

MODELO ESTATÍSTICO PARA FILTRAGEM DE EXEMPLOS NEGATIVOS NA DETECÇÃO DE PEDESTRES

DOUGLAS ALMONFREY*, RAQUEL FRIZERA VASSALLO[†], EVANDRO OTTONI TEATINI SALLES[‡],
MYLÈNE C.Q. FARIAS[‡]

*IFES, Av. Vitoria, 1729, Vitoria, ES, Brasil

[†]UFES, Av. Fernando Ferrari, 514, Vitoria, ES, Brasil

[‡]UnB, Brasília, DF, Brasil

Emails: dalmonfrey@ifes.edu.br, raquel@ele.ufes.br, evandro@ele.ufes.br,
mylene@ieee.org

Abstract— Methods for automatic pedestrian detection have presented a lot of progress in the last years motivated mainly by driver assistance systems, demanded by autonomous cars. Most of the pedestrian detection solutions are appearance-based and demand exhaustive sliding windows search over the image. In general, these solutions have a high computational cost. As the detection time is critical for real time applications, procedures to filter out negatives and generate candidate windows (FENGJC) are often useful to reduce the number of evaluations by the detector. Besides that, the elimination of negatives tends to change the distribution of the data used by the detector, and, when applied at the end of the detection task, the FENGJC procedure tends also to influence in the precision and quality of the detector. In this sense, this work employs a statistical pedestrian model based on histograms of oriented gradient to build a novel FENGJC technique.

Keywords— Pedestrian Detection, Negative Filtering.

Resumo— A detecção automática de pedestres em imagens tem sido objeto de grande atenção nos últimos anos, principalmente devido ao aumento de pesquisas na área de veículos autônomos. A maioria das soluções para o problema de detecção de pedestres utilizam modelos baseados em aparência e a busca exaustiva na imagem por meio de janelas deslizantes. Em geral, essas soluções possuem um alto custo computacional. Como o tempo demandado durante a detecção é crítico para aplicações de tempo real, a filtragem de exemplos negativos e a geração de janelas candidatas (FENGJC) é importante para se ter uma redução no número de inspeções realizadas pelo detector na imagem. Além disso, os mecanismos de FENGJC tendem a alterar a distribuição dos dados analisados pelo detector de pedestres, e, quando aplicados na saída do detector, impactam também na precisão e na qualidade da detecção. Nesse sentido, o presente trabalho desenvolve um modelo estatístico do pedestre, baseado em características extraídas de histogramas de gradiente orientado com o objetivo de construir um novo procedimento de FENGJC.

Palavras-chave— Detecção de Pedestres, Filtragem de Negativos.

1 Introdução

A detecção de pedestres sempre foi um assunto relevante em visão computacional e processamento de imagens e vídeos, devido à importância da detecção, identificação e monitoramento dos seres humanos em uma variedade de cenas (Nguyen et al., 2016). Contudo, essa área de pesquisa tem se tornado cada vez mais importante, principalmente devido ao recente crescimento de pesquisas na área de veículos autônomos (Gerónimo et al., 2010).

Na detecção de pedestres, além da qualidade, o tempo de processamento é fundamental. Embora o tempo demandado no treinamento do detector seja importante, o tempo do processo de detecção é crucial. Desta forma, diferentes soluções foram propostas na literatura no sentido de reduzir a complexidade computacional e o tempo do processo de detecção. Dentre essas soluções destacam-se a utilização do conceito de imagem integral (Viola et al., 2003), o emprego de classificadores em cascata (Dollár, Appel and Kienzle, 2012), detecção multiescala utilizando aproximações exponenciais (Dollar et al., 2014) e uso de unidades gráficas de processamento (UGP) (Benenson et al., 2012). Detectores em cascata estão diretamente relacionados a procedimentos

de Filtragem de Exemplos Negativos¹ e Geração de Janelas Candidatas (FENGJC). Eles tendem a empregar classificadores com alto *recall*² e alto desempenho computacional, para gerar janelas candidatas para detectores de melhor qualidade e maior tempo de detecção.

O presente trabalho propõe uma estratégia de FENGJC que, até onde se pode constatar, é diferente das existentes na literatura e que pode ser utilizada em uma abordagem em cascata, tanto a priori como a posteriori ao processo de detecção. Quando utilizada a priori, o objetivo é eliminar exemplos negativos, gerando um conjunto de janelas candidatas para o procedimento de detecção, reduzindo o número de avaliações necessárias por parte do detector de pedestres. Quando utilizado a posteriori, o objetivo é reduzir o número de falsos positivos identificados pelo detector de pedestres, melhorando sua precisão.

Este trabalho possui a seguinte organização: na Seção 2, uma breve revisão da literatura é apresentada e, na Seção 3, o modelo estatístico desen-

¹Exemplos negativos, no contexto do presente trabalho, são aquelas partes da imagem em que pedestres não estão presentes. Exemplos positivos são partes da imagem onde pedestres estão presentes.

²*Recall* é o termo em inglês que está relacionado a quantidade de eventos relevantes obtidos dentre todos os eventos relevantes existentes.

volvido é abordado. Em seguida, na Seção 4, os procedimentos experimentais e seus resultados são discutidos e, por fim, na Seção 5, são feitas as considerações finais sobre este artigo.

2 Trabalhos Relacionados

A maioria das soluções, existentes na literatura para detecção de pedestres, empregam o modelo baseado em aparência (*appearance-based*), sendo alguns exemplos abordados em (Zhang et al., 2015; Dollar et al., 2014; Yang et al., 2015). Esse modelo utiliza características (*features*) como descritores de partes da imagem e envolve uma etapa de treinamento de um classificador, em geral, realizado de maneira supervisionada. A etapa de treinamento antecede a de detecção, que, na maioria dos casos, utiliza um método de busca exaustiva pela imagem, conhecido como janela deslizante (JD) (*sliding window*). A Figura 1 apresenta um fluxograma simplificado de um detector de pedestres.




Figura 1: Fluxograma de um detector de pedestres. SNM significa supressão de não máximo.

O mecanismo de FENGJC, também chamado de *detection proposal* na literatura, pode substituir o procedimento de JD na Figura 1, gerando janelas candidatas para a etapa de extração de características. Sendo assim, filtram-se janelas que correspondem a exemplos negativos e evita-se a busca exaustiva. Se a complexidade computacional do mecanismo de FENGJC for menor que a do detector, uma redução no tempo de processamento pode ser obtida, haja visto que o detector realizará menos avaliações. A filtragem de negativos pode também ser posicionada imediatamente antes ou após o procedimento de supressão de não máximo (SNM), de maneira a eliminar detecções que são falsos positivos, melhorando a precisão do detector. É válido ressaltar que a SNM é uma etapa do detector de pedestres que elimina múltiplas detecções relativas a um mesmo pedestre³. O método de FENGJC influencia também no processo de treinamento, pois altera a distribuição dos exemplos negativos com os quais o detector está trabalhando, principalmente se etapas de *hard negative mining* forem utilizadas.

Em (Hosang et al., 2014), um estudo sobre os métodos de *detection proposals* existentes na lite-

ratura de detecção de objetos é realizado. Além disso, uma plataforma de comparação unificada desses métodos é desenvolvida. Dentre as métricas dessa plataforma de comparação estão a repetibilidade, o critério da área de intercessão sobre união (*intersection over union criteria* - IoU), o número de janelas candidatas retornadas e o *recall* considerando a variação de cada uma dessas métricas. Considerando-se o compromisso entre as métricas analisadas, os métodos *EdgeBox* (Zitnick and Dollar, 2014), que utiliza aprendizado de máquina, e o *Selective Search* (Uijlings et al., 2013), que não envolve aprendizado e utiliza superpíxeis, foram os que apresentaram os melhores resultados.

Recentemente, em (Hosang et al., 2015), em um dos resumos mais completos sobre *detection proposals* da literatura, expande-se o trabalho realizado em (Hosang et al., 2014). Apresentam-se as métricas, dentre as avaliadas em (Hosang et al., 2014), que resultam em uma melhor predição da qualidade da detecção quando utilizando *detection proposal* junto ao detector chamado LM-LLDA. Chega-se a conclusão de que não há a garantia de que o método de FENGJC venha a melhorar o desempenho de um detector de objetos em termos da qualidade de detecção. Espera-se, ainda, que um procedimento de detecção que utilize janelas deslizantes tenha um desempenho no mínimo tão bom quanto o que utiliza o *detection proposal*. Contudo, utilizando-se as métricas adequadas, pode-se obter resultados competitivos entre métodos que utilizam e não utilizam *detection proposals*.

A solução proposta neste trabalho para o problema de FENGJC tem como foco a tarefa de detecção de pedestres. A maioria das soluções atualmente existentes na literatura são voltadas para a detecção de objetos, da qual a detecção de pedestres é uma instância. O método proposto neste trabalho é inspirado na tabela de probabilidade e máscara de pré-filtragem de pedestres apresentada em (Liu et al., 2014), um dos poucos trabalhos conhecidos na literatura de detecção de pedestres que emprega diretamente mecanismos de FENGJC. Como contribuições em relação ao referido trabalho, destacam-se a alteração no conjunto de características empregadas para gerar o modelo estatístico do pedestre, a modificação no procedimento de obtenção da máscara de pré-filtragem e a realização de dezenas de experimentos para validação dos resultados, utilizando um procedimento estatístico consistente.

É importante salientar que nenhum dos procedimentos apresentados em (Hosang et al., 2015) utilizam modelos estatísticos tais quais o desenvolvido neste trabalho para remover negativos e gerar janelas candidatas. Em geral, são utilizados procedimentos que empregam classificadores, passando por um processo de aprendizado, ou características de baixo nível em um processo de seg-

³Como a detecção de pedestres é multiescala, haja visto que não se sabe o tamanho do pedestre na imagem a priori, múltiplas detecções de um mesmo pedestre podem ocorrer em diferentes escalas ou em uma única escala.

mentação. Considerando-se ainda a escassez de procedimentos de FENGJC na  rea da detec  o de pedestres, a solu  o apresentada neste trabalho representa uma proposta diferente da existente na literatura.

3 Modelo Estat stico Proposto

Nesse trabalho, um modelo estat stico do pedestre   proposto para auxiliar no procedimento de FENGJC. Esse modelo estat stico   inspirado na tabela de probabilidade e m scara de pr -filtragem de pedestres apresentadas em (Liu et al., 2014) e reproduzidas abaixo

$$P(y, x, V_C^{(i)}(y, x)) \text{ e } M(y, x) = \frac{1}{sdv(V_C^{(i)}(y, x))}, \quad (1)$$

onde V_C   a caracter stica em quest o, $i = 1...K$ exemplos positivos e sdv o desvio padr o. Essa tabela de probabilidade P   um histograma em fun  o da posi  o (y, x) , do leiaute padr o do pedestre, e da magnitude ou a orienta  o (V_C) da imagem de gradiente de Sobel do pedestre.

Neste artigo, ser  utilizado como caracter stica, para a formula  o do modelo probabil stico, o Histograma de Gradiente Orientado - *Histogram of Oriented Gradient* (HOG) (Dalal and Triggs, 2005). A constru  o do HOG   baseada no histograma do gradiente para diferentes orienta  es e isso o torna um descritor mais completo e eficaz que a imagem do gradiente de Sobel. O modelo probabil stico da Equa  o 1 ser  adaptado para ser representado em fun  o da orienta  o e da magnitude do gradiente, naquela orienta  o, conforme apresentado na seguinte equa  o

$$P(y, x, M_\varphi, \varphi), \quad (2)$$

onde φ e M_φ s o a orienta  o e sua magnitude fornecida pelo descritor HOG.

O resultado da obten  o do HOG de uma imagem s o canais (imagens) contendo a magnitude em cada posi  o (y, x) da orienta  o representada pelo respectivo canal. Neste trabalho, s o consideradas seis orienta  es ($1 = 90^\circ$, $2 = 60^\circ$, $3 = 30^\circ$, $4 = 0^\circ$, $5 = -30^\circ$ e $6 = -60^\circ$), e cada um dos seis canais obtidos, possui as mesmas dimens es vertical e horizontal da imagem original. Al m disso, a magnitude do HOG   representada no intervalo $[0, 255]$ e o leiaute padr o do pedestre empregado   de 32×16 pixels⁴. Desta forma, a constru  o do modelo probabil stico do pedestre ser  realizada conforme apresentado no Algoritmo 3.1. As sa das do algoritmo s o 2 histogramas. P   a tabela de probabilidade que considera todas as magnitudes e orienta  es e M   uma m scara de pr -filtragem obtida marginalizando-se P em rela  o  s orienta  es e magnitudes de interesse. M  , portanto, um histograma representado por uma matriz bi-dimensional.

⁴O leiaute do pedestre possui as mesmas dimens es da janela deslizante utilizada na detec  o.

Algoritmo 3.1: Constru  o do modelo estat stico.

```

1  entrada:
2  K imagens  $X_i(y, x, canal)$  RGB de pedestres.
3  sa da:
4  Tabela de Probabilidade:  $P(y, x, M_\varphi, \varphi)$ ;
5  M scara de Pr -filtragem:  $M(y, x)$ .
6  in cio
7   $P$  e  $M$  = inicializaZero();
8  para  $i = 1$  at   $K$ 
9     $HOG(y, x, \varphi)$  = calculaHOG( $X_i$ )
10   para  $u = 1$  at   $16$ ,  $v = 1$  at   $32$ ,
11      $o = 1$  at   $6$ 
12      $P(v, u, HOG(v, u, o) + 1, o) =$ 
13      $P(v, u, HOG(v, u, o) + 1, o) + 1$ 
14   fim
15 fim
16  $ori = [1, 2, 3, 5, 6]$  - orienta  es do HOG
17  $minMag = 70$ 
18  $M(v, u) =$ 
19 soma(soma( $P(:, :, minMag:256, ori)$ , 3), 4)
20  $M = \text{normaliza}(M)$ 
21 fim

```

Na obten  o de M , a orienta  o de 0°   descartada, pois essa orienta  o est  geralmente relacionada a elementos que n o s o pedestres. Essa afirma  o   de certa forma intuitiva, pois o pedestre, em imagens e na maior parte dos casos, aparece em p , possuindo, portanto, contornos com orienta  es pr ximas a dire  o vertical. Al m disso, essa decis o tamb m se justifica com base na anisotropia das imagens naturais, que, segundo (Hyvri nen et al., 2009), apresentam uma maior correla  o na dire  o horizontal. Como o pedestre, em geral, n o ocupa a maior parcela de uma imagem natural, essa anisotropia se deve em grande parte a regi es da imagem que n o contemplam o pedestre. Dessa forma, eliminar as orienta  es relacionadas a essas regi es torna o modelo estat stico do pedestre mais adequado. Al m disso, magnitudes de HOG abaixo de um determinado limiar tamb m n o s o consideradas na constru  o do modelo, pois geralmente est o relacionadas a orienta  es de dif cil determina  o, o que n o   o caso do pedestre e seus contornos. Repare que um limiar de 70 foi estabelecido de forma emp rica, embora a solu  o seja relativamente est vel para valores pr ximos a esse limiar.

Ap s obtidos os histogramas P , M , de posse de um conjunto de imagens de pedestres, pode-se realizar a estimativa do limiar de separa  o L , empregado para classificar janelas de detec  o em exemplos positivos e negativos. A estimativa de L   apresentada no Algoritmo 3.2.

Repare que o valor do limiar escolhido no Algoritmo 3.2   o m nimo valor do produto interno (PI) entre P e M . Essa decis o pode ser compreendida por meio da Figura 2(a), onde s o exibidos os histogramas (vetorPI) dos exemplos positivos e negativos. Assim como no caso dos exemplos positivos, o vetorPI para exemplos negativos pode ser obtido por meio do Algoritmo 3.2. Observe, por meio da Figura 2(a)⁵, que o m nimo valor de

⁵As abscissas dos gr ficos da Figura 2 s o diferentes, pois as tabelas de probabilidade e m scaras de pr -filtragem utilizadas no c lculo de PI , pelos dois modelos sendo comparados, s o diferentes.

PI , para os exemplos positivos, permite filtrar, aproximadamente, metade dos exemplos negativos, sem eliminar qualquer exemplo positivo. De certo, para os conjuntos de validação, existe a possibilidade de que alguns exemplos positivos sejam descartados.

Algoritmo 3.2: Estimativa do limiar L .

```

1  entrada :
2  K imagens  $X_i(y, x, canal)$  RGB de pedestres.
3  Tabela de Probabilidade:  $P(y, x, M_\varphi, \varphi)$ ;
4  Máscara de Probabilidade:  $M(y, x)$ .
5  saída :
6  Limiar:  $L$ 
7  início
8   $ori = [1, 2, 3, 5, 6]$  - orientações do HOG
9   $minMag = 70$ 
10 para  $i = 1$  até  $K$ 
11    $HOG(y, x, M_\varphi, \varphi) = \text{calculaHOG}(X_i)$ 
12    $PI = 0$ ;
13   para  $u = 1$  até  $16$ ,  $v = 1$  até  $32$ 
14      $o = 1$  até  $\text{tamanho}(ori)$ 
15     se ( $HOG(u, v, ori(o)) \geq minMag$ )
16        $PI = PI +$ 
17        $P(v, u, HOG(v, u, ori(o)) + 1, ori(o)) * M(u, v)$ 
18     fim
19   fim
20    $\text{vetorPI}(i) = PI$ 
21 fim
22  $L = \text{minimo}(\text{vetorPI})$ 
23 fim

```




Figura 2: Histograma das ocorrências de valores de PI para exemplos positivos e negativos (a) do presente trabalho e (b) de (Liu et al., 2014).

O método apresentado em (Liu et al., 2014) necessita de um processo adicional de otimização usando mínimos quadrados, para obter um limiar adequado de separação entre os exemplos positivos e negativos. Esse procedimento adicional não é necessário no método proposto neste trabalho. A Figura 2(b) apresenta o histograma dos exemplos positivos e negativos, quando considerando o modelo estatístico de (Liu et al., 2014) sem o procedimento de otimização. Repare, por meio da Figura 2(b), a dificuldade em se encontrar um limiar de separação entre exemplos positivos e negativos. As Figuras 2(a) e 2(b) foram obtidas a partir do conjunto de treino do banco de dados

INRIA. Além da utilização do HOG, ao invés do gradiente de Sobel, como característica para obtenção da tabela de probabilidade, a máscara de pré-filtragem M deste trabalho é mais adequada que a de (Liu et al., 2014) sem o procedimento de otimização, conforme pode ser visto na Figura 3. Conforme apresentado na Equação 1, a máscara de pré-filtragem de (Liu et al., 2014) é baseada apenas no desvio padrão das características.




Figura 3: (a) Máscara de probabilidade desenvolvida neste trabalho e em (b) (Liu et al., 2014).

4 Resultados Experimentais

4.1 Metodologia dos Experimentos

Para validar os resultados, são empregadas duas bases de dados da literatura de detecção de pedestres: INRIA (Dalal and Triggs, 2005) e Caltech (Dollár, Wojek, Schiele and Perona, 2012). Como métricas para a análise dos resultados, são utilizados o *recall* e a taxa de eliminação de negativos (*txElimN*). Nos experimentos onde o método de FENGJC é validado isoladamente, as janelas de exemplos negativos são aleatoriamente amostradas das imagens da base de dados, antes de passarem pelo procedimento de FENGJC. Por isso, são realizadas 10 rodadas aleatórias com diferentes sementes (*seeds*) e como resultado são apresentados a média e o desvio padrão de cada métrica. Esse procedimento agrega robustez à validação e não foi empregado em (Liu et al., 2014). Por fim, um último processo de validação é o emprego do procedimento de FENGJC junto ao detector de pedestres ACF (Aggregated Channel Features) (Dollar et al., 2014), de forma a observar seu impacto na qualidade das detecções.

4.2 Experimentos

No primeiro conjunto de testes, o desempenho do método de FENGJC é analisado em diferentes cenários. Para realizar a estimativa do limiar L , é utilizada a metade dos exemplos positivos dos conjuntos de treino das bases de dados. Os exemplos positivos são obtidos por meio das anotações existentes nos conjuntos dos bancos de dados. Existem, respectivamente, 1236 e 589 pedestres anotados nos conjuntos de treino e teste da base de dados INRIA e 12249 e 998 nos conjuntos de treino e teste da base de dados Caltech. Já os exemplos negativos são obtidos por meio de amostragem aleatória de 5000 janelas dessas bases. Desta forma,

o desvio padr o   exibido apenas para a txElimN.

A Tabela 1 apresenta os resultados da primeira rodada de experimentos. Para os casos onde o limiar foi obtido e testado na mesma base de dados, o *recall* foi muito pr ximo ou igual a 100%, enquanto a txElimN ficou em torno de 50%. Se utilizado em um est gio anterior ao processo de detec  o, o procedimento de FENGJC reduz em aproximadamente 50% o n mero de inspe  es necess rias por parte do detector em janelas de exemplos negativos, n o eliminando qualquer exemplo positivo a priori. Dependendo do tempo de detec  o do detector de pedestres, o ganho de tempo pode ser consider vel. Em (Liu et al., 2014), o *recall* foi de 99.02% com uma txElimN de 59.54% ap s o procedimento de otimiza  o, no banco de dados INRIA,  nico caso avaliado. Embora mais exemplos negativos tenham sido descartados em rela  o ao presente trabalho, procedimentos de FENGJC devem sempre buscar o maior *recall* poss vel. Por fim, quando se realiza o treinamento e o teste do procedimento de FENGJC em bases de dados diferentes, o desempenho sofre uma redu  o, devido as particularidades das distribui  es dos dados de cada base. Esse tipo de teste   desafiador na detec  o de pedestres e, geralmente, leva a uma redu  o de desempenho nos procedimentos sendo avaliados, conforme pode ser constatado em (Benenson et al., 2015).

Tabela 1: Resultados do procedimento de FENGJC nos bancos de dados INRIA e Caltech

Treino	Teste	<i>recall</i> (%)	txElimN (%)
INRIA-Treino	INRIA-Treino	100,00	55,09 $\pm$ 1,92
INRIA-Treino	INRIA-Teste	100,00	52,81 $\pm$ 1,55
INRIA-Treino	Caltech-Treino	89,41	73,29 $\pm$ 0,87
INRIA-Treino	Caltech-Teste	89,36	71,47 $\pm$ 0,84
Caltech-Treino	INRIA-Treino	100,00	39,56 $\pm$ 1,58
Caltech-Treino	INRIA-Teste	100,00	38,17 $\pm$ 1,51
Caltech-Treino	Caltech-Treino	99,98	50,70 $\pm$ 0,54
Caltech-Treino	Caltech-Teste	100,00	49,52 $\pm$ 0,62

Neste ponto, destaca-se a import ncia de uma das contribui  es deste artigo, que   a filtragem das magnitudes e orienta  es de interesse na constru  o do modelo estat stico do pedestre. Caso fossem utilizadas todas as magnitudes e orienta  es retornadas pelo HOG na constru  o do modelo estat stico, o resultado do procedimento de filtragem de negativos apresentaria uma redu  o de desempenho consider vel, conforme apresentado na Tabela 2. Apenas a base de dados INRIA-Treino foi empregado neste conjunto de experimentos, de forma que os resultados da Tabela 2 devem ser comparados com a primeira linha da Tabela 1. Considerar todas as magnitudes e orienta  es poss veis   o mesmo que n o utilizar a m scara de pr -filtragem M , que se mostra fundamental para o sucesso do procedimento de FENGJC.

Repare, por meio da Tabela 2, que empregar todos os valores de magnitude na constru  o do modelo   mais impactante que considerar todos

os valores de orienta  o, embora em ambos os casos o desempenho do procedimento de FENGJC apresente uma redu  o quando analisando o percentual de negativos eliminados. Al m disso, o resultado para limiares de magnitude diferentes de 70 tamb m   analisado nas duas  ltimas linhas da referida tabela. Por fim, a segunda linha da Tabela 2 mostra que a orienta  o de 90    respons vel, sozinha, por grande parte dos negativos eliminados.

Tabela 2: Influ ncia das magnitudes e orienta  es de interesse do HOG no procedimento de FENGJC.

Magnitude/ Orienta��o	<i>recall</i> (%)	txElimN (%)
≥ 70 / [90�, 60�, 30�, 0�, -30�, -60�]	100,00	44,24 $\pm$ 1,54
≥ 70 / [90�]	100,00	49,57 $\pm$ 1,61
≥ 0 / [90�, 60�, 30�, -30�, -60�]	100,00	6,16 $\pm$ 0,99
≥ 60 / [90�, 60�, 30�, -30�, -60�]	100,00	50,52 $\pm$ 1,92
≥ 80 / [90�, 60�, 30�, -30�, -60�]	100,00	48,62 $\pm$ 1,74

A Tabela 3 cont m o *recall* e a txElimN para diferentes tamanhos de leiaute do pedestre. Apenas uma rodada aleat ria   suficiente nesta an lise e a base de dados INRIA   empregada.

Tabela 3: *Recall* e txElimN para diferentes tamanhos de leiautes de pedestres ($\div 4 = 32 \times 16$ pixels).

Leiaute	$\div 16$	$\div 14$	$\div 12$	$\div 8$	$\div 4$	$\div 2$	$\div 1$
<i>recall</i>	98,06	98,54	100,00	100,00	100,00	100,00	100,00
txElimN	44,4	46,34	33,12	47,16	54,84	55,62	48,72

A Figura 4 apresenta os limiares L para cada tamanho de leiaute da Tabela 3, assim como a interpola  o dos valores de L . Repare que a curva de aproxima  o possui um comportamento de f cil predi  o, o que facilita a estimativa de L , reduzindo o custo computacional em um processo de detec  o multiescala.




Figura 4: Curva do limiar L para diferentes tamanhos de leiaute.

Por fim, a Tabela 4 cont m resultados do emprego do m todo de FENGJC junto ao detector ACF em tr s casos: antes da etapa de SNM, durante (1) treinamento e teste, (2) apenas o teste, e (3) ap s a SNM. O resultado individual do ACF   apresentado no caso (4). As m tricas de compara  o utilizadas s o o logaritmo da taxa m dia de perda ($\log average miss rate - \text{LogAvrMR}$)⁶, a

⁶Quanto menor o valor da LogAvrMR melhor.

precis o m dia (*average precision* - AP) e as taxas de elimina  o de positivos (txElimP) e falsos positivos (txElimFP), em rela  o ao n mero de detec  es, apenas no caso (3)⁷.

O caso 1 apresentou uma leve melhoria na qualidade, em termos da AP, e, em se tratando da LogAvrMR, uma leve deprecia  o. Isso indica que o detector foi mais preciso em suas detec  es, ao utilizar a FENGJC, contudo, alguns pedestres deixaram de ser encontrados. Nos caso 2 e 3, n o houve altera  o significativa da qualidade do detector, o que est  de acordo com algumas observa  es de (Hosang et al., 2014), onde, para algumas classes de objetos, os melhores m todos de *detection proposal*, quando associados a detectores de objetos, n o apresentaram ganhos ou perdas expressivas em rela  o ao detector utilizado de forma isolada.

Em todos os quatro casos acima, avaliou-se tamb m a pontua  o atribu da pelo classificador   detec  o antes de elimin -la. Foram descartadas detec  es com *PI* menor que o limiar *L* e pontua  o menor que 60. O objetivo desse limiar de 60   evitar que detec  es com alta pontua  o sejam eliminadas pelo m todo de FENGJC, sendo esse valor obtido por meio de uma an lise das pontua  es atribu das aos verdadeiros positivos. Por fim, ainda no caso 3, um baixo n mero de exemplos positivos e negativos, dentre as detec  es retornadas pelo *ACF*, foram eliminados, aproximadamente 0,02% e 2,38%, respectivamente. Isso ocorre, pois os exemplos negativos retornados pelo *ACF* s o aqueles que possuem *PI* pr xima aos dos exemplos positivos, como ocorre na Figura2(a). A m xima pontua  o atribu da pelo detector, dentre as detec  es negativas eliminadas, foi de 48,67, o que mostra que o limiar de 60   adequado, podendo at  mesmo ser reduzido.

Tabela 4: Avalia  o do procedimento de FENGJC junto ao detector *ACF* (INRIA).

Caso	LogAvrMR (%)	AP (%)	txElimP (%)	txElimFP (%)
1	18,25 ± 1,06	90,55 ± 0,46	—	—
2	18,16 ± 0,98	90,41 ± 0,70	—	—
3	18,17 ± 1,01	90,40 ± 0,74	0,02 ± 0,06	2,38 ± 0,39
4	18,17 ± 0,98	90,40 ± 0,70	—	—

5 Considera  es Finais

O presente trabalho abordou um procedimento de filtra  em de exemplos negativos e gera  o de janelas candidatas, empregando um modelo estat stico do pedestre que utiliza histograma de gradientes orientados. Foram utilizadas na constru  o do modelo, com base em um detalhado estudo, apenas orienta  es e magnitudes avaliadas como caracter sticas de imagens de pedestres, o que foi

⁷Na avalia  o de qualidade de um detector, a determina  o sobre o que   uma correta detec  o ou um falso positivo   feita por meio da an lise da m trica de pascal entre as detec  es e as anota  es de pedestres, conforme padronizado em (Doll r, Wojek, Schiele and Perona, 2012).

primordial para obten  o de resultados promissores. Foram conduzidas dezenas de experimentos para averiguar o *recall* e o percentual de negativos eliminados das bases de dados INRIA e Caltech. Observou-se uma taxa de elimina  o de exemplos negativos em torno de 50% para um *recall* m ximo, al m de uma boa adaptabilidade do m todo quando treinado em uma base e testado em outra. Por fim, a utiliza  o do m todo na sa da de um detector de pedestres foi realizada, obtendo-se resultados compat veis com os da literatura.

Refer ncias

- Benenson, R., Mathias, M., Timofte, R. and Van Gool, L. (2012). *Pedestrian detection at 100 frames per second*, CVPR.
- Benenson, R., Omran, M., Hosang, J. and Schiele, B. (2015). *Ten Years of Pedestrian Detection, What Have We Learned?*, ECCV.
- Dalal, N. and Triggs, B. (2005). *Histograms of Oriented Gradients for Human Detection*, CVPR.
- Dollar, P., Appel, R., Belongie, S. and Perona, P. (2014). *Fast Feature Pyramids for Object Detection*, TPAMI.
- Doll r, P., Appel, R. and Kienzle, W. (2012). *Crosstalk cascades for frame-rate pedestrian detection*, LNCS.
- Doll r, P., Wojek, C., Schiele, B. and Perona, P. (2012). *Pedestrian detection: An evaluation of the state of the art*, TPAMI.
- Ger nimo, D., L pez, A. M., Sappa, A. D. and Graf, T. (2010). *Survey of Pedestrian Detection for Advanced Driver Assistance Systems*, TPAMI.
- Hosang, J., Benenson, R. and Schiele, B. (2014). *How good are detection proposals, really?*, BMVC.
- Hosang, J. H., Benenson, R., Doll r, P. and Schiele, B. (2015). *What makes for effective detection proposals?*, TPAMI.
- Hyvri nen, A., Hurri, J. and Hoyer, P. O. (2009). *Natural Image Statistics: A Probabilistic Approach to Early Computational Vision.*, Springer Publishing Company, Incorporated.
- Liu, Y.-F., Guo, J.-M. and Chang, C.-H. (2014). *Low Resolution Pedestrian Detection Using Light Robust Features and Hierarchical System*, Pattern Recognition.
- Nguyen, D. T., Li, W. and Ogunbona, P. O. (2016). *Human Detection from Images and Videos*, Pattern Recognition.
- Uijlings, J., van de Sande, K., Gevers, T. and Smeulders, A. (2013). *Selective search for object recognition*, IJCV.
- Viola, P., Jones, M. J. and Snow, D. (2003). *Detecting pedestrians using patterns of motion and appearance*, IJCV.
- Yang, B., Yan, J., Lei, Z. and Li, S. Z. (2015). *Convolutional Channel Features For Pedestrian, Face and Edge Detection*, ICCV.
- Zhang, S., Benenson, R. and Schiele, B. (2015). *Filtered channel features for pedestrian detection*, CVPR.
- Zitnick, C. L. and Doll r, P. (2014). *Edge boxes: Locating object proposals from edges*, ECCV.