

DETECÇÃO DO USO DE CAPACETE UTILIZANDO MÁQUINAS DE COMITÊ

Francisco Wender P. dos Reis
franciscowenderreis@gmail.com

Kelson R. T. Aires
krtaires@gmail.com

Francisco Wermeson P. dos Reis
franciscowermeson@gmail.com

Romuere R. V. Silva
romuere@gmail.com

Kalyf A. B. Lima
kalyfabdalla@gmail.com

Universidade Federal do Piauí/Brasil

Abstract: The number of motorcycles in the world has grown rapidly in recent years because it is a more flexible transportation and faster when you are in traffic. This increase in such transportation to the recklessness of drivers involved in a very high number of accidents. The helmet is a mandatory safety item for bikers, but many drivers do not use or use incorrectly. Automatic detection of non-helmet use by a computer system, aims to improve the monitoring of traffic and enable its large-scale deployment. Thus, this study aims to classify images where motorcyclists are or are not using the helmet, this classification is done using committee machines, which aims to use a combination of several experts to reach a comprehensive decision that is supposedly superior to that reached by any of them acting alone.

Keywords: Committee Machine; Classifier; Helmet Detection.

Resumo: O número de motocicletas no mundo vem aumentando muito nos últimos anos, devido ela ser um transporte mais flexível e mais rápido quando se está no trânsito. Este aumento de tal transporte com a imprudência dos condutores implicou em um número muito alto de acidentes. O capacete é um item de segurança obrigatório para os motociclistas, mas muitos dos condutores não utilizam ou utilizam incorretamente. A detecção automática do não uso de capacete, por um sistema computacional, tem como objetivo aperfeiçoar o monitoramento do tráfego e viabilizar sua implantação em larga escala. Dessa forma, este trabalho tem por objetivo classificar imagens onde os motociclistas estão ou não utilizando o capacete, esta classificação é feita usando máquinas de comitê, que tem por objetivo utilizar a combinação de vários especialistas para chegar a uma decisão global que é supostamente superior àquela alcançável por qualquer um deles atuando isoladamente.

Palavras-chave: Máquina de Comitê; Classificador; Detecção de Capacete.

I. INTRODUÇÃO

Motociclistas estão sempre sujeitos a sofrerem acidentes mais graves devido a sua falta de segurança por utilizarem um transporte menor e mais frágil. Segundo o Departamento Nacional de Trânsito (DENATRAN), no Brasil, existem aproximadamente 19,3 milhões de motocicletas [1]. De acordo com o Departamento Nacional de Infraestrutura de Transportes, em 2011 foram registrados no Brasil 34.635 acidentes envolvendo motociclistas [2]. Destes acidentes, muitos são fatais devido a não utilização do capacete.

Nos Estados Unidos, em 2013, o Departamento de Transportes publicou que aproximadamente 93 mil pessoas sofreram acidentes de motocicleta. Deste número, 1,85 mil pessoas não utilizaram o capacete e vieram a óbito [3].

Diante dessa questão, um sistema de detecção automática da não utilização de capacete apresenta-se como uma ferramenta fiscalizadora para forçar o uso correto do principal equipamento de segurança dos motociclistas. O uso de tal sistema possibilitaria um aumento no poder de fiscalização e aplicação da lei do uso do capacete. Tal fato propiciaria uma redução no número de acidentes graves, bem como nos gastos públicos do sistema de saúde com eventos dessa natureza.

Muitos sistemas de monitoramento vêm sendo estudados e desenvolvidos. Em [4] foi desenvolvido um sistema que detecta e classifica, motocicletas e capacetes utilizando algoritmos de classificação. O diferencial do nosso trabalho é a combinação do conhecimento de vários classificadores para obter uma única saída que seja superior à dos classificadores isoladamente. Tal combinação é chamada de máquina de comitê.

Este trabalho propõe a aplicação de máquinas de comitê ao problema da detecção do uso de capacete

por motociclistas. Máquina de comitê é um algoritmo de aprendizado de máquina que emprega a estratégia dividir e conquistar na qual as respostas de múltiplos especialistas são combinadas em uma resposta única. Esta resposta combinada deve ter desempenho superior a qualquer um de seus especialistas, caso contrário não seria necessário a utilização da máquina de comitê.

O esboço do sistema desenvolvido neste trabalho é mostrado na Fig. 1, onde é apresentado o resumo das etapas do sistema para o processo de classificação.

Na Seção seguinte falaremos dos principais trabalhos relacionados que envolvem a utilização das máquinas de comitê e detecção do capacete. Na Seção III o descritor é apresentado. Os classificadores utilizados são abordados na Seção IV. A máquina de comitê proposta é abordada na Seção V. Os métodos de avaliação dos resultados estão na Seção VI. Na Seção VII é feito um levantamento dos resultados e discussões. Por último, as conclusões e trabalhos futuros são mostrados na Seção VIII.

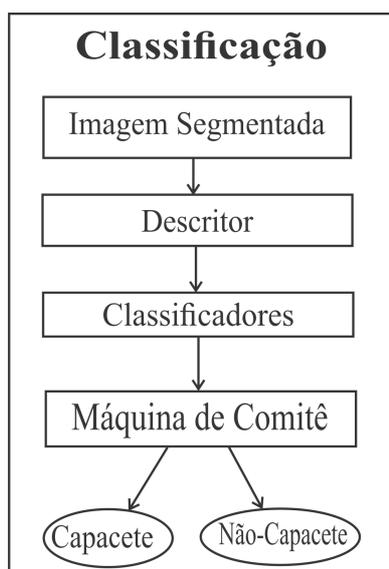


Figura 1. Etapas do Sistema.

II. TRABALHOS RELACIONADOS

O trabalho de Rodrigues [4] tem por objetivo estudar e implementar métodos para a detecção automática de motociclistas em vias públicas com o intuito de identificar o não uso do capacete. Para isso, eles utilizaram imagens de trânsito capturadas por uma câmera de vídeo. A partir das imagens, diferentes atributos foram utilizados através dos descritores *Histogram of Oriented Gradients* (HOG), *Local Binary Pattern* (LBP) e a *Wavelet Transform* (WT). Na classificação das imagens, os autores utilizaram a máquina de vetor de suporte (SVM), *MultiLayer Perceptron* (MLP), *Radial Basis Function Network* (RBFN), *Naive Bayes*, *Random Forest* e *K-Nearest Neighbors* (K-NN). Os autores obtiveram um bom resultado na detecção de capacetes chegando a 91,4% na taxa acerto.

Chiverton [5] descreveu e testou um sistema para a classificação automática e rastreamento de motociclistas com e sem capacetes. O sistema utiliza o classificador Máquina de Vetor de Suporte, treinadas com histogramas derivados dos dados de imagem da região da cabeça dos motociclistas, que utilizam fotografias estáticas e quadros de imagem individuais a partir dos dados de vídeo. O método obteve uma alta taxa de acerto nos seus resultados, mas o número de imagens na fase de teste foi pouco.

Em [6] é proposto um sistema que detecta automaticamente os motociclistas que não utilizam o capacete. O sistema extrai objetos em movimento e classifica-os como “motocicleta” ou “não-motocicleta” com base nas características extraídas das propriedades da região utilizando o classificador K-NN. Depois de classificadas, as motocicletas, é segmentada a região da cabeça dos motociclistas, manualmente. O sistema classifica “capacete e não-capacete” utilizando o K-NN com base em características derivadas de quatro seções da região segmentada da cabeça. Os autores mostraram em seus resultados que para a detecção do capacete, a taxa de acerto foi de 89%. Vale ressaltar que as imagens da região da cabeça foram cortadas manualmente.

Tang et al. [7] propuseram um sistema de reconhecimento facial dinâmico utilizando máquinas de comitê, comparando-as com as estruturas que não envolvem o sinal de entrada (estruturas estáticas), e as que utilizam o sinal de entrada (estruturas dinâmicas), com objetivo de melhorar no desempenho global. Eles mostraram nos resultados que a utilização das máquinas de comitê tornou o sistema mais eficaz.

Shi et al. [8] propuseram um sistema de identificação de gás com base na máquina de comitê. Eles usaram a combinação de cinco classificadores diferentes: *K* vizinhos mais próximos (K-NNs), Perceptron de Múltiplas Camadas (MLP), Função de Base Radial (RBF), Modelo de Mistura Gaussianas (GMM) e análise probabilística dos principais componentes (PPCA). Os autores comprovaram com experimentos que a eficácia do sistema obteve uma maior precisão em comparação com os classificadores individualmente.

É proposto no trabalho de Su e Basu [9] um estudo do desempenho das funções de rede de passagem na máquina de comitê. Os autores testaram a capacidade do sistema com o problema da imagem *deblurring*. Eles utilizaram uma máquina de comitê dinâmica para combinar com as saídas de vários especialistas, onde obtiveram uma melhoria significativa sobre as imagens que são produzidas a partir da saída da máquina de comitê com a rede de passagem.

Diante do exposto, e considerando que até o momento existem poucos trabalhos envolvendo classificação de imagens utilizando máquinas de comitê, julga-se importante a realização deste estudo na perspectiva de ampliar o conhecimento em relação ao tema.

III. DESCRITOR

Objetos em imagens possuem forma, cor e textura. Estas propriedades podem ser mensuradas e a medida denominada característica da imagem. Estas características são normalmente agrupadas em um vetor de escalares, denominado descritor de imagem [10].

O descritor utilizado foi o *Haar Wavelet*, pois na utilização dos classificadores os melhores resultados foram obtidos a partir deste. Outros descritores foram testados incluindo os descritores HOG e LBP, mas eles não obtiveram as mesmas taxas de sucesso e a performance computacional também não foi a melhor.

A. Transformada de Wavelet

As Transformadas de Wavelet (TW) surgiram como uma abordagem alternativa em relação à transformada de Fourier para o processamento de imagens. A TW permite que tantas informações sobre a frequência quanto informações sobre o tempo estejam presentes. As TWs foram formalmente definidas nos trabalhos publicados por Daubechies [11] e Mallat [12]. A TW é o resultado da convolução da Equação 1 com uma imagem ou função.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (1)$$

Onde $a \neq 0$ é o fator de escala e representa uma contração ou dilatação no sinal, dependendo do seu valor; $b \in \mathbb{R}$ é a translação.

De acordo com o trabalho de Silva [13], observou-se que não foram encontrados trabalhos onde todos os pixels de uma imagem fossem passados como parâmetro para algum classificador. Por esse motivo, foi utilizada TW para realizar uma compressão na imagem com o objetivo de reduzir a quantidade de atributos obtidos na imagem.

A eficiência do Haar Wavelet ocorreu por conta da transformada fazer uma filtragem e uma compressão da informação contida na imagem. O resultado do filtro é uma informação mais limpa e com menos ruído, o que torna o aprendizado do classificador mais fácil e conseqüentemente a classificação correta dos objetos. Por isso, essa abordagem foi usada neste trabalho.

IV. CLASSIFICADORES

O principal objetivo de qualquer classificador é mapear uma entrada de um objeto para identificar a qual classe ele pertence. O sistema proposto pressupõe a existência de duas classes: “capacete” e “não-capacete”. Aqui serão apresentados os resultados para os classificadores *Random Forest* [14], *J48* [15], *Sequential Minimal Optimization (SMO)* [16], *K-Nearest Neighbors (K-NN)* [17], *SVM* [18] e *MLP*.

Todos estes classificadores utilizados estão disponíveis na ferramenta *Weka* [19]. Nela todos os parâmetros de cada classificador citado nos resultados são mais detalhados.

A. SVM

Os estudos sobre SVM foram introduzidos por Cortes e Vapnik [20]. De um modo geral, a SVM faz um mapeamento do espaço de entrada para um espaço de dimensionalidade maior. Em seguida, é calculado um hiperplano de separação ótimo. O hiperplano de separação ótimo é escolhido de modo a maximizar a distância de separação entre as classes [21]. Diz-se que duas classes são linearmente separáveis se existe um hiperplano que separe as mesmas. A Fig. 2 mostra duas classes linearmente separáveis e seu hiperplano de separação ótimo.

A SVM é uma técnica de aprendizagem supervisionada, que possui as fases de treinamento e teste. Na fase de treinamento, atributos e saídas desejadas são dadas a fim de projetar os vetores de suporte. Os vetores de suporte são utilizados para obter um classificador. Na fase de teste, o classificador é utilizado para encontrar uma saída a partir de um vetor de entrada.

Ao utilizar SVM para reconhecimento de padrões, se faz necessário tornar uma função não-linearmente separável em uma função linearmente separável. Para isso, é necessário que seja aumentada a dimensionalidade do problema [22]. As funções que aumentam a dimensionalidade do espaço de entrada são chamadas *Funções de Kernel*.

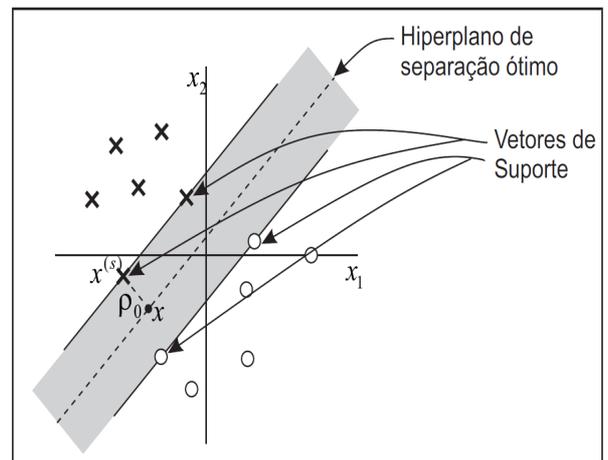


Figura 2. Hiperplano de separação ótimo para classes linearmente separáveis. Imagem adaptada de [21].

As funções de *Kernel* são aplicadas nos vetores de entrada. Ao aplicar uma Função de *Kernel* em um vetor de entrada de dimensão N , é obtido um novo vetor de dimensão X , onde X é maior que N . Após esse cálculo são obtidos os vetores de suporte. Com os vetores calculados é possível definir o hiperplano de separação ótimo. O hiperplano estará a uma igual distância (ρ_0) dos vetores de suporte de cada classe, como mostrado na Fig. 2. Um novo objeto é

classificado utilizando o hiperplano ótimo, cada lado do hiperplano representa uma classe diferente.

B. SMO

Sequencial Minimal Optimization (SMO) é um algoritmo que resolve o problema da Programação Quadrática (PQ) que surge durante o treinamento de máquinas de vetores de suporte (SVM).

SMO é um novo algoritmo de aprendizagem para SVMs que é conceitualmente simples, fácil de implementar. É geralmente mais rápido, e tem melhores propriedades de escala para os problemas de SVM difíceis, do que o algoritmo de treinamento SVM padrão. Em vez de algoritmos de aprendizagem para SVM anteriores que usam programação quadrática numérica (PQ) como um loop interno, SMO usa um passo da PQ analítica.

Ao contrário dos métodos anteriores, SMO opta por resolver o problema de otimização menor possível a cada passo. Para o problema SVM PQ padrão, o menor problema de otimização possível envolve dois multiplicadores de *Lagrange*, porque os multiplicadores de *Lagrange* devem obedecer a uma restrição de igualdade linear. A cada passo, SMO escolhe dois multiplicadores de *Lagrange* para otimizar em conjunto, encontra os valores ideais para esses multiplicadores, e atualiza o SVM para refletir os novos valores ideais [23].

A vantagem do uso do SMO reside no fato de que as soluções de dois multiplicadores de Lagrange podem ser feitos analiticamente. Assim, a otimização numérica PQ é totalmente evitada [23].

C. Random Forest

O algoritmo *Random Forest* [24] é uma combinação de predições de diversas árvores em que cada árvore depende dos valores de um vetor independente, amostrados aleatoriamente e com a mesma distribuição para todas as árvores da floresta. Aqui, floresta é o que se denomina para uma série de árvores de decisão. Após a geração de um grande número de árvores, as classes com maior número de votos são eleitas.

Em um *Random Forest*, cada nó é dividido usando o melhor dentre um subconjunto de indicadores escolhidos aleatoriamente naquele nó. Esta estratégia um tanto contraditória acaba por funcionar muito bem em comparação com muitos outros classificadores, além de ser robusto a superajuste nos parâmetros [24]. Além disso, é de fácil utilização, no sentido que ele tem apenas dois parâmetros (o número de variáveis no subconjunto aleatório em cada nó e o número de árvores da floresta) e, normalmente, não é muito sensível aos seus valores.

A partir de um vetor de atributos, são gerados outros vetores de atributos, que são embaralhados em relação ao vetor original. É gerado um vetor para cada árvore do *Random Forest*. Em seguida, os vetores de atributos são passados como parâmetro para as

árvores de decisão. Cada árvore irá gerar um resultado para a classificação e, os resultados são combinados obtendo uma saída unificada. A Fig. 3 mostra os passos do classificador *Random Forest*.

D. K-NN

K-Vizinhos Mais Próximos (*K-NN*) é um classificador clássico baseado em memória, que frequentemente é utilizado em aplicações do mundo real devido a sua simplicidade. Apesar de simples, obteve considerável exatidão para classificação em diversas aplicações e é comumente utilizado na comparação com outros classificadores [25].

A fase de treinamento do K-NN consiste simplesmente em armazenar todos os padrões de treinamento. O K-NN tem um parâmetro k que é o número de vizinhos a ser considerado para a classificação. Para $k = 1$, K-NN é também chamado de método do vizinho mais próximo (Nearest Neighbor - NN). O K-NN classifica um dado padrão como pertencente a mesma classe do padrão mais próximo a ele no conjunto de treinamento. Há um número de medidas de distâncias usadas neste processo, entretanto a distância euclidiana é a mais utilizada [25].

Quando $k > 1$, primeiramente são calculadas as distâncias do novo padrão a ser classificado com todos os padrões do conjunto de treinamento. Subsequentemente, o algoritmo considera os k padrões do conjunto de treinamento com as menores distâncias ao padrão a ser classificado. Finalmente, o novo padrão é classificado como pertencente a classe da maioria dos k padrões mais próximos do conjunto de treinamento.

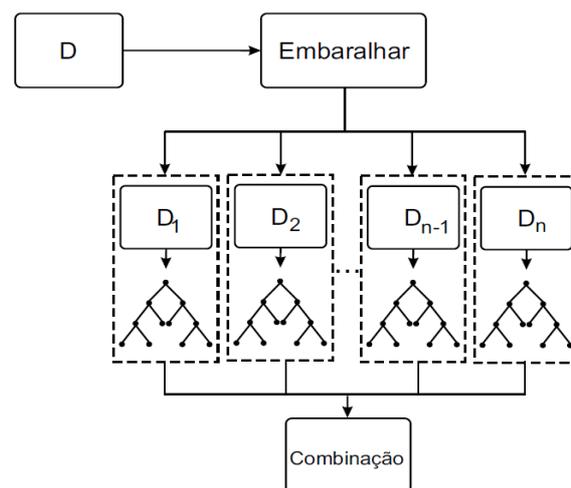


Figura 3. Passos do classificador *Random Forest*.

E. J48

Uma árvore de decisão é um modelo de aprendizado de máquina preditivo que decide o valor de destino (variável dependente) de uma nova amostra com base em vários valores de atributos dos dados disponíveis. Os nós internos de uma árvore de decisão denotam os diferentes atributos, os ramos

entre os nós nos dizem os possíveis valores que esses atributos podem ter nas amostras observadas, enquanto os nós terminais nos dizem o valor final (classificação) da variável dependente.

O atributo que é para ser previsto é conhecido como a variável dependente, uma vez que o seu valor depende de, ou é decidido, pelos valores de todos os outros atributos. Os outros atributos, que ajudam na previsão do valor da variável dependente, são conhecidos como variáveis independentes no conjunto de dados.

O classificador de árvore de decisão J48 segue um algoritmo simples. Para classificar um novo dado, ele primeiro precisa criar uma árvore de decisão com base nos valores de atributos de dados de treinamento disponíveis. Assim, sempre que encontra um conjunto de dados (conjunto de treinamento) ele identifica o atributo que discrimina as várias instâncias mais claramente. Esta característica que é capaz de nos dizer mais sobre as instâncias de dados para que possamos assim classificá-las melhor é dita a que tem o maior ganho de informação. Agora, entre os valores possíveis dessas características, se houver qualquer valor para o qual não exista qualquer ambiguidade, isto é, para as quais as instâncias de dados que abrangem sua categoria tenha o mesmo valor para a variável-alvo, então esse ramo é finalizado e é atribuído para ele o valor alvo que foi obtido [26].

F. Multi-Layer Perceptron

RNAs são modelos computacionais inspirados no sistema nervoso dos seres vivos. Possuem a capacidade de aquisição e manutenção do conhecimento e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões, chamadas de pesos sinápticos [27]. Dentre os vários tipos de redes neurais artificiais, foi utilizado neste trabalho o Perceptron de Múltiplas Camadas (*Multi Layer Perceptron* - MLP). A Fig. 4 mostra a arquitetura básica de um MLP.

A MLP foi concebida para resolver problemas mais complexos, que não poderiam ser resolvidos pelo modelo de neurônio básico. Para isto, são necessárias mais conexões, que só existem em uma rede de perceptrons dispostos em camadas. Na camada oculta (ou camada intermediária), os neurônios são denominados ocultos porque eles não têm acesso direto à saída da rede, onde os erros de aproximação são calculados [13].

O método mais popular para aprendizado em MLP é chamado de retropropagação (*backpropagation*). A aprendizagem por retro-propagação do erro consiste em dois passos através das diferentes camadas da rede.

O primeiro passo é chamado de propagação. Nesse passo um padrão de atividades é aplicado aos nós sensoriais e é produzida a resposta real da rede.

O segundo passo é a retro-propagação. Nesse passo os pesos sinápticos são ajustados de acordo com um sinal de erro. Este sinal é então propagado na direção contrária das conexões sinápticas. O objetivo é minimizar o erro médio global, ou seja, fazer com que a resposta real da rede se aproxime da resposta desejada.

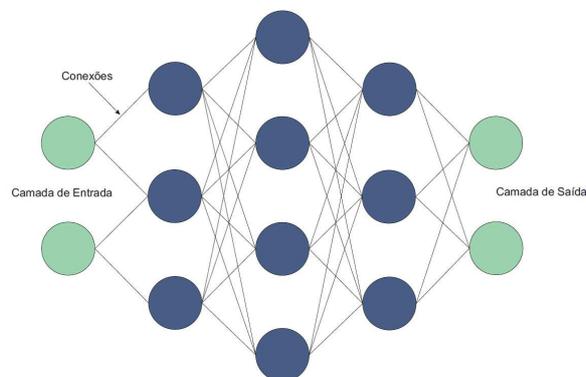


Figura 2. Arquitetura da MLP [13].

V. MÁQUINA DE COMITÊ PROPOSTA

Este trabalho aborda o problema de detecção do uso de capacete por motocicletas em vias públicas utilizando máquinas de comitês.

De acordo com o *princípio de dividir e conquistar*, uma tarefa computacional complexa é resolvida dividindo-a em um número de tarefas computacionais simples e então combinando as soluções destas tarefas. Na aprendizagem supervisionada, a simplicidade computacional é alcançada distribuindo-se a tarefa de aprendizagem entre um número de *especialistas*, que, por sua vez, divide o espaço de entrada em um conjunto de subespaços. Diz-se que a combinação de especialistas constitui uma *máquina de comitê*. Basicamente, ela funde o conhecimento adquirido por especialistas para chegar a uma decisão global que é supostamente superior àquela alcançável por qualquer um deles atuando isoladamente [21].

A máquina de comitê proposta é dividida em duas estruturas: estática e dinâmica. Na estrutura estática as respostas de vários classificadores (especialistas) são combinadas por meio de um mecanismo que não envolve o sinal de entrada. Na estrutura dinâmica o sinal de entrada faz parte do mecanismo que integra as saídas dos especialistas.

Foram desenvolvidas três máquinas de comitê: por votação, com rede de passagem ou mistura de especialistas (ME) e com mistura hierárquica de especialistas (MHE). A de votação é baseada na estrutura estática e os modelos ME e MHE são baseadas em estruturas dinâmicas.

Na máquina de comitê por votação (Fig. 5), temos a “votação por maioria”. Ela elege a opção que tem mais votos a partir de p especialistas, ou seja, destes p especialistas a saída global da máquina é a opção que mais se repetiu nos especialistas. Por exemplo, dada

uma imagem (“capacete” ou “não-capacete”) na máquina de comitê, no caso de existir cinco especialistas e três tiveram como resposta que é “capacete” a saída global será “capacete”.

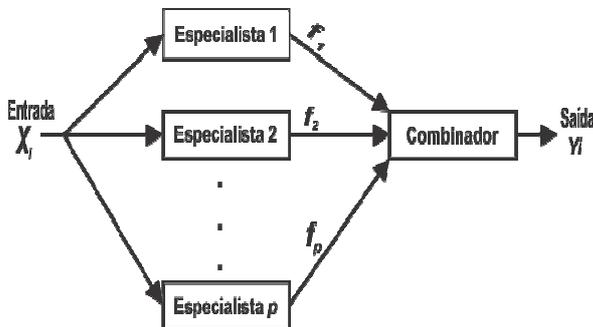


Figura 3. Máquina de Comitê por Votação.

A máquina de comitê com a rede de passagem (Fig. 6) possui uma função a mais do que a máquina de comitê por votação, onde o próprio nome infere, uma rede de passagem, ou seja, são calculados pesos para cada especialista. Na máquina de comitê com a rede de passagem as respostas individuais dos especialistas são combinadas por meio do cálculo de um peso ponderado g_{ij} , que possui a função de um mediador entre as redes especialistas. Para o cálculo do peso foi utilizada a fórmula “sum-norm”, que normaliza os parâmetros da rede de passagem pela norma do somatório,

$$g_{ij} = \frac{t_{ij}}{\sum_{j=1}^p t_{ij}}, \text{ onde } t_{ij} = x_i^T * v_j, \text{ } x_i^T \text{ é a transposta}$$

do vetor de entrada gerado pelo descritor e v_j é o vetor unitário [9].

O modelo ME na Fig. 6 funciona dividindo-se o espaço de entrada em diferentes subespaços, com uma única rede de passagem responsável pela distribuição da informação para os vários especialistas. O modelo de mistura hierárquica de especialistas, ilustrado na Fig. 7, é uma extensão natural do modelo ME. A ilustração é para um modelo MHE de quatro especialistas. A arquitetura do modelo MHE é similar a uma árvore, na qual as redes de passagem estão em pontos não-terminais da árvore e os especialistas se encontram nas folhas da árvore. O modelo MHE se diferencia do modelo ME na medida que o espaço de entrada é dividido em conjuntos *aninhados* de subespaços, com a informação sendo combinada e redistribuída entre os especialistas sob o controle de várias redes de passagem arranjadas em uma forma hierárquica [21].

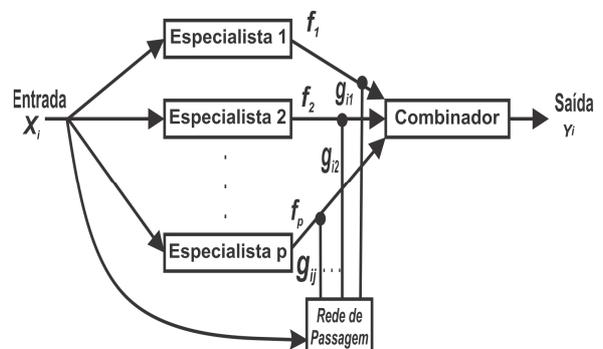


Figura 4. Máquina de Comitê com Rede de Passagem.

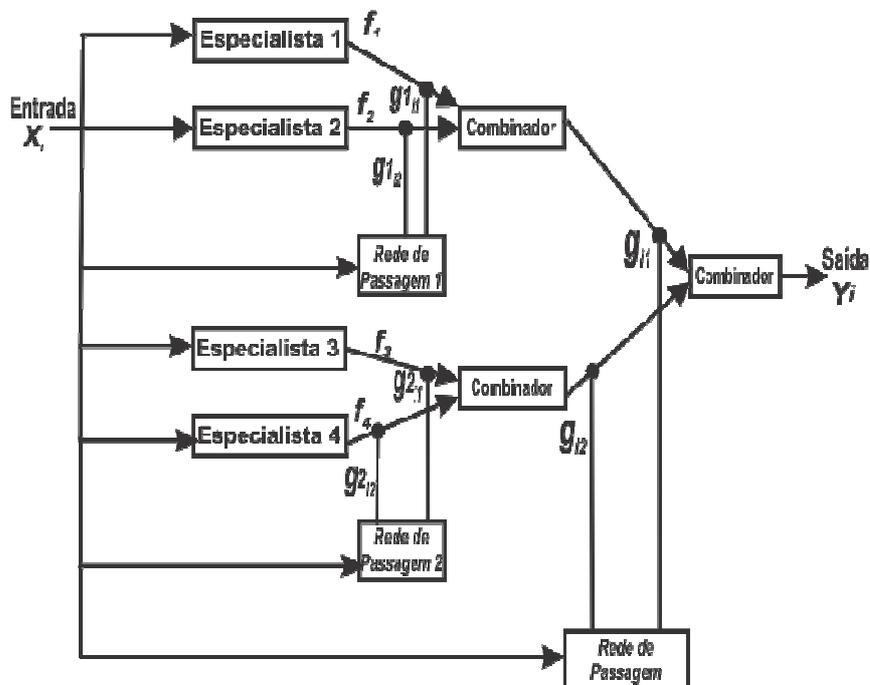


Figura 5. Máquina de Comitê com Mistura Hierárquica de Especialistas.

Para os resultados da máquina de comitê com ME e MHE serem gerados, primeiro são computados as

saídas dos especialistas já treinados. Depois é calculado o peso g_{ij} , este passo é repetido até que

todas as entradas (imagens) sejam apuradas. A saída da rede é representada por

$$Y_i = \sum_{j=1}^p g_{ij} * f_j, \quad Y_i \text{ pode assumir valores no}$$

intervalo de -1 a 1, no treinamento foi utilizado a estratégia de se Y_i for maior ou igual a zero, a saída será 1 (“capacete”), caso contrário, será -1 (“não-capacete”). O diferencial do modelo de ME para o de MHE é que são utilizadas três redes de passagem na MHE, como ilustrado na Fig. 7. Foram feitos os testes com apenas combinações de quatro especialistas na MHE.

VI. MÉTODOS DE AVALIAÇÃO

Os desempenhos dos algoritmos desenvolvidos neste trabalho são avaliados utilizando alguns conceitos: Matriz de Confusão, Especificidade, Sensibilidade, Precisão, Acurácia e Índice Kappa.

A. Matriz de Confusão

A matriz de confusão é uma tabela que é muitas vezes usada para descrever o desempenho de um algoritmo de classificação. Geralmente ela é composta pelos valores: Verdadeiro Positivo (VP), Falso Positivo (FP), Falso Negativo (FN) e Verdadeiro Negativo (VN). Estes valores são obtidos após o resultado da classificação.

- VP: número de objetos da classe “**capacete**” classificados como “**capacete**”.
- VN: número de objetos da classe “**não-capacete**” classificados como “**não-capacete**”.
- FP: número de objetos da classe “**não-capacete**” classificados como “**capacete**”.
- FN: número de objetos da classe “**capacete**” classificados como “**não-capacete**”.

B. Especificidade - E

A Especificidade mede a proporção de verdadeiros negativos, ou seja, do total de verdadeiros negativos é possível saber quantos foram classificados corretamente. Ela pode ser calculada através da equação:

$$E = \frac{VN}{VN + FP} \quad (2)$$

C. Sensibilidade - S

A Sensibilidade mede a proporção de verdadeiros positivos, ou seja, do total de verdadeiros positivos é possível saber quantos foram classificados corretamente. O cálculo é realizado através da equação:

$$S = \frac{VP}{VP + FN} \quad (3)$$

D. Precisão - P

A precisão mede a proporção de verdadeiros positivos em relação a todas as predições positivas. A precisão de uma classificação mostra a quantidade de objetos da classe “capacete” classificados corretamente em relação a todos os objetos classificados como sendo da classe “capacete”. O cálculo é realizado através da equação:

$$P = \frac{VP}{VP + FP} \quad (4)$$

E. Acurácia - A

A acurácia é o percentual de acertos do conjunto de teste apresentado a um classificador, ou seja, é medido o quão bem um classificador reconhece instâncias de diversas classes. O cálculo é realizado através da equação:

$$A = \frac{VP + VN}{VP + FP + VN + FN} \quad (5)$$

F. Índice Kappa - K

O índice Kappa é utilizado como uma medida apropriada da exatidão por representar inteiramente a matriz de confusão. Este índice toma todos os elementos da matriz em consideração, ao invés de apenas aqueles que retratam a quantidade de classificações verdadeiras, o que ocorre quando se calcula a exatidão global da classificação [28].

O índice Kappa é um coeficiente de concordância para escalas nominais que mede o relacionamento entre a concordância, além da casualidade, e a discordância esperada [28]. O índice Kappa pode ser encontrado com base na Equação 6:

$$K = \frac{\theta_1 - \theta_2}{1 - \theta_2} \quad (6) \quad \text{onde,}$$

$$\theta_1 = \frac{VP + VN}{VP + VN + FP + FN} \quad (7)$$

e

$$\theta_2 = \frac{[(VP+FN)(VP+FP)] + [(VN+FN)(VN+FP)]}{(VP+VN+FP+FN)^2} \quad (8)$$

A avaliação dos classificadores foi realizada através do índice *Kappa* obtido para cada um deles. O nível de exatidão do índice *Kappa* foi classificado conforme a Tabela I, de acordo com o estabelecido por Landis e Kock [29].

TABELA I. NÍVEL DE EXATIDÃO DO ÍNDICE *KAPPA*.

Índice <i>Kappa</i> (K)	Qualidade
$K \leq 0,2$	Ruim
$0,2 \leq K \leq 0,4$	Razoável
$0,4 \leq K \leq 0,6$	Bom
$0,6 \leq K \leq 0,8$	Muito boa
$K \geq 0,8$	Excelente

VII. RESULTADOS E DISCUSSÕES

Para testar as máquinas de comitê utilizou-se a ferramenta *Weka*. Nela existem vários algoritmos de classificação. Os resultados destes são utilizados na máquina de comitê, que tem por objetivo “juntar” esses classificadores e obter uma resposta que seja mais eficiente que os classificadores individualmente.

Dentre os algoritmos testados, foram escolhidos seis que obtiveram um melhor resultado na detecção de “capacete” e “não-capacete”: SMO (1), *Random Forest* (2), KNN (3), MLP (4), J48 (5) e SVM (6). A Tabela II mostra os resultados dos métodos de avaliação aplicado.

Para classificar as imagens foi utilizada validação cruzada, uma estratégia de selecionar 10% do

conjunto de dados para treinamento e os outros 90% para testes, repetindo esse processo 10 vezes. Para a detecção de “capacete” e “não-capacete”, foram testadas 238 imagens, obtidas a partir de uma câmera CCD em vias públicas. Estes testes foram realizados apenas utilizando as imagens já segmentadas. Algumas dessas imagens são mostradas na Fig. 8.



Figura 6. Imagens utilizadas no trabalho.

Na fase de classificação, o número de árvores geradas foi de 36 para algoritmo *Random Forest*. O J48 e o KNN foram executados com as configurações padrão da ferramenta *Weka*. No SMO o parâmetro de complexidade C foi igual a 3.0 e o *Kernel* escolhido foi o *RBKernel*. O SVM foi executado utilizando uma função *Kernel linear*, o peso usado para as classes foi de 2000, e o parâmetro de custo foi igual a 1. Para o MLP utilizamos duas camadas ocultas, os pesos são gerados aleatoriamente, a taxa de aprendizado é de 0.3 e o *momentum* é 0.1.

Na Tabela II observa-se que o melhor resultado foi a partir do classificador SMO. De um total de 238 imagens, 18 foram classificadas erroneamente. Observa-se também que o índice *Kappa* classificou o resultado como “excelente” de acordo com a Tabela I, onde o *kappa* foi igual a 0,841, a especificidade, sensibilidade e precisão foram iguais a 0,958, 0,875 e 0,933 respectivamente.

TABELA II. RESULTADO DOS CLASSIFICADORES.

Classificadores	VP	FP	VN	FN	E	S	P	K	A
1	84	6	136	12	0,958	0,875	0,933	0,841	0,924
2	82	5	137	14	0,965	0,854	0,943	0,833	0,92
3	89	14	128	7	0,901	0,927	0,864	0,819	0,912
4	81	13	129	15	0,908	0,843	0,862	0,755	0,882
5	80	15	127	16	0,894	0,833	0,842	0,729	0,87
6	77	14	128	19	0,901	0,802	0,846	0,71	0,861

Na máquina de comitê podem-se combinar os classificadores de diversas formas. Por exemplo, escolhendo dois ou mais classificadores para serem combinados. O melhor resultado na máquina de comitê por votação foi a combinação dos três especialistas KNN, J48 e *Random Forest*, onde obteve-se uma taxa de acerto de 93,3%. Com a ME foram utilizados os mesmos classificadores, com taxa de acerto de 93,7%. As Tabelas III e IV mostram os testes realizados com várias combinações de classificadores para a máquina de comitê por votação e com a ME.

Nas Tabelas III, IV e V, observamos que em alguns resultados não é necessário a utilização máquina de comitê, pois alguns dos classificadores individualmente possuem uma acurácia maior do que a máquina de comitê.

Com a utilização da máquina de comitê por votação, foram classificadas erroneamente 16 imagens, o índice *kappa* foi de 0,859, ou seja, o resultado foi excelente, com acurácia de 0,933.

TABELA III. RESULTADOS DA MÁQUINA DE COMITÊ POR VOTAÇÃO.

Combinação dos Classificadores	VP	FP	VN	FN	E	S	P	K	A
2, 3 e 5	85	5	137	11	0,965	0,885	0,944	0,859	0,933
1, 4 e 5	85	5	137	11	0,965	0,885	0,944	0,859	0,933
1, 2, 3 e 4	84	5	137	12	0,965	0,875	0,944	0,85	0,929
1, 2 e 3	84	5	137	12	0,965	0,875	0,944	0,85	0,929
1, 2,3, 4, 5 e 6	83	5	137	13	0,965	0,865	0,943	0,841	0,924
1, 2, 3, 4 e 5	83	5	137	13	0,965	0,865	0,943	0,841	0,924
1 e 2	82	5	137	14	0,965	0,854	0,943	0,832	0,92
1, 2 e 6	80	6	136	16	0,958	0,833	0,93	0,805	0,908
3, 4, 5 e 6	84	10	132	12	0,93	0,875	0,894	0,807	0,908
4, 5 e 6	82	12	130	14	0,916	0,854	0,872	0,772	0,891

Os índices *kappa* dos modelos ME e MHE foram de 0,868 e 0,877 respectivamente, ou seja, nos dois modelos foi obtido um resultado excelente levando em consideração o *kappa*, a acurácia foi de 0,937 no modelo ME e 0,941 no MHE.

Na MHE a ordem em que os especialistas são apresentados para a rede de passagem 1 e 2 (RP1 e RP2) pode mudar o valor da acurácia. A melhor taxa

de acerto foi obtida utilizando conjuntos dos classificadores [{J48 e SMO}, {Random Forest e KNN}], com uma acurácia de 94,12%. Outros testes foram realizados, todos estes ilustrados na Tabela V.

Os gráficos comparativos entre os classificadores utilizados, bem como para as máquinas de comitê, estão ilustrados nas Figuras 9 e 10, respectivamente.

TABELA IV. RESULTADOS DA MÁQUINA DE COMITÊ COM A ME.

Combinação dos Classificadores	VP	FP	VN	FN	E	S	P	K	A
2, 3 e 5	86	5	137	10	0,965	0,896	0,945	0,868	0,937
1, 4 e 5	83	7	135	13	0,951	0,865	0,922	0,824	0,916
1, 2, 3 e 4	83	5	137	13	0,965	0,865	0,943	0,841	0,924
1, 2 e 3	84	5	137	12	0,965	0,875	0,944	0,85	0,929
1, 2,3, 4, 5 e 6	81	7	135	15	0,951	0,844	0,921	0,805	0,908
1, 2, 3, 4 e 5	84	5	137	12	0,965	0,875	0,944	0,85	0,929
1 e 2	80	5	137	16	0,965	0,833	0,941	0,813	0,912
1, 2 e 6	81	6	136	15	0,958	0,844	0,931	0,814	0,912
3, 4, 5 e 6	83	9	133	13	0,937	0,865	0,902	0,807	0,908
4, 5 e 6	82	13	129	14	0,909	0,854	0,863	0,764	0,887

TABELA V. RESULTADOS DA MÁQUINA DE COMITÊ COM A MHE.

Combinação dos Classificadores										
<i>RP1</i>	<i>RP2</i>	<i>VP</i>	<i>FP</i>	<i>VN</i>	<i>FN</i>	<i>E</i>	<i>S</i>	<i>P</i>	<i>K</i>	<i>A</i>
5 e 1	2 e 3	87	5	137	9	0,965	0,906	0,946	0,877	0,941
5 e 2	1 e 3	84	5	137	12	0,965	0,875	0,944	0,85	0,929
1 e 2	3 e 4	83	5	137	13	0,965	0,865	0,943	0,841	0,924
2 e 3	4 e 6	84	6	136	12	0,958	0,875	0,933	0,841	0,924
3 e 4	5 e 6	84	10	132	12	0,93	0,875	0,894	0,807	0,908
3 e 5	6 e 4	83	10	132	13	0,93	0,865	0,893	0,798	0,903
1 e 2	3 e 5	83	5	137	13	0,965	0,865	0,943	0,841	0,924
1 e 4	5 e 2	85	7	135	11	0,951	0,885	0,924	0,842	0,924
4 e 2	6 e 1	79	7	135	17	0,951	0,823	0,919	0,787	0,899
4 e 5	3 e 1	83	6	136	13	0,958	0,865	0,933	0,832	0,92

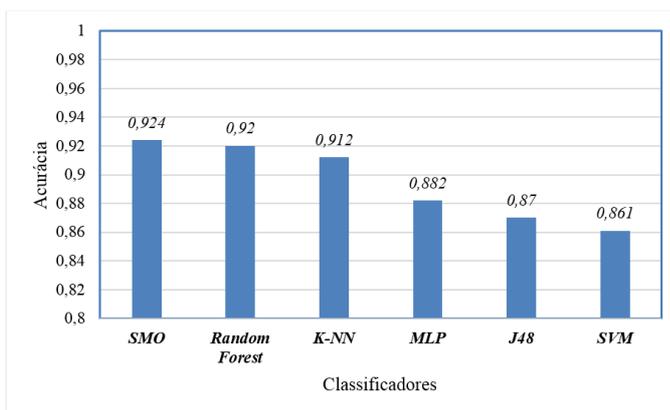


Figura 7. Gráfico comparativo dos Classificadores.

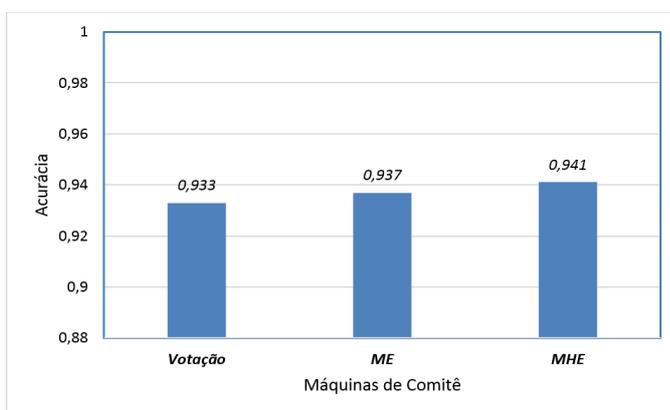


Figura 8. Gráfico comparativo entre as Máquinas de Comitê.

VIII. CONCLUSÃO E TRABALHOS FUTUROS

Os resultados das máquinas de comitê mostram-se satisfatórios comparando com os classificadores individualmente. Nas três máquinas de comitê obtivemos um melhoramento na acurácia.

O principal problema encontrado na máquina de comitê por votação e com a ME é quando a maioria dos especialistas possuem as saídas equivalentes. Por exemplo, utilizando cinco especialistas, quando quatro computam sua saída “não-capacete” e a saída esperada é “capacete”. Dessa forma, a máquina de comitê classificará erroneamente, pois apenas um especialista atingiu a saída esperada. No caso da MHE o problema é semelhante ao de votação e da ME. O problema ocorre quando, por exemplo, utilizando quatro especialistas, três computaram como saída “não-capacete”, um computou a saída “capacete” e a saída esperada é “capacete”, neste caso, pode ser que seja classificado erroneamente, dependerá somente da distribuição dos pesos na rede passagem do especialista que acertou e da última rede de passagem.

Os possíveis trabalhos futuros seriam: um estudo e desenvolvimento de descritores híbridos; uma investigação mais detalhada nos classificadores, para que a máquina de comitê obtenha melhor desempenho; por último, uma implementação de um sistema automático, desde a captação do vídeo de motociclistas até as máquinas comitê, em uma linguagem de programação que seja capaz de dar uma resposta em tempo real, por exemplo, C++.

REFERÊNCIAS

- [1] DENATRAN (2014). Frota por tipo de veículo. <http://www.denatran.gov.br/frota2014.htm>. Acessado: 21/06/2015.
- [2] DNIT (2011). Numero de veiculos envolvidos em acidentes por finalidade do veiculo. <http://www.dnit.gov.br/download/rodovias/operacoes-rodoviaras/estatisticas-de-acidentes/quadro-0501-numero-de-veiculos-envolvidos-por-finalidade-do-veiculo-ano-de-2011.pdf>. Acessado: 21/06/2015.
- [3] N. H. T. S. Administration (2013), “Traffic safety facts 2013: A Compilation of Motor Vehicle Crash Data from the Fatality Analysis Reporting System and the General Estimates System.”. <http://www-nrd.nhtsa.dot.gov/Pubs/812139.pdf>. Acessado: 25/06/2015.
- [4] Rodrigues Veloso e Silva, R., Teixeira Aires, K., and De Melo Souza Veras, R. (2014). Helmet detection on motorcyclists using image descriptors and classifiers. In Graphics, Patterns and Images (SIBGRAPI), 2014 27th SIBGRAPI Conference on, pages 141–148.
- [5] CHIVERTON, J. Helmet presence classification with motorcycle detection and tracking. IET, v. 6, n. 3, p. 259–269, 2012. ISSN 1751-956X.
- [6] WARANUSAST, R. et al. Machine vision techniques for motorcycle safety helmet detection. In: Image and Vision Computing New Zealand (IVCNZ), 2013 28th International Conference of. [S.l.: s.n.], 2013. p. 35–40. ISSN 2151-2191.
- [7] Tang, H.-M., Lyu, M., e King, I. (2003). Face recognition committee machines: dynamic vs. static structures. In Image Analysis and Processing, 2003.Proceedings. 12th International Conference on, pp 121–126.
- [8] Shi, M., Bermak, A., Chandrasekaran, S., Amira, A., e Brahim-Belhouari, S. (2008). A committee machine gas identification system based on dynamically reconfigurable fpga. Sensors Journal, IEEE, 8(4):403–414.
- [9] Su, M. e Basu, M. (2001). Gating improves neural network performance. In Neural Networks, 2001. Proceedings. IJCNN '01. International Joint Conference on, volume 3, pp 2159–2164 vol.3.
- [10] Santos, T. S., Aires, K. R., Romuere, R., Silva, K. A., Veras, R. M., and Soares, A. C. Histograma de gradientes orientados na detecção de motocicletas.
- [11] DAUBECHIES, I. *Tem lectures on wavelets*. 1. Ed. Society for Industrial and Applied Mathematics, 1992. Paperback. ISBN 0898712742. Disponível em: <http://www.amazon.com/exec/obidos/redirect?tag=citeulike07-20&path=ASIN/0898712742>.
- [12] MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 11, n.7, p. 674–693, 1989.
- [13] SILVA, R. Detecção do Uso de Capacete por Motociclistas em Vias Publicas. 2014. 100 f. Dissertação (Mestrado em Ciencia da Computação) – Departamento de Computação – Universidade Federal do Piauí, Teresina – PI.
- [14] Breiman, L. (2001). Random forests. *Machine Learning*, 45(1):5–32.
- [15] Quinlan, R. (1993). C4.5: Programs for Machine Learning. Morgan Kaufmann Publishers, San Mateo, CA.
- [16] Keerthi, S., Shevade, S., Bhattacharyya, C., and Murthy, K. (2001). Improvements to platt’s smo algorithm for svm classifier design. *Neural Computation*, 13(3):637–649.
- [17] Aha, D. and Kibler, D. (1991). Instance-based learning algorithms. *Machine Learning*, 6:37–66.
- [18] Chang, C.-C. and Lin, C.-J. (2001). Libsvm - a library for support vector machines. The Weka classifier works with version 2.82 of LIBSVM.
- [19] Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., and Witten, I. H. (2009). The weka data mining software: an update. *SIGKDD Explor. Newsl.*, 11(1):10–18.
- [20] CORTES, C.; VAPNIK, V. Support-vector networks. *Machine Learning*, Springer Netherlands, v. 20, p. 273–297, 1995. ISSN 0885-6125. Citado 2 vezes nas páginas 3 e 26.
- [21] HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2. ed. [S.l.]: Prentice Hall, 2001.
- [22] COVER, T. M. Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition. *IEEE Transactions on Electronic Computers*, EC-14, n. 3, p. 326–334, June 1965. ISSN 0367-7508.
- [23] Platt, J. (1998). Sequential minimal optimization: A fast algorithm for training support vector machines. Technical Report MSR-TR-98-14, Microsoft Research.
- [24] BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001.
- [25] SILVA, E. R. J. Investigação de Técnicas de Extração e Seleção de Características e Classificadores Aplicados ao Problema de Classificação de Dígitos Manuscritos de Imagens de Documentos Históricos. Dissertação — Universidade Federal de Pernambuco, 2007.
- [26] Padhye, A. (2006). Comparing Supervised and Unsupervised Classification of Messages in the Enron Email Corpus. PhD thesis, UNIVERSITY OF MINNESOTA.
- [27] Da Silva, I. N., Spatti D., e Flauzino R. (2010). Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático, Artliber Editora Ltda, São Paulo, SP, Brasil. ISBN978-85-88098-53-4.
- [28] ROSENFELD, G. H.; FITZPATRICK-LINS, K. A. A coefficient of agreement as a measure of thematic classification accuracy. *Photogrammetric Engineering and Remote Sensing*, v. 52, p. 223–227, 1986.
- [29] J., L.; G., K. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, n. 1, p. 159–174, 1977.