

Compressão de Vocalizações de Anuros para Classificação de Espécies Usando Redes de Sensores Sem Fio

Javier J. M. Diaz¹, Juan G. Colonna¹, Rodrigo B. Soares¹
Eduardo F. Nakamura^{1,2}, Carlos M. S. Figueiredo²

¹Instituto de Computação (IComp)
Universidade Federal do Amazonas (UFAM)

²Núcleo de Estudos e Pesquisas em Computação (NEPComp)
Fundação Centro de Análise, Pesquisa e Inovação Tecnológica (FUCAPI)

{jjmd90, juancolonna, rborges.soares}@gmail.com

{eduardo.nakamura, mauricio.figueiredo}@fucapi.br

Abstract. *One of the most common problems in Wireless Sensor Networks (WSN) is to collect enough data to analyze some phenomenon and to maximize the network lifetime. By using an anura (frogs and toads) classification example, this paper shows how it is possible to significantly decrease the amount of samples collected without compromising the classification results. To do that, is proposed a methodology using Compressive Sensing (CS) that allows partially collected signal reconstruction. This is done by using a sparse basis that best represents the information used by the classifying software. We show how it is possible to keep a classification rate near to 98% using only 10% of the original data, beside the impact of this compression on the energy consumption, delivery rate and average delay of the network*

Resumo. *Um dos problemas mais comuns em redes de sensores sem fio (RSSFs) é coletar dados suficientes para analisar um determinado fenômeno maximizando o tempo de vida da rede. Utilizando o exemplo de classificação de anuros (sapos e rãs), este trabalho mostra como é possível reduzir a quantidade de amostras coletadas sem comprometer a precisão da classificação. Para isso, é proposta uma metodologia utilizando Compressive Sensing (CS) que permite a reconstrução de sinais parcialmente coletados. Isto é feito utilizando uma base esparsa que represente as informações usadas pelo classificador. Mostramos como é possível manter uma taxa de classificação de cerca de 98% utilizando apenas 10% da informação original, além do impacto desta compressão no consumo de energia, na taxa de entrega e no atraso médio da rede.*

1. Introdução

Redes de sensores sem fio (RSSFs) são cada vez mais utilizadas em aplicações de monitoramento ambiental [Wang et al. 2011]. Mediante o monitoramento de espécies é possível obter informações úteis para o entendimento e a preservação do ecossistema no qual a RSSF se encontra [Mainwaring et al. 2002]. Entretanto, ainda existem limitações do tempo de vida destas redes, devido à capacidade limitada das baterias [Gowrishankar et al. 2008, Rocha and Gonçalves 2008].

A utilização de RSSFs para monitoramento de anuros, é de grande utilidade nos campos da Ecologia e Biologia. Devido à sua relação com o ambiente, os anuros servem de referência para avaliar a qualidade do ambiente no qual vivem [Carey et al. 2001]. Isto é possível mediante a captação do áudio emitido pelos anuros para determinar as espécies presentes no local. No entanto, aplicações de classificação de anuros captam do meio mais informação que a necessária pelo classificador [Colonna et al. 2011], aumentando o tráfego e consumo de energia.

Utilizando técnicas de Compressive Sensing (CS) é possível diminuir a quantidade de amostras coletadas de um determinado sinal, para reconstruí-lo posteriormente. Para isso, basta que o sinal seja representável em uma base esparsa [Candes and Waking 2008, Ji and Carin 2007]. Em RSSFs a quantidade de amostras está diretamente relacionada ao consumo de energia da rede, assim como a quantidade de pacotes que trafegam pela mesma [Hempstead and Yang 2006, Buluso and Hu 2008].

Utilizando o classificador de anuros proposto por [Colonna et al. 2011] este trabalho mostra como é possível diminuir em até 90% a quantidade de amostras captadas e enviadas pela RSSF sem comprometer os resultados de classificação. Mediante a análise das frequências fundamentais de cada espécie, foi construída uma base esparsa que garante a reconstrução do áudio utilizando técnicas de CS. Além disso, o impacto da técnica em uma RSSF foi avaliado mediante simulações feitas no Network Simulator 2 (NS-2).

A utilização de CS em RSSFs é muito vantajosa pois reduz o consumo de energia desde a captação da informação, pois são captadas menos amostras. Além disso, a quantidade de informação que trafega pela rede diminui de acordo com a compressão utilizada. Já o processamento necessário para reconstruir o áudio é realizado fora da RSSF, evitando também consumo desnecessário de energia ao tratar o áudio comprimido.

O restante deste trabalho apresenta-se como segue. A seção 2 mostra os fundamentos e trabalhos relacionados. A seção 3 explica a metodologia adotada nos experimentos de CS. A seção 4 mostra o cenário de simulação adotado para representar a RSSF. Na seção 5 são apresentados os experimentos e, os resultados obtidos. Por último, a seção 6 apresenta as conclusões e propostas para trabalhos futuros.

2. Fundamentos e Trabalhos Relacionados

2.1. Compressive Sensing

O teorema de Nysquist diz que é necessário uma taxa de amostragem de no mínimo o dobro da frequência máxima presente no sinal, para recuperar esta sem *aliasing* nem perda de informação [Candes and Waking 2008]. Graças a técnicas de CS é possível recuperar certos sinais com uma quantidade de amostras muito menor que as requeridas pelo teorema de Nysquist [Luo et al. 2010, Ji and Carin 2007, Ji et al. 2009].

Compressive Sensing (CS) pode ser aplicado sempre que o sinal a ser reconstruído tiver duas propriedades básicas: esparsidade e independência linear (ou incoerência) [Candes and Waking 2008]. Uma vez garantida a esparsidade e a independência linear do sinal, é necessário gerar uma base ψ com componentes independentes do mesmo para utilizá-la durante a reconstrução [Baraniuk 2007].

A aplicação mais conhecida de CS é sua utilização em equipamentos de ressonância magnética. Estes equipamentos têm um alto custo de amostragem (grande quantidade

de amostras) e as imagens por eles geradas podem ser representadas em bases esparsas [Aelterman et al. 2010]. Estudos em áreas relacionadas mostram uma melhoria de 89% no tempo de reconstrução mantendo um erro de até 16% em relação a técnicas de reconstrução normais [Ji and Carin 2007].

Além disso, [Candes and Waking 2008] mostra como é possível aplicar a mesma metodologia a sinais de áudio gerados aleatoriamente utilizando amostragem parcial, seguida de reconstrução via minimização ℓ_1 . A metodologia proposta em [Candes and Waking 2008] é muito similar à utilizada neste trabalho. Entretanto, em vez de utilizar sinais gerados aleatoriamente, este trabalho utiliza vocalizações de anuros captadas em seu habitat, sujeitas aos ruídos reais.

2.2. Classificação de Anuros

Devido à íntima relação com seu habitat, os anuros são considerados como métrica de avaliação dos impactos ambientais em uma determinada região [Carey et al. 2001]. Entretanto, a tarefa de encontrar e classificar anuros diretamente no seu habitat não é trivial.

A classificação dos anuros pode ser feita de forma manual [Riede 1993], mediante a análise de gravações e seus espectros por especialistas, ou de forma automática, utilizando RSSFs como suporte para a captação e processamento de dados [Hu et al. 2005, Huang et al. 2009, Colonna et al. 2011].

Quando feita de forma manual, a qualidade da classificação de anuros está relacionada à experiência do especialista que a realiza [Colonna et al. 2011], podendo se tornar um processo lento, sujeito a falhas e intrusivo.

Os resultados de classificação utilizando meios automáticos variam entre 50% em [Taylor et al. 1996], 82,6% em [Huang et al. 2009] e 99,3% em [Colonna et al. 2011]. A grande diferença entre os resultados deve-se às informações utilizadas como base para a classificação. [Taylor et al. 1996] utiliza a intensidade dos pixels do espectrograma das gravações como referência para fazer a classificação.

Trabalhos como [Huang et al. 2009] e [Colonna et al. 2011] dividem o áudio captado em segmentos chamados sílabas e considerados a menor unidade de vocalização de um anuro, contendo assim as informações mais importantes para sua classificação.

Em [Huang et al. 2009] a classificação é realizada utilizando técnicas de *k-Nearest Neighbor (kNN)* e *Support Vector Machine (SVM)*, utilizando as sílabas como referência. Já [Colonna et al. 2011] acrescenta a utilização de *Mel-Fourier Cepstral Coefficient (MFCCs)* para melhorar os resultados. MFCCs são conhecidos por serem muito utilizados em reconhecimento de fala [Davis and Mermelstein 1980], . Por possuir melhores resultados em termos de classificação, este trabalho usa como base a técnica proposta por [Colonna et al. 2011] . No entanto, em vez de utilizar as gravações completas como entrada para o classificador, a quantidade de informação utilizada é reduzida em até 90%.

2.3. Gradient Projection for Sparse Reconstruction (GPSR)

Este trabalho utiliza um método para reconstrução esparsa mediante projeção de gradientes (GPSR) [Figueiredo et al. 2007]. O método proposto em [Figueiredo et al. 2007] toma como base o problema de otimização definido como:

$$\min_x = \frac{1}{2} (\| \mathbf{y} - \mathbf{A}\mathbf{x} \|_2)^2 + \tau \|\mathbf{x}\|_1 \quad (1)$$

Em que $\mathbf{x} \in \mathbb{R}^n$, $\mathbf{y} \in \mathbb{R}^k$, \mathbf{A} é uma matriz $k \times n$, τ é um parâmetro positivo, $\|v\|_2$ é a norma Euclidiana de v e $\|v\|_1 = \sum_i |v_i|$ é a norma ℓ_1 , ou distância de Manhattan, de v . Esta classe de problema é comum na área de processamento de sinais, sendo diretamente relacionado à estimativa de de observações em um sistema do tipo:

$$\mathbf{y} = \mathbf{A}\mathbf{x} + n \quad (2)$$

A presença do termo ℓ_1 na Equação 1 implica que os menores componentes de x na Equação 2 tendam a zero, resultando em soluções esparsas, cumprindo assim os requerimentos de CS.

3. Metodologia

3.1. Captação e análise dos áudios

Para a realização dos experimentos deste trabalho foram utilizadas amostras de áudio captadas diretamente na natureza de quatro espécies de anuros. Foram coletados entre 30 a 50 MB de áudio de cada espécie em arquivos do tipo *.wav*.

Como foi descrito na seção 2.1, para reconstruir um sinal baseado em uma amostragem esparsa, é necessário definir uma base de reconstrução que possua as principais características desse sinal. Tratando-se de classificação de anuros, as frequências dos sinais bioacústicos de cada espécie são um fator suficientemente representativo para fazer a classificação das mesmas [Colonna et al. 2011, Huang et al. 2009].

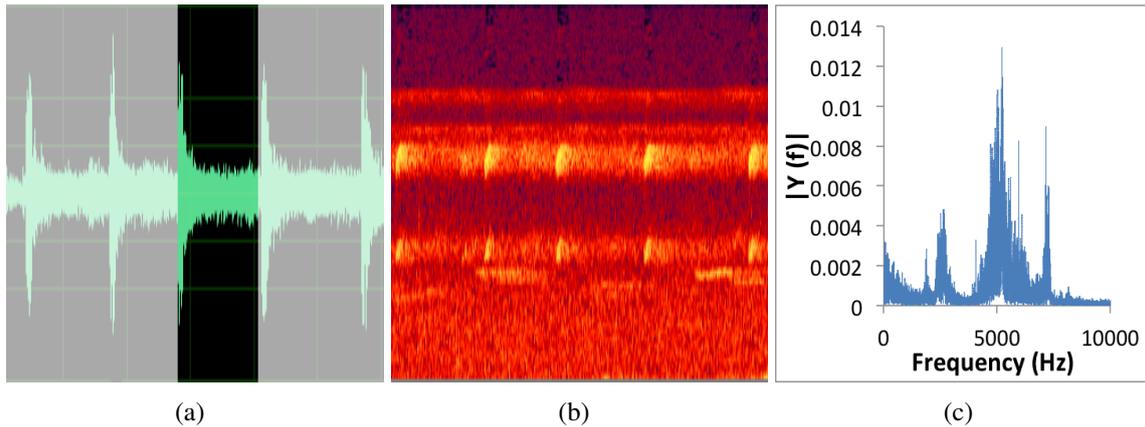


Figura 1. (a) Vocalizações da espécie *Adenomera andreae* com uma sílaba em destaque, (b) Espectrograma das vocalizações da mesma espécie e (c) Taxa de ocorrência de frequências com a aplicação da Transformada Rápida de Fourier (FFT) da espécie *Adenomera andreae*

Para a extração das características de cada espécie monitorada, foi feita uma segmentação em sílabas de acordo com a figura 1(a). Como pode ser visto na figura 1(b), apesar das frequências fundamentais da espécie apresentarem picos de maior intensidade,

elas continuam presentes nos momentos de repouso. Para maximizar o aproveitamento das frequências fundamentais, são consideradas todas as frequências presentes entre o início de uma vocalização e outra.

Uma vez separadas as sílabas, extraímos as frequências mais representativas e as utilizamos como critério de reconstrução e de classificação dos anuros. Para separar as frequências foi aplicada a Transformada Rápida de Fourier (FFT) nas sílabas e, a partir disso, consideramos as frequências com maior ocorrência em cada espécie. A geração do espectro de uma sílaba assim como as frequências fundamentais, pode ser visto na figura 1(c).

3.2. Base de reconstrução e parâmetros experimentais

Uma vez obtidas as frequências fundamentais de cada espécie, é necessário criar uma base de reconstrução de áudio. A base de reconstrução é a matriz \mathbf{A} , que será utilizada para avaliar e reconstruir o áudio de acordo com o vetor de amostragem x (Equação 2).

Por se tratar de áudio, é necessário que a base de reconstrução represente as características de uma onda sonora. Para isso, foram geradas ondas senoidais semelhantes às emitidas nas vocalizações dos anuros. Cada frequência foi convertida em uma onda e inserida como uma linha da matriz \mathbf{A} , condizente com 10 s, que é o tamanho das amostras que serão reconstruídas.

Uma vez gerada a base de reconstrução, e utilizando a implementação de GPSR proposta em [Figueiredo et al. 2007], é possível reconstruir gravações de anuros utilizando subamostragens de um áudio original. Para isso, definimos um parâmetro de *down-sampling* chamado α e geramos pacotes onde apenas uma em cada α amostras de um áudio é captada e enviada pela rede. Gravações completas correspondem a um *downsampling* de $\alpha = 1$, e a compressão aumenta de forma proporcional a α .

O objetivo principal das técnicas de CS é minimizar a perda de informação. Desta forma, mesmo para sinais gerados com *undersampling*, onde $\alpha > 1$, o resultado da reconstrução do sinal será equivalente (em número de amostras) a um sinal onde $\alpha = 1$.

4. Cenário de Simulação

Com o objetivo de avaliar o impacto da aplicação de CS em RSSFs foram realizadas simulações utilizando o *Network Simulator 2* (NS2) [Fall and Varadhan 2010] para os diferentes valores de α (de 5 a 100), de acordo com a seção 3.2. O cenário simulado foi um *grid* com 625 nós com células de 10 m onde, para simular uma situação real, as coordenadas $\langle x, y \rangle$ dos nós foram perturbadas de forma aleatória.

Foi definida uma posição de origem para o áudio gerado pelo anuro na qual foi colocado um nó emitindo informação para todos os nós vizinhos. Para enviar a informação foi realizado um *broadcast* e todos os nós que captassem a mensagem a transmitem para o sorvedouro de acordo com o protocolo de roteamento definido. As posições do nó gerador (anuro) e do sorvedouro foram definidas aleatoriamente em cada cenário.

As métricas utilizadas para avaliação do desempenho da RSSF foram: atraso médio de chegada dos pacotes, perda de pacotes e consumo de energia dos nós sensores. Para realizar o roteamento dos pacotes gerados foi utilizado o algoritmo *One-Phase Push Diffusion* (OPPD) [Cheng et al. 2008] que consiste em duas etapas: reconhecimento e

transmissão. O consumo de energia da rede é baseado nas informações presentes na tabela 1 e a energia inicial dos nós foi atribuída para 22.000 mAh, conforme sugerido em [Mainwaring et al. 2002].

Tabela 1. Energia utilizada por um sensor MICA em diversas operações de rede/sensoriamento. Tabela adaptada de [Mainwaring et al. 2002].

| Operação | Consumo em nAh |
|----------------------------------|----------------|
| Transmitir um pacote | 20.000 |
| Receber um pacote | 8.000 |
| Capturar uma amostra (analógica) | 1.080 |
| Capturar uma amostra (digital) | 0.347 |
| Ler uma amostra do ADC | 0.011 |
| Ler EEPROM | 1.111 |
| Escrever/Apagar EEPROM | 83.333 |

Para testar a variabilidade do ambiente foram considerados nove cenários de acordo com o alcance das vocalizações do anuro (20 m, 40 m e 60 m) e dos nós da rede (15 m, 30 m e 45 m). Cada cenário consiste no envio de 5 minutos de áudio (seção 3.1) com as posições dos nós, do sorvedouro e do anuro atribuídas aleatoriamente. Além disso, cada cenário foi repetido 33 vezes para estabelecer uma média dos parâmetros avaliados.

5. Resultados

Ao aplicar o parâmetro α nas gravações é possível ver uma redução de até 90% na quantidade de informação enviada pela rede de acordo com a figura 2. Uma vez feito o *undersampling* das gravações realizadas, os áudios foram testados no classificador proposto em [Colonna et al. 2011] para verificar a qualidade da reconstrução. Como pode ser visto na figura 2, conforme a compressão aumenta, a qualidade na classificação diminui. Foi constatado que utilizando valores de $\alpha < 15$ é possível manter a taxa de classificação próxima a 95%, mesmo utilizando apenas 10% do áudio original.

Para melhor entender o comportamento de cada método de classificação, foi feita uma regressão utilizando os valores de α utilizados e calculado o erro quadrático médio (EQM) em cada um dos casos. Na figura 3(a) podemos ver a regressão feita para o método kNN, onde temos um EQM_{kNN} de 1.6%.

Já na figura 3(b) temos o mesmo cálculo para o método SVM, onde o EQM_{SVM} é de 2.2%. Vale a pena ressaltar que apesar do EQM_{kNN} ser menor que o EQM_{SVM} , o kNN se mostra muito mais sensível a variações de α do que o SVM. Isso pode ser avaliado mediante o coeficiente angular das retas vistas na figura 3(a) e figura 3(b).

Além do impacto da compressão na classificação, também foi avaliado o desempenho da RSSF de acordo com os parâmetros definidos na seção 4. Para todas as avaliações feitas referentes à simulação foram calculados os intervalos de confiança e mostrados em cada gráfico utilizando dois cenários como referência: $\alpha = 1$, que representa o áudio original (pacotes de 1.8MB de dados) e $\alpha = 15$ (45 KB de dados), que representa a melhor compressão possível mantendo a taxa de classificação acima de 95%.

O primeiro parâmetro avaliado foi o consumo de energia, que foi calculado para cada um dos nove cenários propostos. Na figura 4 podemos ver a diferença no consumo de

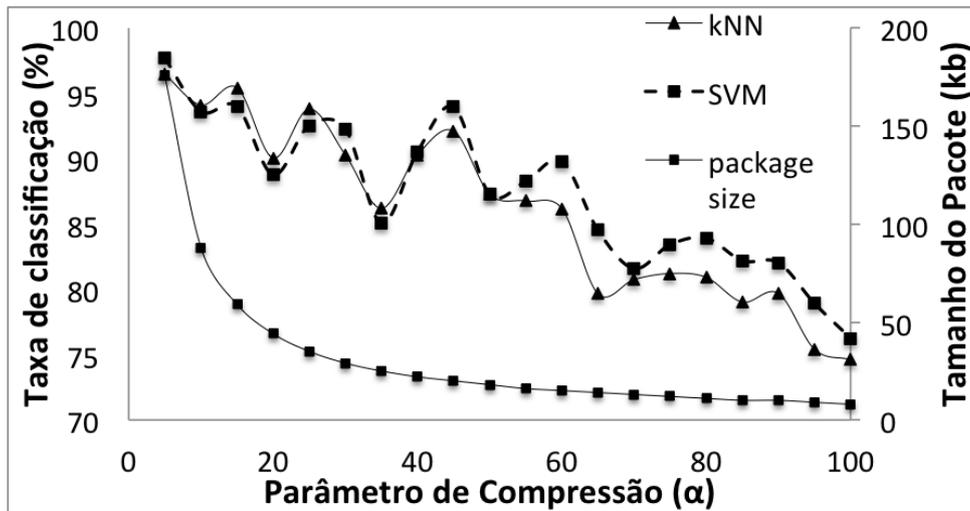


Figura 2. Tamanho do pacote de áudio em relação ao parâmetro α e taxa de classificação usando os métodos kNN e SVM propostos em [Colonna et al. 2011]

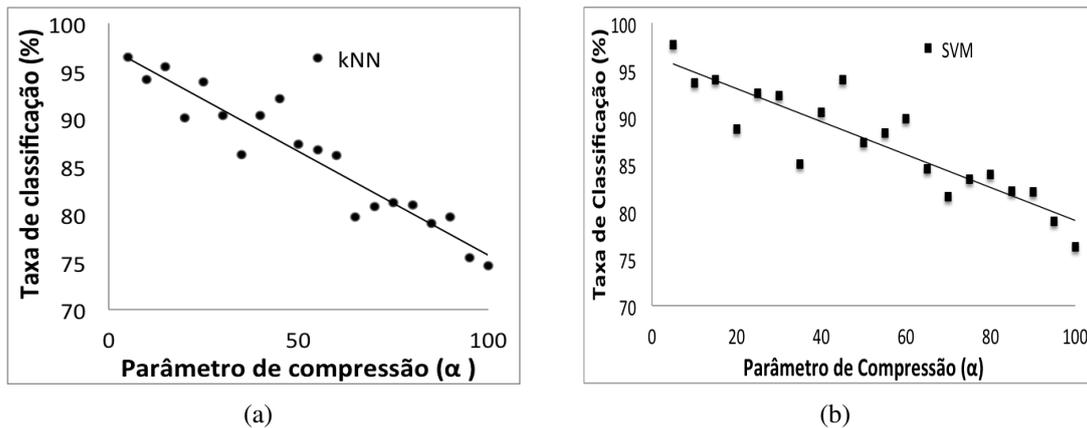


Figura 3. (a) Regressão representando a queda na qualidade da classificação de acordo com α utilizando método kNN e (b) utilizando o método SVM

energia quando utilizado o áudio original e o áudio comprimido. Com 90% de compressão o consumo de energia diminui em até oito vezes no cenário proposto na figura 4, onde o alcance de transmissão dos nós foi fixado em 15 m. Os cenários onde o alcance dos nós é definido para 30 m e 45 m possuem resultados muito similares aos mostrados na figura 4.

O segundo parâmetro avaliado foi o atraso médio dos pacotes enviados ao sorvedouro, a partir dos nós captadores. Como pode ser visto na figura 5(a), com o aumento do alcance das vocalizações dos anuros, o atraso também aumenta. Isso se deve ao fato de mais nós captarem o áudio, gerando assim um maior tráfego para a rede. No caso do áudio original, o atraso pode variar entre 59.9 s e 597.5 s. No caso do áudio comprimido, o atraso varia entre 1.8 s e 2.2 s. O experimento mostrado na figura 5(a) teve o alcance dos nós fixado em 15 m. No entanto, para outros cenários (30 m e 45 m) o comportamento do atraso é muito similar.

O último parâmetro avaliado foi a taxa média de entrega de pacotes. Na figura 5(b) é mostrado o cenário onde o alcance dos nós é fixado em 15 m (os resultados para 30

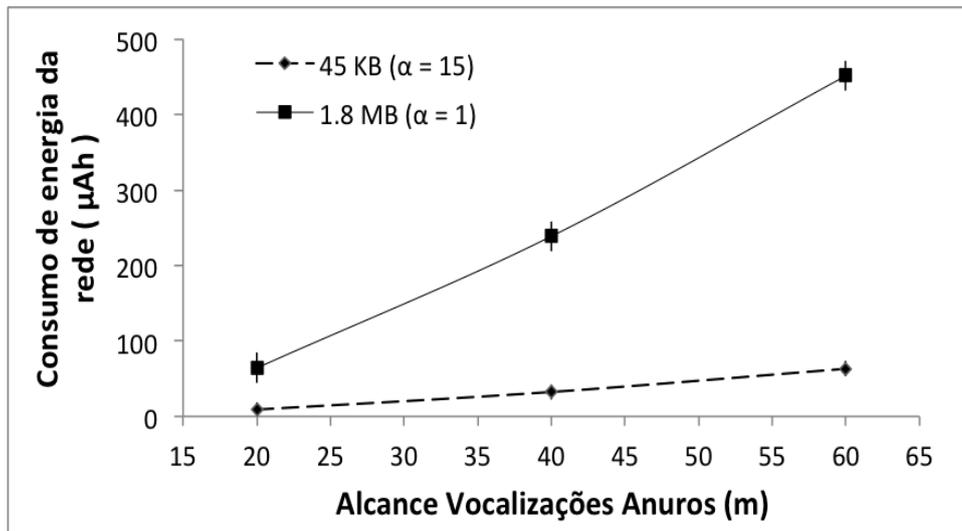


Figura 4. Consumo de energia de acordo com o tamanho do pacote e o alcance das vocalizações

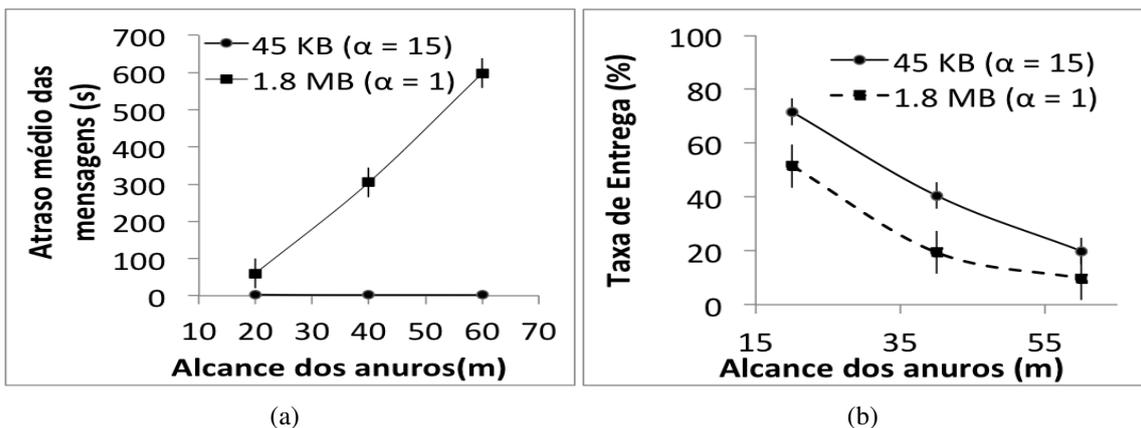


Figura 5. Atraso médio dos pacotes (a) com relação ao alcance das vocalizações e (b) Taxa média de entrega com relação ao alcance das vocalizações

m e 45 m são similares). Neste cenário é possível verificar que conforme o alcance das vocalizações dos anuros aumenta, a taxa de entrega diminui, pois o aumento deste alcance implica em um aumento na quantidade de nós que estão captando dados, aumentando assim o tráfego da rede e comprometendo a qualidade da entrega.

No caso da figura 5(b) é avaliada a taxa de entrega ao fixar o alcance das vocalizações em 20 m e variando o alcance dos nós. De modo análogo ao comportamento observado na figura 5(a), o aumento no alcance das vocalizações implica em uma saturação da rede, que compromete tanto o tempo de entrega como a quantidade de pacotes recebidos pelo sorvedouro.

6. Conclusões e Trabalhos Futuros

Este trabalho mostrou a viabilidade da aplicação de *Compressive Sensing* para classificação de anuros em redes de sensores sem fio utilizando uma abordagem prática com o auxílio de simulações.

O recurso mais crítico em RSSFs é a energia pois este tipo de redes são muito utilizadas em ambientes hostis ou de difícil acesso, dificultando assim a troca de baterias. Foi mostrado que é possível realizar uma compressão de até 90% sem comprometer a taxa de classificação. Esta compressão diminui o consumo de energia da rede em até 88% com relação ao consumo de uma rede que utiliza áudio original (sem compressão).

Além disso, avaliando os parâmetros de atraso médio e taxa de entrega da RSSF, é possível verificar que a utilização de CS melhora significativamente a qualidade da rede, conseguindo uma taxa de entrega até 70% maior do que uma rede sem a utilização desta técnica, e diminuindo o atraso em até 99% nos melhores casos.

O grande diferencial da aplicação de CS é a construção da base que será utilizada para reconstruir as amostragens realizadas. Ao escolher bem os parâmetros que serão utilizados nesta base, a reconstrução chega a ser quase perfeita com uma quantidade muito pequena de informação.

Entre os trabalhos futuros pretende-se implementar algoritmos distribuídos para maximizar a quantidade de informação obtida sem aumentar os custos. Além disso, métodos para uma construção automática da base de reconstrução, gerando assim uma rede sensível ao contexto no qual ela se encontra. A construção de bases de avaliação e reconstrução de áudio de outras espécies como primatas ou aves também se apresenta como uma idéia promissora se o objetivo é desenvolver métodos de monitoramento ambiental mas efetivos e generalizados.

Agradecimentos

Este trabalho foi parcialmente financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), concessão 575808/2008-0, e o Fundo de Amparo à Pesquisa no Amazonas (FAPEAM), concessão 2210.UNI175.3532.03022011 (Projeto Anura - PRONEX 023/2009).

Referências

- Aelterman, J., Luong, H. Q., Goossens, B., Pi, A. U., and Philips, W. (2010). Compass: a joint framework for parallel imaging and compressive sensing in mri. *Image Processing (ICIP)*.
- Baraniuk, R. (2007). Compressive sensing. *IEEE Signal Processing Magazine*.
- Buluso, N. and Hu, W. (2008). Lightweight acoustic classification for cane toad monitoring. *Asimolar Conference on Signals, Systems and Computers*.
- Candes, E. J. and Waking, M. B. (2008). An introduction to compressed sampling. *Signal Processing Magazine*.
- Carey, C., Heyer, W. R., Wilkinson, J., Alford, R., Arntzen, J. W., Halliday, T., Hungerford, L., Lips, K. R., Middleton, E. M., Orchard, S., and Rand, S. (2001). Amphibian declines and environmental change: Use of remote-sensing data to identify environmental correlates. *Conservation Biology*.
- Cheng, X., Wang, F., and Liu, J. (2008). Hybrid push-pull for data diffusion in sensor networks without location information. *International Conference on Communications (ICC)*.

- Colonna, J. G., Nakamura, E. F., and dos Santos, E. M. (2011). Classificação de anuros baseado em vocalizações para monitoramento ambiental pervasivo. *Simpósio Brasileiro de Computação Ubíqua (SBCUP)*.
- Davis, S. and Mermelstein, P. (1980). Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *IEEE Transactions on Acoustics, Speech, and Signal Processing*.
- Fall, K. and Varadhan, K. (2010). The ns manual. <http://www.isi.edu/nsnam/ns/ns-documentation.html>.
- Figueiredo, M. A. T., Nowak, R. D., and Wright, S. J. (2007). Gradient projection for sparse reconstruction: Application to compressed sensing and other inverse problems. *IEEE Journal of Selected Topics in Signal Processing*.
- Gowrishankar, S., Basavaraju, T. G., Manjaiah, D. H., and Sarkar, S. K. (2008). Issues in wireless sensor networks. *Proceedings of the World Congress on Engineering*.
- Hempstead, Q. W. and Yang, M. (2006). A realistic power consumption model for wireless sensor network devices. *Sensor and Ad Hoc Communications and Networks (SECON)*.
- Hu, W., Tran, V. N., Bulusu, N., Chou, C. T., Jha, S., and Taylor, A. (2005). The design and evaluation of a hybrid sensor network for cane-toad monitoring. *Symposium on Information Processing in Sensor Networks*.
- Huang, J. C., Yang, Y. J., Yang, D. X., and Chen, J. Y. (2009). Frog classification using machine learning techniques. *Expert Systems with Applications*.
- Ji, S. and Carin, L. (2007). Bayesian compressive sensing and projection optimization. *International Conference on Machine Learning (ICML)*.
- Ji, S., Dunson, D., and Carin, L. (2009). Multi-task compressive sensing. *IEEE Transactions on Signal Processing*.
- Luo, J., Xiang, L., and Rosenberg, C. (2010). Does compressed sensing improve the throughput of wireless sensor networks? *IEEE International Conference on Communications (ICC)*.
- Mainwaring, A., Polastre, J., Szewczyk, R., and Culler, D. (2002). Wireless sensor networks for habitat monitoring. *Proceedings of the 1st ACM international workshop on Wireless sensor networks and applications*.
- Riede, K. (1993). Monitoring biodiversity: analysis of amazonian rainforest sounds. *Ambio*.
- Rocha, V. and Gonçalves, G. (2008). Sensing the world: Challenges on wsns. *Automation, Quality and Testing, Robotics. (AQTR)*.
- Taylor, A., Watson, G., Grigg, G., and a. McCallum, H. (1996). Monitoring frog communities: An application of machine learning. *Proceedings of the 8th Innovative Applications of Artificial Intelligence Conference (IAAI)*.
- Wang, J., Cho, J., and Lee, S. (2011). An adaptive power-aware multi-hop routing algorithm for wireless sensor networks. *Information Technology: New Generations (ITNG)*.