

UM MÓDULO DE SOFTWARE PARA O RECONHECIMENTO DE SINAIS ESTÁTICOS  
DA LÍNGUA BRASILEIRA DE SINAIS

Adriel Vieira Santos<sup>1</sup>, Iago Franco Bacurau<sup>1</sup>, Jayne de Moraes Silva<sup>1</sup>, Talles Brito Viana<sup>1</sup>

<sup>1</sup> Instituto Federal de Educação, Ciência e Tecnologia do Ceará – campus Crato

{adriel.klt, iago.bacurau, devjaynemoraes}@gmail.com, tallesbrito@ifce.edu.br

**RESUMO:** A comunicação é algo crucial para que um indivíduo possa estar incluso na sociedade, entretanto, é visível o problema de comunicação entre um surdo e um ouvinte. Portanto, este trabalho propõe um módulo de software para o reconhecimento de sinais estáticos da LIBRAS (Língua Brasileira de Sinais). Para isso, utiliza-se do algoritmo SURF para detecção de características invariantes, rotação e escala. A classificação dos gestos é feita com a aplicação do conjunto de características em uma rede neural Perceptron de Multicamadas. Os resultados são razoavelmente consideráveis e evidenciam a viabilidade da utilização das técnicas citadas para contribuir com a resolução do problema em questão.

**Palavras-chave:** LIBRAS. Reconhecimento de Sinais. SURF.

**ABSTRACT:** Communication is something crucial for an individual included in society, but still there are problems on deaf to listener communication. Therefore, is this work is proposed a software module for recognizing static signals of LIBRAS (Brazilian Sign Language). In order to achieve this, it is used the SURF algorithm to detect invariant rotation and scale characteristics. Besides, gesture classification is done applying a set of recognized features into a multi-layer Perceptron neural network. The obtained results are reasonably considerable, showing that applying the mentioned techniques is feasible to contribute to solve the discussed problem.

**Keywords:** LIBRAS. Signals Recognition. SURF.

## 1. INTRODUÇÃO E JUSTIFICATIVA

Estima-se que existem mais de 300 (trezentos) milhões de deficientes auditivos no mundo, e deste total, de acordo com o Censo de 2010 produzido pelo IBGE, cerca de 9,7 milhões se encontram no Brasil. Embora a Língua Brasileira de Sinais (LIBRAS) tenha sido reconhecida como a segunda língua oficial do país por meio da sanção da lei de nº 10.436 em 2008, ainda é pouco utilizada pela população. A mesma Lei ainda descreve em seu decreto Nº 5.626, de dezembro de 2005 no artigo 26º sobre a garantia de um tratamento diferenciado, por meio de uso e difusão, tradução e interpretação da LIBRAS, realizada por indivíduos capacitados e o acesso às tecnologias de informação.

Atualmente, no Brasil há leis que possuem o objetivo de garantir os direitos da pessoa com deficiência, estabelecendo normas e critérios para promover a acessibilidade. No que diz respeito às leis que tratam da deficiência auditiva, a Lei nº 4.304 de 07 de Abril de 2004 é de grande importância no que diz respeito à veiculação da informação, pois dispõe sobre a utilização de recursos visuais destinados a pessoas com deficiência auditiva, na veiculação de informações, apresenta que:

Art. 1º - As comunicações oficiais de campanhas, programas, informes, publicidades e atos da administração direta e indireta do Estado, difundidas pela televisão, deverão conter subtítulo (legendas) e terão tradução simultânea para a Língua Brasileira de Sinais (LIBRAS), a fim de assegurar sua compreensão pelos portadores de deficiência auditiva, em consonância com o disposto no art. 19 da Lei Federal N.º 10.098 /2000 (BRASIL,2004).

Ainda com o auxílio das leis existentes, a comunidade surda ainda sofre com problemas relacionados à inclusão, sobretudo quando se trata da comunicação, uma atividade essencial na vida do ser humano, que no caso desse grupo minoritário se torna bastante crítica e comprometida.

Tendo em vista que a comunidade de utilizadores da LIBRAS é formada em maior parte: a) pelos próprios deficientes auditivos que a tem como língua nativa, os quais normalmente pertencem a famílias em que seus genitores são surdos; b) por indivíduos surdos que aprenderam a LIBRAS ainda durante o período de escolaridade, estes normalmente possuem surdez severa ou profunda; c) por indivíduos que se relacionam com

surdos; d) e por uma parcela mínima de indivíduos com interesses pessoais.

Desta forma, tem-se que a dificuldade na interação entre as comunidades surda e ouvinte é agravada, o principal motivo deste cenário é ressaltado por Neto e Oquendo (2013, p. 1):

As línguas de sinais não são meras transcrições das línguas faladas, sendo compreensível a dificuldade de comunicação existente entre pessoas não surdas e surdas, mesmo que por meio da escrita, uma vez que pessoas surdas podem não ser alfabetizadas em português (NETO, 2013).

No contexto atual e da problemática em questão, existem aplicações que auxiliam e facilitam a tradução da língua portuguesa para a LIBRAS por meio de uma animação 3D de um intérprete individual, tais como o Prodeaf e o HandTalk, porém ainda carece de soluções que possam viabilizar o cenário inverso, isto é, que possa reconhecer através de uma câmera o significado em Português do gesto realizado.

De acordo com Neto e Oquendo (2013), as abordagens utilizadas para o reconhecimento de sinais por computador são: a baseada em dispositivos agregados a uma luva especial para a detecção e rastreamento dos movimentos e a baseada em técnicas de visão computacional, um método não invasivo por não exigir acessórios acoplados ao corpo e gastos adicionais, tendo como foco deste trabalho, a segunda abordagem.

Visando reduzir o problema de acessibilidade detectado, este trabalho tem como principal contribuição social e científica o desenvolvimento de um módulo de software capaz de traduzir sinais estáticos da LIBRAS para a língua portuguesa.

A LIBRAS, assim como qualquer outra língua, possui estrutura gramatical própria e é formada pela combinação de cinco parâmetros fonológicos, sendo estes: configuração de mão, ponto de articulação, orientação da mão, movimento e expressão facial.

Portanto, haja vista a importância entre a relação do sinal e dos parâmetros que constituem a formação do mesmo, este trabalho foca no desenvolvimento de um módulo de software para o reconhecimento do parâmetro da configuração de mão da LIBRAS. O intuito é que futuramente este módulo de software faça parte de um sistema maior que combine o reconhecimento do conjunto total de parâmetros da LIBRAS apresentados por usuários do sistema, e assim reconhecer os mais diversos tipos de sinais contidos na LIBRAS.

Este trabalho está organizado da seguinte forma: Na Seção 2, o referencial teórico relacionado a este trabalho é apresentado e discutido. Na Seção 3, a metodologia

empregada no desenvolvimento deste trabalho é descrita. Após isso, na Seção 4, um experimento desenvolvido neste trabalho é descrito bem como discute-se os respectivos resultados obtidos. Por fim, na Seção 5 são apresentadas considerações finais e trabalhos futuros.

## 2. REFERENCIAL TEÓRICO

Nesta seção, inicialmente é discutido como que autores definem o que é o parâmetro de configuração de mão da LIBRAS. Além disso, na sequência, também é discutido como que o problema de reconhecimento de gestos por computador tem sido tratado por outros autores e, especificamente, quais os problemas existentes no reconhecimento da configuração de mão por dispositivos computacionais.

### 2.1. O Parâmetro de Configuração de Mão

O parâmetro de *Configuração de Mão* é definido como a forma que a mão assume durante a realização do sinal da LIBRAS. Existem diferentes abordagens que apontam a quantidade de configurações de mão na LIBRAS, dentre estas existem a abordagem segundo BRITO (1998, p. 33) que apresenta 46 configurações de mão e a segundo FERREIRA (2011, p. 35) com 60 destas. Tais configurações de mão são mostradas na Figura 1(a) e Figura 1(b), respectivamente.

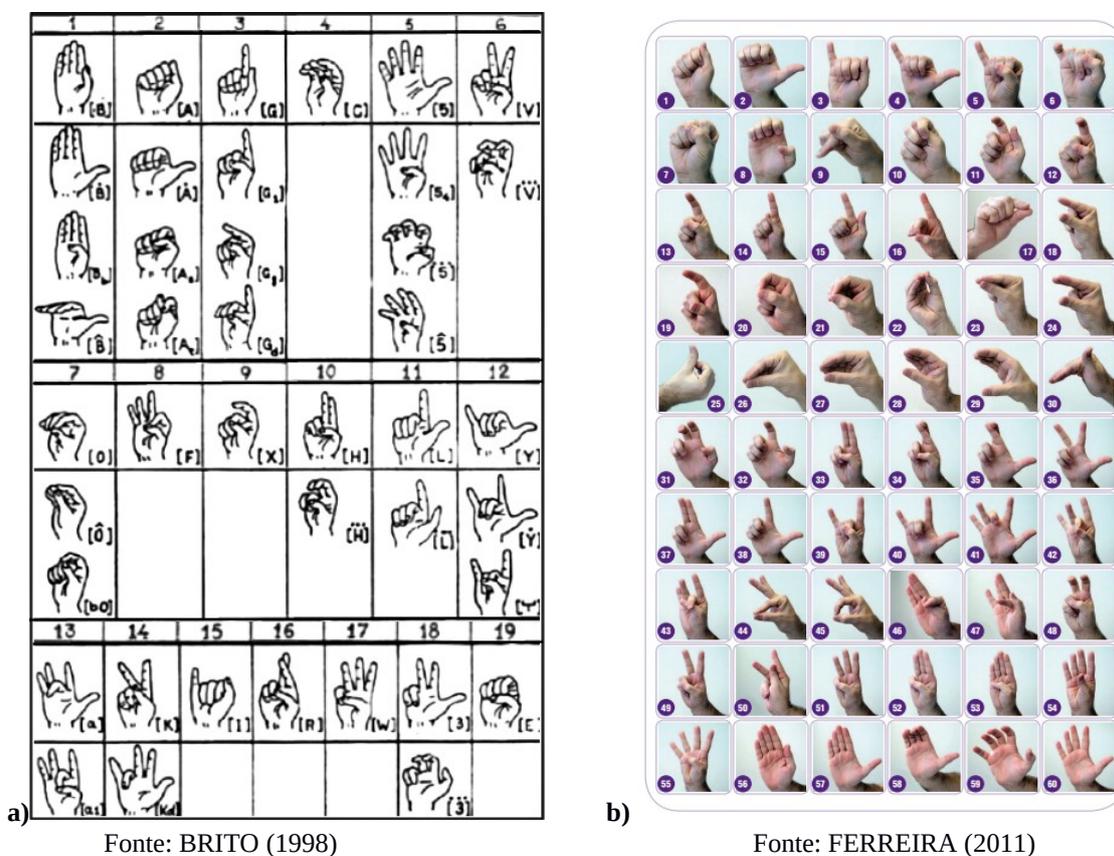
Grande parte destas configurações de mão correspondem aos numerais e às letras do alfabeto português, o qual é conhecido como alfabeto manual ou datilologia e é usado normalmente para formar nomes de pessoas, lugares e palavras que não possuem sinal associado na LIBRAS e precisam ser formadas através de datilologia.

### 2.2. Reconhecimento de Gestos por Computador

Em relação ao reconhecimento de imagens por computador, segundo SAVARIS (2010) pg. 36 apud (MITRA et al., 2007):

As técnicas de visão computacional buscam aumentar a naturalidade da utilização de gestos como componentes de uma interface de comunicação humano-computador. O objetivo principal é permitir que o elemento humano interaja livremente com o elemento computacional, sem a necessidade de que o primeiro vista dispositivos instrumentados e fique restrito ao espaço delimitado pelas conexões desses dispositivos ao computador (MITRA et al., 2007).

Figura 1: a) 46 Configurações de Mão da LIBRAS de acordo com BRITO(1998) e b) 60 Configurações de Mão da LIBRAS de acordo com FERREIRA (2011)



Ainda segundo Neto e Oquendo (2013), a complexidade do problema de reconhecimento da Língua de Sinais pelos computadores advém das seguintes características das LS:

- i). Os gestos nas línguas de sinais não se limitam apenas a movimentos das mãos e braços, os chamados gestos manuais, mas também de sinais realizados por expressões faciais, movimentos da cabeça, do dorso e por posturas do corpo. Desta maneira, para o reconhecimento dos gestos nas línguas de sinais é necessária uma observação simultânea dessas partes do corpo.
- ii). A quantidade de sinais é muito grande, da ordem de milhares, alguns difíceis de diferenciar de outros.
- iii). Um mesmo gesto nas línguas de sinais é feito diferentemente por pessoas diferentes e até pela mesma pessoa quando repetido.
- iv). Uma frase nas línguas de sinais é uma sequência contínua de gestos, sendo difícil a detecção de onde termina um gesto e começa o seguinte (NETO, 2013).

O autor ainda destaca que para o reconhecimento de sinais por computador “se busca soluções que ofereçam precisão (para minimizar erros), velocidade de

processamento (para suportar aplicações em tempo real) e facilidade de escalabilidade (para suportar os milhares de sinais)”.

Alguns desenvolvedores apostaram no uso do *Microsoft Kinect*<sup>31</sup> como uma ferramenta para o auxílio no processo de reconhecimento da LIBRAS. Isso se dá devido ao fato do dispositivo apresentar a possibilidade de mapeamento de diversos membros do corpo e deste sensor reconhecer a profundidade de objetos. Tang (2011) propôs um método que, através de informações RGB e da profundidade retornadas pelo *Microsoft Kinect*<sup>31</sup>, permite reconhecer gestos como segurar e soltar numa taxa alta de acerto.

Porém, o maior problema apresentado pelo *Microsoft Kinect*<sup>31</sup>, especificamente para o reconhecimento da configuração de mão da LIBRAS, se dá ao fato de não prover um mapeamento da mão de forma completa. O sensor não possui pontos de rastreamento nos dedos nativamente, tornando difícil o reconhecimento de padrões que é essencial para detectar uma configuração de mão na LIBRAS, e a câmera RGB do dispositivo possui uma baixa qualidade, inviabilizando

mais ainda o uso do sensor para reconhecer o parâmetro de configuração de mão da LIBRAS.

### 3. METODOLOGIA

Dados os problemas do *Microsoft Kinect*<sup>31</sup>, discutidos na Seção 2.2, neste trabalho opta-se por utilizar uma câmera RGB comum para capturar fotografias de diferentes tipos de configurações de mão. Após a captura, as fotografias são processadas com algoritmos de visão computacional. Na sequência, as fotografias têm características extraídas com um algoritmo de extração de características. Tais características são informadas no treinamento de uma Rede Neural Artificial. Após o treinamento da Rede Neural, esta pode ser utilizada para classificar e reconhecer configurações de mão do usuário. Nas próximas subseções, cada um destes passos é discutido e detalhado.

#### 3.1. OpenCV

Para realizar a classificação de imagens é necessária a utilização de técnicas sofisticadas para segmentar, detectar e extrair características da imagem. Além disso, é necessário utilizar-se de um classificador o qual pode ser visto como um objeto que, dado um vetor de características, realiza uma série de processos que tentam relacionar o conjunto de entrada com um rótulo.

Para realizar essas etapas, neste trabalho é empregada a biblioteca de visão computacional OpenCV, a qual possui vários algoritmos para realizar processamento de imagem e vídeo em tempo real. Além disso, possui algoritmos de visão computacional, tais como filtros de imagem e reconhecimento de objetos.

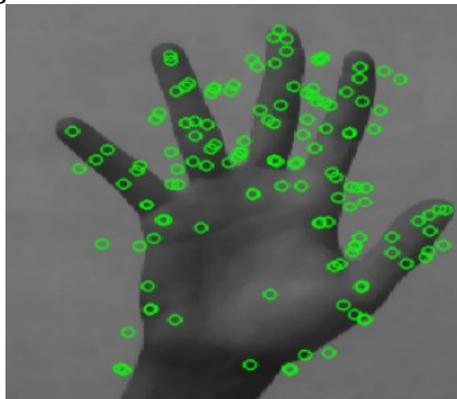
Através da técnica simples de limiar é possível realizar a segmentação da imagem, isto é, um procedimento de análise de pixels isoladamente tendo como objetivo o destaque da mão. Essa separação é baseada na variação de intensidade entre os pixels do objeto (mão do usuário) e os pixels de fundo.

#### 3.2. SURF

Após a segmentação das imagens, o SURF (BAY et al., 2008) é o algoritmo empregado para extração de características das imagens. Este tipo de algoritmo é implementado basicamente em três partes: a detecção dos pontos de interesse, que são pontos que de alguma forma servem para caracterizar alguma imagem; a descrição da vizinhança local, que é um conjunto de características do entorno de cada ponto de interesse baseando-se na intensidade; e correspondência, que é algum método para realizar a comparação e correspondência entre os pontos de interesse das imagens.

A principal propriedade deste algoritmo é a invariância à escala e rotação na detecção e extração de descritores em imagens integrais (BAY et al., 2008). Estes descritores são também conhecidos como os pontos de interesse, os quais podem ser observados na Figura 2. O SURF é um algoritmo baseado no *Scale-Invariant Feature Transform* (SIFT) (LOWE, 2004), que possui função semelhante. Entretanto, o SURF realiza o processo de forma mais eficiente e é capaz de detectar pontos tão importantes quanto o SIFT. As técnicas utilizadas para detecção dos pontos de interesses são baseadas na Matriz Hessiana, e a descrição desses pontos nas respostas da Haar *wavelet* de primeira ordem.

Figura 2: Pontos de Interesses da Mão Direita.



Fonte: Elaborado pelo autor (2017).

#### 3.3. WEKA e Redes Neurais

A ferramenta *Waikato Environment for Knowledge Analysis* (WEKA) (WITTEN et al, 2016) é utilizada para análise dos dados gerados pelo SURF. Segundo Witten et al (2016), o Weka é uma coleção de algoritmos de aprendizado de máquina para tarefas de mineração de dados. Os algoritmos podem ser aplicados diretamente a um conjunto de dados ou chamados a partir de uma implementação em código Java. WEKA contém ferramentas para pré-processamento de dados, classificação, regressão, agrupamento, regras de associação e visualização. Tal ferramenta implementa diversos algoritmos de aprendizagem de máquina, e é escolhido para ser utilizado por conter a implementação do modelo necessário para o presente trabalho e por conta da grande possibilidade de análise de resultados disponíveis, como: *i*) tabela de confusão, que possibilita entender como os elementos foram classificadas em cada uma das classes; *ii*) validação cruzada, que permite compreender se o classificador escolhido possui ou não superdatação.

No modelo utilizado neste trabalho, a classificação das imagens é feita através de uma rede neural artificial conhecida na literatura como *Perceptron* Multicamadas.

O problema de reconhecimento do parâmetro de configuração de mão é um problema não linear, isto é, no processo de classificação dos gestos não é possível traçar uma reta que separe todos os símbolos de maneira correta. Esta conclusão pode ser visualizada ao plotar as características dos símbolos em um plano. Sendo assim, os *Perceptron* Multicamadas podem contribuir para resolução do problema, pois visam resolver problemas não lineares.

Segundo Haykin (2003), uma rede neural pode ser definida como um processador paralelo e distribuído que é composto de unidades de processamento chamadas de neurônios, os quais quando combinados possuem propensão natural para armazenar conhecimento e torná-lo disponível para uso. Este tipo de rede, ainda segundo Haykin (2003), consiste de um conjunto de unidades sensoriais que constituem a camada de entrada, uma ou mais camadas ocultas de nós computacionais e uma camada de saída de nós computacionais. O sinal de entrada então se propaga para frente através da rede, camada por camada.

De acordo com Barca (2005), tem-se que para uma tarefa onde o problema não é linearmente separável, é necessária a utilização de uma rede de múltiplas camadas. O algoritmo mais popular e amplamente usado para este tipo de redes neurais artificiais é o *Backpropagation*. Sendo assim, o algoritmo utilizado para realizar o treinamento é o *Backpropagation*. A aprendizagem utilizando este algoritmo funciona basicamente em duas etapas: propagação para frente e propagação para trás. Na primeira etapa do processo, um vetor de entrada é aplicado na estrutura e então é propagado por toda a rede gerando a saída. Já a segunda etapa consiste em ajustar os valores atribuídos aos pesos da rede fazendo uso da diferença entre a saída e a resposta desejada. Esse sinal então é propagado para trás. O intuito é fazer com que a resposta de saída se aproxime cada vez mais da resposta correta.

Esse algoritmo pode ser classificado como uma técnica de aprendizagem supervisionada. Esse tipo de técnica consiste em: a partir de um conjunto de dados com rótulos encontrar uma função no espaço de soluções que se aproxima da função que descreva o problema modelado.

#### 4. RESULTADOS E DISCUSSÃO

Com o objetivo de avaliar a viabilidade do reconhecimento do parâmetro de configuração de mão da LIBRAS através do módulo de software discutido neste trabalho, foi desenvolvido um experimento. Este consiste em gerar uma amostra com imagens reais, a qual é utilizada para o treinamento, e após isso, é verificada a taxa de acerto.

A amostra utilizada nos testes executados neste trabalho contém duas mil (2000) imagens de tamanho 200x200 pixels em escala de cinza, representando a configuração de mão designada para a identificação dos números de zero a nove na LIBRAS. Para cada configuração de mão foi usada uma base de dados de 200 imagens. Na Figura 3 é mostrado um exemplo de imagem retirada da amostra que representa a configuração de mão correspondente ao número seis (6) na LIBRAS.

**Figura 3: Configuração de Mão correspondente ao número 6.**



Fonte: Elaborado pelo autor (2017).

Buscando um treinamento mais homogêneo da rede neural artificial, as imagens foram obtidas de duas pessoas diferentes e com pequenas rotações no gesto, sendo que das cem (100) imagens de uma determinada configuração de mão de cada pessoa, cinquenta correspondem à mão esquerda e cinquenta correspondem à mão direita. A captura dessas imagens foi feita por uma câmera RGB simples em um ambiente com iluminação controlada e fundo branco.

Após a criação da base de dados com as imagens, foi realizada a aplicação do algoritmo de extração de pontos de interesses SURF em cada imagem, gerando um vetor de características de tamanho máximo, limitado a duzentos pontos de interesses por imagem processada.

Para realização do treinamento da rede neural, foi utilizado o método de *cross-validation*. Como o próprio nome do método sugere, as informações retiradas da própria base de dados são usadas para testar o modelo, pois nesse método separa-se o conjunto de dados em duas partes: uma parte de treinamento, e uma parte para testes. O *cross-validation* usado foi o *k-fold*, que segundo Kohavi (1995) este método consiste em dividir o conjunto de dados aleatoriamente em *k* diferentes subconjuntos de tamanho semelhantes, em que um (1) dos *k* conjuntos é usado para o teste e os demais são usados no treinamento e desta forma, repete-se sucessivamente para todos os

subconjuntos. O nível de precisão total do modelo é medido pela média da taxa de acerto encontrada em cada um dos  $k$  subconjuntos.

Após a extração das características das duas mil imagens presentes na amostra, o método de *k-folds cross-validation* foi aplicado. Neste trabalho, foi escolhido o método padrão de *10-folds* que está presente no WEKA. Esse método dividiu a amostra em 10 subconjuntos iguais de 200 instâncias com as informações sobre os pontos de interesses das imagens. Na primeira iteração do *cross-validation*, o primeiro subconjunto com as informações das 200 imagens é usado para os testes e os nove outros subconjuntos (1800 imagens) são usados para o treinamento da rede. Na segunda iteração, é utilizado o próximo subconjunto de 200 imagens para teste e as restantes (1800 imagens) para treinamento. Assim por diante, na  $i$ -ésima iteração é utilizado o  $i$ -ésimo subconjunto para testes, e as imagens restantes para treinamento. Com isto, para cada iteração é calculada a taxa de acerto, e a taxa de acerto total é dada pela média das taxas de acerto de todas as iterações (até a décima iteração). No final, a média de reconhecimento encontrada no modelo foi de 80,45%, sendo 1609 das 2000 imagens reconhecidas de forma correta. A Tabela 1 mostra a quantidade de imagens reconhecidas de forma correta e incorreta e a porcentagem de acordo com os resultados obtidos pela ferramenta WEKA.

**Tabela 1: Taxa de Reconhecimento total do Modelo.**

Imagens Classificadas	Quantidade	Porcentagem
Corretamente	1609	80,45%
Incorretamente	391	19,55%

Analisando individualmente a taxa de reconhecimento de algumas das configurações de mão, nota-se um valor maior que a média geral de acerto em determinados gestos, e abaixo da média em relação a outros. Por exemplo, a configuração de mão

correspondente ao número zero (0) obteve uma taxa de reconhecimento de 88,5%, já o do número três (3) e do número nove (9) apenas 70,5%. Isso pode ser justificado devido a determinadas configurações de mão serem semelhantes, gerando dados aproximados após o processamento dos pontos de interesse. O gráfico da Figura 4 exibe a taxa de acerto individual para cada configuração de mão correspondente aos números de zero (0) a nove (9) na LIBRAS.

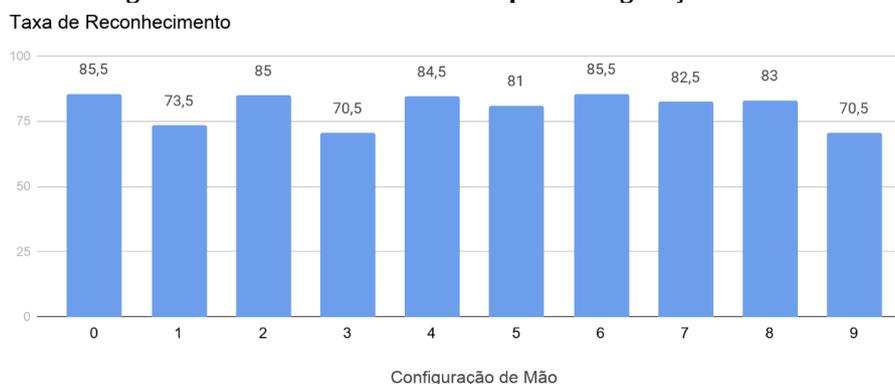
## 5. CONSIDERAÇÕES FINAIS

Em razão do problema de comunicação entre as comunidades surda e ouvinte fazer parte da realidade brasileira, a proposta da utilização de um sistema que permita a tradução de sinais da LIBRAS nos mais variados âmbitos sociais é de fundamental importância para promover a inclusão social e a acessibilidade de pessoas com deficiência auditiva. Como o reconhecimento desses símbolos é um problema complexo (já que este é um problema não linear), esta pesquisa focou em apenas um dos possíveis módulos para a solução do problema, nomeado como reconhecimento de configuração de mão.

Com o resultado dos experimentos foi alcançada uma taxa de reconhecimento média de 80,45%. A fim de tentar melhorar esta taxa de reconhecimento, como trabalhos futuros, se faz necessário a análise e o estudo de outros algoritmos extratores de características, sendo plausível até o desenvolvimento de novos algoritmos específicos para tratar das imagens que se quer reconhecer nesse parâmetro específico, a configuração de mão da LIBRAS.

Além disso, a continuidade deste trabalho tem como objetivo o desenvolvimento direcionado a outros módulos correspondentes ao reconhecimento e tradução dos demais parâmetros da LIBRAS, de forma que através da integração destes, seja possível o reconhecimento da língua de forma completa, através de sentenças simples e respeitando a estrutura gramatical da língua.

**Figura 4: Taxa de Reconhecimento por Configuração de Mão.**



## REFERÊNCIAS BIBLIOGRÁFICAS

- BARCA, Maria Carolina Stockler; SILVEIRA, Tiago Redondo de Siqueira; MAGINI, Marcio. **Treinamento de redes neurais artificiais: o algoritmo Backpropagation**. IX Encontro Latino Americano de Iniciação Científica, V Encontro Latino Americano de Pós-Graduação–Universidade do Vale do Paraíba, Anais. Jacareí, 2005. Disponível em: <[http://www.inicepg.univap.br/cd/INIC\\_2005/inic/IC1%20anais/IC1-17.pdf](http://www.inicepg.univap.br/cd/INIC_2005/inic/IC1%20anais/IC1-17.pdf)>. Acesso em: 20 Ago. 2018
- BAY, H. et al. Speeded-Up Robust Features (SURF). **Computer Vision and Image Understanding (CVIU)**, v. 110, n. 3, pp. 346-359, 2008. Disponível em: <<http://www.vision.ee.ethz.ch/surf/>>. Acesso em 23 set. 2017.
- BRASIL. Regulamenta a Lei no 10.436, de 24 de abril de 2002, que dispõe sobre a Língua Brasileira de Sinais - Libras, e o art. 18 da Lei no 10.098, de 19 de dezembro de 2000. **Diário Oficial - República Federativa do Brasil**, Poder Executivo, Brasília, DF, 21 mar. 2007. Seção 1, p. 1. Brasília, DF. 22 dez. 2005.
- BRASIL. Regulamenta a Lei nº 4.304, de 07 de Abril de 2004. Dispõe sobre a utilização de recursos visuais, destinados as pessoas com deficiência auditiva, na veiculação de propaganda oficial. **Assembléia Legislativa do Estado do Rio de Janeiro**. Rio de Janeiro, RJ. 04 dez. 2004.
- BRITO, L. F. Língua Brasileira de Sinais. In RINALDI, G. Programa de Capacitação de Recursos Humanos do Ensino Fundamental. **Língua Brasileira de Sinais. Educação Especial: Língua Brasileira de Sinais**. V III, Fascículo 7, Série: Atualidades Pedagógicas, n 4. Brasília; MEC, SEESP, 1998, 19 – 22. Disponível em: <<http://www.dominiopublico.gov.br/download/texto/me002297.pdf>>. Acesso em: 14 mai. 2018.
- FERREIRA, Adir L. et al. **Aprendendo Libras: módulo 2**. Natal: EDUFRRN, 2011. 64p. ISBN 978-85-7273-872-9. Disponível em: <[http://sedis.ufrn.br/bibliotecadigital/site/pdf/TICS/Livro\\_MOD2\\_LIBRAS\\_Z\\_WEB.pdf](http://sedis.ufrn.br/bibliotecadigital/site/pdf/TICS/Livro_MOD2_LIBRAS_Z_WEB.pdf)> Acesso em: 14 mai. 2018.
- HAKYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. Bookman, Porto Alegre, RS. 2003. 898 p.
- IBGE. **Instituto Brasileiro de Geografia e Estatística. Censo 2010: Características gerais da população, religião e pessoas com deficiência**. Banco de Dados Agregados. Sistema IBGE de Recuperação Automática - SIDRA. Disponível em: <<https://sidra.ibge.gov.br/tabela/3426>>. Acesso em 24 set. 2017.
- KOHAVI, Ron. **A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection**. 1995. International Joint Conference on Artificial Intelligence (IJCAI). Disponível em: <<http://robotics.stanford.edu/~ronnyk/accEst.pdf>>. Acesso em: 30 de mai. 2018.
- LOWE, David G. **Distinctive image features from scale-invariant keypoints**. International journal of computer vision, v. 60, n. 2, p. 91-110, 2004.
- NETO, J. P. S.; OQUENDO, L. S. **Estudo do estado da arte das técnicas de reconhecimento por computador de gestos das línguas de sinais**. In: VI CONGRESSO TECNOLÓGICO INFOBRASIL TI & TELECOM (INFOBRASIL), 2013. *Anais...* Fortaleza, CE.
- SAVARIS, Alexandre. **Avaliação comparativa de técnicas para reconhecimento de gestos estáticos e dinâmicos com foco em precisão e desempenho**. 2010. 100p. Dissertação (mestrado) - Universidade Federal de Santa Catarina. Disponível em: <<http://repositorio.ufsc.br/xmlui/handle/123456789/93561>>. Acesso em: 10 mai. 2018.
- TANG, Matthew. **Recognizing Hand Gestures with Microsoft's Kinect**. 2011. Department of Electrical Engineering, Stanford University. Disponível em: <<https://pdfs.semanticscholar.org/3208/1e6dd2897418578a7d4f14e4ff25b706490c.pdf>> Acesso em: 30 mai. 2018.
- WITTEN, Ian H. et al. **The WEKA Workbench. Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques"**. Morgan Kaufmann, Fourth Edition, 2016. Disponível em: <[https://www.cs.waikato.ac.nz/ml/weka/Witten\\_et\\_al\\_2016\\_appendix.pdf](https://www.cs.waikato.ac.nz/ml/weka/Witten_et_al_2016_appendix.pdf)>. Acesso em: 30 de mai. 2018.