

Segmentação Semântica de Medidores de Energia Elétrica e Componentes de Identificação**Semantic Segmentation of Electricity Meters and Identification Components**

DOI:10.34115/basrv4n3-100

Recebimento dos originais: 20/04/2020

Aceitação para publicação: 21/06/2020

Arthur Costa Serra

Graduado em Ciência da Computação pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966, Bacanga, São Luís – MA, Brasil

E-mail: arthursr@nca.ufma.br

João Vitor Ferreira França

Graduando em Ciência da Computação pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966, Bacanga, São Luís – MA, Brasil

E-mail: jvitorfranca@nca.ufma.br

Jefferson Alves de Sousa

Mestre em Ciência da Computação pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966, Bacanga, São Luís – MA, Brasil

E-mail: jefferson.alves@nca.ufma.br

Robherson Wector de Sousa Costa

Graduado em Ciência da Computação pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966, Bacanga, São Luís – MA, Brasil

E-mail: robherson@nca.ufma.br

Italo Francyles Santos da Silva

Mestre em Ciência da Computação pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966, Bacanga, São Luís – MA, Brasil

E-mail: francyles@nca.ufma.br

Simara Vieira da Rocha

Doutora em Engenharia de Eletricidade pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966, Bacanga, São Luís – MA, Brasil

E-mail: simara.rocha@nca.ufma.br

Anselmo Cardoso de Paiva

Doutor em Informática pela Pontifícia Universidade Católica do Rio de Janeiro

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966, Bacanga, São Luís – MA, Brasil

E-mail: paiva@nca.ufma.br

Aristófanés Correa Silva

Doutor em Informática pela Pontifícia Universidade Católica do Rio de Janeiro
 Instituição: Universidade Federal do Maranhão
 Endereço: Av. dos Portugueses, 1966, Bacanga, São Luís – MA, Brasil
 E-mail: ari@nca.ufma.br

Eliana Márcia G. Monteiro

Instituição: Equatorial Energia - MA
 Endereço: Alameda A, 100, Quitandinha, São Luís - MA, Brasil
 E-mail: eliana.monteiro@cemar-ma.com.br

Italo Fernandes S. da Silva

Instituição: Equatorial Energia - MA
 Endereço: Alameda A, 100, Quitandinha, São Luís - MA, Brasil
 E-mail: italo.silva@cemar-ma.com.br

Márcia Izabel A. da Silva

Instituição: Equatorial Energia - MA
 Endereço: Alameda A, 100, Quitandinha, São Luís - MA, Brasil
 E-mail: marcia.silva@cemar-ma.com.br

Jose Messias dos Santos

Instituição: Equatorial Energia - MA
 Endereço: Alameda A, 100, Quitandinha, São Luís - MA, Brasil
 E-mail: jose.messias@cemar-ma.com.br

RESUMO

A Agência Nacional de Energia Elétrica (ANEEL) classifica erros de medição de consumo e processamento de fatura como perdas não-técnicas. Quando essas irregularidades são identificadas, é solicitada a aquisição da imagem do medidor e a captura da localização geográfica do leitorista para registrar a sua presença no local. Essas imagens são enviadas para o setor de auditoria. Este recebe um grande volume de imagens, cuja análise completa é muito lenta. Como alternativa, tem-se a autoleitura, que é a leitura feita pelo próprio cliente através de plataformas digitais. E para garantir a segurança no processo de autoleitura, é necessária uma etapa automática de validação (autoauditoria). Este trabalho propõe um método baseado em aprendizado profundo para a segmentação semântica de medidores de energia e componentes de identificação, almejando contribuir com mais eficiência ao processo de validação de leitura. O método apresenta *mean average precision* (mAP) de 73,10% para os casos em que *intersection over union* (IoU) \geq a 0,50; 42,17% para IoU \geq 0,75 e 41,28% quando IoU \geq 0,99.

Palavras-chave: Autoleitura, Autoauditoria, Processamento de imagens, Segmentação Semântica, Aprendizado Profundo

ABSTRACT

Brazilian Electricity Regulatory Agency (ANEEL) classifies energy consumption measurement and bill processing errors as non-technical losses. When those irregularities are identified, meter imaging and geographic location are requested to a reader. Those images are sent to audit sector. This receives a great volume of images, and its whole analysis is too slow. As an alternative, there is the self-reading, which is the reading done by the customer through digital platforms. To ensure safety in self-reading process,

a validation stage (self-audit) is necessary. This work proposes a method based on deep learning for semantic segmentation of energy meters and identification components, aiming to contribute with more efficiency in reading validation. This method obtains 73.10% mean average precision (mAP) for intersection over union (IoU) ≥ 0.50 ; 42.17% mAP for $\text{IoU} \geq 0.75$ and 41.28% mAP for $\text{IoU} \geq 0.99$.

Keywords: Self-reading, Self-audit, Image Processing, Semantic Segmentation, Deep Learning

1 INTRODUÇÃO

Medidores de energia elétrica são equipamentos capazes de mensurar o consumo de energia elétrica de uma unidade consumidora. Para efetuar a leitura do consumo de um consumidor, a Companhia Energética do Maranhão (CEMAR) e as Centrais Elétricas do Pará S.A (CELPA) utilizam um dispositivo móvel e uma impressora portátil. Nesse processo, as informações de consumo são coletadas e processadas, gerando, por fim, a fatura impressa dos consumidores. O leiturista precisa informar manualmente o consumo tal qual é mostrado no medidor de energia, o que torna esse procedimento mais lento e passível de erros, os quais acarretam, portanto, em inconsistências no faturamento mensal.

De acordo com a Agência Nacional de Energia Elétrica (ANEEL), erros de medição de consumo e processamento de fatura, sejam por falha humana, ou impedimento de acesso à unidade consumidora, são considerados perdas não-técnicas (ANEEL, 2019). Esse tipo de perda é descoberto durante os processos de leitura e fiscalização do consumo de energia. Nos casos em que o consumo aferido para um consumidor está fora da sua média de consumo, ou o leiturista não consegue realizar a leitura, é solicitada a aquisição da imagem do medidor e a captura da localização geográfica do leiturista para registrar a sua presença no local.

Essas informações são enviadas para o setor de crítica das concessionárias, onde se efetuam auditorias para avaliar esses casos. Porém, em decorrência da grande quantidade de imagens recebidas, a auditoria ocorre por amostragem, visto que a avaliação de todos os casos demandaria um grande número de pessoal e de tempo. Em geral, analisa-se nas imagens questões como ausência de medidor, identificação incorreta do medidor, impossibilidade de leitura e consumo anômalo.

Uma alternativa para auxiliar neste processo, seria a leitura realizada pelo próprio consumidor, denominada autoleitura. Esta engloba o uso de plataformas digitais, como sites ou aplicativo desenvolvido para dispositivo móvel, por onde o consumidor registraria e enviaria as informações de consumo. Este processo traz vantagens ao consumidor, pois lhe garante um controle maior sobre o seu consumo de energia; e para as concessionárias, porque proporciona a diminuição de custos e a redução dos erros de leituras.

Nesse contexto, métodos computacionais capazes de realizar a leitura automática do consumo de energia através da análise de imagem podem facilitar e agilizar a mensuração do consumo, tornando-a menos suscetível a erros. E para garantir a segurança no processo de autoleitura, esse método precisa contar com uma etapa automática de auditoria, denominada de autoauditoria, a ser executada periodicamente ou quando o consumo aferido apresentar valores fora da faixa mensal esperada para um consumidor.

Inicialmente, a imagem é adquirida pelo consumidor. Em seguida é enviada para o servidor da concessionária onde será feito todo o tratamento da imagem e identificação dos componentes do medidor. A primeira etapa do processo é identificar se existe ou não medidor na imagem. Caso exista, este é extraído da imagem. O próximo passo é a segmentação dos seguintes componentes: o *display*, onde estão os dígitos do consumo e o código de identificação do medidor (*tag*).

Embasando-se nessa proposta, este trabalho apresenta um método para a segmentação semântica de medidores de energia elétrica e componentes de identificação, aplicado em imagens dos medidores utilizados pelas concessionárias CEMAR e CELPA, objetivando contribuir com mais eficiência ao processo de validação de leitura e também com a diminuição de perdas relacionadas ao faturamento, o que poderá garantir segurança para consumidores e para as concessionárias.

Na literatura, são encontrados alguns trabalhos com propostas voltadas para a leitura de consumo automática 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).

Ainda no contexto de leitura automática, Reis et al. (2017) propuseram um método para segmentar automaticamente a região do medidor de energia elétrica em imagens adquiridas por leituristas de distribuidoras de energia, de forma a facilitar o processo de auditoria com a validação da existência de medidor. O método utiliza binarização e estatística para delimitar a região do medidor na imagem, obtendo acurácia de 96,41%, 89,81% e 78,85%, respectivamente para as imagens categorizadas como boas, regulares e ruins.

Diferente desses trabalhos relacionados, nossa proposta é baseada em técnicas aprendizado profundo aplicadas à tarefa de segmentação semântica, com o intuito de detectar, nas imagens, o medidor e os componentes de identificação. Esse método é parte integrante de uma aplicação, em desenvolvimento, para a implantação dos processos de autoleitura e autoauditoria.

Este trabalho está estruturado da seguinte forma: a Seção 2 apresenta detalhes sobre o conjunto de imagens utilizado e explica o método proposto; a Seção 3 discute os resultados obtidos por este estudo; e, a Seção 4 apresenta as conclusões.

2 MATERIAIS E MÉTODOS

Esta seção descreve os procedimentos realizados para a segmentação semântica de medidores de energia e componentes de identificação. Também são apresentados detalhes sobre o conjunto de imagens utilizado para validar o método proposto.

2.1 BASE DE IMAGENS

Os medidores de energia utilizados pelas companhias CE- MAR e CELPA são de dois tipos: digitais e analógicos. No geral, os medidores são protegidos por uma caixa com uma parte transparente para que o leitor possa conferir o código de identificação (*tag*) e os dígitos no display. A Figura 1 mostra exemplos de imagens que compõem a base.

A base tem, ao todo, 4325 imagens. Essas foram capturadas sob diferentes condições, simulando o processo de auditoria no qual, em alguns casos, quem captura a imagem pode não ter familiaridade com a tecnologia utilizada, ou a iluminação do ambiente não está favorável; ou quando a caixa protetora apresenta condições precárias devido intempéries. Sendo assim, a base é também composta por imagens borradas, com oclusões parciais e diferentes orientações. Há também imagens sem a presença do medidor.

Na Figura 2, os medidores estão destacados pelo retângulo número 1; os retângulos 2 e 3 delimitam, respectivamente, as regiões da *tag* e do *display*. Cada imagem está associada a um arquivo com anotações manuais dos pontos *x*, *y*, *w*, *h* que determinam os limites das *bounding boxes* que localizam o medidor, a *tag* e o *display*, objetos de interesse do método de segmentação.

Figura 1. Exemplos de imagens da base.



Figura 2. Regiões do medidor (1), tag (2) e display (3).



2.2 SEGMENTAÇÃO SEMÂNTICA UTILIZANDO A REDE *SINGLE SHOT MULTIBOX DETECTOR*

Este trabalho tem como objetivo a segmentação semântica de medidores e componentes de identificação. Esta etapa surge como o primeiro passo para a auditoria por imagem, pois, para esse processo, a identificação e segmentação dessas regiões é imprescindível.

Para esta tarefa, é proposto o uso de uma arquitetura de rede neural chamada *Single Shot Multibox Detector* (SSD). Essa rede tem apresentado resultados promissores para a detecção e segmentação de objetos em imagens

(Liu et al., 2015). E também, segundo Huang et al. (2017), é um modelo capaz de gerar bons resultados balanceando velocidade, acurácia e uso de memória. A Figura 3 apresenta o fluxo de execução do método.

Figura 3. Etapas do Método Proposto

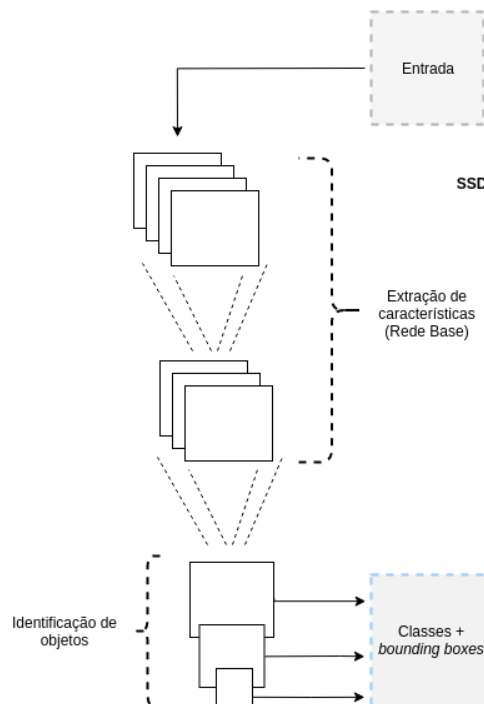


A entrada para a rede SSD é a imagem capturada. Essa rede, então, procura na imagem a localização do medidor (1), *tag* (2) e *display* (3) e, por fim, delimita as regiões à medida que identifica a presença desses objetos de interesse na imagem.

Desenvolvida por Liu et al. (2015), a *Single Shot Multibox Detector* (SSD) é uma rede para detecção de objetos em imagens em uma única etapa. Ela trabalha sobre amostras densas de pixels que são possíveis regiões. Assim, a SSD consegue ser mais rápida se comparada a outras redes que utilizam a abordagem de detecção em duas etapas, como a fazer R-CNN (Ren et al., 2015).

A SSD é uma rede convolucional *feed-forward* que gera um conjunto fixo de *bounding boxes* para cada classe de objeto a ser detectado. Ela pode ser dividida em duas fases: de extração de características e de detecção. Na primeira fase, as camadas são baseadas em alguma arquitetura de rede, como, por exemplo, a VGG (Simonyan and Zisserman, 2014) ou YOLO (Redmon et al., 2015), da qual se elimina a camada responsável pela classificação. Essa rede escolhida é chamada de rede base. A segunda fase é caracterizada pela adição à rede base de várias camadas de convolução, que aplicam filtros de dimensões específicas e geram um número k de *bounding boxes*, definindo, portanto, a arquitetura final SSD, como ilustrado pela Figura 4.

Figura 4. Arquitetura da rede SSD.



No treinamento, a SSD recebe uma imagem de entrada e as *bounding boxes* de cada objeto. No estágio convolucional, são avaliados um conjunto pequeno de *bounding boxes* de diferentes *aspect ratios*

e escalas nos vários mapas de características gerados. Então, para cada objeto, são preditas as coordenadas de sua *bounding box* e também um valor de confiança. A *bounding box* que delimita corretamente o objeto de interesse é tratada como positiva e as demais, que não o delimitam, como negativas.

No presente trabalho, são adicionadas 33 camadas convolucionais no final da rede base para a fase de predição de *bounding boxes* para a identificação de objetos. O referido número de camadas foi definido empiricamente. A Tabela 1 mostra mais detalhes sobre essas camadas, na ordem que foram adicionadas.

Tabela 1. Quantidade de camadas convolucionais adicionadas e suas respectivas dimensões.

Ordem	Num. camadas	Dimensões
1	4	19 X 19
2	15	10 X 10
3	4	5 X 5
4	4	3 X 3
5	4	2 X 2
6	2	1 X 1

Uma vez que a rede encontra, na imagem, a localização do medidor, da *tag* e do *display*, basta fazer o recorte desses componentes utilizando as *bounding boxes* geradas pela SSD.

2.3 MÉTRICAS DE AVALIAÇÃO

São utilizadas como métricas de avaliação dos resultados produzidos pelo método a *intersection over union* (IoU) e *Mean Average Precision* (mAP).

O IoU mede a sobreposição entre duas regiões definidas pelas *bounding boxes*, a gerada pelo método e a anotada manualmente (*ground-truth*). Calcula-se pela razão entre a interseção dos conjuntos X e Y e a união desses (Equação 1). Neste caso, X e Y representam as *bounding boxes*.

$$IoU = \frac{|X \cap Y|}{|X \cup Y|} \quad (1)$$

A *Average Precision* (AP) é estabelecida como a área sob a curva definida pela relação entre *Precision* (P) e *Recall* (R), calculados como mostram as Equações 2 e 3

$$R = \frac{VP}{VP + FN} \quad (2)$$

$$P = \frac{VP}{VP + FP} \quad (3)$$

Onde VP e FP são os verdadeiros e falsos positivos, respectivamente; e FN os falsos negativos.

No caso da AP, é preciso estabelecer uma condição para que a *Precision* seja considerada correta. Essa condição, neste caso, é se a IoU obtida é igual ou superior a algum valor definido.

Logo, mAP é definida pela média da *Average Precision* calculada para cada classe de objeto. Essa métrica apresenta valores entre 0 e 1 (100%). Quanto mais próximo de 1, melhor é o resultado.

3 RESULTADOS E DISCUSSÃO

A rede SSD foi implementada em linguagem Python 3.7.1 com o auxílio da biblioteca *TensorFlow* 2, que é voltada para aplicações de aprendizado de máquina. A SSD foi treinada por 50 épocas em uma GPU NVIDIA Tesla K80 utilizando o otimizador *rmsprop* (Tieleman and Hinton, 2012). Cada época contém 200 mil passos. A taxa de aprendizado utilizada foi de 4×10^{-3} . Demais parâmetros de configuração seguem o padrão estabelecido pelo *TensorFlow*.

A base de imagens foi dividida em 70% para treino e 30% para teste. Os resultados produzidos pelo método proposto podem ser visualizados pela Tabela 2.

Tabela 2. Resultados obtidos pelo método proposto.

Critério	mAP
IoU $\geq 0,50$	73,10%
IoU $\geq 0,75$	42,17%
IoU $\geq 0,99$	41,28%

Para avaliar a mAP obtida pelo método, é preciso também analisar o critério baseado em IoU para a consideração de predições corretas. No caso em que $\text{IoU} \geq 0,50$, o método alcança 73,10% de mAP, portanto, pode-se verificar que os resultados de AP para as classes *medidor*, *tag* e *display* estão razoavelmente equilibrados. Ou seja, os objetos de interesse são identificados corretamente em grande parte das imagens com IoU igual ou superior a 0,50.

Para o limiar de $\text{IoU} \geq 0,75$, o valor de mAP diminui para 42,17%. E quando se define $\text{IoU} \geq 0,99$, o resultado de mAP alcança 41,28%. Observa-se que, conforme IoU se eleva, o valor de mAP

diminui. Isso se dá porque a avaliação das predições torna-se mais criteriosa, logo, as segmentações serão descartadas caso o seu valor IoU esteja fora da faixa de valores desejada.

No entanto, o fato de as bounding boxes geradas pela rede não alcançarem, em grande totalidade, 100% de IoU não significa que os objetos não tenham sido identificados na imagem. Esse resultado é bastante sensível às anotações manuais, visto que elas são utilizadas para o cálculo das métricas de avaliação.

A Figura 5 mostra exemplos de imagens submetidas ao método, nas quais as regiões de interesse foram delimitadas corretamente.

As Figuras 5(A), 5(B) foram capturadas próximas ao medidor. Na primeira, o método obteve uma taxa de confiança mais baixa para o medidor em comparação aos componentes, devido à proximidade da câmera, o que fez a rede perder informações de contexto. No caso da 5(B), mesmo apresentando inclinação, as regiões são delimitadas. Outra observação é que devido as diferenças entre os modelos de medidor de energia, a localização do código identificador também varia. Não obstante, o método consegue localizar os objetos de interesse e definir para eles uma bounding box respectiva.

O caso apresentado pela Figura 5(C) retrata a aplicação do método em um cenário menos favorável para acertos. Pois, a caixa protetora apresenta condições precárias e isso é um complicador para a visualização do medidor e de seus componentes. No entanto, houve a delimitação correta das regiões de interesse, com destaque para a identificação do *display*, visto que esse se encontra numa região de difícil compreensão na imagem.

Por fim, a Figura 5(D) apresenta um caso capturado com certa distância, o que oferece mais informação de contexto à rede, resultando em uma alta taxa de confiança para a delimitação do medidor, *display* e *tag*.

Como observado, os resultados obtidos mostram-se satisfatórios, pois, mesmo em condições adversas, o método mostrou-se capaz de delimitar as regiões dos medidores e componentes.

4 CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho apresentou um método para a segmentação semântica de medidores de energia elétrica e componentes de identificação. O trabalho propôs a utilização da rede convolucional SSD aplicada à delimitação das regiões do medidor, do *display* e do código identificador (*tag*).

O método apresenta mAP de 73,10% para os casos em que a métrica IoU é igual ou superior a 0,50; 42,17% para $Iou \geq 0,75$ e 41,28% quando $Iou \geq 0,99$. Esses resultados considerados são vistos como promissores para a aplicação ao qual este trabalho será integrado. Entretanto, entende-se que podem ser melhorados com o desenvolvimento de mais testes.

Figura 5. Segmentação semântica do medidor e componentes em imagens utilizando o método proposto.




A

Medidor: 56,50%
 Display: 97,60%
 Tag: 98,10%




B

Medidor: 59,50%
 Display: 59,20%
 Tag: 57,30%



C

Medidor: 72,00%
 Display: 97,20%
 Tag: 57,40%



D

Medidor: 99,50%
 Display: 77,70%
 Tag: 83,40%

Como trabalho futuro, propõe-se desenvolver o reconhecimento dos dígitos mostrados pelo *display* e do código de identificação do medidor.

REFERÊNCIAS

- ANEEL (2019). Energia no brasil e no mundo. URL http://www2.aneel.gov.br/arquivos/pdf/atlas_par1_cap2.pdf.
- Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A., Fischer, I., Wojna, Z., Song, Y., Guadarrama, S., and Murphy, K. (2017). Speed/accuracy trade-offs for modern convolutional object detectors. In *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S.E., Fu, C., and Berg, A.C. (2015). SSD: single shot multibox detector. CoRR, abs/1512.02325. URL <http://arxiv.org/abs/1512.02325>.
- 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.
- Redmon, J., Divvala, S.K., Girshick, R.B., and Farhadi, A. (2015). You only look once: Unified, real-time object detection. CoRR, abs/1506.02640. URL <http://arxiv.org/abs/1506.02640>.
- Reis, A.B.S., de Sousa, J.A., da Silva Neto, O.P., Silva, A.C., de Paiva, A.C., de Almeida, J.D.S., Junior, G.B., Azevedo, L.M., and Monteiro, E.M. (2017). Segmentação automática de medidores eletromecânico e eletrônico baseado em imagens. In *Simpósio Brasileiro de Automação Inteligente (SBAI)*.
- Ren, S., He, K., Girshick, R.B., and Sun, J. (2015). Faster R-CNN: towards real-time object detection with region proposal networks. CoRR, abs/1506.01497. URL <http://arxiv.org/abs/1506.01497>.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv 1409.1556.
- Tieleman, T. and Hinton, G. (2012). Lecture 6.5— RmsProp: Divide the gradient by a running average of its recent magnitude. COURSE: Neural Networks for Machine Learning.
- 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.