

Sensor Acústico para Detecção de Desmatamento Ilegal na Floresta Amazônica

Waldomiro J. G. Seabra^{1,*}, Juan G. Colonna^{1,†}, 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 of chainsaw engines to combat illegal logging into rain forests. Our approach introduces an one-class classification method able to detect only the sound of a chainsaw, rejecting all other natural and non-natural sounds, such as wind, rain, several animal calls, human speech, and boat engines. For this purpose, we chose Support Vector Data Description (SVDD) as the classification method, which creates a hypersphere around the points of the target class into the feature space. We apply then, the Wavelet transforms to process and extract the main features of the input acoustic signal in real time. The proposed method has low computational complexity, which benefits the use of sensors by saving processing and reducing battery consumption. It is shown that the method is efficient discriminating sounds of chainsaws from natural sounds (AUC = 96%), discriminating sounds of chainsaws and non-natural sounds from natural sounds (AUC = 95%), but loses efficiency when tested against non-natural sounds (AUC = 77%).*

Resumo. *Neste trabalho, apresentamos um método para detecção de sons de motosserras, com o objetivo de auxiliar no combate de extração ilegal de madeira nas florestas tropicais. Em nossa abordagem utilizamos um método de classificação de uma classe para detectar apenas o som de interesse e rejeitar todos os outros sons, sejam estes naturais ou artificiais, tais como: chuva, vento, diversas vocalizações de animais, fala humana, e motores de barcos. O método de classificação escolhido é o Support Vector Data Description (SVDD), que consiste em criar uma hipersfera ao redor dos pontos que representam a classe alvo no espaço de características acústicas. Aplicando a transformada Wavelet, para a extração das características acústicas, conseguimos processar o sinal de entrada em tempo real. Assim, o método proposto consegue processar e classificar os áudios em tempo real com baixa complexidade computacional, o que beneficia o uso de sensores por economizar processamento, reduzindo o consumo de bateria. 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 = 95%), mas perde eficiência quando comparada com sons artificiais (AUC = 77%).*

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 uma alternativa economicamente viável e eficiente, embarcando um modelo de classificação em sensores acústicos. Estes sensores podem ser posicionados em árvores nas bordas de áreas de proteção ambiental onde muitos dos cortes de madeira acontecem. 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). Tendo em vista esse aspecto, nosso objetivo é identificar apenas o som emitido por uma motosserra em operação, ignorando todos os outros sons ambientais ou humanos. Isto requer o uso de um método baseado na teoria de aprendizagem de máquina, sem a necessidade de conhecer todos os sons a priori.

Métodos de classificação são técnicas frequentemente utilizadas na prática 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]. A classe alvo, chamada de classe positiva, é bem representada por um conjunto de exemplos apresentados ao classificador durante a fase de treino, enquanto tudo que não pertence a classe positiva, chamado de classe negativa, tem poucos ou nenhum exemplo na fase de treino [Tax and Martinus 2001].

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, minimizar o consumo de bateria e aumentar o tempo de vida útil do sensor.

Para extrair o vetor de características de um áudio é usada a Decomposição Wavelet. A transformada Wavelet (\mathcal{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]. Dos sinais resultantes da decomposição são gerados os elementos do vetor de características (Figura 1). Essa transformada com seu esquema discreto, é conhecida por consumir menos memória que a transformada rápida de Fourier tradicional (FFT). Isso torna o método mais leve.

Para sumarizar o desempenho de nosso método é utilizada a curva ROC (*Receiver Operating Characteristic*). Esta curva é gerada utilizando a taxa de verdadeiros positivos (TPR) e a taxa de falsos 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 os desempenhos.

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 diminuição de desempenho ($\sim 77\%$), 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 resultados ótimos ($\sim 95\%$). 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. Quando testado contra sons naturais é possível estabelecer um limiar de decisão onde não há falsos positivos e um valor aceitável de acertos.

O restante do artigo está organizado da seguinte forma: a Seção 2 descreve os fundamentos teóricos utilizados no trabalho; a Seção 3 apresenta os trabalhos relacionados que já abordaram o problema de detecção de motosserras; a Seção 4 apresenta a abordagem proposta; a Seção 5 explica a metodologia experimental utilizada; a Seção 6 mostra os resultados obtidos no decorrer dos experimentos; as conclusões e direções futuras encontram-se na Seção 7.

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 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 $L = 2^m$ 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 y_k^l , aplicando a Equação 1.

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

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.




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

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 motosserras 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:

$$\text{minimizar}_{R, \mathbf{a}, \xi} R^2 + C \sum_{k=1}^K \xi_k, \quad (2) \quad \text{sujeito a: } \|\phi(\mathbf{c}_k) - \mathbf{a}\|_2^2 \leq R^2 + \xi_k \quad (3)$$

$$\xi_k \geq 0, \quad k = 1, 2, \dots, K$$

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 verdadeiros positivos deve-se escolher o volume da hipersfera controlado pelo parâmetro C e pelo parâme-

tro σ da função do kernel Gaussiano, como ilustrado na Figura 2. O objetivo final, é encontrar uma combinação ótima para esses parâmetros, que minimize 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 este tipo de curva ser definida 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 verdadeiros positivos (TPR) contra a taxa de falsos positivos (FPR) enquanto varia-se o limiar de decisão entre zero e um [Fawcett 2006], definidas como:

$$TPR = \frac{TP}{TP + FP}, \quad (4)$$

$$FPR = \frac{FP}{FP + TN}. \quad (5)$$

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 das classes. Portanto, esta métrica é adequada para entender o gráfico ROC como um único valor escalar que indica o desempenho do classificador (Figura 5). 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 [Soisinthorn and Rujipattanapong 2007] foram propostos métodos baseados em autocorrelação, 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. Esta transformada foi escolhida por sua baixa complexidade computacional ($O(N)$) e seu esquema de processamento em tempo real. O segundo diferencial deste trabalho é o uso do Support Vector Data Description cujo modelo de classificação resulta num produto vetorial simples que consegue rejeitar amostras desconhecidas.

4. Abordagem

Para abordar o problema de fiscalizar áreas de floresta contra corte ilegal de madeira, nosso trabalho propõe o uso de uma Rede de Sensores Acústicos Sem Fio (RSASF). Estas redes consistem em um conjunto de dispositivos autônomos disseminados em um ambiente remoto, com a finalidade de monitorar e coletar dados [Pereira et al. 2016]. Em nosso caso 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.

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 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.




Figura 3. Sensor acústico com o método proposto embarcado.

	Experimento 1	Experimento 2	Experimento 3	Experimento 4
Classe Positiva	Motosserras	Motosserras	Motosserras	Motosserras e Sons Artificiais
Classe Negativa	Sons Naturais	Sons Artificiais	Sons Naturais e Sons Artificiais	Sons Naturais

Tabela 1. Composição das classes para cada configuração dos nossos experimentos. Nota-se que a classe motosserras sempre fez parte da classe positiva.

5. Metodologia Experimental

As bases de dados utilizada, como mostrada na Tabela 1, são composta por: 12 áudios de motosserras (classe positiva); 33 áudios com sons naturais (primeira classe negativa); 22 áudios com sons artificiais (segunda classe negativa); uma terceira classe negativa com 55 amostras, concatenando todos os sons naturais e artificiais; e uma segunda classe positiva com 34 amostras, concatenando todos os sons de motosserras com sons 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 seu 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 ao modelo de classificação ser 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 $C = \{0.1, 1.0\}$ e $\sigma = \{0.5, 0.6, 1.0, 1.5\}$. No total foram geradas as curvas ROC e os valores de AUC para cada combinação descrita na Tabela 1, obtendo-se assim um total de 32 valores de AUC.

6. Resultados

Para avaliar nosso método, calculamos as curvas ROC e os valores de AUC nas quatro configurações descritas na seção anterior utilizando validação cruzada por áudio. A Ta-

bela 2 apresenta os resultados do AUC para as diferentes combinações dos parâmetros σ e C . 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.

$\sigma \backslash C$	Experimento 1		Experimento 2		Experimento 3		Experimento 4	
	0,1	1,0	0,1	1,0	0,1	1,0	0,1	1,0
0,5	0,966	0,969	0,704	0,775	0,801	0,847	0,952	0,950
0,6	0,958	0,961	0,650	0,740	0,764	0,822	0,951	0,947
1,0	0,951	0,955	0,600	0,663	0,730	0,771	0,949	0,948
1,5	0,951	0,954	0,597	0,649	0,728	0,762	0,946	0,945

Tabela 2. Valores do AUC nos quatro experimentos.




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 “Experimento 2” somente atingiu 77% do valor máximo. No experimento 3, quando todos os sons da classe negativa são apresentados ao classificador, o valor de AUC aumenta para 84%, avançado pelos resultados dos sons naturais. Na última coluna da tabela, experimento 4, é mostrado mais uma vez um valor próximo do máximo (95%), quando sons de motosserras são agrupados com outros sons artificiais e avaliados contra os sons naturais.

A Figura 5 apresenta as curvas ROC dos melhores valores da Tabela 2. 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.

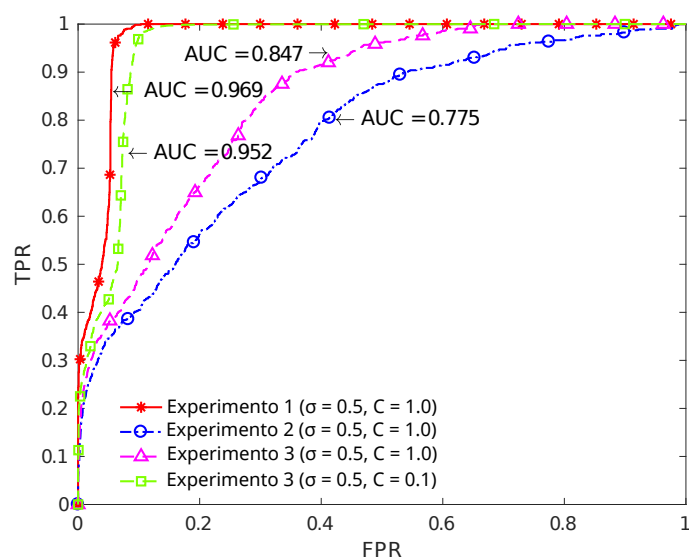


Figura 5. Curvas ROC, uma para cada configuração do experimento, dos melhores resultados da Tabela 2.

Observa-se também que a taxa de falsos positivos é zero quando a taxa de verdadeiros positivos é aproximadamente 22% nos experimentos com sons naturais. 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 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 artificiais similares ao de uma motosserra. Esta similaridade entretanto, alavanca os resultados quando sons de motosserras são agrupados na mesma classe positiva que sons artificiais. Contra sons naturais 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 desmatamento não permitido na floresta amazônica. Também é mostrado a viabilidade da instalação de sensores em áreas densas de florestas ou estradas ilegais onde não deveriam existir sons de origem artificial. Esses sensores devem ser posicionados longe de estradas legais e margens de rios para evitar ocorrência de falsos alarmes.

Para melhorar os resultados gerais do reconhecimento podemos: 1) aprimorar a

extração de características acústicas, 2) melhorar o método de classificação. Portanto, como trabalho futuro pretendemos melhorar a separabilidade das classes experimentando outras bases para a transformada Wavelet que discriminem melhor as altas frequências. Outra possível técnica de classificação de uma classe, tal como 1NN (um vizinho mais próximo), será avaliada.

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 chainsaw 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.
- 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.
- Pereira, A. S., Silva, T. R. M. B., Silva, F. A., Loureiro, A. A. F., & Ruiz, L. B. (2016). Avaliando algoritmos para um elemento sensor autônomo. *Simpósio Brasileiro de Computação Ubíqua e Pervasiva*.
- Sosisinthorn, T. & Rujipattanapong, S. (2007). Deforestation detection algorithm for wireless sensor networks. In *Communications and Information Technologies, 2007. ISIT'07. International Symposium on*, pages 1413–1416. IEEE.
- Tax, D. & Duin, R. (2004). Support vector data description. *Machine learning*, 54(1):45–66.
- Tax, D. & Martinus, J. (2001). *One-class classification*. PhD thesis, TU Delft, Delft University of Technology.