



UNIVERSIDADE FEDERAL DO MARANHÃO

Curso de Ciência da Computação

Ricardo Costa da Silva Marques

**Medição de Consumo Elétrico de Medidores
Eletromecânicos através de Dispositivos Móveis**

São Luís

2018

Ricardo Costa da Silva Marques

Medição de Consumo Elétrico de Medidores Eletromecânicos através de Dispositivos Móveis

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Geraldo Braz Junior

São Luís

2018

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

Silva Marques, Ricardo Costa da.
Medição de Consumo Elétrico de Medidores
Eletromecânicos através de Dispositivos Móveis / Ricardo
Costa da Silva Marques. - 2018.
43 f.

Orientador(a): Geraldo Braz Junior.
Monografia (Graduação) - Curso de Ciência da
Computação, Universidade Federal do Maranhão, São Luís,
2018.


1. Medição do Consumo Elétrico. 2. Processamento de
Imagens. 3. Reconhecimento de Padrões. I. Braz Junior,
Geraldo. II. Título.

Ricardo Costa da Silva Marques

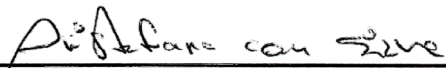
Medição de Consumo Elétrico de Medidores Eletromecânicos através de Dispositivos Móveis

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.


Trabalho Aprovado em São Luís, 22 de Janeiro de 2018:



Prof. Dr. Geraldo Braz Junior
Orientador
Universidade Federal do Maranhão



Prof. Dr. Aristófanés Correa Silva
Examinador 1
Universidade Federal do Maranhão



Msc. Darlan B. Pontes Quintanilha
Examinador 2
Universidade Federal do Maranhão

São Luís

2018

Agradecimentos

À minha família, incondicionalmente, por todo o apoio ao longo da minha trajetória de vida. Em especial minha mãe Marlene, por estar sempre ao meu lado, me apoiar nas minhas decisões e por ter sempre me ensinado o caminho correto. Minha avó Josefa, por toda sua dedicação e amor. Ao meu pai Raimundo, por sempre ter as palavras certas. Aos meus irmãos Raphael e Rodrigo, que mesmo com a distância, de alguma forma, sempre estivemos unidos.

À minha namorada Taynara, por todo carinho e paciência, e por estar sempre presente nos momentos difíceis dessa trajetória, por me ouvir, pelas palavras de força e também por me ajudar com suas habilidades de bibliotecária.

Ao meu orientador e amigo, Geraldo, por ter oferecido minha primeira chance em um laboratório, e por me incentivar à conhecer esse vasto caminho que escolhi trilhar, e por seu constante interesse em minha formação.

Aos professores, Ari, Anselmo, Simara e Dallysson por todas as críticas construtivas ao longo de minha formação acadêmica, que foram de fundamental importância para mim. E durante o tempo em que estive no NCA.

Aos amigos de laboratório Artur, Caio, Darlan, Giovanni, Jefferson, João, Kelson, Otilio, Petterson e Robherson, pelos momentos de descontração e também os momentos de seriedade, e pelos conhecimentos mutuamente compartilhados.

Aos amigos da graduação Alexandre, André, Alex, Fumihiro, Gabriel, Júlia, Marcio e Marcos, por todos os momentos felizes e difíceis que compartilhamos nessa jornada de provas e trabalhos.

Ao Núcleo de Computação Aplicada, por todo o suporte e apoio técnico e científico durante todo o processo desse trabalho.

À Universidade Federal do Maranhão por toda a estrutura oferecida.

E às companhias energéticas, CEMAR e CELPA pelo apoio financeiro.

*"Não fiques em terreno plano.
Não subas muito alto.
O mais belo olhar sobre o mundo
Está a meia encosta."*

Friedrich Nietzsche, em *"A Gaia Ciência"*

Resumo

No Brasil e no mundo, o procedimento de medição do consumo elétrico é feito de forma manual. Logo, esse processo é suscetível a falhas. Quando o valor do consumo não é anotado corretamente, na aquisição de leitura mensal, resulta em problemas de relacionamento entre a prestadora de serviço e o cliente. Nesse contexto, busca-se implantar uma nova estratégia para que seja feita a medição automática do consumo elétrico. Técnicas de processamento de imagens, reconhecimento de padrões e visão computacional são usadas na criação de um sistema de dispositivo móvel com boa capacidade de generalização, o Sistema de Leitura de Medição (SILEM). O objetivo principal do SILEM é prover um suporte ao trabalho realizado por leituristas das companhias de distribuição energética do grupo Equatorial, CEMAR e CELPA. Tendo em vista a simplificação da rotina de leitura, pois esta aplicação propõe uma ferramenta capaz de reconhecer o valor mostrado na região ocupada pelo display. A fim de otimizar o tempo de aquisição e aperfeiçoar o processo que vai desde a anotação do consumo até a impressão da fatura. Os testes da metodologia feitos com 361 imagens de medidores eletromecânicos. Casos de leitura automática que precisaram de correção do leiturista em no máximo um dígito alcançaram uma taxa 86,97% de acurácia, enquanto casos que não houveram necessidade de correção obtiveram 67,86% de acurácia. Considerando um total de 1805 dígitos no processo de classificação, a taxa de acerto individual obteve 87,42% de acurácia.

Palavras-chave: Medição do Consumo Elétrico; Processamento de Imagens; Reconhecimento de Padrões.

Abstract

In Brazil, the measuring procedure of electrical consumption is made manually. Therefore, this process is susceptible to failures. When the consumption value is not type correctly, in the monthly acquiring, this may have ends up resulting in problems of relationship between service provider and customer. In this context, we have to seek a new implementation strategy for automatic measurement of electric consumption. Techniques of Image Processing, Pattern Recognition and Computer Vision are used in the creation of a mobile system with quite generalization capacity, the Measurement Reading System (SILEM). The main goal of SILEM is provide support to the work performed by readers of the energy distribution companies of the Equatorial group, CEMAR and CELPA. In order to simplify the reading routine, this application proposes a tool capable of recognizing the value shown in the display region. In accordance to optimize the acquisition time and perfecting the process that goes from consumption annotation until the invoice printing. The methodology tests made with 361 images of eletromechanical meters. Automated reading cases that required correction of the reader in a maximum of one digit reached a rate of 86,97% accuracy, while cases that did not require correction had a 67,86% accuracy. Considering a total of 1805 digits in the classification process, the individual hit rate obtained 87,42% accuracy.

Keywords: Measurement of Electrical Consumption; Image Processing; Pattern Recognition.

Lista de ilustrações

| | |
|--|----|
| Figura 1 – Login MOM | 14 |
| Figura 2 – Sistema de coordenadas usado para representar uma imagem. | 19 |
| Figura 3 – Etapas de um sistema de processamento de imagens. | 20 |
| Figura 4 – a) imagem original, b) resultado da limiarização. | 22 |
| Figura 5 – Resultado da Aplicação: a) imagem original, b) resultado do CLAHE. . . | 23 |
| Figura 6 – Comparação da Aplicação: a) <i>Unsharp</i> com CLAHE aplicado, b) sem aplicação do CLAHE. | 23 |
| Figura 7 – a) dígito resultante da limiarização, b) resultado da aplicação do HOG. . | 25 |
| Figura 8 – Representação gráfica de uma SVM. | 28 |
| Figura 9 – Etapas da Metodologia Proposta. | 30 |
| Figura 10 – Exemplos de Displays. | 31 |
| Figura 11 – Aplicação do CLAHE e <i>Unsharp</i> | 31 |
| Figura 12 – Método de Detecção dos Dígitos. | 32 |
| Figura 13 – Representação da Sobreposição de <i>blobs</i> | 33 |
| Figura 14 – Representação Geométrica de dois <i>blobs</i> Vizinhos. | 33 |
| Figura 15 – Passos da segmentação. | 35 |
| Figura 16 – Execução do SILEM. | 37 |
| Figura 17 – Casos de erro da metodologia. | 40 |
| Figura 18 – Casos de acerto da metodologia. | 40 |

Lista de tabelas

| | |
|--|----|
| Tabela 1 – Resultado por display | 38 |
| Tabela 2 – Resultado por dígitos | 38 |

Lista de abreviaturas e siglas

| | |
|-------|---|
| ANEEL | <i>Agência Nacional de Energia Elétrica</i> |
| CEMAR | <i>Companhia Energética do Maranhão</i> |
| CELPA | <i>Centrais Elétricas do Pará</i> |
| CLAHE | <i>Contrast Limited Adaptive Histogram Equalization</i> |
| HOG | <i>Histogram of Oriented Gradients</i> |
| KWh | <i>KiloWatts-hora</i> |
| SVM | <i>Máquina de Vetores de Suporte</i> |
| NCA | <i>Núcleo de Computação Aplicada</i> |
| P&D | <i>Pesquisa & Desenvolvimento</i> |
| PDA | <i>Personal Digital Assistants</i> |
| SILEM | <i>Sistema de Leitura da Medição</i> |
| SIVAL | <i>Sistema de Validação</i> |
| UFMA | <i>Universidade Federal do Maranhão</i> |

Sumário

| | | |
|------------|---|-----------|
| 1 | INTRODUÇÃO | 13 |
| 1.1 | Trabalhos Relacionados | 15 |
| 1.2 | Objetivos | 17 |
| 1.3 | Contribuições | 17 |
| 1.4 | Organização do Trabalho | 17 |
| 2 | FUNDAMENTAÇÃO TEÓRICA | 19 |
| 2.1 | Processamento Digital de Imagens | 19 |
| 2.1.1 | Pré-Processamento | 21 |
| 2.1.1.1 | Limiarização | 21 |
| 2.1.1.2 | <i>Contrast Limited Adaptive Histogram Equalization - CLAHE</i> | 21 |
| 2.1.1.3 | <i>Unsharp Filter</i> | 22 |
| 2.2 | Extração de Características | 24 |
| 2.2.1 | <i>Histogram of Oriented Gradients - HOG</i> | 24 |
| 2.2.1.1 | Gradiente | 25 |
| 2.2.1.2 | Orientação das Células dos Histogramas | 26 |
| 2.2.1.3 | Normalização de Bloco | 26 |
| 2.3 | Reconhecimento de Padrões e Aprendizado de Máquina | 27 |
| 2.3.1 | Máquina de Vetores de Suporte | 28 |
| 3 | METODOLOGIA | 30 |
| 3.1 | Aquisição | 30 |
| 3.2 | Pré-Processamento | 31 |
| 3.3 | Segmentação de Dígitos | 31 |
| 3.3.1 | Programação Dinâmica | 32 |
| 3.4 | Extração de Características | 34 |
| 3.5 | Reconhecimento de Dígitos | 35 |
| 4 | RESULTADOS | 37 |
| 4.1 | Resultados da Metodologia | 38 |
| 4.2 | Estudo de Caso - SILEM | 39 |
| 5 | CONCLUSÃO | 41 |
| 5.1 | Trabalhos Futuros | 42 |

| | |
|--------------------------|-----------|
| REFERÊNCIAS | 43 |
|--------------------------|-----------|

1 Introdução

No Brasil, o dispositivo utilizado para registrar a medição de energia elétrica mensalmente nas residências e empresas é conhecido como Medidor de Energia. Este equipamento acumula o consumo de Kilowatts-hora (KWh) utilizado em um mês. A partir desse dispositivo é possível medir o consumo de energia elétrica comparando o valor da leitura atual com o valor da leitura no mês anterior. No Maranhão, a empresa responsável pela distribuição de energia elétrica é a Companhia Energética do Maranhão (CEMAR) e, no Pará, a Centrais Elétricas do Pará (CELPA), ambas concessionárias do grupo Equatorial.

No contexto atual dessas empresas, o processo de leitura do consumo elétrico é feito manualmente. Após inserir o valor da medição a fatura é impressa. O profissional responsável por esse trabalho é o leiturista. E o sistema utilizado em campo durante o processo de leitura é o MOM, um ambiente em que o funcionário pode obter informações a respeito das ordens de serviço que irá executar, e qual rota deverá seguir, para realizar a leitura.

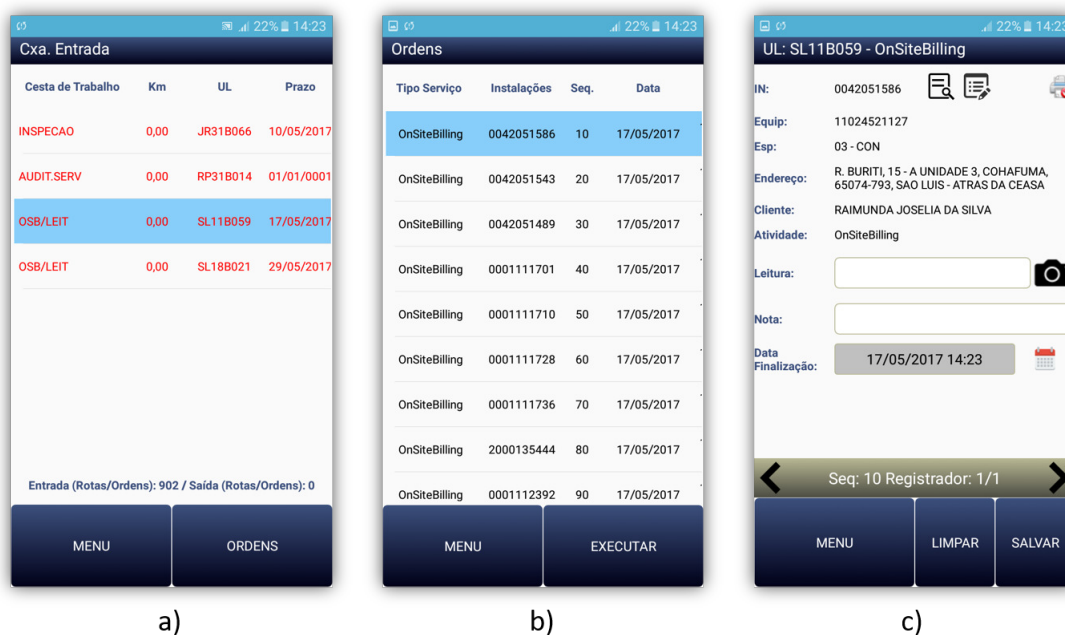
A tarefa do leiturista consiste nos seguintes passos (Figura 1): após fazer *login* no sistema MOM, selecionar uma ordem de serviço e executar a coleta de um dos medidores listados. Em caso de inconsistências na leitura, por exemplo, se o valor informado está fora da média de consumo do cliente ou caso o leiturista não consiga obter o valor registrado no medidor, o sistema MOM solicita que seja adquirida uma imagem para ser utilizada num processo de crítica que aferirá a consistência da leitura.

Esse cenário é suscetível a erros, pois nem sempre os medidores possuem boa visibilidade ou estão em locais insalubres e de difícil acesso. Nesses casos em que a leitura não pôde ser feita, essas imagens adquiridas são enviadas para um setor de crítica que é responsável por analisar o problema.

A quantidade de imagens que caem no setor de crítica por problemas de leitura é grande, fato este que motivou o projeto de Pesquisa e Desenvolvimento (P&D), sob contrato das empresas CEMAR/CELPA (ANEEL PD-00371-0029/2016) está sendo desenvolvido pelo Núcleo de Computação Aplicada (NCA) da Universidade Federal do Maranhão (UFMA). Tendo como objetivo a criação de um Sistema de Validação (SIVAL), visando a automatização da rotina de leitura dessas empresas, apresentamos o Sistema de Leitura da Medição (SILEM), que tem como objetivo principal automatizar o processo de leitura.

Diante desta situação, introduzimos o SILEM, uma aplicação com o papel de automatizar o processo de leitura. Que complementa o sistema MOM, portanto este trabalho busca realizar a tarefa de reconhecimento do consumo elétrico registrado no

Figura 1 – Sistema MOM: a) tela de ordens de serviço, b) lista dos medidores, c) tela de leitura da medição.



Fonte: o autor.

display do medidor, através da criação de um modelo de reconhecimento de dígitos associado ao SILEM. Logo, a atividade como um todo é automatizada e a função do leiturista consistirá em fazer a captura controlada de imagens, que sigam um protocolo de aquisição, para então serem processadas.

A aplicação faz uso da câmera do aparelho, a fim de facilitar o trabalho do leiturista em campo, principalmente em casos que a medição acompanhe o procedimento padrão, para validar os dados coletados pelo leiturista e evitar erros de leitura que podem acabar resultando em processos judiciais. Dessa forma, ao invés de informar manualmente o valor de consumo, é necessário que seja feita a captura de uma imagem da área dos dígitos no medidor.

Para realização deste trabalho é indispensável estudar e utilizar técnicas de processamento de imagens e reconhecimento de padrões, unidas a visão computacional em dispositivos *mobile* com o propósito de criar um modelo de classificação de dígitos para ler o consumo automaticamente.

Nesse contexto, tendo em vista a criação de um módulo de leitura automática da medição de consumo para facilitar a rotina de trabalho e melhorar o processo de leitura e crítica, este trabalho propõe a criação de um modelo de reconhecimento de dígitos que dê suporte a aplicação SILEM para reduzir erros associados ao processo de digitação da leitura e para que o trabalho manual executado pelo leiturista possa ser substituído por um

método automático de medição do consumo de energia, reduzindo custos e maximizando a produtividade da leitura.

Portanto, o papel do SILEM é realizar a leitura mensal do consumo de energia elétrica nas instalações através da imagem obtida do display do medidor. Para realizar esse processo, este estudo utiliza técnicas de inteligência computacional com ênfase em processamento de imagens e reconhecimento de padrões. Para resolver isso, o SILEM conta com uma interface simples e bem adaptada ao contexto da atividade.

1.1 Trabalhos Relacionados

A seguir são apresentados alguns trabalhos que desenvolvem a extração e o reconhecimento de dígitos em diversos tipos de abordagens, mas baseados exclusivamente na análise de formas, objetivando o reconhecimento de dígitos em geral, e fazendo a captura das imagens de modo que o foco principal seja a região dos dígitos.

Em [Parthiban e Palanisamy \(2013\)](#) é proposto um método para extração dos números de série dos medidores, porém corresponde ao campo de pesquisa de reconhecimento de dígitos. Inicialmente a imagem passa pela limiarização e em seguida, a operação morfológica em imagem binária é realizada para produzir uma imagem binária aprimorada. Então é obtida uma imagem digitalizada horizontalmente até o pixel branco ser encontrado e a imagem resultante é armazenada em uma matriz. Por fim, a imagem resultante é segmentada pelo algoritmo de detecção de borda vertical e cada imagem segmentada é armazenada em uma matriz individual. Cada imagem é então comparada com o modelo real e o resultado é armazenado.

No trabalho de [Elrefaei et al. \(2015\)](#) é feito uso de uma metodologia em que o equipamento de captura da imagem esteja bem posicionado em relação a orientação, para que possam utilizar técnicas de processamento e extração de características, a partir de melhoramentos em imagens em escala de cinza, com aplicação de limiarização para que a imagem seja limiarizada, dando foco na região composta pelos dígitos.

[Zhang et al. \(2016\)](#), propõe um sistema de leitura automática do medidor doméstico tradicional, projetado com base no processamento de imagem e no sistema DSP avançado. Para identificar a leitura do medidor com precisão, é proposto um método médio regional para implementar a escala da imagem para evitar a distorção. No processo de filtragem de imagens, é criado um método de produto médio que é verificado para alcançar bons efeitos. Para a segmentação da imagem, propõe-se um novo método de limiar de união, baseado na transformação em escala de cinza, para melhorar a adaptabilidade da luminância irregular. Uma biblioteca de treinamento com 1400 caracteres foi projetada e coletada para o treinamento de uma rede neural BP. Para transmissão de dados, a tecnologia NAT é utilizada para conexão de dados entre o servidor remoto e os coletores de dados que

trabalham na rede de área local. De acordo com o teste de campo, o sistema proposto pode obter uma taxa de reconhecimento de 99,7% em ambiente normal, com o período de identificação inferior a 2s.

No artigo de [Reis et al. \(2017\)](#) é apresentado um método para segmentar automaticamente a região da imagem que diz respeito ao medidor, essa imagem é adquirida por um leitorista de distribuidoras de energia e enviadas a um setor de crítica. Esta é uma tarefa fundamental para facilitar o processo de validação manual e uma etapa necessária para a leitura automática dos dígitos que representam o consumo. O método proposto obteve acurácia de 96,41%, 89,81% e 78,85%, respectivamente para três grupos de imagens categorizadas como boas, regulares e ruins.

Uma outra forma de validar a medição foi proposta por [Quintanilha et al. \(2017\)](#) através de imagens obtidas a partir da solicitação de aquisição de imagens em situações que existem divergência no consumo informado pelo leitorista. Todavia, esse processo de validação em duas companhias energéticas brasileiras (CEMAR e CELPA) retornam cerca de 30 mil imagens para serem analisadas. Neste contexto, é apresentado um método de aprendizado em cascata que utiliza ensemble de classificadores formado por dois classificadores SVM em paralelo e uma CNN para realizar a tarefa de detectar medidores elétricos em imagens. O método obteve acurácia de 92,79%, sensibilidade de 87,75% e especificidade de 97%.

Em [Kang \(2009\)](#), é proposto um método para identificação de veículos através da leitura da placa, esse tipo de sistema está no contexto de metodologias LPR do inglês *License Plate Recognition*. No trabalho é descrito um método de segmentação para recuperar os caracteres numéricos das placas dos carros utilizando programação dinâmica, para otimizar o processo de distribuição dos intervalos entre os dígitos, alinhamento dos caracteres, e aplicação de diferentes limiares para extrair dígitos.

Nas abordagens de [Popa \(2011\)](#), [Al-Ali et al. \(2011\)](#) e [Prapasawad, Pornprasitpol e Pora \(2012\)](#) para a leitura automática do consumo elétrico é proposta uma metodologia baseada no uso de Medidores Inteligentes do inglês *Smart Meters*. Medidores inteligentes são dispositivos capazes de ler e enviar automaticamente o valor obtido no reconhecimento, por algum tipo de transmissão de dados (SMS, GSM, PLC ou wireless).

Com base, nesses trabalhos busca-se criar uma metodologia capaz de extrair os dígitos do display e em seguida realizar o reconhecimento. Visando como tarefa principal, obter um modelo de reconhecimento de dígitos em displays eletromecânicos com um bom poder discriminatório diante de uma grande variedade de fontes de dígitos.

1.2 Objetivos

O objetivo deste trabalho é propor um método para o reconhecimento de dígitos em medidores eletromecânicos. Com a finalidade de aplicar esse modelo em uma aplicação móvel, que analise as imagens capturadas, realize a leitura do valor registrado por medidores de consumo elétrico e retorne o valor lido para a tela do MOM.

Como suporte para essa tarefa, um modelo de classificação de dígitos deve ser criado usando a técnica de aprendizado supervisionado Máquina de Vetores de Suporte (SVM). Empregando como características o *Histogram of Oriented Gradients* (HOG).

Destaca-se como objetivos específicos deste trabalho:

- Implementar uma técnica de segmentação de dígitos em displays de medidores eletromecânicos;
- Criar um modelo de reconhecimento de dígitos de displays eletromecânicos;
- Integrar o modelo de reconhecimento a uma aplicação móvel para tornar possível o teste e a validação da metodologia em campo;
- Validar os resultados obtidos com a metodologia proposta sobre uma base de dados reais obtidos em campo.

1.3 Contribuições

Este trabalho possui as seguintes contribuições:

- Adaptação de uma abordagem para tornar automático o processo de aferição da medição de consumo elétrico;
- Aumento da confiabilidade da medição de consumo de realizada automaticamente através da aquisição de imagem;
- Diminuir o tempo de registro da leitura;
- Promoção da organização e planejamento de ações antifraude baseado na medição automática.

1.4 Organização do Trabalho

Este trabalho está organizado em cinco capítulos, de forma a apresentar o conteúdo mais claramente, conforme os parágrafos a seguir.

O Capítulo 2, *Fundamentação Teórica*, apresenta o embasamento teórico necessário para o entendimento e desenvolvimento da metodologia proposta.

O Capítulo 3, *Metodologia Proposta*, apresenta as etapas realizadas de forma detalhada para a classificação dos dígitos baseado nas dez classes de números, por meio de imagens de medidores eletromecânicos.

O Capítulo 4, *Resultados*, apresenta e discute os resultados obtidos pela metodologia proposta, comparando-os com os resultados obtidos pelos trabalhos relacionados.

O Capítulo 5, *Conclusão*, apresenta as considerações finais acerca do trabalho realizado.

2 Fundamentação Teórica


Este capítulo apresenta a fundamentação teórica utilizada no desenvolvimento deste trabalho e necessária para compreensão das técnicas utilizadas na metodologia proposta para o reconhecimento de dígitos em displays de medidores eletromecânicos.

2.1 Processamento Digital de Imagens

O processamento digital de imagens envolve processos cujas entradas e saídas são imagens e, além disso, envolve processos de extração de atributos de imagens, inclusive, o reconhecimento de objetos individuais (GONZALEZ; WOODS, 2010). O processamento de imagens é composto por diversas fases, que englobam uma série de técnicas computacionais capazes de realizar operações que melhoram a visualização de características presentes em imagens, de modo que o olho humano seja incapaz de determinar.

Uma imagem é definida como um conjunto finito de valores representados por uma função de $f(x, y)$ (Figura 2), cada par ordenado (x, y) representa a intensidade de um *pixel*. Mesmo que a visão seja o sentido mais desenvolvido do corpo humano, é incapaz de visualizar todas as frequências de cor, por outro lado a visão computacional pode tratar estes problemas com o suporte de técnicas de processamento.

Figura 2 – Sistema de coordenadas usado para representar uma imagem.

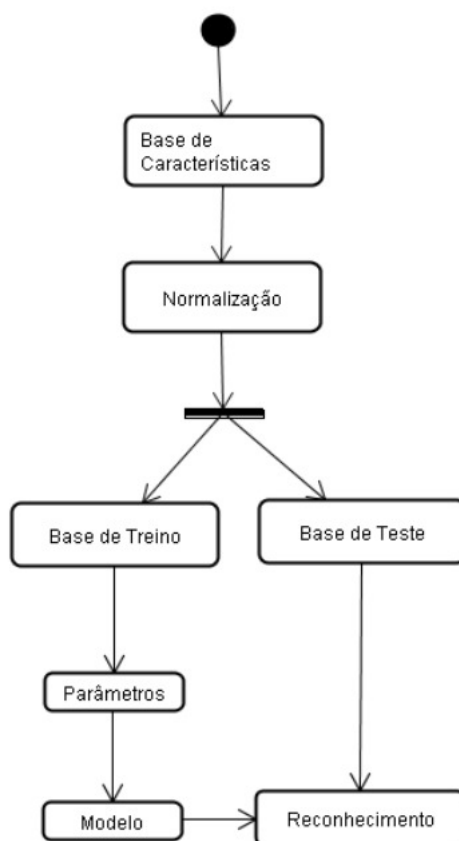


Fonte: (GONZALEZ; WOODS, 2010).

Assim, com o uso de técnicas de processamento digital de imagens existem diversos estudos, métodos e aplicações para realizar o processamento, descrição e a análise de feições em imagens digitais. Dentre elas podemos citar, transformações geométricas tais como, escala, rotação e inclinação, aplicações de filtros, operações com histograma, detecção

de borda, redução de ruídos e segmentação. Estes passos são evidenciados no fluxo de atividades da Figura 3, com o SILEM fazendo o papel do bloco de Reconhecimento.

Figura 3 – Etapas de um sistema de processamento de imagens.



Fonte: (ROCHA, 2014).

Hoje, está cada vez mais presente a importância dos avanços na área de processamento digital de imagens. Seja em sistemas de vigilância, monitoramento de vias ou até mesmo no dia a dia, onde diversos dispositivos eletrônicos possuem uma câmera integrada, que atualmente proporciona uma grande onda de informação digitalizada pela rede.

Por outro lado, diversas áreas trabalham com imagens, não somente recebendo uma imagem como entrada e devolvendo uma imagem processada como saída. As aplicações são inúmeras, em física, astronomia, engenharia, defesa e também na área médica, que por sinal faz bastante uso dessas técnicas de processamento de imagens. Seja em exames de Raio-x, ressonância magnética e ultrassons. Portanto, torna-se cada vez mais indispensável estudar e compreender tais técnicas de processamento, pois estas auxiliam diversos âmbitos da sociedade. Desde áreas de entretenimento até aplicações mais sérias.

2.1.1 Pré-Processamento

Nesta seção são mostradas algumas técnicas conhecidas no campo de estudo de processamento de imagens, essas técnicas são fundamentais para a metodologia deste trabalho pois faz-se necessário o uso de imagens com bom contraste, para que seja feita uma extração de características com sucesso.

2.1.1.1 Limiarização

A limiarização é vista na literatura como um caso específico de segmentação, sendo uma das abordagens mais importantes na tarefa de segmentação de imagens. Este método consiste em separar objetos presentes na imagem em duas classes, sendo essas o fundo e o próprio objeto. Assim, ao fazer a segmentação, temos a região de interesse bem evidenciada em relação ao restante da imagem. Neste trabalho, é aplicada para realçar os dígitos, deixando-os bem visíveis em comparação ao *background*.

É muito importante também a tarefa de escolha de um limiar diferente para cada tipo de problema, pois isso influi significativamente no resultado que será obtido. Geralmente, ao se trabalhar com imagens binárias, objetos pretos são representados pelo valor 0 e o branco corresponde ao valor 255. Desse modo, tem-se uma imagem binária composta por duas partes, o objeto representado pelo branco e o fundo pelo preto.

Em (GONZALEZ; WOODS, 2010), matematicamente, o processo de limiarização é definido como uma função de limiarização $g(x, y)$, dado pela Equação 2.1, que um certo $f(x, y)$ que é a função que representa o valor de intensidade, seja o resultado de uma limiarização, os valores de $f(x, y)$ maiores que um limite T representam os objetos e os valores de $f(x, y)$ menores ou iguais a T , correspondem ao fundo, podemos visualizar o resultado de uma limiarização na Figura 4.


$$g(x, y) = \begin{cases} 255, & f(x, y) > T \\ 0, & f(x, y) \leq T \end{cases} \quad (2.1)$$

2.1.1.2 Contrast Limited Adaptive Histogram Equalization - CLAHE

O *Contrast-Limited Adaptive Histogram Equalization* (CLAHE) é uma técnica de realce de contraste aplicada localmente em imagens, ou seja, a imagem é subdividida em setores e esses setores são realçados independentemente, o que acaba proporcionando um melhor ajuste de informação relevante para a abordagem em questão, pois outras técnicas de realce globais que não realçam com mais clareza a região de interesse.

A vantagem do CLAHE em relação a outros ajustes de contraste é que ele evita que possíveis ruídos sejam realçados (PEDRINI; SCHWARTZ, 2008). Ao fazer a análise

Figura 4 – a) imagem original, b) resultado da limiarização.



Fonte: o autor.

da imagem *pixel a pixel*, é feita com janelamento e caracteriza um *pixel* central através das informações dos seus vizinhos.

O CLAHE (PIZER, 1987) é um algoritmo que faz uma equalização de histograma individualmente, dividindo a imagem em regiões. Nesse trabalho é utilizado o estado da arte para calcular uniformemente o realce da imagem, pela Equação 2.2:

$$r = (x_{max} - x_{min})G(x) + x_{min} \quad (2.2)$$

onde x_{max} e x_{min} são respectivamente o maior e o menor valores de *pixel*, $G(x)$ representa o acúmulo dos valores que mais se repetem em uma determinada região da imagem e por último r recebe o novo valor de *pixel* associado a coordenada da imagem. A técnica CLAHE, foi utilizada no realce dos dígitos para deixar as bordas dos dígitos mais nítidas, isto ajuda a obter melhores resultados na tarefa de segmentação ((Figura 5)).

2.1.1.3 Unsharp Filter

O *Unsharp Filter* é um operador de forma que tem como finalidade acentuar bordas de objetos em uma imagem, realinhando os contornos dos objetos e deixando-as um pouco mais nítidas que as originais (GONZALEZ; WOODS, 2010). Ao aplicar uma máscara de *Unsharp* um ponto $g(x, y)$ recebe o resultado da operação definida pela Equações 2.3 onde $f_{smooth}(x, y)$ é a versão suavizada de $f(x, y)$.

$$g(x, y) = f(x, y) - f_{smooth}(x, y) \quad (2.3)$$

Figura 5 – Resultado da Aplicação: a) imagem original, b) resultado do CLAHE.




Fonte: o autor.

E k é uma constante de escala. Os valores razoáveis para k variam entre 0,2 e 0,7, com os valores maiores proporcionando quantidades crescentes de nitidez (Equação 2.4):

$$f_{unsharp}(x, y) = f(x, y) + k.g(x, y) \quad (2.4)$$

esta operação resulta em bordas mais acentuadas. Nota-se que, ao usar esse tipo de filtro ruídos podem ser gerados demasiadamente, por isso antes de utilizarmos esse filtro espacial o CLAHE foi aplicado (Figura 6).

Figura 6 – Comparação da Aplicação: a) *Unsharp* com CLAHE aplicado, b) sem aplicação do CLAHE.

Fonte: o autor.

2.2 Extração de Características

Nesta seção, trataremos a respeito dos conceitos de extração de características, uma vez que as regiões de interesse sejam processadas e segmentadas faz-se necessário o uso de um algoritmo para geração do vetor de atributos. Para tanto, fazemos a extração das características presentes nas imagens, de modo que, o vetor sirva de parâmetro de entrada para criação do modelo de reconhecimento.

De outro modo, os dados armazenados no vetor de atributos possuem uma representação matemática sobre os indivíduos de uma determinada classe, caracterizando e identificando peculiaridades pertinentes a um conjunto de imagens, dessa maneira a extração ajuda na construção mais completa e com maior número de informações a respeito de atributos extraídos das regiões de interesse.

Visto que, ao criar um arquivo de características é gerado um grupo de singularidades, que unidas constituem as informações necessárias para descrever dados obtidos em um extenso módulo de amostragem, composto geralmente por um grande volume de dados. Por fim, dizemos que a fase de extração de características consiste em verificar e encapsular as partes mais importantes de um grupo de objetos em análise, e isolar atributos relevantes, a fim de gerar um significado.


2.2.1 *Histogram of Oriented Gradients* - HOG

Proposto por Dalal e Triggs (2005), o algoritmo *Histogram of Oriented Gradients* é uma abordagem para representar características de forma e é a base de muitos detectores modernos. A extração de características HOG consiste na aplicação do gradiente, na divisão da imagem em células sem sobreposição e na construção de histogramas da orientação dos vetores do gradiente ponderado pela magnitude do mesmo para cada célula. Logo, as células são agrupadas em blocos com superposição onde é executada uma normalização local. É largamente utilizado para descrever formas também em diversas aplicações como representação de um símbolo, um carro, uma face, entre outros.

Nesse contexto, sabe-se que boas características podem ajudar o classificador a convergir com mais facilidade, ajudando a diminuir redundâncias no modelo. Pois, ao determinar e caracterizar formas de objetos usando HOG pode-se representar essas formas através da intensidade local dos gradientes ou direções das bordas. Na prática, a imagem é dividida em pequenos blocos conhecidos como células, para cada célula acumula-se um histograma local das direções dos gradientes, extraíndo a informação dos *pixels* de cada célula, com essas combinações é formada a representação de uma forma (Figura 7).

Portanto, para melhorar a invariância causada por alta iluminação, sombreamento e etc. É feita uma normalização de contraste local antes de aplicar a técnica. Isto é feito acumulando medidas de energia local do histograma sobre as regiões espaciais maiores,

Figura 7 – a) dígito resultante da limiarização, b) resultado da aplicação do HOG.



Fonte: o autor.

denominadas blocos. Por fim, o resultado dessa normalização é concatenado a todas as células de um bloco. Isto posto, nos referimos aos descritores de blocos normalizados como *Histogram of Oriented Gradients* (DALAL; TRIGGS, 2005).

2.2.1.1 Gradiente

Com essa descrição introduzimos a formulação matemática do HOG, lembrando que, os valores obtidos da extração não são gerais e cada situação pode promover diferentes valores para representação do HOG em diferentes objetos. Diante disso, o trabalho original acaba gerando um grande número de descritores e muitos detalhes podem variar.

Assumindo, uma imagem I em níveis de cinza temos que, aproximando os componentes I_x e I_y do gradiente de I pela diferença central dada pelas Equações 2.5 e 2.6.

$$I_x(r, c) = I(r, c + 1) - I(r, c - 1) \quad (2.5)$$

$$I_y(r, c) = I(r - 1, c) - I(r + 1, c) \quad (2.6)$$

A convolução é feita através da derivada da Gaussiana, em ambas as direções, I_x e I_y , com o papel de suavização para remover detalhes desnecessários. Adicionalmente, alguns níveis de ruído podem ocorrer em passos anteriores da computação do HOG, porém a suavização Gaussiana mesmo sendo mais custosa obtém melhores resultados.

Dessa maneira, o gradiente μ é transformado em coordenadas polares com ângulo θ limitado entre 0 e 180 graus, desconsiderando pontos de direções opostas para um mesmo

ângulo, a Equação 2.7 representa o cálculo da convolução e o ângulo é determinado pela tangente inversa na Equação 2.8 com valores de $-\pi$ a π .

$$\mu = \sqrt{I_x^2 + I_y^2} \quad (2.7)$$

$$\theta = \frac{180}{\pi} (tg_2^{-1}(I_y, I_x) \bmod \pi) \quad (2.8)$$

2.2.1.2 Orientação das Células dos Histogramas

O histograma de b orientações (*bins*) de gradientes, para cada célula, é computado dividindo a imagem em células adjacentes de tamanho $C \times C$, sem sobreposição de células. Com poucos *bins*, na orientação de um *pixel* cujo o *bin* esteja próximo de uma borda nota-se uma leve mudança de orientação, com a finalidade de manter uma boa representação da borda. Logo, em cada célula a computação do HOG é armazenada em B *bins*, onde uma fração de *pixels* irá representar a magnitude μ que diminui linearmente com a distância de cada gradiente de orientação do *pixel* aos dois centros de *bins* mais próximos à orientação.

Especificamente, os *bins* são numerados de 0 a $B - 1$ e tem largura:

$$w = \frac{180}{B} \quad (2.9)$$

um *bin* i tem bordas definidas em $[wi, w(i + 1)]$ e está centralizado em:

$$c_i = w(i + \frac{1}{2}), \quad (2.10)$$

Um *pixel* com magnitude μ e orientação θ determinam uma função de escolha pelo voto:

$$v_j = \mu \frac{c_{j+1} - \theta}{w}, \quad (2.11)$$

no *bin*

$$j = (\frac{\theta}{w} - \frac{1}{2}) \bmod B, \quad (2.12)$$

e em um voto

$$v_{j+1} = \mu \frac{\theta - c_j}{w} \quad (2.13)$$

para o *bin* $(j + 1) \bmod B$. Esse esquema é denominado Interpolação Bi linear, e o histograma da célula é um vetor com B entradas não negativas (TOMASI, 2015).

2.2.1.3 Normalização de Bloco

Agrupando as células em sobreposição de blocos 2×2 em cada célula, cada bloco terá *pixels* de tamanho $2C \times 2C$. Com blocos de dois em dois horizontalmente ou verticalmente

consecutivos sobrepostos por duas células em comum, isto é conhecido como deslizamento de blocos em uma quantidade C de *pixels*.

Uma característica de bloco b é adquirida ao concatenar as quatro células do histograma e normalizando essa característica com a norma Euclidiana (Equação 2.14). Nesta expressão ϵ representa a menor constante positiva para evitar perda de blocos de gradientes em divisões por zero.

$$b \leftarrow \frac{b}{\sqrt{\text{mod } b^2 + \epsilon}} \quad (2.14)$$

Por fim, o bloco de características normalizado é concatenado a um vetor de atributos h do HOG. Essa normalização é dada por:

$$h \leftarrow \frac{h}{\sqrt{\text{mod } h^2 + \epsilon}} \quad (2.15)$$

em uma n -ésima entrada h_n , h é computado por,

$$h_n \leftarrow \min(h_n, t) \quad (2.16)$$

tal que o valor de *threshold* t seja positivo. Desse modo, esta normalização final faz com que uma característica do HOG seja independente do contraste geral da imagem.

2.3 Reconhecimento de Padrões e Aprendizado de Máquina

Nesta seção, explicaremos os procedimentos utilizados na etapa de classificação de uma imagem. Sendo este, o último passo da metodologia de sistemas inteligentes. Partindo do princípio que para fazer um reconhecimento de padrões devemos analisar as similaridades em um conjunto de classes existentes. Sabe-se que, se existe uma classe então pode-se dizer que existem objetos pertencentes a esta classe, e esses objetos são classificados a partir dos atributos que eles possuem, e será por meio destes atributos que o objeto poderá ser classificado.

[Gonzalez e Woods \(2010\)](#) definiram que um padrão é um arranjo de vetores de atributos, que pertencem a uma classe ou família de objetos que compartilham as mesmas características. O processo de reconhecimento de padrões se divide em duas etapas, o primeiro é a classificação, onde cada indivíduo de um grupo é adicionado a uma classe e em seguida o reconhecimento, que recebe um indivíduo de uma classe para que este seja inserido em uma classe existente, de acordo com os seus atributos.

O processo de classificação se baseia no princípio de indução para chegar a uma solução geral sobre um conjunto particular de indivíduos. A esse processo é dado o

nome de aprendizado de máquina e este é dividido em dois tipos: supervisionado e não-supervisionado.


O primeiro apoia-se na ideia de utilizar uma amostragem de teste com objetos já conhecidos, de modo que estes sirvam de treinamento para uma metodologia. Assim, ao introduzir objetos desconhecidos o sistema de reconhecimento já terá capacidade de gerar uma saída válida, baseado no treinamento adquirido na etapa de treinamento. Já o segundo método não utiliza informações previamente selecionadas para a tarefa de classificação. Nesse caso, todos os dados inseridos servirão como base de treinamento para a máquina. Portanto, ao testar cada amostra é que o algoritmo irá agrupar as informações necessárias para realizar a classificação.

2.3.1 Máquina de Vetores de Suporte

Existem várias metodologias computacionais de reconhecimento de padrões capazes de realizar a tarefa de classificação, porém este trabalho fará uso de Máquina de Vetores de Suporte, pela larga escala de trabalhos na literatura que escolheram esse método de classificação e obtiveram sucesso.

SVM é um método de aprendizagem supervisionado usado para estimar uma função que classifique dados de entrada em classes, sendo que o princípio básico por trás da SVM é a construção de um hiperplano (Figura 8) que serve como base para as tomadas de decisão, de modo que, a diferenciação entre as classes submetidas é maximizada. Assim, a intenção de fazer a classificação com SVM é a obtenção de hiperplanos que dividam as amostras de tal modo que sejam otimizados os limites de generalização (VAPNIK, 1998).

Figura 8 – Representação gráfica de uma SVM.



Um hiperplano é definido como um separador de regiões multidimensional, tal que a quantidade de dimensões possa tender ao infinito. Até mesmo quando dois grupos

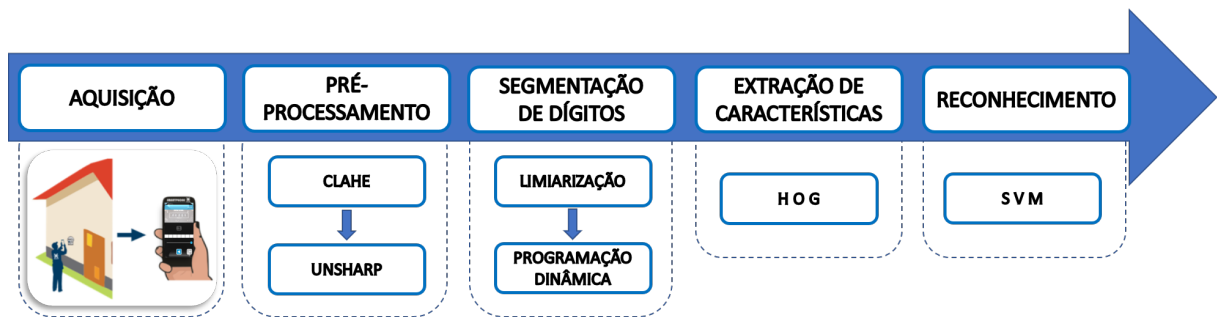
de objetos não estiverem desagrupados, o SVM traça um hiperplano otimizado entre as classes. É capaz de delimitar um hiperplano com base no conjunto de pontos, conhecido como vetores de suporte. Estes são capazes de maximizar a fronteira que divide as classes do teste (VAPNIK, 1998).

Os vetores de suporte são fundamentais para que haja uma classificação bem-sucedida. Estes representam elementos chave de um conjunto de treinamento, caso algum seja removido, a solução é alterada consideravelmente. Por fim, neste trabalho é utilizado um *Kernel* radial para estruturar as amostras, devido a sua baixa complexidade computacional mesmo sendo usado em aplicações com grande espaço dimensional. E por apresentar performance superior a outros núcleos do SVM.

3 Metodologia

Neste capítulo, apresentamos o método desenvolvido para leitura do consumo em medidores eletromecânicos, isto posto, descreveremos os procedimentos presentes na metodologia proposta neste trabalho para classificação de padrões presentes em dez classes, sendo estas compostas pelos dígitos de 0 a 9. O método apresentado foi aplicado em imagens de regiões ocupadas pelos dígitos do medidor. A Figura 9 representa as etapas da metodologia, sendo estas: aquisição, pré-processamento, segmentação de dígitos, extração de características e reconhecimento.

Figura 9 – Etapas da Metodologia Proposta.



3.1 Aquisição

Inicialmente, para validação desse trabalho, foram selecionados dois grupos de imagens o primeiro é composto por 1886 imagens de medidores do banco de dados das companhias energéticas CEMAR e CELPA, nesse grupo de imagens existem apenas displays com 5 dígitos. Essas imagens são resultantes do processo de crítica dessas empresas. O segundo, composto por 361 imagens, foi obtido em quatro visitas a campo com os técnicos da CEMAR. Esse segundo módulo de imagens foi obtido com o SILEM e possui fotos dos displays dos medidores (Figura 10).

As imagens da base possuem grande variabilidade nas características, dentre as quais podemos destacar, ambientes com pouca e muita luz, borradas, com sujeira e pontos de luz ou sombra cobrindo os dígitos. Destaca-se também, a quantidade de modelos de medidores e fontes de dígitos, presentes na base de imagens, em um total de 63 modelos do tipo eletromecânicos, dispostos em 30 da CEMAR e 33 da CELPA. Ao todo 11 fontes de dígitos foram encontradas nos modelos. Por isso, o teste com variados casos torna-se importante, pois ajuda a metodologia a se adaptar aos diversos tipos de problemas e

Figura 10 – Exemplos de displays de medidores eletromecânicos da base de dados adquirida nas visitas técnicas.



Fonte: o autor.

condições reais dos equipamentos, incluindo características específicas de cada modelo e fonte de dígito.

3.2 Pré-Processamento

Na etapa de pré-processamento, busca-se melhorar a qualidade das imagens para a fase de extração de características. Nessa fase, as imagens são usadas em escala de cinza. O CLAHE é usado para realçar o contraste da imagem, e *Unsharp* para realçar o contorno dos dígitos, deixando estes bem evidentes. Esse processo é visto na Figura 11.

Figura 11 – a) área dos dígitos adquirida pelo SILEM, b) resultado do CLAHE, c) resultado do *Unsharp*.



Fonte: o autor.

3.3 Segmentação de Dígitos

A tarefa de segmentação busca separar os dígitos presentes na imagem, com isso podemos extrair características que descrevem com melhor definição um determinado objeto, evitando características não pertinentes a forma.

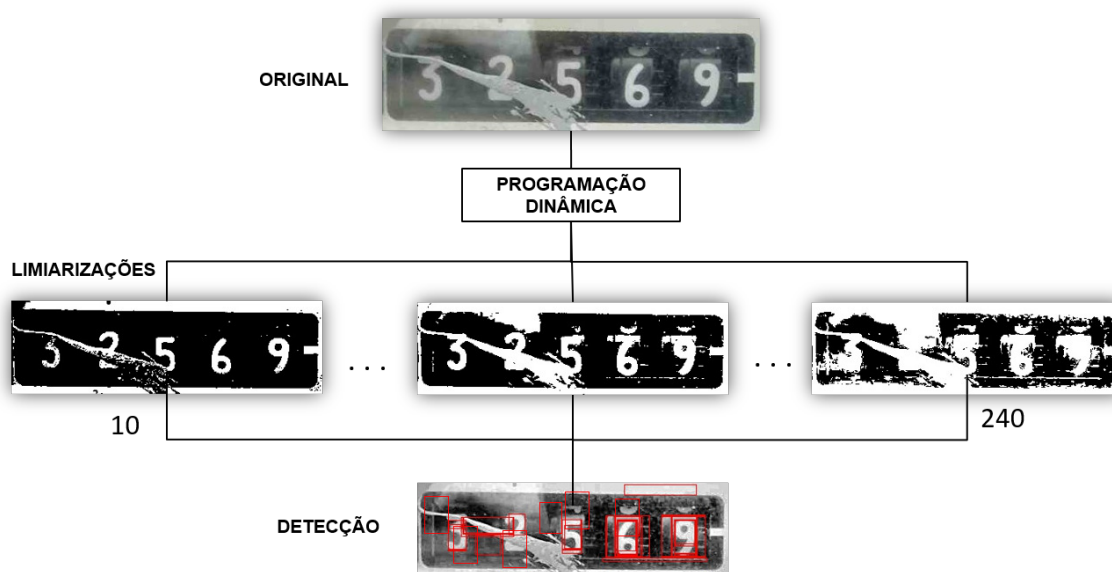
3.3.1 Programação Dinâmica

Programação dinâmica é um nome extravagante para recursão com uma tabela. Em vez de resolver subproblemas de forma recursiva, resolva-os sequencialmente e armazene suas soluções em uma tabela (PARBERRY, 1995). O artifício é resolvê-los na ordem certa, de modo que sempre que a solução para um subproblema seja necessária, já está disponível na tabela.

Esta técnica é muito utilizada quando resolver problemas pelo método dividir-e-conquistar não gera resultados em tempo ótimo. Particularmente produz uma abordagem que evita recálculos desnecessários. Neste caso, faz sentido calcular cada solução pela primeira vez e armazená-la em uma tabela para uso posterior, em vez de repeti-la recursivamente sempre que for necessário.

Para segmentação dos dígitos, é utilizado um esquema de programação dinâmica onde são aplicadas múltiplas limiarizações (entre 10 e 240, com passo 10) (Figura 12) para extrair as regiões de interesse, todavia muitos objetos binários resultam da etapa de limiarização, esses objetos são denominados *blobs*. O grande volume de *blobs* gerados pode tornar-se inviável para uma boa representação. O primeiro passo para reduzir essa quantidade é fazer uma filtragem a partir informações de altura ($H(b_i)$), área da *bounding box* ($A_{bb}(b_i)$) e a proporção largura/altura ($W_{bb}(b_i)/H_{bb}(b_i)$) associada a cada *blob*.

Figura 12 – Método de detecção dos dígitos com programação dinâmica aplicada a múltiplos limiares, resultando na concatenação das detecções.




Fonte: o autor.

A segunda filtragem, consiste em descartar *blobs* duplicados. Assumindo que um display possui 5 dígitos. O primeiro passo é selecionar um par de *blobs* adjacentes (b_i e

b_{i+1}). Para cada par que tiver distância entre seus centros de massa menor que 5 *pixels* e uma proporção mínima entre áreas maior que 0.8, feito isso o menor é eliminado (Figura 13).

Figura 13 – Representação da sobreposição de dois *blobs*: o descarte é feito usando a altura h , largura w e centro de massa C .




Fonte: o autor.

O resultado da filtragem retorna os *blobs* melhores adaptados aos dígitos. Algumas informações como a quantidade de dígitos (n) e o espaço entre os mesmos (dw) são definidos previamente. Essas informações usam a similaridade local considerando o espaçamento entre os dígitos. Kang (2009) utiliza esse modelo de programação dinâmica para otimizar o processo de separação dos dígitos.

Esse método é eficaz porque reduz as limitações criadas por fatores externos como iluminação, sujeira, borrado e variação de dimensão dos dígitos por trabalhar com os resultados de múltiplos limiares. A Figura 14 refere-se as medidas usadas nas Equações 3.1 a 3.5.

Figura 14 – Representação geométrica de dois *blobs vizinhos*: d é a distância dos centros de massa de cada *blob*, h_i e h_{i-1} as alturas dos *blobs adjacentes*.



Fonte: o autor.

Por fim, a energia (E_T) da disposição dos *blobs* é computada pela Equação 3.1,

$$E_T = \sum E_h(b_i, b_i + 1) + E_{c_h}(b_i, b_i + 1) + E_{distW}(b_1, b_i + 1) + E_{th}(b_1, b_i + 1) \quad (3.1)$$

Sabendo que:

$$E_h(b_i, b_{i+1}) = \alpha_1 |h(b_i) - h(b_{i+1})| \quad (3.2)$$

$$E_{c_h}(b_i, b_{i+1}) = \alpha_2 |C_h(b_i) - C_h(b_{i+1})| \quad (3.3)$$

$$E_{distW}(b_i, b_{i+1}) = \alpha_3 |d_w(b_i) - d_w(b_{i+1} - d_w)| \quad (3.4)$$

$$E_{th}(b_i, b_{i+1}) = \alpha_4 |th(b_i) - th(b_{i+1})| \quad (3.5)$$

onde $(b_i, b_i + 1)$ é o ajuste dos *blobs* adjacentes, h é a altura de um *blob* candidato, α uma constante de ponderação, E_h a energia da diferença de altura entre os dígitos, E_{c_h} é a energia da diferença vertical entre o centro de massa C_h , E_{distW} é a energia horizontal da variação de espaçamento entre os dígitos e E_{th} a energia da diferença dos valores de limiarizações th usados para obter as *blobs*. Por fim, temos como resultado (Figura 15) com as *bounding box* selecionadas como melhores resultados da segmentação.


3.4 Extração de Características

Esta etapa inicia com a extração de características usando o HOG, a ideia principal por trás dos descritores do HOG é que a aparência de objetos é caracterizada por uma distribuição local de bordas orientadas (BALLESTEROS; SALGADO, 2014). O segundo passo é a divisão em blocos chamados células, de onde os histogramas são retirados. Cada *pixel* na célula contribui com um voto ponderado de acordo com a magnitude do gradiente e a distância para o centro dos blocos, e os gradientes mais votados definem com mais exatidão os dados do vetor de características.

Primeiramente, descobriu-se que os dígitos não seguem um padrão de tamanho único. Assim, para fazer a extração de características invariante ao tamanho, os parâmetros do HOG foram configurados de modo constante, para que todas as imagens de dígitos extraídas sejam caracterizadas com a mesma configuração do vetor de atributos.

Assim, cada dígito é centralizado no menor retângulo delimitado pela *bounding box*, variando de 32 a 512 *pixels* de comprimento e altura, apresentando as dimensões máxima

Figura 15 – Passos da segmentação dos dígitos: partindo dos objetos detectados com os múltiplos limiares, é feita uma primeira filtragem, em seguida uma redução de falsos positivos e por último o resultado da detecção.



Fonte: o autor.

e mínima presentes nas imagens obtidas e os espaços vazios foram preenchidos com zero. Desta forma, não há distorções na extração regiões e é garantido que as regiões centrais do *bounding box* contém apenas informações do dígito. Dessa forma, os parâmetros utilizados para configuração do HOG, foram de 4 blocos, 8 células por bloco e com sobreposição igual a 1. Empiricamente, o número de direções usadas nos histogramas foi de 24 direções.

Recomenda-se que a base de características seja normalizada para valores no intervalo de 0 a 9. Afim de padronizar a distribuição de valores no vetor de atributos de cada indivíduo, evitando que estes assumam domínios diferentes do esperado. Além disso, busca ajudar o classificador a convergir com maior facilidade na etapa de treinamento (JUNIOR, 2008).

3.5 Reconhecimento de Dígitos

Para criar o modelo de reconhecimento de dígitos do SILEM, inicialmente, foi usado o primeiro grupo de imagens apresentado na Seção 3.1. Foi utilizada a base composta por 3866 dígitos para extração de características com o HOG. Esses dígitos foram manualmente

segmentados e separados em classes. Dispostos em: 478 dígitos 0, 462 dígitos 1, 454 dígitos 2, 354 dígitos 3, 372 dígitos 4, 362 dígitos 5, 350 dígitos 6, 336 dígitos 7, 356 dígitos 8 e 342 dígitos 9.

Na configuração dos parâmetros da extração, cada dígito foi centralizado no menor *bounding box* retangular, com dimensões acompanhando potências de 2, no intervalo de 32 a 512 *pixels* na altura e na largura.

Os espaços vazios foram criados preenchidos com zero (*Zero Padding*). Desse modo, não há distorções nos valores obtidos com a extração. Isso garantido pois, a região marcada pelo *bounding box* possui apenas o dígito. Os parâmetros usados para todos os dígitos foram: blocos de tamanho 4 com 8 células por bloco e sobreposição 1. Empiricamente, 24 direções foram usadas no histograma.

As características extraídas com o HOG, foram submetidas para o treinamento do SVM com as seguintes configurações: kernel radial, C igual a 32, γ igual a 0,0078125, estimado com método de pesquisa em grade usando validação cruzada em 10 *folds*. A escolha do classificador SVM se deu porque muitos trabalhos na área de processamento de imagens, obtiveram resultados bastante satisfatórios. O comprova a eficiência do método para o reconhecimento de padrões em diferentes tarefas.

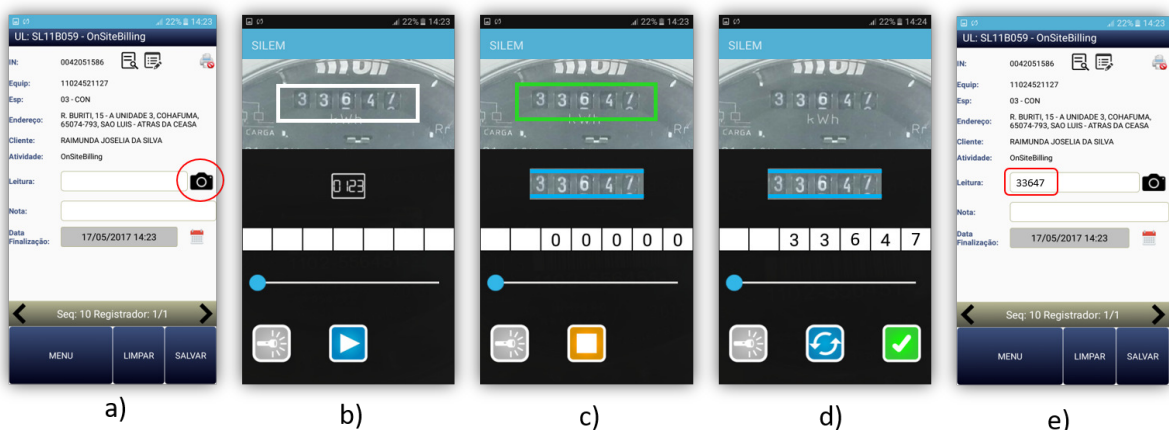
4 Resultados

Neste capítulo são apresentados os resultados obtidos seguindo a metodologia proposta no capítulo anterior. Primeiramente, como resultado desse trabalho, demonstramos a aplicação móvel SILEM, integrada ao sistema MOM para realizar a tarefa de leitura da medição do consumo elétrico de maneira automática. Em seguida, apresentamos as acurácias do modelo de reconhecimento por display e por dígitos reconhecidos e um estudo de caso sobre o funcionamento da aplicação.

O reconhecimento por display consiste no reconhecimento total de todos os dígitos presentes numa leitura. Quando maior esse valor, menor será a quantidade de correção da leitura do consumo por parte do leiturista e menor será o tempo total de aquisição. O reconhecimento por dígito consiste na acurácia geral por classes de 0 a 9.

Iniciando o SILEM, o primeiro passo consiste em fazer a captura da imagem. Essa é a primeira etapa da metodologia de reconhecimento. Na Figura 16, mostramos as etapas do SILEM, iniciando pelo protocolo de aquisição, nessas telas podemos ver uma área demarcada por um retângulo, esta área diz respeito ao local da imagem em que devem estar presentes os dígitos.

Figura 16 – Passos de execução do SILEM: a) tela de leitura do MOM, b) posicionamento dos dígitos dentro do retângulo, c) *feedback* da captura, d) leitura obtida, e) retorno da leitura para o MOM.



Fonte: o autor.

Seguir esse protocolo de aquisição é importante, pois reduz a área de busca na fase de separação dos dígitos e contribui com a eficiência da aplicação que depende de

uma aquisição correta para um bom funcionamento. Assim que a imagem for capturada, o processamento da imagem é iniciado e tem como resultado final o retorno do valor lido.

A interface do SILEM é simples de usar e atende bem requisitos de usabilidade como: consistência, eficiência e facilidade de uso. Sua navegação é rápida e possui todas as funcionalidades em uma única tela, com os ícones bem-dispostos na tela do aparelho. Ferramentas como Zoom e lanterna também estão disponíveis. Ao final do processo, note que as caixas onde os dígitos estão dispostos ficam liberadas para edição caso ocorra erro de leitura. Por fim, basta apertar o botão verde de confirmar e retornar o valor lido para a tela do MOM.

4.1 Resultados da Metodologia

Para avaliação de acurácia do SILEM, a análise foi dividida em duas abordagens. A primeira, calcula a eficiência do método por display, considerando casos de acerto em que todos os dígitos foram corretamente classificados. Os resultados obtidos são apresentados na Tabela 1. A taxa de acerto por display alcançou um percentual de 67,86% (245/361) de acurácia, em 19,11% (69/361) dos casos um dígito precisou ser corrigido e somente em 4,15%(15/361) não houve qualquer acerto dos dígitos.

Tabela 1 – Resultado do SILEM por display.

| Resultado | Acertos/Total | Acurácia |
|---------------------|----------------------|-----------------|
| Acertou tudo | 245/361 | 67,86% |
| Errou 1 | 69/361 | 19,11% |
| Errou 2 | 18/361 | 4,98% |
| Errou 3 | 9/361 | 2,49% |
| Errou 4 | 5/361 | 1,38% |
| Errou tudo | 15/361 | 4,15% |

Na segunda análise é apresentada a acurácia por dígito. Em 361 imagens, obtemos um total de 1805 dígitos, nessa base todos os medidores possuem 5 dígitos no display. O detalhamento desse resultado está disposto na Tabela 2, com essa abordagem a metodologia atingiu uma acurácia de 87,42% (1578/1805).

Tabela 2 – Resultado do SILEM por dígito.

| Resultado | Acertos/Total | Acurácia |
|---------------------|----------------------|-----------------|
| Acertou tudo | 1225/1805 | 67,86% |
| Acertou 4 | 276/1805 | 15,29% |
| Acertou 3 | 54/1805 | 2,99% |
| Acertou 2 | 18/1805 | 0,99% |
| Acertou 1 | 5/1805 | 0,27% |
| TOTAL | 1578/1805 | 87,42% |

Ao avaliar os resultados obtidos pela metodologia proposta para a classificação dos dígitos, em ambos os procedimentos foi verificado bom rendimento. Como mostrado na Tabela 1, de 361 casos somente em 15 casos não houve qualquer acerto, considerando que há muitas características a serem analisadas pelo modelo de reconhecimento, os resultados foram bastante satisfatórios. Sabendo que, o tempo médio da leitura manual é de 1 minuto e 40 segundos, com o uso do SILEM, esse tempo é reduzido em média para 25 segundos. Desde a captura até o retorno do valor reconhecido para o MOM.

4.2 Estudo de Caso - SILEM

Para averiguar o potencial dos resultados do SILEM, testamos a aplicação com 361 imagens divididas em 26 modelos, adquiridas em diferentes situações. Nesse processo, destacam-se as particularidades que os equipamentos podem apresentar e as recomendações a serem seguidas em cada caso:

- Aquisição em ambiente com ausência de iluminação.

Recomendação: utilizar a lanterna, tome cuidado no posicionamento da lanterna para não gerar pontos de luz sobre os dígitos.

- Excesso de iluminação.

Recomendação: utilizar a câmera em diferentes ângulos para evitar reflexos indesejados na imagem.

- Transição de dígitos.

Recomendação: em casos de transição, se o reconhecimento não retornar o valor correto, orienta-se que seja feita a correção manual do dígito.

- Inclinação.

Recomendação: deve-se posicionar o celular no mesmo ângulo de rotação do medidor de uma maneira que o display tenha a orientação corrigida.

- Desgaste de proteção do visor.


Recomendação: diante desta situação, o celular deve ser posicionado bem próximo da tampa do visor. Caso não seja possível capturar uma imagem com boa qualidade, deve-se realizar o procedimento manual.

Note que, a etapa de aquisição é de extrema importância para a metodologia. Pois, a captura de imagens de boa qualidade, aumenta as chances de o método funcionar de modo correto nos passos seguintes. Como consequência dos casos de difícil uso da aplicação, exemplificamos na Figura 17 resultados em que a metodologia não funcionou corretamente.

Isso se dá pelo fato de as recomendações não terem sido seguidas ou por desgaste do medidor.

Figura 17 – Casos de erro da metodologia.

Casos de erro




Fonte: o autor.

Portanto, se as recomendações de uso forem seguidas corretamente o método funcionará com melhor precisão. Visto que, precisão do aplicativo está diretamente relacionada a qualidade de sua operação. Assim, a exposição desse estudo de caso tem por objetivo apresentar a operação do SILEM, seguindo as recomendações para entender o seu funcionamento e as restrições atreladas a sua utilização. Estas recomendações devem ser usadas como manual básico de operação do aplicativo. Na Figura 18 são mostrados resultados em que o protocolo foi seguido e resultou em acerto no reconhecimento.

Figura 18 – Casos de acerto da metodologia.

Casos de acerto



Fonte: o autor.

5 Conclusão

Este trabalho apresentou a metodologia do Sistema de Leitura da Medição, com o uso de características do HOG para treinar uma máquina de vetores de suporte, visando a criação de um modelo de reconhecimento de dígitos de medidores eletromecânicos. Nesse contexto, a metodologia apresentada, comprometeu-se em analisar as diferentes características de forma nas dez classes de dígitos (0-9), separadas em onze fontes e subdivididas em 63 tipos de equipamento, respectivamente 30 da CEMAR e 33 da CELPA.

O desempenho da classificação, obteve como resultado valores significativos de acurácia. Esta métrica serve para avaliar, o quão bom o método criado foi capaz de acertar na classificação dos dígitos. Logo, o SILEM demonstrou robustez na tarefa de classificação, mesmo em ambientes não controlados, pois conseguiu acertar também em casos de difícil visualização.

Analisando os casos de erro, percebe-se que, quando não é seguido o protocolo definido, o modelo de classificação torna-se mais suscetível a falhas. Devido a problemas associados as características físicas descritas em cada situação que os equipamentos podem representar. Esses problemas, podem ser reduzidos por meio de manutenções nos medidores, para proporcionar melhores resultados na tarefa desempenhada pelo SILEM.

A partir destas observações, sabe-se que a metodologia possui bom poder discriminatório pois, a partir do momento em que as imagens comecem a ser analisadas com o SILEM, as empresas de distribuição elétrica passam a ter um *feedback* melhor, a respeito do estado dos equipamentos, o que ajudará no processo de manutenção e aperfeiçoamento dos serviços prestados.

Os percentuais de acurácia apresentados, evidenciam como a implantação dessa ferramenta no procedimento de leitura é importante. Pois, em uma rota de leitura, em média um leiturista faz o processo completo, da leitura à impressão da fatura, em um minuto e meio. Uma vez que, o tempo do SILEM, da captura até o fim do processamento, dura em média 25 segundos.

Trazendo esse resultado para o contexto atual, onde cerca de 300 medidores são analisados em uma rota. E por volta de 1500 dígitos são inseridos manualmente, com o uso da ferramenta esse número é reduzido significativamente. Pois, a partir dos resultados obtidos, sabe-se que a taxa de acerto total por display é 67% e 87% admitindo correção de apenas um dígito. Assim, levando-se em consideração o acerto por dígito, 87% do trabalho manual fica a cargo do SILEM.

Portanto, a fim de reduzir erros, a implantação do SILEM com o protocolo. A aplicação é capaz de trazer melhorias significativas para o procedimento de leitura do consumo. Pois, este método é capaz contribuir com a diminuição de erros associados a leitura manual, evitando problemas tanto para os clientes quanto para as empresas prestadoras do serviço de distribuição de energia elétrica. Em suma, este é um método útil e sem custos adicionais com novos equipamentos. Sendo este, um modulo de um sistema maior.

5.1 Trabalhos Futuros

Os resultados promissores obtidos na classificação dos dígitos em medidores eletromecânicos servem de base para o desenvolvimento de uma nova abordagem. Trazendo como ideia principal a implantação de um dispositivo acoplado no medidor, que possua uma câmera capaz de capturar uma imagem com menos chance de erros no posicionamento e enviar essa imagem obtida para o SILEM.

Esse dispositivo ficaria apto a adquirir imagens bem ajustadas ao protocolo de aquisição. E seria capaz de se comunicar com o SILEM, por meio de algum tipo de transmissão de dados, tais como, *Bluetooth*, NFC e Infravermelho. Em seguida, enviar a imagem capturada para a aplicação. Dessa maneira, o procedimento de leitura automática pode ser realizado com mais exatidão, descartando a ideia de obter a foto pelo dispositivo móvel.

Assim, o SILEM seria capaz de receber imagens mais controladas, o que pode contribuir para melhorias nos resultados da metodologia de reconhecimento dos dígitos e também melhorar a questão da segurança, de modo que os leituristas não precisariam ter nenhum tipo de contato físico com os medidores, evitando os riscos de acidentes causados por descarga elétrica.

Referências

- AL-ALI, A.; EL-HAG, A.; BAHADIRI, M.; HARBAJI, M.; HAJ, Y. A. E. Smart home renewable energy management system. *Energy Procedia*, Elsevier, v. 12, p. 120–126, 2011. Citado na página 16.
- BALLESTEROS, G.; SALGADO, L. Optimized hog for on-road video based vehicle verification. In: IEEE. *Signal Processing Conference (EUSIPCO), 2014 Proceedings of the 22nd European*. Lisbon, Portugal, 2014. p. 805–809. Citado na página 34.
- DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: IEEE. *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*. San Diego, California, 2005. v. 1, p. 886–893. Citado 2 vezes nas páginas 24 e 25.
- ELREFAEI, L. A.; BAJABER, A.; NATHEIR, S.; ABUSANAB, N.; BAZI, M. Automatic electricity meter reading based on image processing. In: IEEE. *Applied Electrical Engineering and Computing Technologies (AEECT), 2015 IEEE Jordan Conference on*. Jordan, 2015. p. 1–5. Citado na página 15.
- GONZALEZ, R.; WOODS, R. *Processamento Digital de Imagens*. 3. ed. São Paulo: Pearson Prentice Hall, 2010. Citado 4 vezes nas páginas 19, 21, 22 e 27.
- JUNIOR, G. B. *Classificação de Regiões de Mamografias em Massa e Não Massa usando Estatística Espacial e Máquina de Vetores de Suporte*. Dissertação (Mestrado) — Universidade Federal do Maranhão, 2008. Citado na página 35.
- KANG, D.-J. Dynamic programming-based method for extraction of license plate numbers of speeding vehicles on the highway. *International Journal of Automotive Technology*, Springer, v. 10, n. 2, p. 205–210, 2009. Citado 2 vezes nas páginas 16 e 33.
- PARBERRY, I. *Problems on algorithms*. [S.l.]: Prentice Hall, 1995. v. 50. Citado na página 32.
- PARTHIBAN, K.; PALANISAMY, A. Reading values in electrical meter using image processing techniques. In: IEEE. *Intelligent Interactive Systems and Assistive Technologies (IISAT), 2013 International Conference on*. India, 2013. p. 1–7. Citado na página 15.
- PEDRINI, H.; SCHWARTZ, W. R. *Análise de imagens digitais: princípios, algoritmos e aplicações*. Campinas, São Paulo: Thomson Learning, 2008. Citado na página 21.
- PIZER, S. M. Adaptive histogram equalization and its variations. *Computer Vision, Graphics and Image Processing*, p. 355–368, 1987. Citado na página 22.
- POPA, M. Gateway design and implementation in an automatic meter reading system based on power line communications. In: IEEE. *Networked Computing and Advanced Information Management (NCM), 2011 7th International Conference on*. Gyeongju, Korea (South), 2011. p. 295–298. Citado na página 16.

- PRAPASAWAD, C.; PORNPRASITPOL, K.; PORA, W. Development of an automatic meter reading system based on zigbee pro smart energy profile ieeec 802.15. 4 standard. In: IEEE. *Electron Devices and Solid State Circuit (EDSSC), 2012 IEEE International Conference on*. Hong Kong, Thailand, 2012. p. 1–3. Citado na página 16.
- QUINTANILHA, D. B. P.; SILVA, G. L. F. da; EDUARDO, C.; FALCAO, M.; SILVA, A. C.; PAIVA, A. C. de; DALLYSON, J.; ALMEIDA, S. de; JUNIOR, G. B.; AZEVEDO, L. M. et al. Detecção automática de medidores elétricos em imagens utilizando uma combinação de svm e cnn. 2017. Citado na página 16.
- REIS, A. B. S.; SOUSA, J. A. de; NETO, O. P. da S.; FROZ, B. R.; SILVA, Í. F. S. da; MARANHÃO-CEMAR, C. E. do; SA-CELPA, C. E. do P. Segmentação automática de medidores eletromecânico e eletrônico baseado em imagens. 2017. Citado na página 16.
- ROCHA, S. V. da. *Diferenciação do Padrão de Malignidade e Benignidade de Massas em Imagens de Mamografias Usando Padrões Locais Binários, Geoestatística e Índices de Diversidade*. Tese (Doutorado) — Universidade Federal do Maranhão, 2014. Citado na página 20.
- TOMASI, C. *Histograms of Oriented Gradients*. Duke University: Diakses, 2015. Citado na página 26.
- VAPNIK, V. *Statistical Learning Theory*. New York: Wiley New York, 1998. Citado 2 vezes nas páginas 28 e 29.
- ZHANG, Y.; YANG, S.; SU, X.; SHI, E.; ZHANG, H. Automatic reading of domestic electric meter: an intelligent device based on image processing and zigbee/ethernet communication. *Journal of Real-Time Image Processing*, Springer, v. 12, n. 1, p. 133–143, 2016. Citado na página 15.