

Detecção de Desmatamento Ilegal na Floresta Amazônica Baseada em Processamento de Áudio

Aluno: Waldomiro J. G. Seabra^{1,*}
Coorientador: Juan G. Colonna^{1,†}
Orientador: Eduardo F. Nakamura^{1,‡}

¹Instituto de Computação – Universidade Federal do Amazonas (UFAM)
Av. General Rodrigo Octávio, 6200, CEP: 69080-900, Manaus – AM – Brasil

{*wjgs, †juancolonna, ‡nakamura}@icomp.ufam.edu.br

Abstract. *In this work, we present a sound detection method for chainsaw engines to combat illegal logging. Our approach uses the Wavelet Decomposition in high frequencies, which divides optimally the natural sounds class from the other classes and divides very well, although there is still overlap, the chainsaw class from the artificial sounds class. We used a one-class classifier method, the Support Vector Data Description (SVDD), that creates a hypersphere around the points representing the target class (chainsaws) into the feature space, thus being able to differentiate chainsaws from other natural and artificial sounds. It is shown that the method is efficient discriminating sounds of chainsaws from natural sounds (AUC = 96%), discriminating sounds of chainsaws and artificial sounds from natural sounds (AUC = 91%), but loses efficiency when tested against artificial sounds (AUC = 87%).*

Resumo. *Neste trabalho apresentamos um método de detecção de motosserras através de som para auxiliar no combate a extração ilegal de madeira. Em nossa abordagem é utilizada a decomposição Wavelet (W) nas altas frequências, o que divide de forma ótima a classe de sons naturais das demais classes e divide muito bem, apesar de ainda haver sobreposição, a classe de motosserras da classe de sons artificiais. Nós usamos um método de classificação de uma classe, o Support Vector data Description (SVDD), que cria uma hiperesfera ao redor do dos pontos que representam a classe alvo (motosserras) no espaço de características acústicas, desta forma sendo capaz de diferenciar motosserras de outros sons naturais e artificiais. Através dos experimentos realizados, concluímos que nossa abordagem é eficiente diferenciando sons de motosserras de sons naturais (AUC = 96%), diferenciando motosserras e sons artificiais de sons naturais (AUC = 91%), mas perde eficiência quando comparada com sons artificiais (AUC = 87%).*

1. Introdução

O desmatamento da Amazônia cresceu em ritmo acelerado nos últimos anos, colocando em risco a fauna e a flora da região [Greenpeace 2016]. Os métodos atuais para detectar esses atos incluem o uso de imagens obtidas por Veículos Aéreos Não Tripulados (VANT), imagens satelitais e fiscalização humana. Os dois primeiros são computacionalmente complexos e conseguem monitorar somente acima do nível das copas das árvores, e o terceiro é operativamente custoso e ineficiente, devido aos recursos humanos necessários.

Nós apresentamos aqui um método eficiente embarcando um modelo de classificação em sensores acústicos. Estes podem ser posicionados em áreas de proteção ambiental onde deseja-se impedir o corte ilegal de madeira. O processamento e reconhecimento automático de áudio é uma tarefa complexa, devido a elevada riqueza acústica da floresta, na qual, os sons podem ser de origem natural (cantos de aves, chuva) ou causados pela ação humana (voz, sons de barcos). O objetivo de nosso trabalho é identificar uma motosserra, ignorando todos os outros ambientais ou artificiais.

Para extrair o vetor de características de um áudio é usada a Decomposição Wavelet nas altas frequências. A decomposição Wavelet (W) permite decompor o sinal acústico, captado pelos sensores, utilizando um conjunto de funções ortogonais que podem ser dilatadas e transladadas no tempo [Graps 1995]. Aplicando-a nas altas frequências é possível observar uma clara separação entre as classe, como mostrado na Figura 5(a). Dos sinais resultantes da decomposição são gerados os elementos do vetor de características (Figura 1). Essa transformada é conhecida por ser mais rápida que a transformada rápida de Fourier tradicional. Isso torna o sensor mais rápido.

Métodos de classificação são técnicas frequentemente utilizadas para resolver problemas de tomada de decisão. Em nossa abordagem optamos por um método de classificação de uma classe (*One-Class Classifier*). Este consiste em classificar um objeto como pertencente ou não a uma classe alvo [Khan 2010]. O método utilizado é o Support Vector Data Description (SVDD) [Tax and Duin 2004]. O SVDD é um método vetorial que cria uma hipersfera, em torno dos exemplos da classe positiva no espaço vetorial definido pelo conjunto das características acústicas. Consequentemente, o SVDD rejeita todos os exemplos de teste que se encontram fora da hipersfera. A simplicidade do método permite que seja embarcado em nós sensores com poucos recursos de hardware, pois o modelo de classificação resulta num produto vetorial simples. Assim, podemos reduzir a complexidade do processamento, reduzir o consumo de bateria e aumentar o tempo de vida útil do sensor.

Para sumarizar a performance do método é utilizada a curva ROC (*Receiver Operating Characteristic*). Esta curva é gerada utilizando a taxa de verdadeiro positivos (TPR) e a taxa de falso positivos (FPR). Para avaliar o desempenho final do método, mediante a curva ROC, utilizamos a área sob a curva (*Area Under ROC Curve* - AUC). Esta métrica é uma forma de caracterizar cada curva ROC por um valor real e usá-lo para comparar performances.

Nos experimentos realizados neste trabalho observamos que o classificador obtém resultados ótimos quando a classe negativa usada é composta inteiramente por sons naturais ($\sim 96\%$). Quando sons artificiais são usados como classe negativa há uma perda de desempenho ($\sim 87\%$), isso ocorre pela semelhança entre alguns sons artificiais e o som característico das motosserras. Quando sons de motosserras são agrupados com sons artificiais na mesma classe positiva o classificador novamente obtém bons resultados ($\sim 91\%$). Estes resultados indicam que o sensor deve ser posicionado longe de fontes de sons artificiais como estradas ou margens de rios, inseridos dentro das unidades de conservação.

O restante do artigo está organizado da seguinte forma: a Seção 2 descreve os fundamentos teóricos utilizados no trabalho (Decomposição Wavelet, Classificação de uma Classe, Support Vector Data Description e Curvas ROC e AUC); a Seção 3 apresenta tra-

balhos relacionados que já abordaram o assunto de detecção de motosserras em operação através de áudio; a Seção 4 apresenta a abordagem para o sensor proposto neste trabalho; a Seção 5 explica a metodologia utilizada para obtenção dos resultados; a Seção 6 mostra os resultados obtidos no decorrer dos experimentos; por fim a Seção 7 faz uma pequena revisão do que foi apresentado no trabalho e cita possíveis formas de melhorar os resultados.

2. Fundamentos Teóricos

Formalmente, o sinal acústico captado pelo microfone do sensor é uma série temporal da forma $X(t) = \{x_1, x_2, \dots, x_N\}$, na qual seus valores representam a amplitude do som dentro do intervalo temporal $1 \leq t \leq N$, com duração máxima N . Um *frame* deste sinal pode ser obtido aplicando uma janela deslizante de tamanho $n < N$, o que resulta num subconjunto com k vetores da forma $\mathbf{x}_k = \{x_i, x_{i+1}, \dots, x_{i+n}\}$, com n valores consecutivos. Desta forma, o sinal original pode ser representado pelo conjunto $k = 1, 2, \dots, K$ de *frames* sucessivos.

2.1. Decomposição Wavelet

Neste trabalho, optamos pelo uso da Transformada Wavelet (\mathcal{W}) ao invés da Transformada de Fourier (\mathcal{F}) para realizar a extração das características acústicas que representam cada sinal. Esta escolha é fundamentada pela menor complexidade computacional da \mathcal{W} em comparação à Transformada Rápida de Fourier ($O(N) \leq O(N \log N)$).

A Wavelet utilizada neste trabalho é aplicada nas altas frequências ao invés da tradicional que decompõe as baixas frequências. Esta forma de decomposição foi utilizada pois sons gerados por motores possuem mais energia nas altas frequências como mostrado mais a frente na Seção 6. Desta forma é possível descrever melhor as diferenças entre motosserras e alguns sons da classe artificial, como motores de barcos, o que também é mostrado na Seção 6.

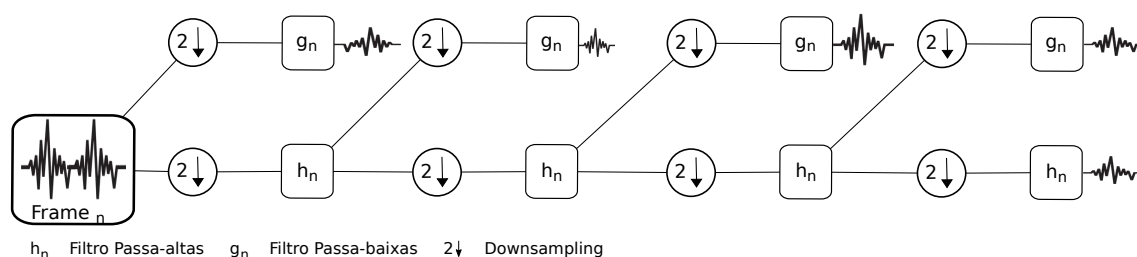


Figura 1. Exemplo de decomposição Wavelet dos frames e extração das características acústicas relacionadas às frequências principais utilizando quatro níveis do discrete wavelet transform (dwt).

A decomposição Wavelet discreta pode ser obtida pelo seu *esquema discreto - dwt*, o qual é definido como uma decomposição recursiva aplicando filtros passa-alta e passa-baixa ao sinal de entrada (Figura 1). Após a aplicação do *dwt* a cada *frame* do sinal \mathbf{x}_k obtemos $L = m + 1$ novos sinais no domínio $\mathcal{W}(\mathbf{x}_k)_m = \mathbf{y}_k^L$, onde m é a quantidade de níveis da decomposição. Cada um dos L sinais y_k^l possui a mesma duração que o *frame* original \mathbf{x}_k . Finalmente, podemos obter L coeficientes, que representam a energia de cada

\mathbf{y}_k^l , aplicando a Equação 1.

$$\mathbf{c}_k^l = \frac{1}{n} \sum_{i=1}^n (y_{ki}^l)^2, \quad (1)$$

onde $l = 1, 2, \dots, L$ e $i = 1, 2, \dots, n$ representa o índice temporal. Assim, os vetores de coeficientes $\mathbf{c}_k = [c_k^1, c_k^2, \dots, c_k^L]$ correspondentes a cada *frame* constituem o vetor de características acústicas utilizados para treinar o classificador descrito na próxima seção.

Para analisar a qualidade da extração de características utilizamos o plano da complexidade (\mathcal{C}_w) pela entropia (\mathcal{H}_w). Para isso é observada a separação entre as classes de nosso problema (motoserras, sons artificiais e sons naturais) no plano gerado. O plano obtido em nosso trabalho é mostrado na Sessão 6. \mathcal{H}_w é definida pela Equação 2, onde P é o histograma de entrada com tamanho K . \mathcal{C}_w é definida pela Equação 3 onde JSD é a divergência de Jensen-Shannon [Lin 1991].

$$\mathcal{H}_w = - \sum_{k=1}^K P_k * \ln P_k \quad (2)$$

$$\mathcal{C}_w = \mathcal{H}_w * JSD \quad (3)$$

2.2. Classificador de Uma Classe

A classificação de uma classe, diferente da classificação tradicional multi-classe, tem como objetivo identificar objetos da classe alvo (ou positiva) dentre várias outras, fazendo isso sem nenhuma amostra da classe negativa. Em nosso contexto de aplicação, a classificação multi-classe torna-se impossível devido a diversidade de sons da floresta. Por este motivo, escolhemos utilizar um método de classificação de uma classe, pois o objetivo é detectar motoserras em meio aos demais sons da floresta.

2.2.1. Support Vector Data Description

Support Vector Data Description (SVDD) foi inspirado na ideia do Support Vector Machine (SVM). O objetivo do SVDD é criar uma hipersfera dentro do espaço de características \mathbf{c}^l transformadas por uma função não linear chamada kernel. A hipersfera é caracterizada pelo centro \mathbf{a} e pelo raio R , contendo a maioria dos objetos da classe positiva utilizada para treinar o classificador [Chang et al. 2013]. Assim, dado um conjunto de treinamento $\mathbf{c}_k \in \mathbb{R}^L$, onde $k = 1, 2, \dots, K$ representa a quantidade de *frames* do áudio, SVDD resolve o seguinte problema de otimização:

$$\begin{aligned} & \text{minimizar}_{R, \mathbf{a}, \xi} R^2 + C \sum_{k=1}^K \xi_k \\ & \text{sujeito a: } \|\phi(\mathbf{c}_k) - \mathbf{a}\|_2^2 \leq R^2 + \xi_k \\ & \xi_k \geq 0, k = 1, 2, \dots, K \end{aligned} \quad (4)$$

onde, $\|\cdot\|_2$ é a norma euclidiana, $\phi(\mathbf{c}_k)$ é a função kernel que mapeia cada vetor de coeficientes obtidos pela transformada Wavelet a um espaço vetorial de dimensões maiores,

ξ é a variável de folga que permite relaxar as margens da função de decisão e $C > 0$ é um parâmetro definido pelo usuário que representa a tolerância aos *outliers* próximos à margem de decisão.

Para alcançar a relação ótima entre os falso positivos e os verdadeiro positivos deve-se escolher o volume da hipersfera controlado pelo parâmetro C e pelo parâmetro σ da função do kernel Gaussiano, como ilustrado na Figura 2. O objetivo final, é encontrar uma combinação ótima para esses parâmetros, que minimizem o volume da hipersfera, sem rejeitar amostras da classe positiva (motosserra), pois com um volume muito pequeno apareceria uma quantidade elevada de falso negativos. O SVDD oferece a habilidade de realizar um mapeamento não linear dos dados para um espaço vetorial de dimensões maiores, aplicando o truque do kernel, sem incorrer num custo computacional adicional. Na Seção 6 apresentamos uma avaliação experimental demonstrando o efeito destes parâmetros.




Figura 2. Hipersfera do SVDD onde os círculos representam amostras da classe alvo e os triângulos representam amostras da classe negativa (*outliers*).

2.3. Curva ROC e AUC

Neste trabalho, utilizamos as curvas ROC (*Receiver Operating Characteristic Curve*) para estimar o desempenho de nosso método. Devido a que este tipo de curvas foram definidas somente para os casos binários (somente duas classes), na metodologia incluímos classes negativas, as quais não correspondem ao som das motosserras, para estimar a capacidade de rejeição do nosso método. Assim, uma curva ROC pode ser gerada traçando a taxa de verdadeiro positivos (TPR) contra a taxa de falso positivos (FPR) enquanto varia-se o limiar de decisão entre zero e um [Fawcett 2006], definidas como:

$$TPR = \frac{TP}{TP + FP}, \quad (5)$$

$$FPR = \frac{FP}{FP + TN}. \quad (6)$$

Assim, para cada observação é atribuída uma classe e comparada com a classe correta. Desta forma, a probabilidade condicional de detecção torna-se uma função de probabilidade dos falsos alarmes e nos ajuda a selecionar o modelo ótimo. O modelo ótimo é aquele que maximiza a área sob a curva (AUC), independentemente da distribuição de classe. Portanto, esta métrica é adequada para entender o gráfico ROC como um único valor escalar que indica o desempenho do classificador (Figura 5(b)). O AUC varia no intervalo $0 \leq AUC \leq 1$. Assim, quanto maior é o AUC, melhor é o desempenho do reconhecimento.

3. Trabalhos Relacionados

Nos trabalhos de [Papán et al. 2012] e [Soisiinthorn and Rujipattanapong 2007] métodos baseados em autocorrelação são propostos, entretanto tais métodos não são adequados para uma aplicação real na Amazônia devido a riqueza acústica da floresta e pela possível ocorrência de sons artificiais. Nestes trabalhos, a função de autocorrelação foi aplicada para extrair a frequência fundamental dos sinais, porém, os harmônicos e as sub-bandas de frequências que caracterizam os sons artificiais foram ignorados. Além disso, a função de autocorrelação é sensível aos ruídos ambientais. Dos trabalhos anteriormente citados nenhum leva em consideração a ocorrência de sons não naturais.

Na abordagem apresentada por [Colonna et al. 2016b] foi proposto o uso de redes de sensores acústicos sem fio para detecção de motosserras. Neste caso, foi utilizada a transformada de Fourier (*FFT*) para extrair as características acústicas mais relevantes representadas pelos coeficientes Mel (*Mel Frequency Cepstral Coefficient* - MFCC). Posteriormente, aplicou-se apenas uma função kernel não paramétrica para estimar a densidade de probabilidade dos principais MFCCs. Entretanto, o critério de rejeição foi determinado empiricamente.

Nenhum dos trabalhos relacionados utiliza transformada Wavelet para obtenção das características do áudio, foi preferido utilizar esta transformada pela baixa complexidade computacional ($O(N)$) e seu esquema de processamento em tempo real. Outro diferencial deste trabalho é o uso do Support Vector Data Description cujo modelo de classificação resulta num produto vetorial simples e que consegue rejeitar amostras desconhecidas.

4. Abordagem

Para abordar o problema de fiscalizar áreas de floresta contra corte ilegal de madeira, é proposto neste trabalho o uso de uma Rede de Sensores Acústicos Sem Fio (RSASF). Estas redes consistem em um conjunto de dispositivos autônomos com processamento local, capazes de monitorar as condições acústicas do ambiente em diferentes locais [Bertrand 2011]. Estes sensores obtêm as amostras de áudio do ambiente e processam as mesmas localmente, evitando a transmissão de dados brutos.




Figura 3. Sensor acústico com o método proposto embarcado.

A Figura 3 exemplifica o método embarcado no nó sensor. Nesta figura, o sensor realiza a leitura sonora do ambiente e segmenta o sinal em *frames*. O vetor de características c_k^L correspondente a cada *frame*, extraído utilizando a decomposição Wavelet nas altas frequências com as bases “Haar”, é representado pelo histograma da Figura 3. Este vetor de características é classificado localmente aplicando o modelo SVDD previamente treinado, e se uma motosserra for detectada, um alarme é enviado através da rede de sensores até os agentes ambientais.

5. Metodologia Experimental

A base de dados utilizada é composta por 12 áudios de motosserras (classe positiva); 33 áudios com sons naturais (primeira classe negativa); 22 áudios com sons artificiais (segunda classe negativa); e uma segunda classe positiva com 34 amostras, concatenando todos os sons de motosserras com sons artificiais. Além disso, uma terceira classe negativa com 55 amostras foi criada, concatenando todos os sons naturais e artificiais. Todos os áudios possuem frequência de amostragem igual a 22 050 Hz e duração N variável. Cada áudio foi dividido em *frames* com um segundo de duração sem sobreposição. A base da transformada Wavelet utilizada é “Haar” com quatro níveis.

Primeira etapa da avaliação: O experimento foi realizado em duas etapas, para poder avaliar o erro de generalização esperado pelo modelo de classificação (como recomendado em [Colonna et al. 2016a]). A primeira etapa utiliza validação cruzada por áudio, onde a cada iteração, todos os *frames* pertencentes ao mesmo áudio de motosserra neste caso, são separados da classe positiva e utilizados como conjunto de teste. Os *frames* restantes da classe positiva são utilizados para treinar o modelo SVDD. Após o treino, o conjunto de teste é avaliado. Desta forma, é possível atribuir uma pontuação para cada *frame* de teste representando a confiança de pertencer à classe positiva. Esta iteração é repetida até que todos os áudios da classe motosserra, com seus respectivos *frames*, são avaliados.

Segunda etapa da avaliação: Após a obtenção da pontuação de todos os *frames* da classe positiva, nesta segunda etapa, são avaliados todos os *frames* das classes negativas, obtendo-se um valor de pontuação para cada um deles. Neste caso, não é necessário separar um conjunto de teste para a classe negativa, devido a que o modelo de classificação é criado considerando somente a classe positiva. Esta é a principal vantagem de se utilizar SVDD. Nesta etapa, os parâmetros da função kernel e C não foram alterados, isto é, permanecem os mesmos valores que foram os utilizados para avaliar a classe positiva na primeira etapa.

Finalmente, com as pontuações obtidas na primeira e segunda etapa, criamos as curvas ROC e calculamos o AUC de cada uma destas. Para treinar o modelo SVDD, utilizamos o kernel Guassiano com o parâmetro σ , que representa a largura de banda deste kernel. Cada experimento foi repetido uma vez para cada combinação dos parâmetros $C = 1.0$ e $\sigma = \{1.0, 1.5, 2.0, 2.5, 3.0, 3.5, 4.0\}$. No total foram geradas 7 curvas ROC e valores de AUC para cada combinação das classes: positiva e negativa com sons naturais; positiva e negativa com sons artificiais; e positiva com as duas classes negativas, obtendo-se assim um total de 28 valores de AUC.

6. Resultados

Parte dos resultados de nossa metodologia é o uso de um método de extração de características acústicas que distinga de forma ótima as classes, tal método é a Wavelet nas altas frequências. Isto é mostrado pela visível separação entre as classes no plano da complexidade (\mathcal{C}_w) pela entropia (\mathcal{H}_w) mostrado na Figura 5(a). É possível perceber uma clara separação entre a classe de sons naturais e as outras duas, enquanto a classe de sons de motosserras e a classe de sons artificiais possuem uma intercessão entre elas graças a semelhança entre sons de motosserras e outros motores.

	Motosserras vs Naturais	Motosserras vs Artificiais	Motosserras vs Todos	Motores vs Naturais
$\sigma = 1.0$	0,939	0,7097	0,7945	0,9157
$\sigma = 1.5$	0,952	0,773	0,8392	0,9020
$\sigma = 2.0$	0,9528	0,8289	0,8747	0,8973
$\sigma = 2.5$	0,9594	0,8706	0,9035	0,8938
$\sigma = 3.0$	0,9639	0,8585	0,8974	0,8979
$\sigma = 3.5$	0,9643	0,8324	0,8812	0,8961
$\sigma = 4.0$	0,9610	0,8167	0,8700	0,8630

Tabela 1. Valores do AUC nos três experimentos.

Para avaliar nosso método, calculamos as curvas ROC e os valores de AUC nas três configurações descritas na seção anterior utilizando validação cruzada por áudio. A Tabela 1 apresenta os resultados do AUC para as diferentes configurações do parâmetro σ . Os melhores valores de cada configuração encontram-se ressaltados em negrito. Nesta tabela, podemos notar que o desempenho do método quando comparado contra a primeira classe negativa obteve um resultado próximo do máximo (96%). Isto é devido à diferença acústica que caracteriza os sons ambientais e os sons das motosserras. O espectrograma da Figura 4 ilustra as diferenças de energia entre as bandas de frequências em função do tempo para três exemplos da nossa base.




Figura 4. Exemplos de espectrogramas correspondentes a uma amostras de cada classe.

Na Figura 4 observamos que as baixas frequências, entre 0 Hz e 5000 Hz, dos motores de barcos, incluídos na segunda classe negativa, possuem um padrão similar às frequências das motosserras. No entanto, as motosserras ainda incluem uma maior quantidade de energia nas altas frequências. Embora exista uma diferença visual, dentro do espaço de características estas diferenças não são suficientes para conseguir uma separação destas classes. Por este motivo, o valor de AUC correspondente à coluna “Sons artificiais” atingiu 87% do valor máximo. Na terceira coluna, quando todos os sons da classe negativa são apresentados ao classificador, o valor de AUC aumenta, alavancado pelos resultados dos sons naturais. Na última coluna é possível observar que o método é capaz de separar sons de motosserras e artificiais de sons naturais obtendo um resultado de 91%. Estes valores mostram uma melhora dos resultados quando comparado com trabalhos anteriores, principalmente no experimento de motosserras e sons artificiais contra sons naturais [Seabra et al. 2017].

A Figura 5(b) apresenta as curvas ROC dos melhores valores da Tabela 1. É possível observar novamente que o método é mais preciso quando testado contra sons naturais

e perde precisão contra sons artificiais. Isso ocorre porque alguns sons não naturais (motores de barcos ou carros) são muito semelhantes aos sons produzidos por uma motosserra. Esta característica revela, que para uma aplicação real, a melhor localização dos sensores seria longe de estradas e margens dos rios, para minimizar a probabilidade de falso positivos. Por outro lado quando tiramos proveito desta semelhança o método volta a ganhar precisão. Isto mostra que sensores treinados para reconhecer sons artificiais podem ser posicionados em florestas densas ou estradas ilegais para monitorar atividades na região, uma vez que nelas não deveria haver presença de sons artificiais.

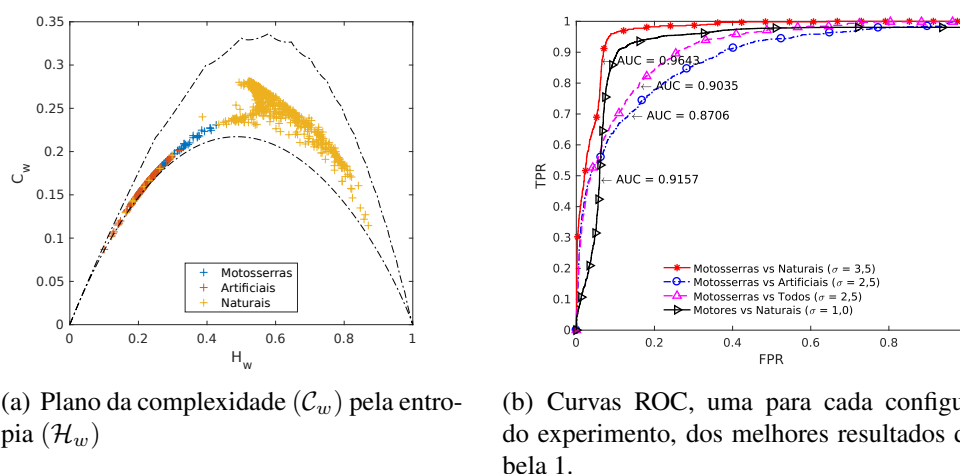


Figura 5. Resultados obtidos em nosso trabalho.

Observa-se também que nas curvas, com exceção da curva referente ao experimento de motosserras e sons artificiais vs sons naturais, a taxa de falso positivos é próxima de zero até a taxa de verdadeiro positivos ser de aproximadamente 30%. Logo é possível estabelecer um limiar de decisão, para o qual os resultados são totalmente confiáveis. A confiabilidade dos resultados é importante, pois um falso positivo poderia resultar no deslocamento desnecessário de agentes ambientais e por consequência gastar recursos, diminuindo a confiabilidade do sistema completo.

7. Conclusão

Neste trabalho apresentamos um método capaz de detectar o som de uma motosserra para ser embarcado num nó sensor de detecção de corte e extração ilegal de madeira. Nosso método inclui a decomposição Wavelet nas altas frequências com *dwt* para criação dos vetores de características acústicas e a técnica de classificação SVDD. Os resultados foram avaliados com as curvas ROC e a área sob as curvas (AUC).

Nos experimentos observamos que o método possui um desempenho ótimo quando sons naturais são usados como classe negativa, porém o desempenho diminui quando há sons não naturais similares ao de uma motosserra. Esta similaridade entretanto, alavanca os resultados quando sons de motosserras são agrupados na mesma classe positiva que sons artificiais. Na maioria dos experimentos é possível observar um limiar onde não há falso positivos mas há um número razoável de verdadeiro positivos.

Os resultados obtidos neste trabalho mostram que seria viável instalar sensores em áreas de preservação ambiental em risco, podendo-se prever extração ilegal e des-

matamento não permitido na floresta amazônica. Esses sensores devem ser posicionados longe de estradas e margens de rios para evitar ocorrência de falsos alarmes. E seria viável também instalar sensores para detectar ação humana em áreas onde não deveriam haver sons de origem artificial. Para melhorar os resultados gerais do reconhecimento podemos: 1) aprimorar a extração de características acústicas, 2) melhorar o método de classificação.

Referências

- Bertrand, A. (2011). Applications and trends in wireless acoustic sensor networks: a signal processing perspective. In *Communications and Vehicular Technology in the Benelux (SCVT), 2011 18th IEEE Symposium on*, pages 1–6. IEEE.
- Chang, W.-C., Lee, C.-P., & Lin, C.-J. (2013). A revisit to support vector data description. *Dept. Comput. Sci., Nat. Taiwan Univ., Taipei, Taiwan, Tech. Rep.*
- Colonna, J. G., Gama, J., & Nakamura, E. F. (2016a). *How to Correctly Evaluate an Automatic Bioacoustics Classification Method*, volume 9868 of *Advances in Artificial Intelligence. Lecture Notes in Computer Science (LNCS)*, pages 37–47. Springer International Publishing.
- Colonna, J. G., Gatto, B., Dos Santos, E. M., & Nakamura, E. F. (2016b). A framework for chain-saw detection using one-class kernel and wireless acoustic sensor networks into the amazon rainforest. In *Mobile Data Management (MDM), 2016 17th IEEE International Conference on*, volume 2, pages 34–36. IEEE.
- Fawcett, T. (2006). An introduction to roc analysis. *Pattern Recognition Letters*, 27(8):861–874.
- Graps, A. (1995). An introduction to wavelets. *IEEE computational science and engineering*, 2(2):50–61.
- Greenpeace (2016). Desmatamento dispara na amazônia. disponível em: <https://goo.gl/3ruDOM>.
- Khan, S. S. (2010). *Kernels for One-Class Nearest Neighbour Classification and Comparison of Chemical Spectral Data*. PhD thesis, College of Engineering and Informatics, National University of Ireland.
- Lin, J. (1991). Divergence measures based on the shannon entropy. *IEEE Transactions on Information theory*, 37(1):145–151.
- Papán, J., Jurečka, M., & Púchyová, J. (2012). Wsn for forest monitoring to prevent illegal logging. In *Computer Science and Information Systems (FedCSIS), 2012 Federated Conference on*, pages 809–812. IEEE.
- Seabra, W. J. G., Colonna, J. G., & Nakamura, E. F. (2017). Sensor acústico para detecção de desmatamento ilegal na floresta amazônica. *IX Simpósio Brasileiro de Computação Ubíqua e Pervasiva (SBCUP)*.
- Soisinthorn, T. & Rujipattanapong, S. (2007). Deforestation detection algorithm for wireless sensor networks. In *Communications and Information Technologies, 2007. ISCIT'07. International Symposium on*, pages 1413–1416. IEEE.
- Tax, D. & Duin, R. (2004). Support vector data description. *Machine learning*, 54(1):45–66.