

Uma Solução de Chatbot para a Realização de Autoleitura do Consumo de Energia por meio de Aplicativos de Mensagens

Carlos V. M. Rocha* Gabriel X. Bras* José E. S. Oliveira*
 Arthur G. S. Fernandes* Arthur A. Lima*
 Anderson M. P. Paiva* Italo Francyles S. da Silva*
 Simara Vieira da Rocha* Eliana Márcia G. Monteiro**
 Eduardo Camacho Fernandes**

* Núcleo de Computação Aplicada
 Universidade Federal do Maranhão (UFMA) - São Luís, MA, Brasil
 (e-mail: {carlos.martins, gabriel.bras, joseduardo, arthurgsf, arthur,
 andersonpaiva, francyles, simara}@nca.ufma.br)
 ** Equatorial Energia - São Luís, MA, Brasil
 (e-mail: {eliana.monteiro,
 eduardo.fernandes}@equatorialenergia.com.br)

Abstract: Power companies have been presenting automatic reading as an efficient alternative to mitigate financial losses and follow the recommended sanitary measures due to the Covid-19 pandemic. In this context, this work presents a chatbot solution for self-reading through messaging applications. The chatbot is integrated with a method that applies image processing and computational intelligence to the automatic reading of energy consumption. This solution is under development as part of a research and development (R&D) project. The reading recognition method presents accuracy of 89 % and 77.2 % for the analogical and digital meters, respectively.

Resumo: As companhias do setor elétrico têm apresentado a autoleitura como uma alternativa eficiente para mitigar perdas financeiras e seguir as medidas sanitárias recomendadas em virtude da pandemia do Covid-19. Nesse contexto, este trabalho apresenta uma solução de chatbot para a autoleitura por meio de aplicativos de mensagens. O chatbot é integrado a um método que aplica processamento de imagem e inteligência computacional para a leitura automática do consumo de energia. Essa solução encontra-se em desenvolvimento no âmbito de um projeto de pesquisa e desenvolvimento (P&D). Preliminarmente, o método de reconhecimento das leituras apresenta acurácia de 89% e 77,2% para os medidores analógicos e digitais, respectivamente.

Keywords: Energy; Covid-19; Self-reading; Chatbot; Image Processing; Deep Learning;
Palavras-chaves: Energia; Covid-19; Autoleitura; Chatbot; Processamento de Imagens; Aprendizado Profundo;

1. INTRODUÇÃO

O processo de distribuição de energia elétrica no Brasil possui uma relevante complexidade. Estudos feitos pela Empresa de Pesquisa Energética (EPE) mostram que, em 2018, quase 30% do consumo nacional de energia está relacionado ao consumo residencial (ANEEL, 2019). Além disso, previsões apontam que o número de domicílios passará de 75 milhões em 2020 (Vidinich and Nery, 2009). Esse cenário é marcado pela frequente ocorrência de perdas financeiras, como furtos de energia e erros nos processos de leitura e faturamento mensal de consumo.

As companhias de energia elétrica realizam a leitura e fiscalização do consumo por meio dos leituristas. Eles são os funcionários responsáveis por recolher as leituras dos medidores diretamente nas residências dos consumidores. Como esse processo é feito manualmente, torna-se susce-

tível a erros que provém ônus para as companhias. Além disso, essa prática pode trazer riscos à saúde dos leituristas devido à exposição às variações do clima e à periculosidade dos locais de leitura. Também é importante ressaltar que a visita dos leituristas às residências não é recomendável de acordo com as normas de distanciamento social elaboradas para conter o avanço da pandemia de Covid-19.

Nesta situação, o grupo Equatorial Energia e outras companhias do setor energético têm buscado meios alternativos de realizar a leitura do consumo de energia com mais eficiência para minimizar os riscos, os custos, e combater irregularidades. Dentre elas, a que mais se destaca é a autoleitura, que é o processo de leitura realizado pelo próprio consumidor através de plataformas digitais, como dispositivos móveis, por meio dos quais as informações referentes ao consumo são enviadas à companhia para que sejam validadas e processadas. Essa prática tem sido apoi-

ada pela Agência Nacional de Energia Elétrica (ANEEL) mediante uma resolução normativa¹.

Ao colocar o consumidor como parte integrante do processo de leitura do consumo, a autoleitura promove o estreitamento na relação entre ele e a companhia. Dessa forma, procura-se diminuir os custos relacionados a esse processo, bem como mitigar a ocorrência de erros e fraudes, principalmente em áreas de difícil acesso e fiscalização, como a zona rural. Vale destacar que o cenário da autoleitura respeita o distanciamento social e demais normas de saúde pública recomendadas em virtude à pandemia do Covid-19.

A massificação do uso de dispositivos móveis é outro forte incentivador para o desenvolvimento de uma solução de autoleitura. Somente no Brasil, mais de 60% da população utiliza smartphones, sendo essa uma das maiores taxas entre as economias emergentes (Pew Research Center, 2019). E os aplicativos de mensagens são os mais populares entre jovens e adultos, tendo também uma considerável adesão entre os idosos (Nielsen IBOPE, 2015).

Nesse cenário, muitas empresas têm se interessado pela produção de assistentes virtuais para atuar por meio de aplicativos de mensagem. Chamados de chatbots, eles buscam agilizar e facilitar a prestação de serviços através do atendimento automatizado. De acordo com o Mapa do Ecossistema Brasileiro de Bots, a quantidade de chatbots criados no Brasil triplicou entre os anos 2018 e 2019 (Panorama Mobile Time, 2019) corroborando, assim, a viabilidade dessas soluções.

Dado esse contexto, este trabalho apresenta o desenvolvimento de uma solução de chatbot para a autoleitura do consumo de energia através de aplicativos de mensagem. O processo consiste no estabelecimento de um diálogo com o assistente, no qual será pedido que o consumidor envie uma imagem do seu medidor. Essa imagem é direcionada para um servidor onde será processada por um método baseado em processamento de imagens e aprendizado profundo para o reconhecimento automático dos dígitos mostrados pelo medidor que caracterizam a leitura. O chatbot integrado com o método pode ser utilizado nos principais aplicativos de mensagem disseminados entre o grande público, provendo, portanto, um suporte mais completo para a prestação do serviço de autoleitura.

Este trabalho está estruturado da seguinte forma: a Seção 2 apresenta os trabalhos relacionados; a Seção 3 traz os detalhes sobre o desenvolvimento do chatbot e do método proposto; a Seção 4 apresenta os resultados e sua discussão; por fim, a Seção 5 faz uma conclusão sobre a abordagem proposta.

2. TRABALHOS RELACIONADOS

Na literatura, são encontrados algumas abordagens propostas voltadas para a leitura automática do consumo de energia baseada em imagens. De maneira geral, esses trabalhos utilizam câmeras fixadas em frente ao medidor para adquirir a imagem da região do *display* e, em seguida, utilizar processamento de imagem e aprendizado de máquina para realizar a leitura através do reconhecimento

de dígitos (Parthiban and Palanisamy, 2013; Zhang et al., 2016).

Quintanilha et al. (2017) propuseram o reconhecimento de dígitos em imagens baseado em características extraídas com *Histogram of Oriented Gradients* (HoG) em conjunto com o classificador Máquina de Vetores de Suporte (SVM). Os autores utilizaram uma base de imagens fornecida pelo grupo Equatorial Energia contendo somente medidores analógicos e obtiveram acurácia de 79,52%. Para o desenvolvimento do método proposto neste trabalho, foi utilizada uma versão ampliada dessa base com o acréscimo de imagens de medidores digitais.

Em relação à autoleitura, há trabalhos voltados para o contexto dos dispositivos móveis (Silva et al., 2019; Mendes et al., 2019; Serra et al., 2019b). Entretanto, esses métodos foram elaborados para serem incorporados em um aplicativo, e sua execução exige capacidade de processamento e armazenamento dos dispositivos. Por outro lado, na solução proposta neste trabalho, o método de reconhecimento das imagens é executado no lado do servidor, que é um ambiente mais robusto. Outro ponto é que essa solução atua em aplicativos de mensagem popularmente utilizados, o que facilita a sua utilização, visto que os consumidores estão mais habituados ao funcionamento desses aplicativos.

3. SOLUÇÃO PROPOSTA

Esta seção apresenta os aspectos estruturais da solução proposta, assim como os detalhes sobre o método desenvolvido para a realização da autoleitura por meio dos aplicativos de mensagem.

3.1 Aspectos Estruturais do Chatbot

A solução proposta está estruturada de forma modular, sendo constituída de quatro componentes principais: gerenciamento de mensagens, núcleo principal, serviços cognitivos e servidor de inferência, como mostra a Figura 1.

O módulo de gerenciamento de mensagens é responsável pela troca de mensagens entre núcleo principal e o aplicativo. Essa comunicação ocorre por meio de APIs RESTful específicas de cada aplicativo, por exemplo, Telegram² e Twilio³ (para Whatsapp). Essas APIs viabilizam, portanto, o estabelecimento do canal de comunicação e, consequentemente, o direcionamento das mensagens.

O núcleo principal do assistente virtual recebe as mensagens e as direciona para o módulo de serviços cognitivos responsável pela interpretação do conteúdo através da plataforma IBM Watson⁴, que é utilizada para a criação de chatbots que apresentam a capacidade de reconhecer as intenções contidas nos diálogos com pessoas. No caso da solução proposta, ela determinará quais ações serão tomadas pelo bot, como conferir ou validar os dados do consumidor por meio de chamadas aos *web services* que se conectam à base de dados do grupo Equatorial; bem como pedir que seja enviada uma imagem do medidor para dar prosseguimento ao processo de autoleitura.

² Disponível em <https://core.telegram.org/>

³ Disponível em <https://www.twilio.com/>

⁴ Disponível em <https://www.ibm.com/cloud/watson-assistant/>

¹ Disponível em <http://www2.aneel.gov.br/cedoc/ren2020878.pdf>



Figura 1. Visão geral da solução proposta.

O servidor de inferência é o módulo que recebe a imagem enviada pelo consumidor e a submete ao método de reconhecimento dos dígitos de leitura, que é baseado em técnicas de processamento de imagem e aprendizado profundo. O ambiente onde esse servidor é executado está encapsulado em um container Docker⁵. Neste container, está configurado o Tensorflow Serving⁶, que será utilizado para a execução dos algoritmos de reconhecimento de leitura que usam módulos implementados com a biblioteca Tensorflow. Em conjunto com o Docker, o Tensorflow Serving fornece os serviços por meio de uma API, tornando a operação do servidor de inferência mais simplificada e eficiente.

Além disso, o uso de container facilita a implantação da solução proposta, pois não haverá necessidade de ajustes de ambiente para o funcionamento correto do serviço, visto que suas dependências são mantidas.

Por fim, o resultado gerado pelo método de reconhecimento de leitura é enviado ao núcleo principal para que seja apresentado ao consumidor, que pode corrigir eventuais erros de reconhecimento. O processo de autoleitura termina, portanto, após a confirmação do consumidor de que a leitura está correta. Com isso, tanto esta quanto a imagem submetida anteriormente são enviadas para os servidores do grupo Equatorial via web services para o processamento de fatura e demais validações.

3.2 Base de Imagens

Para o desenvolvimento e validação do método de reconhecimento de leitura, o grupo Equatorial Energia disponibilizou um amplo conjunto de imagens de medidores de energia. Essas imagens foram capturadas sob diferentes condições de orientação e iluminação. Os medidores são divididos em dois tipos: digitais e analógicos. No geral, esses medidores são protegidos por uma caixa com uma parte transparente para que o leiturista possa conferir os dígitos no *display*. Alguns exemplos de imagens podem ser vistos na Figura 2.



Figura 2. Exemplos da base de imagens.

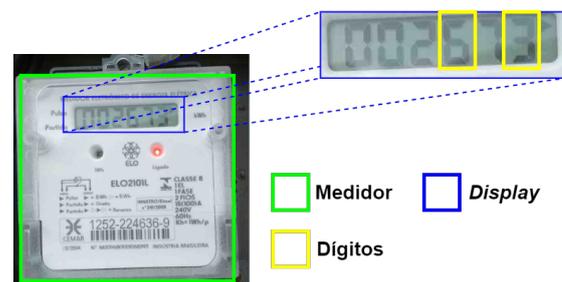


Figura 3. Exemplo de marcação de imagem da base.

A base contém 7513 imagens de medidores, sendo 4216 analógicos e 3297 do tipo digital. É importante ressaltar que, eventualmente, a caixa protetora do medidor pode conter avarias pela ação de agentes externos. Isso pode dificultar a visualização dos medidores e *displays*. Não obstante, imagens com essas características não foram descartadas, dada a necessidade de se elaborar um produto robusto aplicável ao cenário real, no qual deve-se considerar essas adversidades. Cada exemplar é acompanhado de um arquivo .xml contendo as coordenadas das *bounding boxes* que delimitam os objetos de interesse nas imagens, que são: o medidor, o *display* e os dígitos, conforme ilustra a Figura 3.

3.3 Método de Reconhecimento de Leitura em Imagens

Conforme dito anteriormente, o chatbot solicita ao consumidor o envio de uma imagem do seu medidor. Essa imagem é direcionada para o servidor de inferência onde será executado o método proposto, cujas etapas estão ilustradas na Figura 4.

⁵ Disponível em <https://www.docker.com/>

⁶ Disponível em <https://www.tensorflow.org/tfx/guide/serving>

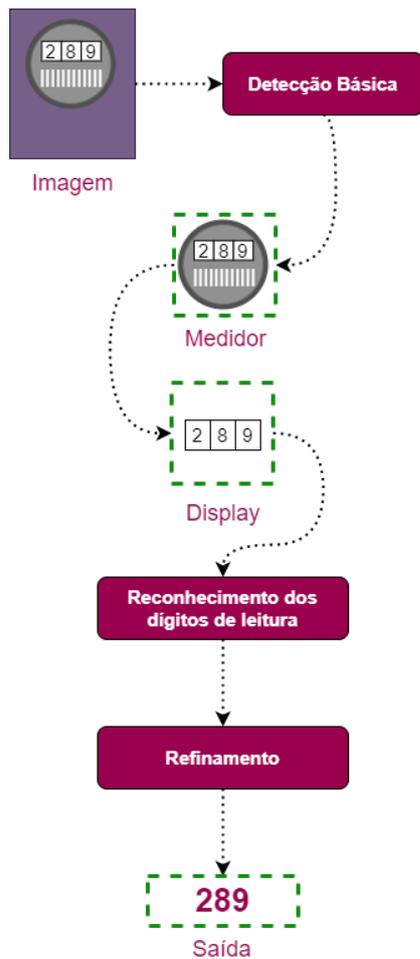


Figura 4. Método proposto de reconhecimento de leitura em imagens.

A primeira etapa é chamada de detecção básica, na qual serão detectados o medidor e, depois, o display. Em seguida, o display detectado é submetido para o processo de reconhecimento da leitura. Por fim, a leitura reconhecida é transmitida para o núcleo principal do chatbot que ficará responsável por enviá-la para o consumidor por meio de mensagem. Na sequência, o método proposto será apresentado com mais detalhes.

Detecção Básica A fase de detecção básica consiste na verificação da presença do medidor e do display na imagem submetida ao método proposto que utiliza a rede convolucional Retina Net (Lin et al., 2017). A escolha dessa rede se deve aos resultados promissores encontrados da literatura para a detecção de objetos. Essa arquitetura é composta por três partes: *backbone*, sub-rede de classificação e sub-rede geradora de *bounding boxes*.

O *backbone* é um módulo de extração de características composto por uma ou mais redes convolucionais. A Retina Net usa como *backbone* padrão a combinação entre a rede ResNet (He et al., 2016) e uma *Feature Pyramid Network* (FPN) responsáveis por gerar mapas de característica de múltiplas escalas. Isso torna essa arquitetura robusta para detectar objetos de diferentes tamanhos, o que é desejável na etapa de detecção básica, dado a diferença entre as dimensões do medidor e do display. Por fim, os

mapas gerados passam como entrada para a sub-redes de classificação, que prediz a probabilidade de um objeto estar presente na imagem; e para a geradora de *bounding boxes*, que define as coordenadas da *bounding box* que delimita o objeto detectado.

Para diminuir as chances de falha do método por causa dos diferentes tipos de medidores, foram treinadas duas Retina Nets: uma para os medidores analógicos e outra para os digitais. Assim, ambas são acionadas simultaneamente, de forma que a rede que detectar os componentes de interesse com a maior taxa de confiança irá direcionar os demais processos, que também foram especializados para cada tipo de medidor. Nesta fase, são usados os *backbones* Resnet-152 para os medidores analógicos e a Resnet-101 para os digitais.

O resultado da detecção básica é decisivo para a execução das demais etapas do método de reconhecimento. Se as redes detectarem o medidor e o *display*, esse último será recortado da imagem original utilizando-se a *bounding box* gerada, produzindo uma nova imagem que será submetida para a etapa de reconhecimento da leitura. Caso contrário, o chatbot enviará uma mensagem ao consumidor solicitando o envio de uma nova imagem do seu medidor.

Reconhecimento dos Dígitos de Leitura A etapa de reconhecimento dos dígitos de leitura consiste, primeiramente, em submeter a região do *display* detectada no passo anterior à Retina Net para a detecção dos dígitos. Ressalta-se que, nesta etapa, também é feito o treinamento de duas redes, uma para cada tipo de medidor. Isso é necessário devido à diferença entre as características dos dígitos (Figura 5). Os medidores analógicos (5.A) apresentam muita variabilidade tendo em vista as diferenças entre os modelos e os fabricantes. Porém, no caso dos medidores digitais (5.B), os dígitos tendem a ser mais homogêneos.

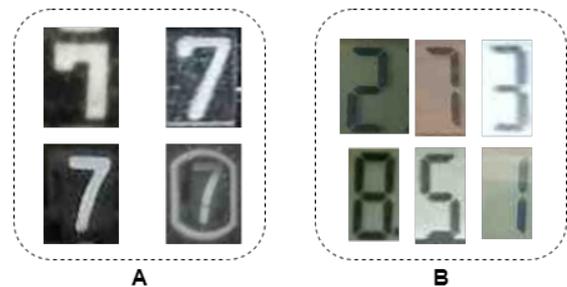


Figura 5. Exemplos de diferenças entre os tipos de dígitos nos medidores analógicos (A) e digitais (B).

Novamente, são utilizados os *backbones* Resnet-101 e Resnet-152 para dígitos de medidores digitais e analógicos, respectivamente. Durante a execução do método, a rede que obtiver a melhor taxa de confiança na etapa de detecção básica irá definir o tipo de medidor que está sendo analisado e, portanto, qual rede será selecionada para a detecção de dígitos.

Como resultado, a rede identifica na imagem os dígitos entre 0 e 9, e gera as suas respectivas *bounding boxes*. Entretanto, a saída da Retina Net pode apresentar algumas inconsistências que precisam ser tratadas. Dessa forma, é preciso executar um refinamento para alcançar resultados mais acurados.

Refinamento O estágio de refinamento é composto pelo conjunto de ações que podem ser visualizadas na Figura 6.

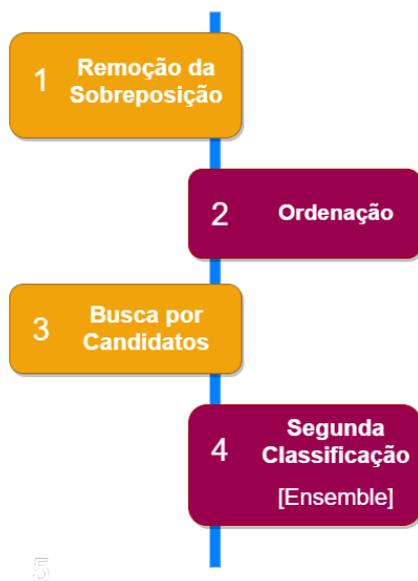


Figura 6. Etapas do processo de refinamento.

Primeiro, corrige-se o problema da sobreposição que é comum nos métodos de detecção. Ele ocorre quando a rede produz duas ou mais *bounding boxes* para o mesmo objeto, podendo classificá-lo erroneamente. Para resolver isso, o método proposto executa os seguintes passos:

- (1) Calcular a área da menor *bounding box* gerada para determinado dígito;
- (2) Definir as interseções entre as *bounding boxes* que delimitam o dígito;
- (3) Selecionar a *bounding box* de interseção cuja área seja N% maior que a área calculada no passo 1.

A Figura 7 ilustra esse processo. Com base em testes realizados, definiu-se N igual a 25%. A intersecção (em verde) é considerada válida pois sua área é, no mínimo, 25% maior que a *bounding box* (em vermelho) que delimita o dígito. Logo, aquelas consideradas inválidas são eliminadas.



Figura 7. Remoção da sobreposição.

Após a remoção de sobreposição, o próximo passo é a ordenação. Isso é necessário porque a Retina Net apenas reconhece os dígitos e fornece a sua localização na imagem. Entretanto, é preciso mostrar ao consumidor a sequência de leitura reconhecida conforme a ordem que ele observa no medidor de energia. Sendo assim, essa etapa consiste em organizar os dígitos detectados da direita para a esquerda, ordenando-se suas *bounding boxes*.

Como dito na Seção 3.1, o chatbot tem acesso aos dados do consumidor, dentre os quais, detalhes importantes do medidor, como a quantidade de dígitos (Q) mostrada por

ele. Esse dado é utilizado no próximo passo, que é a redução de falsos positivos (FP). Para esta fase, define-se como verdadeiros positivos (VP) os dígitos detectados com taxa de confiança acima de 70%. Aqueles que não atendem essa condição, são classificados como FP. Assim, no caso de a rede apresentar Q detecções classificadas como VP, estes serão enviados ao consumidor como o resultado do reconhecimento de leitura.

Entretanto, se a quantidade de VP for inferior a Q, o fluxo de execução do refinamento pode ser direcionado para duas etapas distintas: busca por candidatos e segunda classificação.

A busca por candidatos é uma melhoria implementada para localizar dígitos que não foram detectados, mas que podem estar entre os que foram encontrados. A Figura 8 mostra como ocorre esse processo. Inicialmente, calcula-se a largura média das *bounding boxes*. Em seguida, para cada par de dígitos detectados consecutivamente, é verificado se a distância entre eles é maior que a largura média. Caso seja, significa que há uma lacuna. Então, são calculados quantos dígitos caberiam naquele espaço. A partir dessa informação, são geradas *bounding boxes* na lacuna detectada considerando-se a variação de altura entre os dígitos consecutivos e a distância horizontal entre eles quando não há lacunas.

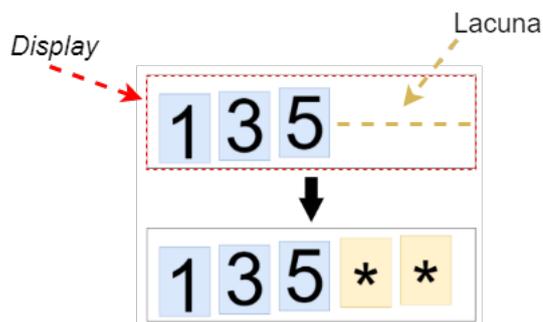


Figura 8. Exemplo da execução da busca por candidatos.

A busca por candidatos também é utilizada para localizar possíveis dígitos faltantes nas bordas do *display*. Para isso, é verificado se os dígitos detectados nas extremidades direita e esquerda não estão muito próximos da borda e se o total de detecções (VP + FP) é menor que Q. Se essas condições são atendidas, utiliza-se a estratégia descrita anteriormente para preencher as lacunas, levando em consideração as variações de altura e distância horizontal. É importante ressaltar que cada novo candidato encontrado é automaticamente rotulado como FP.

Por fim, todas as detecções classificadas como FP são submetidas ao processo de segunda classificação através do *ensemble* dos classificadores *Support Vector Machine* (SVM) (Cortes and Vapnik, 1995), Xgboost (Chen and Guestrin, 2016) e Efficient Net (Tan and Le, 2019), que recebem as imagens recortadas de cada candidato a dígito para então classificá-los entre 0 a 9.

Um passo *a priori* à classificação via SVM e Xgboost é o uso de *Histogram of Oriented Gradients* (HoG) para

extrair as características das imagens dos dígitos (Quintanilha et al., 2017). Já no caso da Efficient Net, isso não é necessário por se tratar de uma rede convolucional. O ensemble, portanto, consiste em verificar o voto da maioria. Sendo assim, se no mínimo dois dos três classificadores apontarem que um dígito pertence a uma classe, esse será o resultado que prevalecerá. No entanto, se houver total divergência, será levado em consideração aquele classificador que gerou a maior taxa de confiança.

No final de todos esses processos, o método proposto retorna a sequência de leitura reconhecida para o chatbot, que enviará esse resultado ao consumidor para que confirme a leitura ou corrija eventuais falhas de reconhecimento.

4. RESULTADOS E DISCUSSÃO

Os módulos da solução de chatbot proposta encontram-se ainda em desenvolvimento. Porém, dentre eles, o método de reconhecimento integrado ao servidor de inferência está em um estágio mais avançado. Portanto, esta seção apresentará os resultados obtidos no experimento realizado com esse módulo.

Os 7513 exemplares da base de imagens foram divididos da seguinte forma: 70% para o conjunto de treinamento e 30% para o teste. As redes Retina Net foram treinadas com o otimizador Adam (Kingma and Ba, 2014), com taxa de aprendizado 10^{-5} por 50 épocas com técnica *Early Stopping* (Prechelt, 1998). Ressalta-se que não foram aplicados os procedimentos de *Transfer Learning* e *Data Augmentation*.

Para o treinamento dos classificadores do *ensemble* foram utilizadas as imagens de dígitos recortadas da base original. Os parâmetros do SVM (*kernel* RBF) e do Xgboost foram estimados pelo algoritmo *Grid Search*. Em relação à Efficient Net, usa-se a arquitetura B0 (Tan and Le, 2019), treinada com o otimizador RMSProp (Igel and Hüsken, 2000) e taxa de aprendizado igual a 2×10^{-5} por 50 épocas.

A Tabela 1 apresenta os resultados alcançados para a detecção de medidores e reconhecimento das sequências de leitura.

Tabela 1. Resultados de acurácia obtidos pelo método de reconhecimento.

	Med. Analógicos	Med. Digitais
Medidores	100,0%	100,0%
Sequência de Leitura	89,0%	77,2%

A Figura 9 mostra como o chatbot apresenta o resultado do reconhecimento da leitura a partir da imagem enviada pelo consumidor pelo aplicativo de mensagem.

O método consegue separar com 100% de acurácia as imagens que contém medidor daquelas que não contém, para ambos os tipos analógico e digital. Essas imagens passam para as etapas seguintes que são o reconhecimento dos dígitos de leitura, cujos resultados apresentados mostram-se promissores, principalmente no caso dos medidores analógicos.

A principal causa para uma diferença acentuada entre as categorias de medidores ocorre por causa das condições do



Figura 9. Chatbot apresentando o resultado do reconhecimento para o consumidor.

ambiente quando da captura das imagens. Os medidores digitais são mais propensos à interferência da luz externa, que pode, dependendo do ângulo de captura, distorcer a forma dos dígitos no *display*, causando erros de identificação da leitura por parte do classificador.

A Tabela 2 apresenta uma comparação entre o método proposto e alguns trabalhos relacionados ao tema levando em consideração a média geral de acertos por dígito. A proposta elaborada por Quintanilha et al. (2017) é voltada para os medidores analógicos, enquanto que Serra et al. (2019a) é aplicada para os dois tipos de medidor. Ambos utilizam somente o classificador SVM combinado a descritores de características. O método proposto, por sua vez, associa aprendizado profundo (Retina Net) com classificadores via *ensemble* e, dessa forma, apresenta os melhores resultados para os medidores analógicos e se equipara estatisticamente no âmbito dos digitais.

Tabela 2. Médias de acertos por dígito em comparação com os trabalhos relacionados.

	Med. Analógicos	Med. Digitais
Quintanilha et al. (2017)	79,52%	-
Serra et al. (2019a)	96,72%	97,90%
Método Proposto	97,06%	97,83%

De maneira geral, o método de reconhecimento integrado à solução de chatbot apresenta resultados promissores. Entretanto, como os referidos processos se encontram em desenvolvimento, ainda são passíveis de melhorias.

5. CONCLUSÃO

Neste trabalho, foi apresentada uma solução de chatbot para a autoleitura em imagens por meio de aplicativos de mensagens. Para efetuar a autoleitura, é necessário que o

consumidor envie uma imagem do medidor para o chatbot que a submeterá para o método de reconhecimento em um módulo chamado de servidor de inferência.

O método proposto usa as redes Retina Net para, inicialmente, detectar o medidor e o *display* no âmbito dos medidores analógicos e digitais. Em seguida, com base nos resultados do passo anterior, usa o *display* encontrado para reconhecer os dígitos da leitura. Nesse estágio, usa-se novamente a Retina Net, cujo resultado é submetido a um refinamento, que culmina na aplicação de uma segunda classificação via *ensemble* composto pelos classificadores SVM, Xgboost e Efficient Net. Os resultados apresentados são promissores e mostram a viabilidade do uso da ferramenta, visto que a solução obtém taxas de acerto acima de 77%, considerando-se os diferentes modelos de medidores. Isso é animador, dada a urgência por soluções que priorizem o cumprimento das normas sanitárias recomendadas para conter a Covid-19; mas que também estendam seus benefícios para o pós-pandemia, refletidos na diminuição de fraudes, erros de leitura e, conseqüentemente, de perdas financeiras.

Como tarefa futura, pretende-se desenvolver um método para a validação do medidor do consumidor a partir do reconhecimento dos códigos de barra na imagem enviada, de forma que o processo de autoleitura se torne ainda mais seguro. Além disso, mais experimentos serão realizados afim de melhorar o resultado do reconhecimento de leitura, testando-se outras configurações de classificadores. E, por fim, ainda será feita a integração entre a solução de chatbot proposta com as APIs dos chatbots já utilizados pelo grupo Equatorial Energia.

AGRADECIMENTOS

Este trabalho contou com o apoio do projeto Autoclara, financiado pelo grupo Equatorial Energia, no âmbito do Programa de P&D da Agência Nacional de Energia Elétrica (ANEEL) código APLPED0004-PROJETOPED-0036-S01.

REFERÊNCIAS

- ANEEL (2019). Energia no brasil e no mundo. URL http://www2.aneel.gov.br/arquivos/pdf/atlas_par1_cap2.pdf.
- Chen, T. and Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 785–794.
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273–297.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770–778.
- Igel, C. and Hüsken, M. (2000). Improving the rprop learning algorithm.
- Kingma, D. and Ba, J. (2014). Adam: A method for stochastic optimization. *International Conference on Learning Representations*.
- Lin, T.Y., Goyal, P., Girshick, R., He, K., and Dollár, P. (2017). Focal loss for dense object detection. In *Proceedings of the IEEE international conference on computer vision*, 2980–2988.
- Mendes, P., Santos, J., Rocha, C., Paiva, A., Oliveira, J., Santos, I., Rocha, S., Silva, A., Paiva, A., Monteiro, E., Silva, I., and Silva, M. (2019). Reconhecimento de dígitos de medidores de energia por meio da voz no contexto de um aplicativo de autoleitura. doi:10.17648/sbai-2019-111434.
- Nielsen IBOPE (2015). 68 milhões usam a internet pelo smartphone no brasil. URL <https://www.nielsen.com/br/pt/press-releases/2015/68-milhoes-usam-a-internet-pelo-smartphone-no-brasil/>.
- Panorama Mobile Time (2019). Mapa do ecossistema brasileiro de robôs 2019. URL <http://panoramamobiletime.com.br/download/16300/?uid=f312d14021>.
- Parthiban, K. and Palanisamy, A. (2013). Reading values in electrical meter using image processing techniques. In *Intelligent Interactive Systems and Assistive Technologies (IISAT), 2013 International Conference on*, 1–7. IEEE.
- Pew Research Center (2019). Smartphone ownership is growing rapidly around the world, but not always equally. URL <https://www.pewresearch.org/global/2019/02/05/smartphone-ownership-is-growing-rapidly-around-the-world-but-not-always-equally/>.
- Prechelt, L. (1998). Early stopping-but when? In *Neural Networks: Tricks of the trade*, 55–69. Springer.
- Quintanilha, D.B.P., Costa, R.W.S., Diniz, J.O.B., de Almeida, J.D.S., Braz, G., Silva, A.C., de Paiva, A.C., Monteiro, E.M., Froz, B.R., Piheiro, L.P.A., and Melho, W. (2017). Automatic consumption reading on electromechanical meters using hog and svm. In *7th Latin American Conference on Networked and Electronic Media (LACNEM 2017)*, 57–61. doi:10.1049/ic.2017.0036.
- Serra, A., França, J., Marques, R., Figueredo, W., Reis, A., Santos, I., Rocha, S., Silva, A., Monteiro, E., Silva, I., Silva, M., and Santos, J. (2019a). Reconhecimento de dígitos em imagens de medidores de energia no contexto de um aplicativo de autoleitura. doi:10.17648/sbai-2019-111448.
- Serra, A., França, J., Sousa, J., Costa, R., Santos, I., Rocha, S., Silva, A., Paiva, A., Monteiro, E., Silva, I., Silva, M., and Santos, J. (2019b). Segmentação semântica de medidores de energia elétrica e componentes de identificação. doi:10.17648/sbai-2019-111530.
- Silva, A.C., Serra, A.C., Reis, A.B.S., Monteiro, E.M.G., da Silva, I.F.S., da Silva, I.F.S., França, J.V.F., dos Santos, J.M., da Silva, M.I.A., da Silva Marques, R.C., et al. (2019). Reconhecimento de dígitos em imagens de medidores de energia no contexto de um aplicativo de autoleitura. *Reconhecimento de Dígitos em Imagens de Medidores de Energia no Contexto de um Aplicativo de Autoleitura*, 1–388.
- Tan, M. and Le, Q. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. In K. Chaudhuri and R. Salakhutdinov (eds.), *Proceedings of the 36th International Conference on Machine Learning Research*, volume 97 of *Proceedings of Machine Learning Research*, 6105–6114. PMLR, Long Beach, California, USA. URL <http://proceedings.mlr.press/v97/tan19a.html>.

- Vidinich, R. and Nery, G. (2009). Pesquisa e desenvolvimento contra o furto de energia. *Revista Pesquisa e Desenvolvimento da ANEEL-P&D*, 15.
- Zhang, Y., Yang, S., Su, X., Shi, E., and Zhang, H. (2016). Automatic reading of domestic electric meter: an intelligent device based on image processing and zigbee/ethernet communication. *Journal of Real-Time Image Processing*, 12(1), 133–143.