATORIAL, 2024). Esse problema pode ocorrer por diversos motivos, como falhas nos sistemas de medição, fraudes relacionadas à adulteração de medidores ou ligações clandestinas, erros administrativos, perdas de recursos, entre outros. Como resultado, o CNR impacta diretamente a receita das empresas e pode comprometer investimentos em melhorias de infraestrutura.

Embora existam propostas de soluções distintas para os fenômenos que contribuem diretamente no CNR (SPIRI, 2015)(CARR & THOMSON, 2022), algumas limitações no processo após a detecção dificultam uma operação eficiente. Essas dificuldades incluem o levantamento de dados para elaboração de parecer técnicos em conformidade com as normas internas da empresa e das agências reguladoras. Além disso,

métodos para estimar o consumo estão sujeitas à complexidade das variáveis socioeconômicas (por exemplo: localização da residência e a falta do histórico de consumo), o que pode resultar em cálculos imprecisos e contestações jurídicas. Em setores como o de energia elétrica, a extensão das redes de distribuição ainda agrava a gestão eficiente do CNR, especialmente durante processos manuais no levantamento de evidências em campo. Desta forma, empresas de energia perdem o direito à cobrança do CNR por questões legais ligadas a não conformidade do processo de inspeção e normalização em campo.

Trabalhos na literatura têm focado na previsibilidade de contestação da cobrança associada ao CNR (ASSIS, 2019)(OLIVEIRA, 2019)(DIAS, 2020), mas há lacuna de soluções metodológicas e tecnológicas para a automação do processo durante a captura de dados e o cálculo do CNR. Por outro lado, modelos de visão computacional e inteligência artificial têm demonstrado ampla aplicabilidade em diversos processos no setor elétrico, desde a classificação de equipamentos defeituosos ou condutas fora dos padrões de segurança (CAO, 2021)(REZENDE, 2021), até aplicações em processos administrativos e regulatórios (COSTA, 2022).

Dentro dessa interface, esse trabalho propõe uma aplicação em inteligência artificial baseado em visão computacional para auxiliar nas etapas de captura de evidência e automatização do cálculo do CNR em uma empresa de companhia elétrica. O projeto está estruturado em duas frentes principais: conformidade das evidências durante a inspeção de campo, que atua diretamente no momento da inspeção, garantindo que a coleta de evidências seja realizada de forma eficiente e em conformidade com os requisitos regulatórios; e uma plataforma para cálculo do CNR, que foca em automatizar e padronizar o processo de cálculo, assegurando que ele seja realizado em conformidade com as normas regulatórias. Com a integração dessas frentes, o projeto busca não apenas otimizar os processos operacionais, mas também elevar o nível de precisão, padronização e transparência nas atividades relacionadas ao CNR. Isso fortalece a capacidade técnica da concessionária e aumenta a confiança nos resultados apresentados, especialmente em situações de contestação legal.

## **2. Desenvolvimento**

Para atender aos objetivos do projeto, foram desenvolvidos dois componentes tecnológicos: modelos de inteligência artificial - baseados aqui como modelos de visão computacional - concebido para atender à conformidade das evidências durante as inspeções de campo; e um plataforma web, que auxilia no processo de automatização do cálculo de CNR. Os modelos de visão computacional são implantados tanto em um aplicativo móvel, que foca principalmente na obtenção das evidências necessárias em operações em campo, quanto na plataforma. Por outro lado, a plataforma foi projetado para suportar as atividades de análise e validação em ambiente corporativo. Além disso, ela reúne todas as evidências necessárias para o processo legal do cálculo e cobrança, permitindo que os analistas tenham acesso simplificado e organizado a informações como imagens, documentos e dados regulatórios. Cada componente é detalhado a seguir.

### **2.1 Modelos de Inteligência Artificial baseados em Visão Computacional**

Os modelos de visão computacional, desenvolvido com a ferramenta SmartVision.AI da Fu2re, usam um banco de imagens personalizado para identificar padrões em imagens e documentos regulatórios. No aplicativo móvel, esses modelos auxiliam inspetores na captura e registro de fotos necessárias, como imagens da irregularidade detectada, testes que comprovam a irregularidade, medidores após a regularização, fachadas das residências, e a presença do acompanhamento da inspeção. Os registros validam o processo e fornecem evidências tanto para os cálculos posteriores quanto para eventuais processos jurídicos.

O uso dos modelos computacionais trabalham sequencialmente em uma das duas etapas e subetapas de classificação dos dados (Fig. 1) - detalhadas abaixo - para alcançar a validação de imagens e documentos.

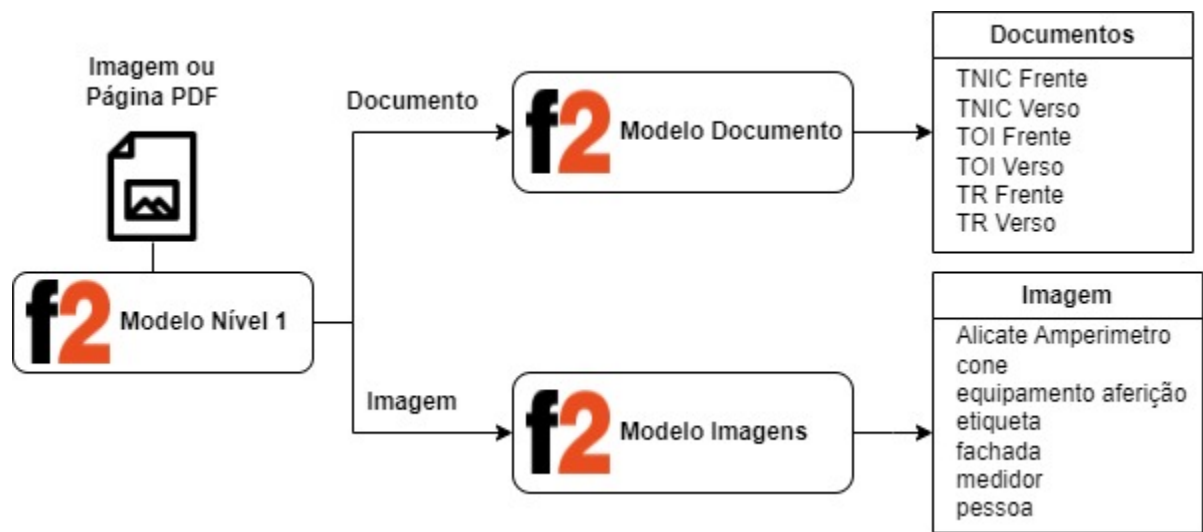


Figura 1 - Diagrama de execução das etapas e subetapas dos modelos de inteligência artificial

Etapa 1: Modelo de classificação inicial:

O primeiro modelo identifica se a entrada da câmera inteligente é uma imagem geral ou um documento regulatório. Esse modelo foi treinado com aproximadamente 11 mil imagens, alcançando métricas de acurácia, precisão e recall superiores a 99% (Fig. 2). Esses resultados comprovam um desempenho sólido na distinção entre os dois tipos de classe: "Imagem/Foto" e "Documento". A Matriz Confusão para as duas classes treinadas são apresentadas na Figura 3.

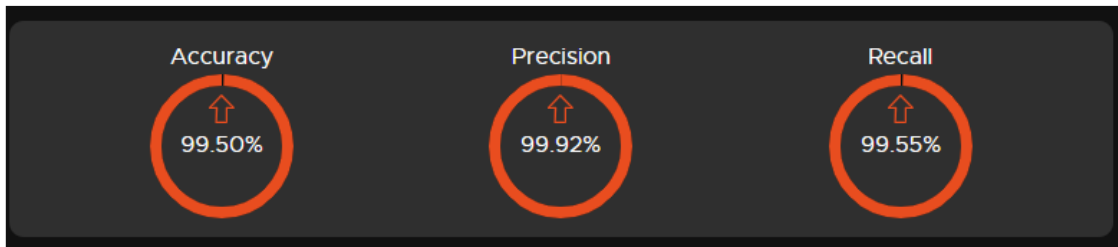


Figura 2 - Métricas do modelo de classificação inicial.

documento	6283	3	29	99.9%	99.5%
imagem	1	4475	16	99.9%	99.6%
FP	4	1			
	documento	imagem	FN	Precision	Recall

Figura 3 - Matriz Confusão do modelo de classificação inicial.

*Etapa 2: Modelo de validação avançada:*

Dependendo da classificação inicial, a segunda etapa é direcionada para duas subetapas de execução - que usam dois novos modelos de visão computacional distintos em cada subetapa - para refinar a validação. A subetapa de validação de documentos é acionada quando o modelo inicial classifica a entrada de dado como 'documento'. Então, um modelo treinado para classificar diferentes tipo de documentos realiza uma categorização em sete possíveis classes: 'toi\_frente', 'toi\_verso', 'tnic\_frente', 'tnic\_verso', 'tr\_frente', 'tr\_verso' e 'outros' (classe de exclusão). O modelo de classificação de documentos foi treinado com aproximadamente de 5 mil imagens e alcançou métricas superiores a 97% em acurácia, precisão e recall (Fig. 4, Matriz Confusão do modelo na Fig. 5).

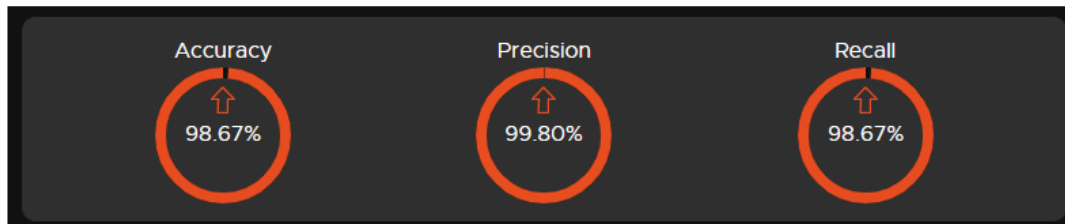


Figura 4 - Métricas do modelo para classificação de documentos.

outros	409	0	0	0	0	2	0	2	100.0%	99.0%
tnic_frente	0	1026	2	0	0	0	0	13	99.7%	98.6%
tnic_verso	0	1	944	0	0	0	0	7	99.7%	99.2%
toi_frente	0	0	0	1305	2	0	0	11	100.0%	99.0%
toi_verso	0	0	1	0	704	0	0	14	99.7%	97.9%
tr_frente	0	2	0	0	0	297	0	5	99.3%	97.7%
tr_verso	0	0	0	0	0	0	280	5	100.0%	98.2%
FP	0	0	0	0	0	0	0			
	outros	tnic_frente	tnic_verso	toi_frente	toi_verso	tr_frente	tr_verso	FN	Precision	Recall

Figura 5 - Matriz Confusão do modelo para classificação de documentos.

Após a identificação e classificação do documento, uma análise verifica se houve o preenchimento correto de campos específicos dentro do documento reconhecido. Essa etapa é necessária para garantir que os dados apresentados estejam em conformidade com os requisitos regulatórios.

Caso a entrada da câmera seja classificada como 'imagem', é acionada a subetapa onde um modelo treinado para categorizar objetos dentro imagens é executado. Em cada imagem, o modelo pode detectar sete possíveis objetos e cenários do processo: 'alicate\_ampermetro', 'pessoa', 'cone', 'equipamento\_afericao', 'etiqueta', 'fachada' e 'medidor'. O modelo de detecção de objetos foi treinado com aproximadamente de 23 mil imagens, alcançando métricas superiores a 95% (Fig. 6, Matriz Confusão na Fig. 7). Enquanto o modelo para classificação documentos identifica uma única categoria em cada foto, o modelo para classificar objetos pode identificar diferentes classes dentro de uma única imagem.

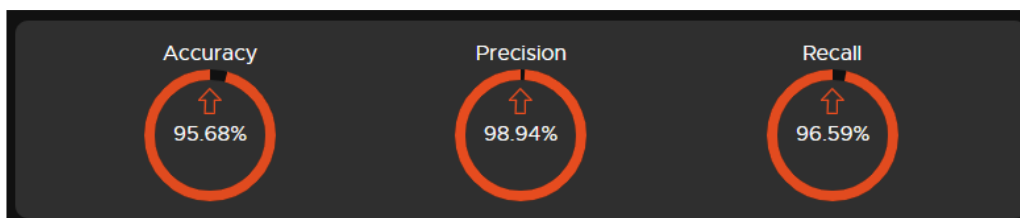


Figura 6 - Resultado modelo nível 2 para imagens

	alicate_amperímetro	cone	Equipamento_aferricao	Etiqueta	fachada	medidor	pessoa	FP		
alicate_amperímetro	1742	0	2	4	0	0	0	16	99.4%	98.8%
cone	0	2225	0	2	0	0	0	154	98.2%	93.4%
Equipamento_aferricao	2	0	1181	1	0	0	0	22	98.5%	97.9%
Etiqueta	0	0	2	5267	0	2	0	29	99.0%	99.4%
fachada	0	0	0	2	2995	0	0	137	97.9%	95.6%
medidor	0	0	3	0	0	8504	1	397	99.6%	95.5%
pessoa	0	0	0	0	0	0	917	31	96.8%	96.7%
FP	8	41	11	42	63	29	29			
	alicate_amperímetro	cone	Equipamento_aferricao	Etiqueta	fachada	medidor	pessoa	FN	Precision	Recall

Figura 7 - Matriz de confusão modelo nível 2 para imagens

## 2.2 Portal de cálculo automatizado de CNR:

O portal de cálculo automatizado de CNR centraliza e organiza todas as informações relacionadas a um processo de cálculo específico e ao cliente associado a ela. O objetivo do portal é promover uma experiência de usabilidade adequada os usuários. Os dados dispostos no portal de cálculo estão divididos em quatro blocos principais:

**Informações da Unidade Consumidora (UC):** fornece os dados cadastrais completos da instalação, incluindo informações como endereço, número da unidade consumidora e dados técnicos relevantes. Ele também apresenta as características do cálculo simulado com regras de negócio do grupo. Além disso, o bloco integra imagens do *Google Street View*, permitindo que o usuário visualize o local inspecionado para validar o endereço e a situação física correspondem às informações registradas. Essa integração visa garantir maior confiabilidade nas análises.

**Cálculo:** nesse bloco, são apresentadas todas as configurações e resultados detalhados do cálculo do Consumo Não Registrado. Aqui, o usuário pode verificar as fórmulas e os valores aplicados no modelo da regras de negócio da empresa, além de simulações realizadas. Essa transparência permite revisões padronizadas, assegurando conformidade com as regulamentações.

**Histórico:** consolida informações históricas da unidade consumidora, fornecendo uma visão holística sobre o comportamento de consumo e outros registros associados. O histórico inclui gráfico de consumo; consumo em formato tabular; lista de notas já executadas; faturas abertas (Fig. 8).

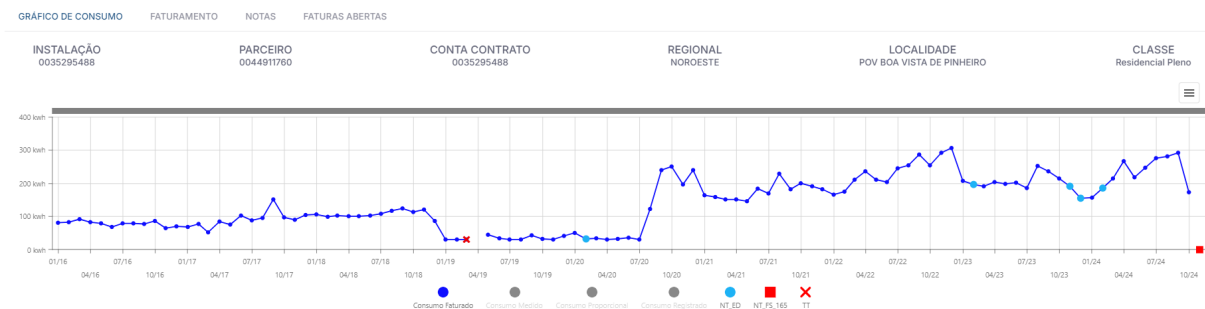


Figura 8 - Gráfico de consumo

*Documentos Classificados:* organiza todos os documentos processados pelos modelos de visão computacional, facilitando o acesso e análise dos dados pelos usuários do sistema. Os documentos estão divididos em três categorias principais: documentos relacionados à nota, como relatórios técnicos, formulários e outros registros oficiais relevantes ao caso (Fig. 9); capturas de tela do sistema comercial SAP, que traz as informações e ações relevantes para garantir a rastreabilidade e conformidade do processo de cálculo; e imagens fotográficas capturadas durante a inspeção de campo. Essas imagens foram automaticamente classificadas pelos modelos de visão computacional (veja Seção 2.1) para identificar itens regulatórios como irregularidades, medidores, equipamentos, fachadas e outros aspectos fundamentais para validação do processo (Fig. 10).

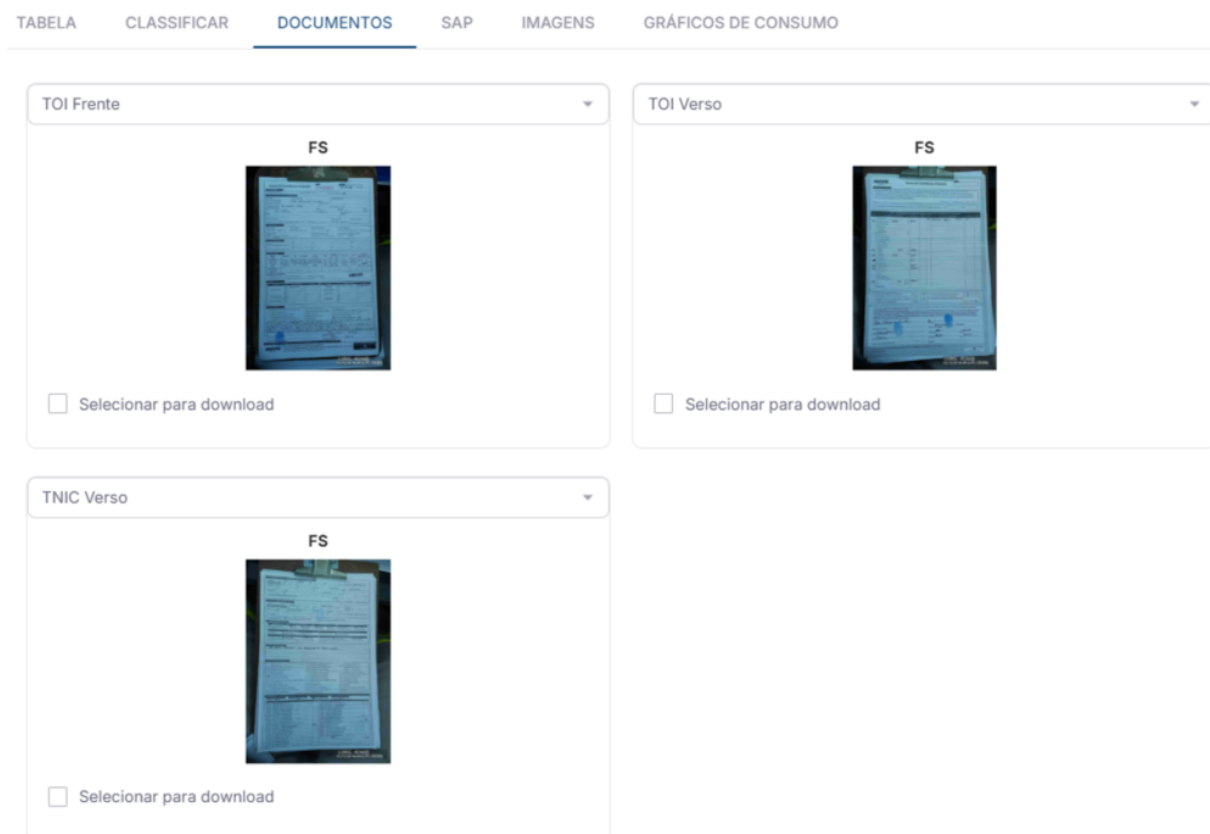


Figura 9 - Documentos automaticamente classificados pelo modelo

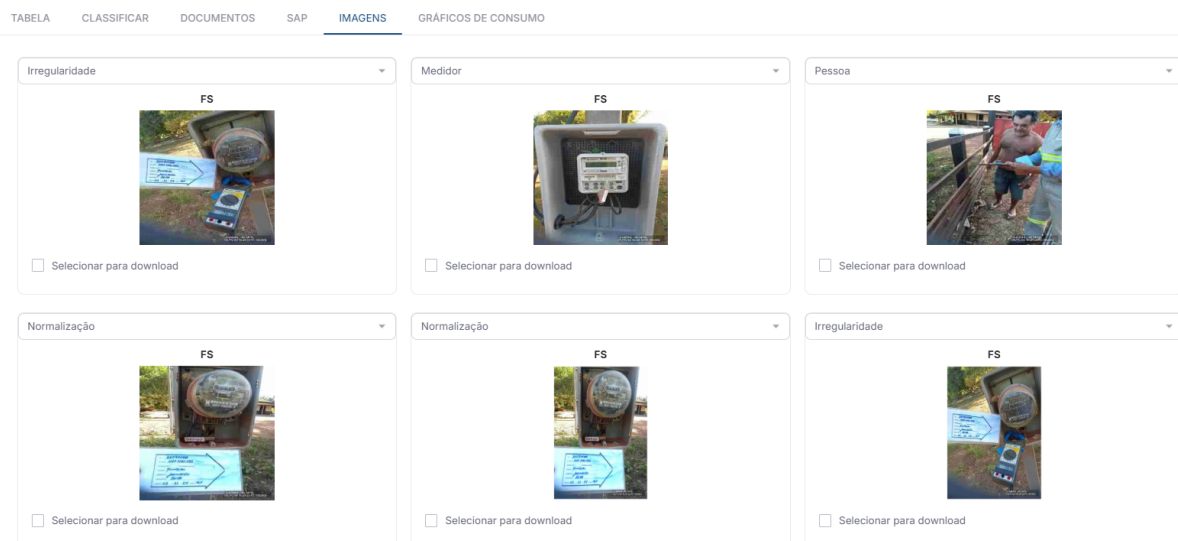


Figura 10 - Apontamento de irregularidades rotuladas pelo modelo

Essa organização estruturada do portal permite que analistas e calculistas acessem rapidamente todas as informações necessárias em um único ambiente, facilitando as revisões, validações e execuções. A integração com modelos de inteligência artificial e visão computacional agilizam os processos, e asseguram maior precisão e padronização em todas as etapas do cálculo e da análise do CNR.

### 3. Conclusão

Nesse projeto, foram apresentadas soluções tecnológicas para abordar os desafios relacionados ao cálculo de Consumo Não Registrado (CNR), integrando inteligência artificial a partir de modelos de visão computacional para padronizar e automatizar processos manuais e regulatórios. Através da integração desses modelos em um aplicativo móvel e, do desenvolvimento de um portal web, o projeto objetiva garantir a precisão, a eficiência e a conformidade regulatória em todas as etapas envolvidas, desde a inspeção em campo até a análise corporativa e a resolução de disputas judiciais.

A aplicação de modelos de visão computacional validam imagens e documentos, além de otimizar o fluxo de trabalho das equipes de campo e dos analistas. Ferramentas como a câmera inteligente embarcada e a centralização de informações no portal facilitam a coleta, organização e análise das evidências, reduzindo a intervenção manual e os erros associados.

Com essa abordagem, esse projeto de PDI ANEEL sob o código PD-00037-0051/2023, pode promover transformações significativas no tratamento de irregularidades de consumo, fortalecendo a capacidade da concessionária de atuar com eficiência, transparência e segurança jurídica. Por fim, os avanços tecnológicos propostos criam um modelo sustentável e replicável para o setor e área de recuperação de energia.

### 4. Referências bibliográficas

EQUATORIAL ENERGIA (Maranhão). *Cobrança por consumo não registrado (CNR)*, 6 dez. 2024. Disponível em: <<https://ma.equatorialenergia.com.br/cobranca-por-consumo-nao-registrado-cnr/>>.

SPIRI, Josif V.; DO I, Miroslav B.; STANKOVI, Slobodan S. Fraud detection in registered electricity time series. *International Journal of Electrical Power & Energy Systems*, v. 71, p. 42-50, 2015. ISSN 0142-0615. Disponível em: <https://doi.org/10.1016/j.ijepes.2015.02.037>.

CARR, Darragh; THOMSON, Murray. Non-technical electricity losses. *Energies*, v. 15, n. 6, art. 2218, 2022. ISSN 1996-1073. Disponível em: <https://doi.org/10.3390/en15062218>.

ASSIS, Erica et al. Predição de ações judiciais de consumo de energia não registrado usando a rede LSTM. In: ANAIS DO 14º SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 2019, Ouro Preto. Anais eletrônicos..., Campinas, Galoá, 2019. Disponível em: <<https://proceedings.science/sbai-2019/trabalhos/predicao-de-acoes-judiciais-de-consumo-de-energia-nao-registrado>

OLIVEIRA, Francisco Y. et al. Prediction of unregistered power consumption lawsuits and its correlated factors based on customer data using extreme gradient boosting model. In: *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*. [S. l.]: IEEE, 2019. p. 2059-2064. DOI: <https://doi.org/10.1109/SMC.2019.8914366>.

DIAS, Domingos et al. A Tool for Spatially Based Prediction of Consumer Lawsuits against Electric Power Companies. In: *12th International Conference on Advanced Geographic Information Systems, Applications, and Services (GEOProcessing)*. 2020. Disponível em: <https://api.semanticscholar.org/CorpusID:229576106>.

CAO, Yuan; XU, Hao; YANG, Qiang. Computer-vision-based abnormal human behavior detection and analysis in electric power plant. In: *2021 33rd Chinese Control and Decision Conference (CCDC)*. [S. l.]: IEEE, 2021. p. 1578-1583. DOI: <https://doi.org/10.1109/CCDC52312.2021.9601435>.

REZENDE, Tamires M. et al. Visão Computacional Aplicada ao Monitoramento de Chaves Seccionadoras de Subestações de Energia Elétrica. *Anais do Congresso Brasileiro de Automática - CBA2022*, v. 3, n. 1, 19 out. 2022. DOI: <https://doi.org/10.20906/CBA2022/3230>.

COSTA, Clayton H. da et al. Inteligência Artificial em Robôs de Software Aplicada em Processos Administrativos e Regulatórios do Setor Elétrico. *Anais do Congresso Brasileiro de Automática - CBA2022*, v. 3, n. 1, 2022. DOI: <https://doi.org/10.20906/CBA2022/3294>.