



Tema: Implantação de Boas Práticas de Gestão e na Melhoria dos Processos de Trabalho e dos Serviços Prestados ao Contribuinte.

3º Lugar

AJNA – Plataforma de Visão Computacional e Aprendizado de Máquina

Responsável pela iniciativa:

Ivan da Silva Brasília

1. TÍTULO DA INICIATIVA

AJNA – Plataforma de Visão computacional e aprendizado de máquina

2. RESUMO DO RELATO DA INICIATIVA

Uso de técnicas de inteligência artificial (IA), visão computacional(CV), mineração de dados e reconhecimento óptico de caracteres(OCR) para classificação, predição e varredura de padrões e alerta de anomalias ou possíveis ameaças. Controle automático por IA de imagens de vigilância e escaneamento de diversas fontes. Integração de pontos de controle por OCR e CV e pontos de comunicação.

3. DESCRIÇÃO DO PROCESSO ANTERIOR À INICIATIVA

Cabe anotar que esta iniciativa impactará positivamente os seguintes processos de trabalho da Cadeia de Valor da RFB:

Fiscalização Tributária e combate aos ilícitos

Promover a Conformidade Tributária

Realizar Pesquisa e Seleção

Realizar a Fiscalização

Realizar a Vigilância e Repressão

Realizar ações de Pesquisa e Investigação

Controle Aduaneiro

Controlar Processos de Importação e Exportação

Realizar Auditorias de Conformidade Aduaneira e Fiscal

Gerenciar Riscos Operacionais Aduaneiros

Vigilância, em breve e ampla definição, é o controle que visa evitar a fuga dos demais controles aduaneiros.

O contrabando e descaminho podem se utilizar de subterfúgios como troca de carga, troca de contêiner, extravio/desvio de carga, simulação de furto, ocultação de carga e simplesmente não declaração ou subdeclaração de conteúdo, passagem de carga e veículos sem registro, etc.

Estes subterfúgios são preocupações do Controle de Carga e da Vigilância Aduaneira.

No processo atual de Vigilância, temos algumas iniciativas nacionais, como a Portaria de Alfandegamento, e iniciativas locais, como análise de risco “Pré-Despacho”, uso de câmeras, OCR, escâneres, dentre outros. Temos rondas terrestres, aéreas e marítimas. Está em estudo o uso de

Drones para complementar estas rondas. Temos também o início de implantação de centrais de vigilância.

A Portaria de Alfandegamento define obrigações para os Recintos Aduaneiros no controle de cargas, pessoas e veículos. Estes sistemas podem ser valiosa fonte de informação para ajudar no combate a ilícitos como contrabando e descaminho, mas falta um processo formal e automatizado de uso das informações destes sistemas.

Algumas unidades, como a Alfândega de Santos com o seu COV – Central de Operações e Vigilância, possuem iniciativas pioneiras de centrais de vigilância. A Alfândega de Santos editou Portarias locais, regulamentando pontos do Alfandegamento. São três portarias, uma regulamenta o uso de OCR nos Gates de entrada e saída, outra regulamenta o uso de escâneres e outra regulamenta o uso de câmeras de vigilância. Além disso, a Alfândega de Santos disciplinou o uso de câmeras para verificação física remota e acompanhamento de saneamentos de mercadorias em roteiro interno.

Com isso, hoje a Alfândega de Santos possui mais de 2.500 câmeras de vigilância disponíveis para a fiscalização, recebe em torno de 3.000 imagens de escaneamento de contêiner. São 15 terminais de carga containerizada para fiscalizar, mais de 15km de piers de atracação, dezenas de REDEX, além de outras dezenas de terminais de granel líquido e sólido, gasodutos, dutos de granel líquido, um universo de 5.000 TEUs por dia, 300.000 declarações de importação por ano, mais as exportações em volume similar, trânsito aduaneiro, processos administrativos, baldeações, entre outros. Tudo isso com uma escassez crescente de mão de obra.

Para navegar neste mar de informação, precisaremos de “robôs” digitais, os chamados agentes inteligentes implementados em aprendizado de máquina.

O recente caso de **apreensão de 60 fuzis** no Aeroporto do Galeão **acende um alerta vermelho** em toda a Receita Federal. O mais alarmante da apreensão é que cargas idênticas haviam sido desembarçadas no passado, algumas no canal vermelho de verificação física, com grande probabilidade de terem sido introduzidos nestas cargas fuzis idênticos. Ocorre que os contrabandistas engenhosamente ocultaram os fuzis no interior da mercadoria. A simples verificação física convencional não consegue detectar o contrabando. Neste caso, a mercadoria não é fácil de ser desmontada e a desmontagem pode comprometer a mercadoria.

Entretanto, neste caso, o uso de imagens de inspeção não invasiva detectaria facilmente os fuzis(conforme imagem abaixo), e seria realizada num tempo e custo muito menor que a verificação física convencional.



Não há, hoje, um processo formal nacional para uso das imagens de escâner (inspeção não invasiva), câmeras de vigilância, reconhecimento automático de caracteres (OCR) e informações de sistemas de controle de carga (ADE02).

Mesmo que a experiência do COV da Alfândega de Santos e outras experiências de sucesso na área de vigilância fossem replicadas na medida do possível, para todas as unidades aduaneiras, ainda assim restaria a dificuldade de lidar com toda a informação disponível. Apenas na Alfândega de Santos, conforme citado, são mais de 3.000 contêineres escaneados ao dia, sem contar os outros tipos de carga movimentados. Isso, somado à crescente escassez de mão de obra, demonstra a necessidade de investimento em tecnologia, análise de risco e automatização.

4. DETALHAMENTO DA INICIATIVA

4.0 – INTRODUÇÃO – Contextualização histórica das tecnologias utilizadas

O processamento de linguagem natural, a visão computacional, o aprendizado de máquina são subcategorias do campo da inteligência artificial. Após um início otimista nos anos 1950, a inteligência artificial amargou alguns anos de ostracismo. As redes neurais artificiais, vedetes atuais do aprendizado de máquina, foram imaginadas inicialmente na década de 60 e amargaram um longo período de desinteresse, devido principalmente à publicação de um estudo de Seymour Papert ¹ que demonstrava a incapacidade dos Perceptrons, redes neurais usadas à época, de aprenderem funções não lineares.

1 Marvin Minsky and Seymour Papert, 1972 (2nd edition with corrections, first edition 1969) Perceptrons: An Introduction to Computational Geometry, The MIT Press, Cambridge MA, ISBN 0-262-63022-2.

Entretanto, este interesse foi renovado após trabalhos de pesquisadores como Geoffrey Hinton² e Yann Le Cun³, que desenvolveram e aperfeiçoaram métodos novos para treinamento de redes neurais, bem como com a disponibilidade crescente de novas tecnologias de processadores(as chamadas GPUs gráficas para jogos 3D, ótimas para processamento de redes neurais) e armazenamento de dados(bases de dados gigantes ou “Big Data”). Começando na década de 90, com pesquisas de técnicas chamadas de “aprendizagem profunda”, “Deep belief nets”, “Redes Convolucionais” e “Redes recorrentes”, o interesse em redes neurais tem crescido ano após ano no meio acadêmico e empresarial especializado, culminando com uma explosão nos últimos 10 anos. Em 2016, após alguns resultados impressionantes, a inteligência artificial se tornou assunto recorrente inclusive de revistas e publicações não especializadas:

“A tradução automática e outras formas de processamento de linguagem também se tornaram muito mais convincentes, com Google, Microsoft, Facebook e Baidu apresentando novos truques todos os meses. O Google Translate agora processa orações faladas em um idioma em orações faladas em outro para 32 pares de idiomas, enquanto oferece traduções de texto para 103 línguas, incluindo Cebuano, Igbo e Zulu. O aplicativo Caixa de entrada do Google oferece três respostas prontas para muitos e-mails recebidos.

Depois, há os avanços no reconhecimento de imagens. As mesmas quatro empresas possuem recursos que permitem pesquisar ou organizar automaticamente coleções de fotos sem tags identificadores. Você pode pedir para ser mostrado, digamos, todos aqueles que têm cachorros neles, ou neve, ou mesmo algo bastante abstrato como abraços. Todas as empresas possuem protótipos nas obras que geram descrições longínquas para as fotos em segundos.

Pense sobre isso. Para reunir fotos de cães, o aplicativo deve identificar qualquer coisa de um Chihuahua a um pastor alemão e não ser tropeçado se o cachorro estiver de cabeça para baixo ou parcialmente obscurecido, à direita do quadro ou à esquerda, em nevoeiro ou neve, sol ou sombra. Ao mesmo tempo, ele precisa excluir lobos e gatos. Usando apenas pixels. Como isso é possível?

Os avanços no reconhecimento de imagens se estendem muito além de aplicativos sociais legais. As startups médicas afirmam que em breve poderão usar computadores

2 Rumelhart, D. E., Hinton, G. E., and Williams, R. J. (1986) Learning representations by back-propagating errors. Nature, 323, 533--536.

3 Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard and L. D. Jackel: Backpropagation Applied to Handwritten Zip Code Recognition, Neural Computation, 1(4):541-551, Winter 1989.

para ler os raios X, as IRM e as tomografias computadorizadas com mais rapidez e precisão do que os radiologistas, diagnosticar o câncer mais cedo e menos invasivo e acelerar a busca por produtos farmacêuticos salva-vidas. Um melhor reconhecimento de imagem é crucial para desencadear melhorias na robótica, nos drones autônomos e, claro, nos carros auto-dirigidos (...)

Mas o que a maioria das pessoas não percebe é que todos esses avanços são, na essência, o mesmo avanço. Todos eles foram tornados possíveis por uma família de técnicas de inteligência artificial (IA) conhecidas popularmente como aprendentes profundos, embora a maioria dos cientistas ainda prefira chamá-los por sua designação acadêmica original: redes neurais profundas.

A coisa mais notável sobre as redes neurais é que nenhum ser humano programou um computador para executar qualquer uma das acrobacias descritas acima. Na verdade, nenhum humano poderia. Os programadores, em vez disso, alimentaram o computador com um algoritmo de aprendizado, expuseram-se a terabytes de dados - centenas de milhares de imagens ou anos de amostras de fala - para treiná-lo e, em seguida, permitiram que o computador descobrisse a si próprio como reconhecer os objetos, palavras ou frases desejadas.”

(Revista Fortune - citação automaticamente traduzida pelo Google, utilizando uma rede neural recorrente - em <http://fortune.com/ai-artificial-intelligence-deep-machine-learning/>)

“Inteligência Artificial causa furor e não é hype!

*Por Eduardo Prado**

17/04/2017 ... Convergência Digital

Recentemente quando foi noticiado que a Apple tinha conseguido autorização para testar seu carro autônomo (sem motorista) na Califórnia [1] constatamos que o DMV (o “Detran” californiano) já tinha a mesma autorização para 30 outras empresas (sic!) [2]. Por que esse “furor” para testar algo que só vai estar no mercado em 2026? [3] Isso é porque o negócio de “self-driving car” está extremamente alavancado e isso foi muito provocado pela Inteligência Artificial (IA) que viabilizou este negócio desde a escalada exponencial dela a partir de 2012 quando a tecnologia de “Deep Learning” [4] que viabiliza a Visão por Computador desse carro autônomo deslançou.

Hoje a IA está muito (muito mesmo) “bombada” (e não é “hype”) no mercado mundial e muito desse furor se deve ao interesse no “Deep Learning” da IA. No fundo no fundo, a IA é baseada em algoritmos que manipulam “dados” que é a sua força motriz. Esses algoritmos da IA são compostos de 03 famílias principais: (1) “Machine Learning” (ou Aprendizagem de Máquina) [5]; (2) “Deep Learning” (ou Rede Neural Profunda); e NLP (Processamento de Linguagem Natural) [6]. O “Deep Learning” é um subconjunto do grupo de “Machine Learning”. Para uma Organização “levar a vantagem” da IA, ela precisa ter dados (e muito dados mesmo para treinar os modelos matemáticos da IA). Sem “dados” é “no way” para a IA ... done!

Os dados atualmente representam um conjunto de alto valor estratégico para as organizações. As empresas na vanguarda das tendências tecnológicas estão usando suas capacidades para estabelecer vantagens formidáveis através dos dados. Estamos presenciando agora no mercado enormes disparidades de desempenho entre um pequeno grupo de empresas líderes e uma empresa média típica. As capacidades de análise de dados (“data analytics”) tornaram-se um fator extremamente diferenciador na competição da indústria, já que os principais players usam dados e análises para aumentar a receita, para entrar no mercado ou, até mesmo, criar novos mercados, para mudar a natureza de sua relação com os clientes e também para aumentar a eficiência organizacional. As organizações que estão atrasadas (e não valorizam dados) precisarão se adaptar rapidamente antes que a diferença cresça.

Os dados se tornaram a nova classe de ativos corporativos – e a melhor maneira para as empresas gerar e acessar eles é digitalizar tudo o que fazem. A digitalização de interações com os clientes fornece uma riqueza de informações para marketing, vendas e desenvolvimento de produtos, enquanto a digitalização interna gera dados que podem ser usados para otimizar as operações e melhorar a produtividade.”


(Retirado de <http://www.convergenciadigital.com.br>)

De fato, tecnologias como reconhecimento facial, reconhecimento de imagens e processamento de linguagem têm evoluído de forma estrondosa. Como exemplo, podemos visualizar os últimos resultados da competição Imagenet.

Da Wikipedia:


“O projeto ImageNet é um grande banco de dados visual projetado para uso na pesquisa de software de reconhecimento de objetos visuais . A partir de 2016, mais

de dez milhões de URLs de imagens foram anotados manualmente pela ImageNet para indicar quais objetos são retratados; em pelo menos um milhão de imagens, caixas de encadernação também são fornecidas. [1] O banco de dados de anotações de URL de imagem de terceiros é livremente disponível diretamente da ImageNet; No entanto, as imagens reais não são propriedade da ImageNet. [2] Desde 2010, o projeto ImageNet executa um concurso de software anual, o Descoberta de Reconhecimento Visual de grande escala ImageNet (ILSVRC), onde os programas de software competem para classificar e detectar objetos e cenas corretamente.”




Conforme visto no gráfico acima, as redes neurais treinadas para reconhecimento de imagens têm obtido avanços espantosos. De fato, as redes neurais têm sido utilizadas em busca e indexação de imagens, categorização de imagens, tradução de idiomas, reconhecimento de objetos, muitas vezes com desempenho superior ao desempenho humano médio.

Como exemplo, vejamos estas imagens retiradas da página da Universidade Stanford, demonstrando uma rede treinada para geração automática de legendas para imagens:



"man in black shirt is playing guitar."




"construction worker in orange safety vest is working on road."




"two young girls are playing with lego toy."



"boy is doing backflip on wakeboard."



"girl in pink dress is jumping in air."



"black and white dog jumps over bar."



"young girl in pink shirt is swinging on swing."



"man in blue wetsuit is surfing on wave."

A Receita Federal do Brasil já utiliza, com sucesso, uma tecnologia de inteligência artificial chamada Redes Bayesianas para auxiliar na parametrização de declarações no Siscomex.

Este projeto propõe o uso de diversas tecnologias de aprendizado de máquina e redes neurais, bem como mineração de dados, "web scraping", "web services", scripts e comunicação máquina-máquina para integrar fontes de informação, especialmente fontes de imagens, e analisar automaticamente o risco, provendo uma ferramenta integrada e automatizada para suporte à análise de risco no controle de carga e vigilância aduaneira.

4.1. IDEALIZAÇÃO, CONCEPÇÃO E TRABALHO EM EQUIPE

Este projeto foi idealizado como uma evolução dos trabalhos desenvolvidos no âmbito do COV da Alfândega de Santos, tendo sido imaginado como consequência natural das necessidades diagnosticadas e dificuldades encontradas no dia a dia dos trabalhos de Vigilância em uma grande Unidade Aduaneira.

4.2. ENQUADRAMENTO NO TEMA CRIATIVIDADE E INOVAÇÃO

Este projeto une diversas tecnologias extremamente modernas, de forma inovadora e com imenso potencial de retorno. Une, de forma inédita, inovações acadêmicas recentes com o domínio específico da especialidade Vigilância Aduaneira. É uma proposta de aplicação dos últimos avanços científicos e acadêmicos da área de inteligência artificial em casos práticos, de forma integrada a processos de trabalho existentes.

O projeto propõe a integração de algoritmos de inteligência artificial aos processos de vigilância e de análise de risco, permitindo expandir enormemente os acertos da análise de risco

na zona primária, aumentar a rastreabilidade e auditabilidade dos processos de importação e exportação, aumentar a produtividade do Servidor Aduaneiro, por não desperdiçar suas horas de trabalho em verificações que não trarão sucesso e permitirá à RFB aumentar para qual número julgar mais estratégico o percentual de cargas “verificadas” em cada Unidade (verificadas por escaneamento, por cruzamento de dados e por análise de risco) com impacto zero ou próximo de zero no fluxo logístico e nos seus custos, bem como nos custos e necessidade de mão-de-obra da própria Receita Federal do Brasil.

4.3. OBJETIVOS DA INICIATIVA

Conforme exposto, hoje existem algoritmos de IA que permitem a análise computacional de padrões, de imagens e de diversas fontes de dados, e a produção de classificações ou previsões numéricas a partir destes dados “não estruturados”. São diversas formas de “visão computacional”, classificação, processamento de linguagem natural, reconhecimento de faces, caracteres, pessoas, veículos, etc.

Assim, através da análise da imagem do escaneamento pelo computador é possível classificá-lo em cheio/vazio, uniforme/não uniforme, bagagem/não bagagem, talvez até classificações mais sofisticadas, como a possibilidade de “enxergar” produtos ou embalagens pré treinados ou até uma classificação fiscal. Além disso, é possível prever peso e volume e detectar padrões como armas e drogas.

O objetivo do sistema AJNA é estabelecer um "*pipeline*", um fluxo de trabalho, para dar suporte a uma série de *scripts* organizados sistematicamente e de forma iterativa e incremental. Estes scripts realizarão a aquisição e pré-processamento de imagens de escaneamento, imagens de câmeras de vigilância, fotografias de radares, sistemas de WMS e sistemas de trânsito, dados de GPS, dados da Internet, e outros dados não estruturados ou estruturados para detectar automaticamente situações de risco (falsa declaração, carga oculta, *ripoff*, movimentos não autorizados, etc).

São objetivos específicos do sistema:

Classificação, previsão e varredura de padrões para alerta de anomalias ou possíveis ameaças

Controle automático por IA de imagens de vigilância e escaneamento

Utilizar tecnologia e métodos para exercer a vigilância aduaneira, otimizando resultados

Aumentar percepção de risco na fraude

Atuar de modo transversal e diversificado na investigação e descoberta de fraudes

Atuar de forma ágil e diversificada, desde antes da descarga até a entrega, mapeando tentativas de enganar os demais controles da Aduana

Permitir “fiscalização ampla, automática e integral”, através de agentes inteligentes automáticos, de diversos processos aduaneiros

Subsidiar e complementar o processo de análise de risco, diminuindo a necessidade de intervenção e parada do fluxo normal da carga (diminuição das aberturas e verificações físicas SEM resultado)

DIMINUIÇÃO do total de verificações físicas tradicionais, e ao mesmo tempo INCREMENTO PERCENTUAL das verificações físicas com RESULTADO.

Resposta às demandas da sociedade.

4.4. PÚBLICO-ALVO CONTEMPLADO NA INICIATIVA

Todos os Servidores envolvidos na Vigilância e Repressão serão direta e positivamente impactados pelo sistema, aumentando sua eficiência e eficácia.

Indiretamente, os Servidores envolvidos em Despacho Aduaneiro, Procedimentos Especiais e Análise de Risco terão mais informação em seus processos, mais subsídios e ferramentas para a verificação física, maiores possibilidades de pesquisas e menor desperdício de tempo em procedimentos sem resultado.

Unidades de recebimento e origem de trânsito aduaneiro poderão fazer comparação e acompanhamento automático de imagens de inspeção não invasiva, informações de cadeia logística e pesagens, entre outras.

Unidades de zona secundária e a revisão aduaneira também serão positivamente impactados, pela possibilidade de pesquisas avançadas e produção de informação e evidências baseadas em imagens mesmo em cargas que não foram submetidas à verificação física tradicional na zona primária.

Maior auditabilidade dos processos de importação, trânsito e importação, e das aberturas, unitizações, desunitizações, movimentações de carga com evento de registro de imagem.

4.5. ETAPAS DA IMPLANTAÇÃO

Já há um protótipo em utilização na Alfândega de Santos. O horizonte temporal de implantação completa do Sistema é de 2 a 4 anos. O projeto prevê um desenvolvimento incremental e iterativo, com entregas frequentes, preferencialmente mensais.

A cada nova entrega do sistema, a implementação exigirá o treinamento dos usuários e a criação e adoção de processos de trabalho baseados na utilização do Sistema informatizado. A metodologia prevê também que a aplicação procurará responder primeiro a demandas simples, passando gradualmente a demandas mais complicadas. **Detalhamento no item 4.7.**

4.6. RECURSOS UTILIZADOS

São recursos necessários ao desenvolvimento do sistema:

Recursos Humanos:

1. Pelo menos 1(um), preferencialmente 3(três) Desenvolvedor(es) dedicado(s), com experiência na área de Vigilância e conhecimento em algoritmos de aprendizado de máquina e visão computacional.

2. No mínimo 2(dois) Servidores aduaneiros, com experiência na área de Vigilância e facilidade com tecnologia, dedicados no mínimo 50% à especificação, teste e utilização da aplicação.

3. 1(um) “Stakeholder”, vinculado a alguma chefia da área de Vigilância da Unidade, que será o “patrocinador” local do sistema, responsável por gerenciar sua utilização e implantação, bem como definir os procedimentos formais de uso e aplicação.

4. Equipe/Setor responsável por tratar os ilícitos aduaneiros apontados pelo sistema.

A estrutura prevista nos itens 2, 3 e 4 deverá ser replicada em cada Unidade que for utilizar o sistema.

Recursos tecnológicos:

Ao menos uma estação de trabalho dedicada ao sistema, mínimo de 8GB de RAM e GPU Nvidia com 2GB e 500GB de HD. Preferencialmente com pelo menos 16GB de RAM, HD de 1TB integrado a SSD e GPU Nvidia compatível com Cuda e com 8GB ou mais de memória dedicada à GPU.

É também necessário que a Unidade tenha acesso a câmeras de vigilância, escâneres e sistemas ADE02/03 dos Recintos jurisdicionados.

Recursos financeiros:

Não há necessidade especial, e é possível desenvolver o projeto sem gastos adicionais. Entretanto, caso sejam disponibilizados recursos financeiros, segue previsão de necessidade.

Pode ser necessário, com a evolução do sistema, adquirir ou alugar *Hardware* para treinamento de redes neurais. Estações tipo “Gamer” possivelmente darão conta da demanda e costumam custar de R\$7.000,00 a R\$15.000,00, com configuração típica de 32GB de RAM, GPU Nvidia com GPU dedicada 16GB e discos rígidos SATA de alto desempenho com cache SSD. Opção mais cara, servidores especializados são encontrados no mercado entre R\$20.000,00 e R\$150.000,00. É possível também alugar espaço em supercomputadores em serviços como Amazon AWS, Google Cloud ou Floyd Hub.

Por ser uma área em franco desenvolvimento e crescimento, seria muito interessante a disponibilidade de verba de treinamento para os servidores envolvidos. Projeta-se um investimento de R\$20.000,00 por Desenvolvedor para todo o Projeto. Outra alternativa seria a contratação de consultorias.

Processos:

Os processos de trabalho terão que acompanhar as funcionalidades do sistema, conforme forem sendo implantadas.

Os objetivos de processo “Ampliar o combate ao contrabando, ao descaminho e à sonegação fiscal” e “Contribuir para a facilitação do comércio internacional” serão os mais positivamente impactados.

4.7. DESCRIÇÃO DO PROCESSO POSTERIOR À INICIATIVA E MELHORIAS ALCANÇADAS

Para lidar com estes desafios e com toda esta informação disponível, a proposta é a concepção e construção de sistema informatizado que, em primeiro lugar, integre o máximo de fontes de informação disponíveis. Em segundo lugar, permita a aplicação e configuração de parâmetros de análise de risco. Em terceiro lugar, o coração do sistema, a aplicação dos últimos avanços em aprendizagem de máquina e redes neurais para análise de imagens e identificação automática pelo sistema, de divergências, inconsistências e ameaças.

O sistema deve cumprir objetivos cumulativos e incrementais, como na construção de um prédio. Começa com as “fundações”, isto é, obter, integrar e validar as fontes de dados, e depois começa a “responder perguntas”, estas por sua vez cada vez mais complicadas. Assim, **são etapas previstas**, podendo surgir novas com a evolução do desenvolvimento do sistema ou com a própria evolução tecnológica:

- Construir um Banco de Dados de imagens e um cadastro de fontes de imagens e informações
- Importar automaticamente e de forma periódica/recorrente imagens e informações das fontes cadastradas
- Aplicar algoritmos e comparação entre fontes para responder questões e enviar relatório para a fiscalização
- Checar se todos os contêineres programados para “escaneamento” possuem imagem disponível
- Se houver fotografia do contêiner e veículo disponíveis, fazer verificação automática por OCR para checar se a imagem de escaneamento declarada pela fonte é compatível com as imagens fotográficas do exterior do contêiner
- Treinar algoritmo para detecção do tipo e tamanho do contêiner: 20' ou 40', FlatRack, Tanque, entre outras. ⁴
- Treinar rede para detecção de bordas das imagens de contêiner e recorte de imagem
- Treinar algoritmo simples para detecção de contêiner vazio ou cheio (implementado)
- Treinar algoritmo mais sofisticado para detecção de contêiner vazio com anomalia de interesse fiscal
- Treinar algoritmo para prever o peso do contêiner de acordo com a imagem. Comparar com a pesagem de balança e a declarada (implementado). Utilizar algoritmo para prever a probabilidade de compatibilidade com as NCMs declaradas.
- Treinar algoritmo de indexação para procura de imagens similares(implementado). ⁵

4 <https://medium.com/towards-data-science/how-to-train-your-own-object-detector-with-tensorflows-object-detector-api-bec72ecfe1d9>

5 <https://arxiv.org/pdf/1511.06434.pdf>
<https://arxiv.org/abs/1004.5370>

<https://arxiv.org/pdf/1708.00838v1.pdf>

- Produzir indexação que permita variação posicional (Semântica/baseado em contexto) ⁶
- Treinar rede que distingue imagem uniforme ou não uniforme
- Treinar rede que distingue as embalagens de uma imagem
- Treinar algoritmo para identificar contêineres com NCMs uniformes ⁷
- Criar pontos de controle próprios da Receita Federal com OCR de contêiner e placa de veículo ⁸

Ou seja, o sistema disponibilizará:

- Uma interface de usuário para interação, consultas e configuração;
- Agentes para importação periódica de dados de fontes externas: imagens de escaneamento, câmeras, outros sistemas informatizados, conforme a necessidade;
- Banco de Dados seguro para armazenar e controlar estas informações.

O Desenho do sistema proverá uma maneira de adicionar, conforme forem sendo implementados, módulos contendo algoritmos que permitirão responder automaticamente às perguntas elencadas acima e outras que forem surgindo.

Segue como exemplo, algumas telas e ações já disponíveis no protótipo do sistema:

AJNA v0.1 (protótipo)

- Todos os dados e imagens de escaneamento (16 escâneres) em uma única base de dados;
- Rápida busca por identificação do contêiner retornando imagem e data e hora do escaneamento;
- Classificação do contêiner em “vazio” ou “não vazio”;
- Análise automática de contêineres vazios embarcados e desembarcados, apontando se todos os contêineres foram escaneados e se há algum vazio classificado como “não vazio”;
- Procura por imagens similares.

6 <https://arxiv.org/pdf/1406.2661.pdf> <https://arxiv.org/pdf/1606.03498v1.pdf>

7 <https://arxiv.org/pdf/1606.02228.pdf> <https://arxiv.org/pdf/1409.1556.pdf>

8 http://doc.openalpr.com/accuracy_improvements.html#training-ocr

Tela inicial do Sistema, informando fontes de imagens, dados estatísticos gerais, e dados sobre as integrações programadas.

Menu AJNA - Interface Web Suporte

Lista de Recintos que fornecem imagens

- BTP
- DEICMAR EXP
- DEICMAR IMP
- ECOPORTO
- LIBRA
- LOCALFRIO
- MARIMEX
- NOVALOG
- SANTOS BRASIL
- SBT

Total de imagens de escaneamento importadas: 21093

- BTP
- ECOPOR
- L
- MARI
- SANTOS BRASIL
- S

Agendamentos programados:

- ECOPORTO 20170727 2359
- MARIMEX 20170727 2359
- SANTOS BRASIL 20170727 2359
- NOVALOG 20170727 2359
- LOCALFRIO 20170727 2359
- BTP 20170727 2359
- DEICMAR IMP 20170727 2359
- DEICMAR EXP 20170727 2359
- LIBRA 20170728 2359
- SBT 20170728 2359

AJNA

Visão computacional e aprendizado de máquina aplicados à Vigilância Aduaneira e Análise de Risco

Tela detalhe da pesquisa de contêiner – exemplo com Contêiner Vazio

Menu AJNA - Interface Web Suporte


Data de registro: July 28, 2017, 1:55 a.m.

Numero: SUDU8906006

Truck ID: 2017072700262100CV

Fonte: SANTOS BRASIL

[Procurar imagens de contêiner similares](#) Contêiner avaliado como VAZIO



Tela detalhe da pesquisa de contêiner – exemplo com Contêiner não Vazio

The screenshot shows the 'AJNA - Interface Web' interface. At the top, there is a navigation bar with 'Menu' and 'Suporte' links. Below the navigation bar, the container details are displayed:

- Data de registro:** July 20, 2017, 7:23 p.m.
- Numero:** MSKU6942459
- Truck ID:** 20170720002631000Q
- Fonte:** MARIMEX

To the right of the details is a small thumbnail image of the container. Below the details, there is a link: [Procurar imagens de contêiner similares](#). The main heading for this section is 'Contêiner avaliado como NÃO VAZIO'. Below this, the text 'Imagem 'Stamp' original:' is followed by a large, high-resolution image of the container's side, showing a 'Stamp' area with various markings and text.

Busca de imagens similares

The screenshot shows the 'AJNA - Interface Web' interface with a search filter section. It includes input fields for 'Numero:', 'Data inicial:', and 'Data final:', along with a 'Filtrar' button. Below the filter section, a grid of 12 thumbnail images of containers is displayed, each with its corresponding container number below it:

- MSKU6942459
- MSKU6942459
- HLXU5056600
- HASU4346220
- HLBU1464905
- SUDU8824021
- HLXU8633394
- MSCU5603699
- GLDU5408275
- BSIU2733051
- SUDU5304387
- HLBU1181736



4.7.1. RESULTADOS QUANTITATIVOS E/OU QUALITATIVOS

Permitir “fiscalização automática integral e ampla”, através de agentes inteligentes, de diversos processos aduaneiros;

Permitir combate a fraudes no trânsito aduaneiro que hoje são de difícil tratamento;

Diminuição da necessidade de intervenção e parada do fluxo normal da carga;

Diminuição do total de verificações físicas;

Incremento percentual das verificações físicas com resultado;

Detecção de novos tipos de fraudes não conhecidas e/ou de difícil detecção pelos métodos convencionais;

Aumento da segurança funcional dos Servidores responsáveis pelas verificações físicas;

Idealmente, detecção total e imediata das fraudes “escancaradas” de contrabando e descaminho;

Incremento da conformidade tributária e da arrecadação aduaneira;

Rastreabilidade de processos;

Diminuição de problemas de troca e extravio no saneamento (contagem) de mercadorias abandonadas e apreendidas;

Empoderamento e incremento brutal da produtividade dos Auditores e Analistas Aduaneiros envolvidos no processo Vigilância.

4.8. LIÇÕES APRENDIDAS

4.8.1. FATORES CRÍTICOS DE SUCESSO

- Existência de um plano de vigilância local;
- Implantação e uso de escâneres de carga e câmeras de vigilância;
- Envolvimento da Administração;
- Envolvimento, como clientes e colaboradores, das equipes de análise de risco, despacho e procedimentos especiais.

4.8.2. IMPREVISTOS OBSERVADOS

Não se aplica.