



Sistema de Segurança do Eletricista – Sistema de Inteligência Artificial para identificação de não conformidade de ações de campo e utilização de EPIs por imagens

Tema: Operação

Autores: Ricardo Rei - ricardo.rei@fu2re.com.br; Thiago Cazes - thiago.cazes@fu2re.com.br

Co-Autores: José Antonio de Souza Brito - jbrito@neoenergia.com; Plínio Pinto de Albuquerque – plinio.albuquerque@neoenergia.com; Mário Coutinho da Costa Pereira Neto - mario.neto@neoenergia.com; Eric Jordan Bastos Nascimento dos Santos - eric.jordan@neoenergia.com; João Manoel Menezes da Fonseca - joao.fonseca@neoenergia.com; Gustavo Travassos Aguiar da Silva - gtravassos@neoenergia.com

Empresa: Companhia Energética de Pernambuco - NEOENERGIA PERNAMBUCO

Resumo

O Sistema de Segurança do Eletricista (SSE) foi construído através da parceria da Fu2re e da Neoenergia usando o programa de P&D ANEEL. Os algoritmos, ferramentais e modelos desenvolvidos usam a inteligência artificial para caracterizar situações de não cumprimento de regras de segurança nas operações de campo, problemas de posicionamento de câmeras e até mesmo direção perigosa praticada pelos colaboradores da distribuidora. O software toma como input a filmagem realizada pelos técnicos de campo e usando modelos de *deep learning* e inteligência artificial processa os mesmos, buscando indícios de anormalidades operacionais em situações relevantes. O desempenho computacional e precisão na identificação obtidos até então permitem afirmar que com a utilização do SSE em produção será possível realizar a análise de 100% das filmagens e operações de campo realizadas com segurança e agilidade. Espera-se que tal análise contribua para a redução significativa de sinistralidades e, por consequência, melhoria dos indicadores de qualidade e segurança das operações de campo e da rede de distribuição do grupo.

1. Introdução

Para garantir a correta operação na distribuição de energia nas respectivas áreas de concessão, as distribuidoras têm que cuidar do correto funcionamento da sua rede. Isso implica em muitos fatores, mas um que se destaca é a gestão operacional das equipes de campo, em especial no que tange ao time de manutenção dessa rede.

O trabalho realizado por estas equipes, pela sua natureza, apresenta diversos riscos que infelizmente se transformam em sinistralidade levando nos casos mais extremos ao falecimento dos técnicos de campo (quedas, choques elétricos, etc).



Figura 1 – Exemplo de operação

Para combater esta sinistralidade existem normas de segurança que todas as equipes de segurança devem seguir. E equipes de gestão responsáveis por garantir que essas normas são realmente seguidas. Esse acompanhamento / monitorização do cumprimento das regras de segurança é feito através da análise da gravação integral em vídeo do trabalho realizado pelas equipes de campo (ou seja, aproximadamente 8h diárias de vídeo para cada equipe).

Como resultado, do trabalho realizado pelas centenas de equipes de campo, são gerados diariamente milhares de horas de gravação. Sendo inviável analisar toda essa informação (principalmente por questões de custos - seria necessário ter quase uma pessoa por equipe de campo para analisar as 8 horas de vídeo diárias gravadas), a solução atual é analisar por amostragem uma pequena parte das gravações. Hoje essa amostra é inferior a 1% o que significa que quase todos os vídeos acabam sendo descartados sem nunca serem analisados.

O projeto Sistema de Segurança do Eletricista (SSE) permite melhorar este cenário ao analisar a totalidade dos vídeos gerados, identificando as principais situações e dessa forma ajudando a equipe de gestão da segurança a focar o seu trabalho nas situações mais críticas.

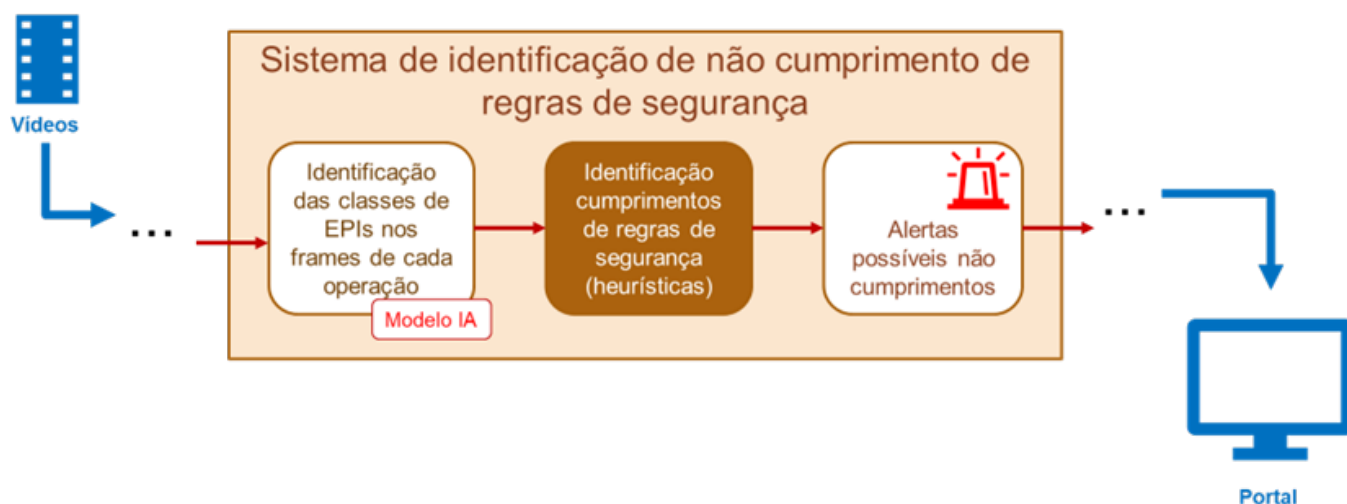


Figura 2 - Esquemático de processamento do robô de identificação de não cumprimento das regras de segurança

2. Desenvolvimento

O sistema foi desenvolvido pela Fu2re Smart Solutions como parte do P&D da Neoenergia. A Fu2re tem ampla experiência no desenvolvimento de produtos e projetos de pesquisa para o setor elétrico Brasileiro e é a proprietária do software denominado SmartvisionAI. O SmartvisionAI é uma ferramenta, no-code, que acelera a criação, treinamento e implantação de modelos de visão computacional e inteligência artificial. O projeto desenvolveu de forma inédita e inovadora um sistema que analisa todos os vídeos gerados pelas operações de campo e identifica não conformidades ao nível da segurança. Ao longo do último ano, ajustes, melhorias, correções foram realizadas.

O resultado é um sistema que analisa os vídeos e identifica 4 situações relacionadas com operações de campo:

- **Os períodos de vídeo onde acontecem operações de campo** - Descartando todo o tempo gasto em deslocamento e em paragens por outros motivos. Tipicamente as equipes trabalham cerca de 8h, gerando outras tantas horas de gravação. O sistema analisa todo esse período, seleciona as partes correspondentes às operações (uma pequena parte das 8h) e agrupa nas diferentes operações (na maioria das vezes 2 a 3 operações de duração variável de 5 min a mais de 1h). Esta funcionalidade por si só já representa um grande ganho operacional pois evita que os analistas de segurança tenham que procurar as operações do dia consultando o vídeo de 8h (este vídeo na realidade é dividido em dezenas de vídeos bem menores – cerca de 5min cada – o que torna a tarefa ainda mais desgastante).
- **O tipo de operação realizado** – As operações foram agrupadas em: com medidor, cesta aérea (com e sem Linha viva), escada ou vara de manobra – este ponto é também bastante relevante porque as regras de segurança diferem dependendo do tipo de operação. Além disso, esta identificação automática permite aplicar filtros e realizar diferentes análises organizadas por tipo de operação.
- **Filmagens fora do padrão** – Situações em que a gravação não está de acordo com regras pré-definidas. São elas gravações contra o sol, fora da distância (demasiado longe ou demasiado perto) e mal orientada (no eixo X ou Y). Ao se identificar que a gravação está “fora do padrão” identificamos que não estão

reunidas as melhores condições para analisar o cumprimento de regras de segurança. Importante este ponto para melhorar a gravação dos vídeos e ter informação de melhor qualidade para analisar (pelo SSE ou por analistas).

- **Situações de não cumprimento de regras de segurança** – Identificação de ausência de EPIs obrigatórios e outras situações específicas dependentes do tipo de operação.

O sistema analisa também os vídeos durante a fase de deslocamento entre as operações. Para estes casos o sistema analisa 3 tipos de infrações:

- **Avançar sinal vermelho** – Se o veículo no seu deslocamento passou por um sinal vermelho (em vez de parar esperando o sinal verde)
- **Excesso de Velocidade** – se em algum momento, durante o deslocamento o veículo ultrapassou a velocidade máxima definida.
- **Ultrapassagem proibida** – se em algum momento o veículo realizou uma ultrapassagem em zona proibida (duplo contínuo, tracejado contínuo). O SSE monitora, desta forma, todo o dia de trabalho de uma equipe de campo, desde que sai da UTD até que volta depois das várias operações realizadas.

O SSE monitora, desta forma, todo o dia de trabalho de uma equipe de campo, desde que sai da UTD até que volta depois das várias operações realizadas.

Arquitetura do SSE

O esquema seguinte resume o processo por trás do SSE:

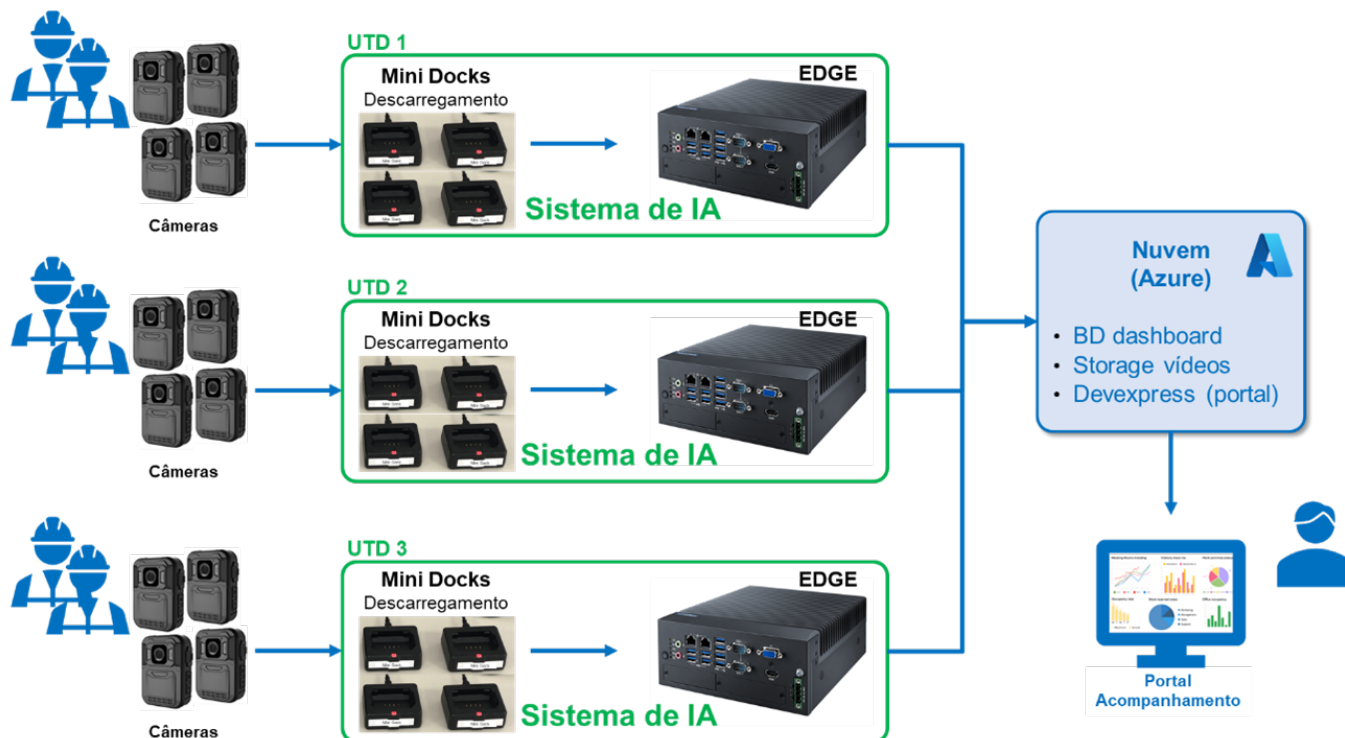


Figura 3 – arquitetura do SmartSafetyEye

O técnico retorna à sua UTD depois de um dia de trabalho, com sua câmera contendo a gravação desse dia. Coloca a câmera na miniDock que descarrega os vídeos para uma pasta local. Nesse momento inicia o processamento desse vídeo (ou fica numa fila caso outros vídeos estejam já sendo processados). O SSE percorre todo o vídeo “buscando” as situações mencionadas antes (períodos de operação, se a gravação está dentro do padrão e se estão sendo cumpridas as regras de segurança). Uma vez terminada essa

análise envia os resultados relevantes para uma base de dados em nuvem que centraliza todas as análises, de todas as operações, de todas as equipes, de todas as UTDs. Finalmente, um portal ligado a essa base de dados permite aos responsáveis pela segurança nas operações, analisar esses resultados e atuar de acordo com o encontrado.

Portal do SSE

O Portal do SSE é a parte visível para os usuários finais de todo o sistema. É nele que é possível analisar as várias operações e visualizar os respectivos vídeos. Para isso várias telas foram desenhadas que são descritas neste capítulo.

A tela seguinte permite consultar as diferentes operações identificadas filtrando por diferentes opções (data, UTD, equipe, etc.) visualizando em cada uma a identificação feita pela IA de erros na filmagem (fora do padrão: distancia, posicionamento da câmera, contra-sol).

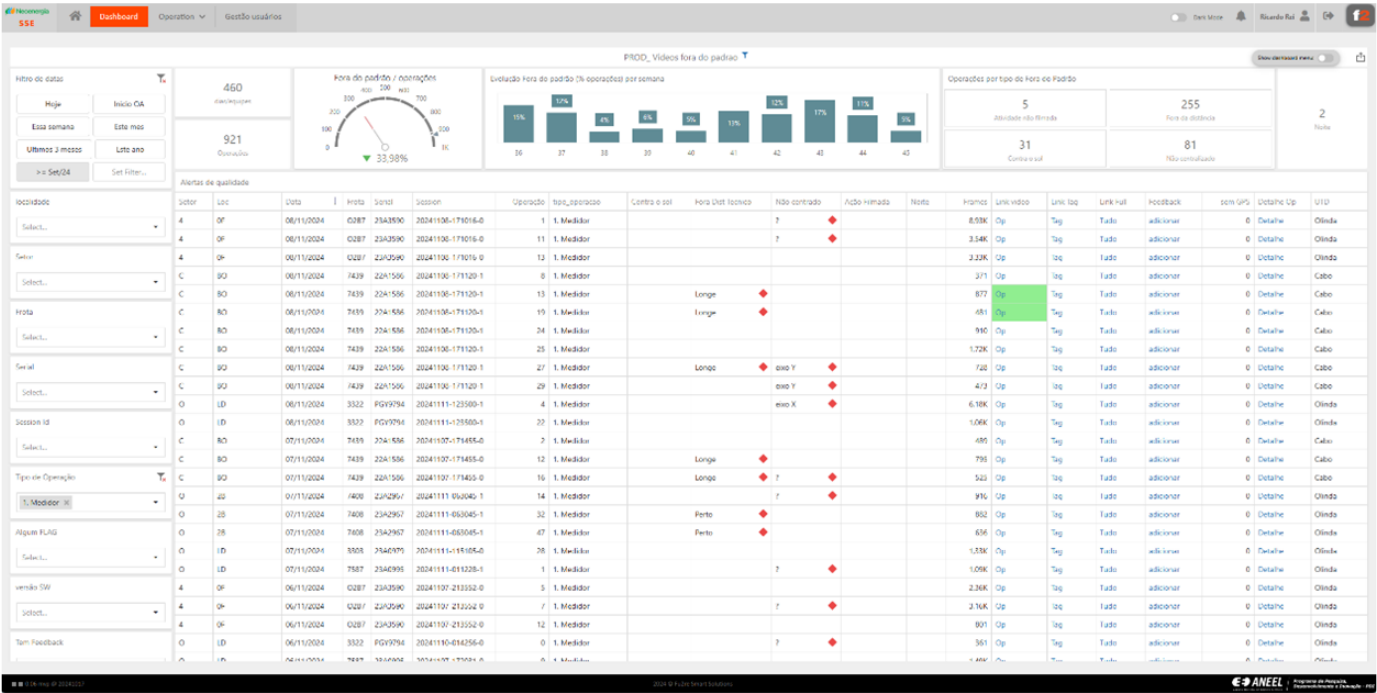


Figura 4 – Tela de acompanhamento de operação e identificação de “fora do padrão”

A tela seguinte mostra também a lista de operações, mas visualizando as inconformidades de segurança encontrados.

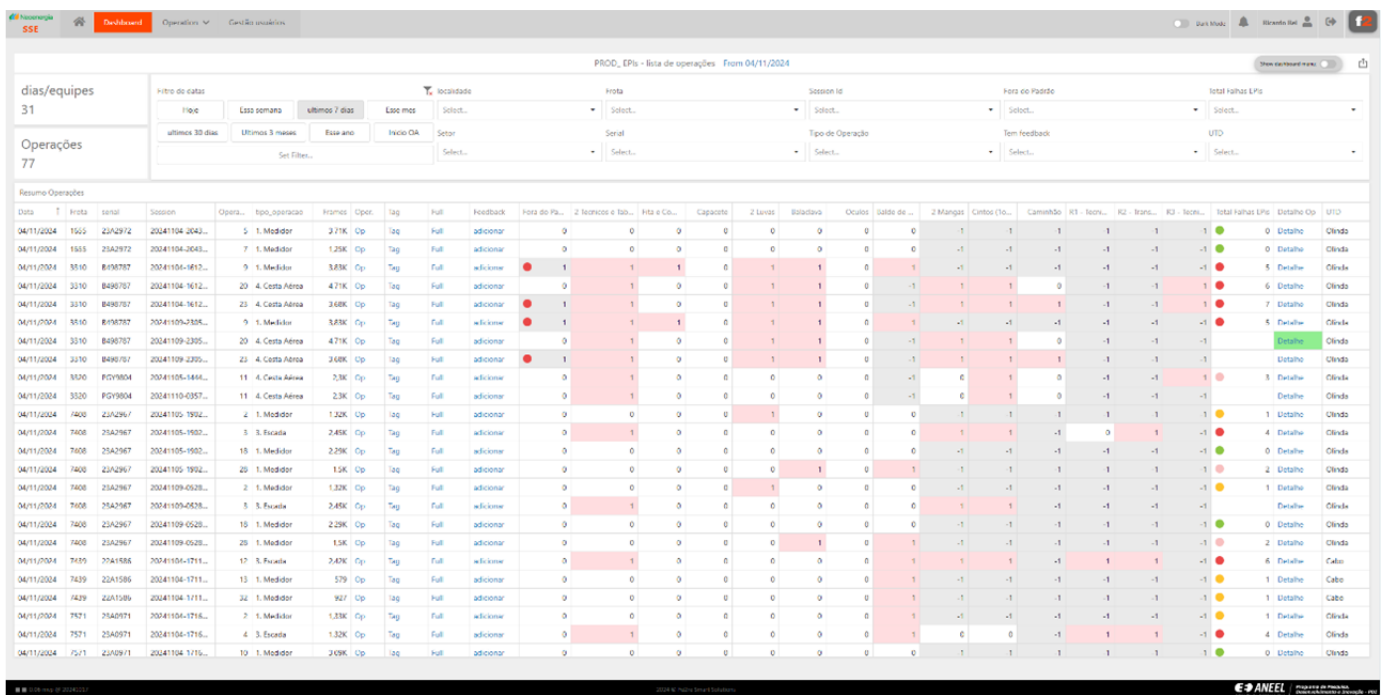


Figura 5 – Lista de operações e respectivas inconformidades de segurança

A tela seguinte mostra o detalhe de uma operação específica (selecionada numa das telas anteriores) com toda a informação relacionada com essa operação (equipe responsável, data, duração, tipo de operação, erros na filmagem, inconformidades de segurança, links para vídeo da operação, etc).

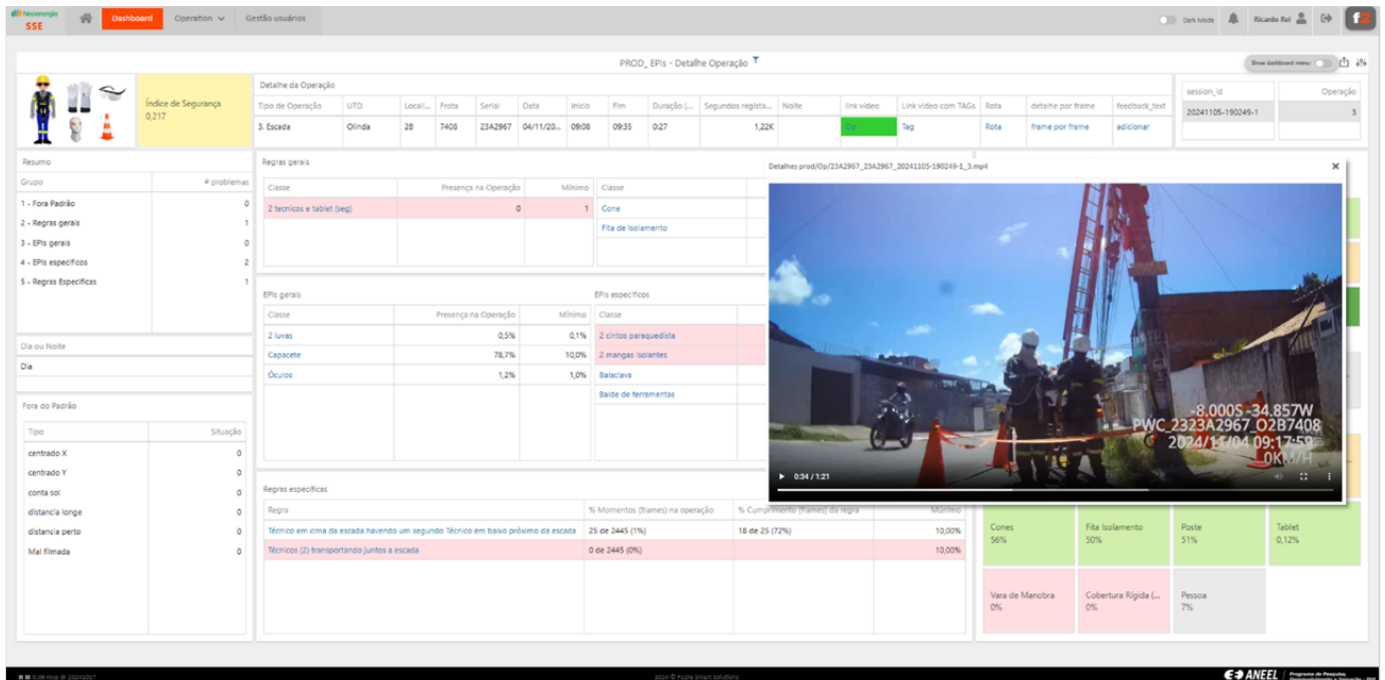
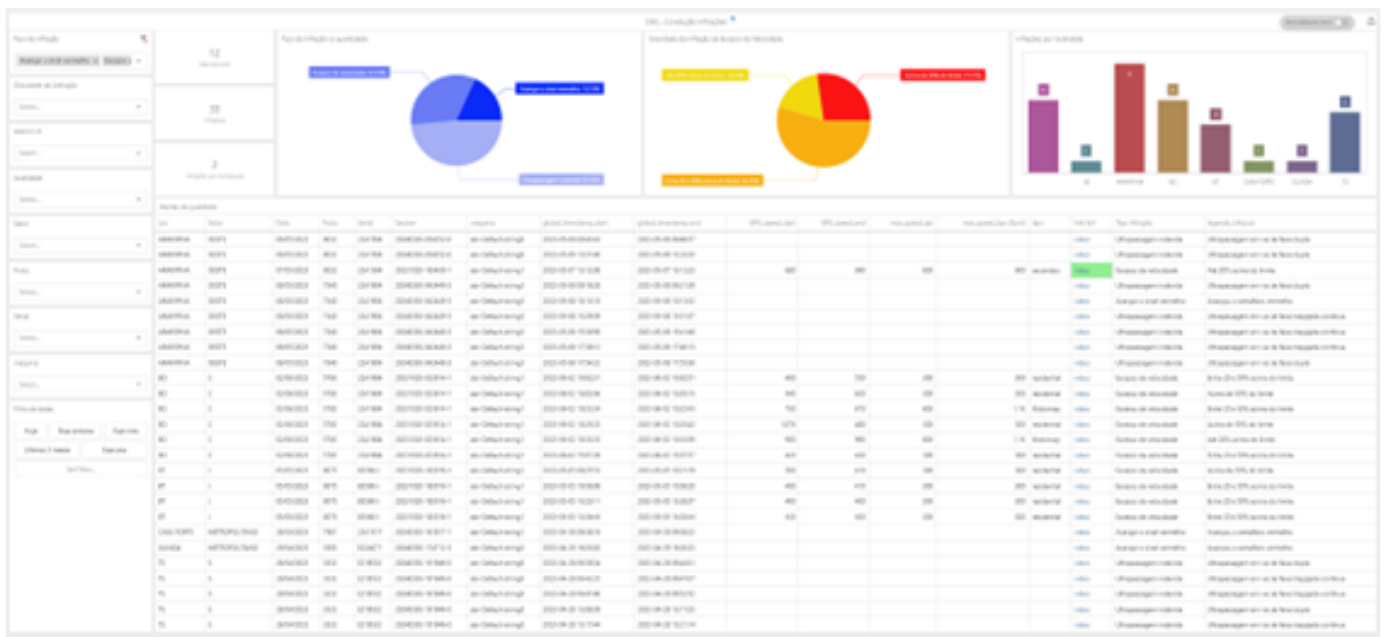


Figura 6 – Detalhe de operação

Para analisar potenciais infrações na condução existe a tela seguinte:



Outro output interessante do SSE é a possibilidade de analisar num mapa as etapas de deslocamento entre as operações e os locais das operações. Que caminhos foram escolhidos, que velocidade em cada etapa. A tela seguinte mostra um exemplo dessa análise:

IA no SSE

Para chegar nestes resultados, no coração do SSE, em cada UTD, está uma máquina com grande capacidade de processamento (CPU e GPU) que processa os vídeos com inteligência artificial. Diferentes modelos de visão computacional foram criados usando o SmartvisionAI. Nesse projeto foram criados modelos de Detecção de objetos (Object Detection) baseados em redes neurais convulsionais do tipo ResNet101 e

YoloV5. Foram escolhidas essas arquiteturas por representarem um bom equilíbrio entre desempenho e performance necessárias para a operação do SSE.

O processo de treinamento dos modelos do SSE foi realizado no SmartvisionAI como mencionado anteriormente. Nesse processo 24 classes foram criadas a fim de identificar diversos elementos que caracterizem situações definidas como potenciais ofensores na utilização de EPI pelas equipes:

Tabela 1 - EPI das Equipes

Luvas	Técnico	Fita isolamento
Capacete	Veículo serviço	Poste
Vestimenta antichama	Utilitário serviço	Tablet
Balaclava	Medidor	Vara de manobra
Protetor facial	Escada	Cobertura Rígida
Óculos de proteção	Cesto veículo	Pessoa
Cinto paraquedista	Balde de lona	Utilitário particular
Manga isolante	Cone	Veículo particular

Para análise da condução foram adicionadas ao modelo as seguintes classes:

- Sinal verde;
- Sinal amarelo;
- Sinal vermelho;
- Faixa duplo contínuo;
- Faixa tracejado contínuo.

No total, cerca de 4.500 imagens, com 30.000 objetos taguados, foram usadas durante o processo de treinamento do modelo de visão computacional. Cerca de 20% desses exemplos de treinamento foram separados para a base de validação.

O processo de treinamento em si demora cerca de 6 horas no servidor do SmartvisionAI e depois de alguns experimentos conseguiu atingir o patamar aceitável para o projeto. Foram ajustados parâmetros internos do modelo e usada a funcionalidade de otimização de modelo do SmartvisionAI, que tem como finalidade otimizar os dados de treinamento para atingir melhores resultados, ou mais expressivos na saída.

A precisão atingida pelo modelo depois do treinamento foi de 85% e o recall de 78%. A matriz de confusão abaixo mostra o detalhe classe a classe. A diagonal mais escura significa que em todas as classes o sistema tende a identificar corretamente o objeto.




Figura 9 - Matriz de confusão observada no conjunto de validação do modelo

Estes indicadores nunca serão “perfeitos” porque as possíveis situações de filmagem são infinitas (o técnico numa mesma operação aparece nas imagens em inúmeras posições, distancias diferentes, com mais ou menos obstáculos entre a câmera e ele, e o mesmo acontece com todos os EPIs usados). E algumas classes puxam naturalmente as métricas para baixo pela sua dimensão e características físicas (por exemplo, os óculos e luvas são objetos muito pequenos, se o técnico estiver a mais de 3 ou 4 metros de distância. São naturalmente mais difíceis de identificar que um cone que é maior, cor forte e quase sempre na mesma posição).

Mas como um filme é uma sequência de imagens, o sistema não precisa encontrar os objetos em todas elas. Assim como um usuário/humano que hoje analisa as imagens, procura momentos dos vídeos para identificar a presença de determinados objetos, o sistema de inteligência artificial faz o mesmo.

Um pós-processamento inteligente analisa depois os objetos encontrados ao longo dos vídeos e conclui sobre a existência de operações e cumprimento das regras de segurança definidas.



Figura 10 – Detecção de objetos relevantes pelo modelo de Object Detection

Ganhos do SSE

O objetivo do sistema, como mencionado antes, é conseguir melhorias na operação das equipas de campo que levem à redução da sinistralidade destas operações.

O SSE aborda esta questão aumentando e melhorando a capacidade de análise do trabalho destas equipas. Ou seja, um olhar mais próximo do seu trabalho que permite depois realizar ações preventivas e corretivas sobre estas equipas). Para tal é essencial um produto confiável em termos de capacidade de análise e volume de trabalho:

1. Ser realmente capaz de **detectar as situações** a que se propôs (identificar operações, tipo de operações, gravações fora do padrão, cumprimento de regras de segurança, inconformidades na condução)
2. **Processar as grandes quantidades de vídeos gerados** pelas equipas operacionais num tempo igual ou inferior ao ritmo de geração desses vídeos.
3. **Otimizar o trabalho das equipas de monitoramento** através de uma plataforma fácil de usar que com toda a informação necessária disponível.

Capacidade de detectar as situações pretendidas

No momento em que este artigo é produzido, o projeto está em fase final da operação assistida tendo os resultados seguintes sido obtidos a partir de uma amostra de operações.

Como mencionado antes, o sistema analisa os vídeos e identifica diferentes situações.

1. **Identificação de operações** – o sistema detecta 100% das operações realizadas desde que minimamente filmadas (câmara apontada durante alguns minutos para a zona da operação). Mesmo em condições adversas (chuva, noite, contra sol) não foram identificadas operações em falta. Um valor baixo de falsas operações é gerado (inferior a 5%), relacionadas com situações em que existe a presença de

objetos típicos das operações, como são o caso de cones, ou os próprios técnicos – exemplo: filmagem durante uma parada num posto de gasolina – com impacto mínimo na operação.

2. **O tipo de operação realizado** – como no anterior, se a operação for corretamente filmada (centralizando a zona de operação de princípio ao fim) o sistema consegue resultados próximos superior a 90%. As exceções encontradas são justificadas na maioria das vezes por questões de filmagem. exemplo: uma operação com cesta aérea que pela distância, luz ou ângulo de filmagem o sistema não detecta corretamente a cesta área boa parte do tempo, acabando por selecionar outro tipo.
3. **Filmagens fora do padrão** – a identificação de situações fora do padrão é o ponto mais subjetivo do sistema (por exemplo: a existência de uma operação considerada contra o contra sol depende do tempo que esse contra sol dura, da intensidade dele, da zona da imagem onde ele acontece). Os resultados mostram um acerto de aproximadamente 95% nas decisões sobre a existência ou não de fora do padrão.
4. **Situações de não cumprimento de regras de segurança** – a verificação do uso de EPIs (uns obrigatórios para qualquer situação, como o capacete, outros específicos por tipo de operação, como o cinto de paraquedista para operações em altura). tem um acerto hoje de aproximadamente 95%. Estes números são impactados pelas características de alguns objetos e pela “qualidade” da gravação – exemplo: objetos pequenos como são óculos, ou luvas, que o técnico está usando, mas estando a filmagem longe deste, dificultam naturalmente a identificação por parte do sistema gerando alguns falsos alarmes. Ainda em desenvolvimento / fase de melhoria está a implementação de regras mais complexas como a validação do uso de cinto de segurança pelo técnico em cima da cesta área.
5. **Inconformidades na condução** – como descrito antes, o sistema identifica situações de excesso de velocidade, passagem de sinal vermelho e ultrapassagem perigosa. São situações (felizmente) mais raras e de difícil avaliação. Está também ainda em desenvolvimento/testes a eficácia desta funcionalidade.

Pelas razões mencionadas, em paralelo com todas as melhorias que têm sido realizadas sobre o sistema ao longo da operação assistida, também o próprio processo de filmagem por parte das equipes de operação vem sofrendo ajustes (melhor posição de filmagem, distância, e comportamento dos técnicos frente à câmera). Estas duas ações realizadas em conjunto têm permitido melhorar a acurácia do sistema a cada mês que passa.

Performance do SSE

Sobre a capacidade de processamento, considerando uma média de 8h de gravação diária por cada equipe operacional, verificou-se que o tempo médio é de aproximadamente 48 minutos. Ou seja, desde que se inicia o processamento de um dia de filmagem até que termine e possa iniciar o seguinte dia de filmagem, passam em média 48 minutos (este resultado é possível entre outros motivos pelo multiprocessamento que permite que 4 dias de gravação possam ser processados em simultâneo sem perda de performance individual. Isto significa que em 24 horas o sistema consegue processar aproximadamente 30 dias de operações ou 240 por semana.

O SSE é escalável, ou seja, se determinada UTD tem um volume de equipes maior que 30 é possível aumentar as capacidades de processamento do SSE para processar mais dias de filmagem. O inverso também, se determinada UTD tiver menor volume de trabalho, um sistema reduzido pode ser aplicado (reduzindo custos naturalmente). Desta forma, qualquer que seja a dimensão da UTD, é possível criar condições para que 100% das operações sejam processadas pelo SSE.

Otimizar o trabalho das equipes de monitoramento

Atualmente as equipes de monitoramento conseguem processar cerca de 1% dos vídeos gerados diariamente pelas equipes de campo. O objetivo do SSE é processar 100% dos vídeos e disponibilizar os resultados disponíveis no portal menos de 24h depois das operações serem realizadas. Tudo automaticamente. Hoje, um funcionário da equipe de monitoramento, para analisar o trabalho de uma equipe de campo, precisa se deslocar na UTD e manualmente baixar os vídeos gravados na câmera da equipe. Depois este funcionário tem que analisar as 8 horas de vídeo (divididos em muitas dezenas de pequenos vídeos) em busca dos momentos de operação para poder analisar se o trabalho foi bem realizado.

O SSE, disponibiliza automaticamente no portal as operações já separadas entre si e com uma pré-avaliação de inconformidades. Ou seja, o mesmo funcionário com a ajuda do SSE consegue de qualquer parte do Brasil acessar informação completa sobre cada operação de cada equipe de campo sem a necessidade de intervenção de terceiros.

Em termos quantitativos um funcionário da equipe de monitoramento consegue hoje analisar cerca de 3 equipes (um dia de trabalho de cada) em aproximadamente 6 horas (sem contar com o tempo de deslocamento para a UTD). Esse mesmo funcionário consegue com o SSE analisar essas mesmas 3 equipes em menos de 1 hora. O ganho direto é de 6 a 10 vezes (depende do volume e tipo de operações realizadas). Este é um ganho direto. Se tivermos em conta outros fatores (de quantificação mais complexa) o ganho é bem maior.

No SSE a informação está online, acesso imediato, o funcionário não tem que se deslocar para a UTD como acontece hoje. Hoje esse funcionário não tem disponível um histórico de vídeos das equipes de campo (com exceções para casos graves encontrados/guardados no passado) pelo que se for detectada uma inconformidade não é possível verificar se é recorrente, ou se é caso isolado. E quando inicia a sua análise, o funcionário tem zero informação sobre o que vai encontrar. A escolha de que equipes / operações para analisar é aleatória.

Com o SSE o funcionário consegue em qualquer momento consultar não apenas as operações mais recentes, mas todas as anteriores, fazendo uma análise mais completa de cada equipe. E como as operações estão pré-avaliadas (informação sobre o tipo de operação, duração, problemas de filmagem e inconformidades de segurança), ele pode focar o seu trabalho em equipes ou operações que o sistema identifica como tendo mais inconformidades. Com a informação reunida e organizada, é possível também ranquear as equipes em função do cumprimento de regras, analisar evolução ao longo do tempo, identificar principais anomalias ou realizar outras análises interessantes cruzando os dados disponíveis. Estes ganhos, contribuem também para otimizar o trabalho da equipe de monitoramento e orientar as ações preventivas/corretivas juntos das equipes de campo.

Finalmente, mas não menos relevante, as equipes de campo sabem que hoje o monitoramento do seu trabalho é raro. Isso cria naturalmente o sentimento de que alguns riscos podem compensar para agilizar/acelerar o trabalho de campo. O fato de saberem que 100% das filmagens serão guardadas (com o SSE) é por si só um incentivo a nunca tentar burlar as regras.

3. Conclusão

O projeto tem como objetivo aumentar a capacidade de identificação de situações de incumprimento de regras de segurança por parte das equipes operacionais (para que deste modo se possam tomar ações que permitam reduzir a sinistralidade destas equipes).

Como demonstrado antes, O SSE não substitui, e sim potencializa as equipes responsáveis por realizar o trabalho de verificações de segurança. Sendo um sistema baseado em IA, ele é probabilístico. Indica

as operações com maior probabilidade de incumprimento, mas com uma enorme capacidade de processamento e escalabilidade. Ao invés da vistoria amostral de cerca de 1% das filmagens realizadas pelas equipes de campo, espera-se que o SSE tenha a capacidade de processar 100% das filmagens e que os alertas possam ser tratados pela mesma equipe que hoje realiza o procedimento amostral (sem aumento de PMSO). Com o grande volume de vídeos analisados, a expectativa da empresa é tratar os desvios de procedimento de segurança junto aos colaboradores, atuando de forma direcionada às principais inconformidades encontradas, gerando ações massivas de prevenção. Sendo assim, teremos uma melhoria significativa e sem precedentes na qualidade e conformidade dos processos de campo e com isso uma redução de eventos acidentais com as equipes.

4. Referências bibliográficas

Modelo Object detection:

Noura, H.N., Salman, O., Couturier, R., & Sider, A. (2021). A Deep Learning Object Detection Method for an Efficient Clusters Initialization. ArXiv, abs/2104.13634. (YoloV5).

Modelo - Sun detection:

Paul E Debevec and Jitendra Malik. Recovering high dynamic range radiance maps from photographs. In ACM SIGGRAPH 2008 classes, page 31. ACM, 2008;

Mark A Robertson, Sean Borman, and Robert L Stevenson. Dynamic range improvement through multiple exposures. In Image Processing, 1999. ICIP 99. Proceedings. 1999 International Conference on, volume 3, pages 159–163. IEEE, 1999;

Tom Mertens, Jan Kautz, and Frank Van Reeth. Exposure fusion. In Computer Graphics and Applications, 2007. PG'07. 15th Pacific Conference on, pages 382–390. IEEE, 2007.

Algoritmo OCR:

Baek, Y., Lee, B., Han, D., Yun, S., & Lee, H. (2019). Character Region Awareness for Text Detection. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 9357-9366;

Shi, B., Bai, X., & Yao, C. (2015). An End-to-End Trainable Neural Network for Image-Based Sequence Recognition and Its Application to Scene Text Recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39, 2298-2304.

Algoritmo Depth estimation:

Ranftl, R., Lasinger, K., Hafner, D., Schindler, K., & Koltun, V. (2019). Towards Robust Monocular Depth Estimation: Mixing Datasets for Zero-Shot Cross-Dataset Transfer. IEEE Transactions on Pattern Analysis and Machine Intelligence, 44, 1623-1637.

Modelo Orientation:

Johnson, J.E., Sundaresan, S., Daylan, T., Gavilan, L., Giles, D., Silva, S.I., Jungbluth, A., Morris, B.M., & Munoz-Jaramillo, A. (2020). RotNet: Fast and Scalable Estimation of Stellar Rotation Periods Using Convolutional Neural Networks. ArXiv, abs/2012.01985.

SMARTVISIONAI:

www.fu2re.com.br / www.smartvisionai.com.br