

Sistemas Ubíquos Eficientes em Consumo de Energia por Meio da Redução de Dados

Thiago A.R. da Silva¹, Liliam B. Leal^{1,2}, Marcus V.S. Lemos^{1,2}
Carlos G.N. de Carvalho¹, José Bringel Filho¹, Raimir H. Filho²

¹Laboratório de Sistemas Onipresentes e Pervasivos (OPALA)
Universidade Estadual do Piauí (UESPI) – Teresina – PI – Brazil

²Laboratório de Redes de Sensores Sem Fio (LARES)
Universidade de Fortaleza (UNIFOR) – Fortaleza – CE – Brazil

{allissonribeiro02,liliamleal,marvinleamos}@gmail.com.br

cgnc@uespi.br,bringelfilho@gmail.com.br,raimir@unifor.br

Abstract. *Adaptability of ubiquitous systems is strongly related to the ability to continuously monitor the environment, which requires energy-efficient solutions. In this scenario, the adoption of mechanisms is required to increase the lifetime of the sensing layer, and consequently to provide high availability to context-aware services. A way to solve the problem is to adopt mechanisms for data reduction, but this may cause noise (errors) that impair accuracy of the application. Thus, this paper proposes an driven-error adaptive data reduction mechanism. Our solution is based on prediction, which is capable of modeling gathering data on parameters of linear function, which are used to recover the signal at the destination (sink node). In the experiment results, our mechanism could reduce about 89.58% to 97.22% of the packets sent on the network and therefore the amount of energy consumed by the devices.*

Resumo. *A adaptabilidade de sistemas ubíquos é fortemente relacionada a capacidade de monitorar continuamente o ambiente, o que requer soluções energeticamente econômicas. Neste cenário, faz-se necessária a adoção de mecanismos para aumentar o tempo de vida da camada de sensoriamento e, consequentemente, prover alta disponibilidade aos serviços sensíveis ao contexto. Uma forma de resolver o problema é adotar mecanismos de redução de dados, mas isso pode gerar ruídos (erros) que prejudiquem a acurácia da aplicação. Assim, este artigo propõe um mecanismo de redução de dados adaptativo ao erro. Esta solução é baseada em predição, a qual é capaz de modelar as coletas de dados em parâmetros de função linear, que são usados para recuperar o sinal no destinatário (sorvedouro). Nos resultados dos experimentos, nosso mecanismo, conseguiu reduzir cerca de 89,58% a 97,22% dos pacotes enviados na rede e consequentemente, a quantidade de energia consumida pelos dispositivos.*

1. Introdução

A computação ubíqua expandiu o universo de aplicações e serviços inteligentes, sensíveis ao contexto, propiciando o surgimento de novas formas de interação entre os seres humanos e tecnologias imersas transparentes [Hodges et al. 2012, Caceres and Friday 2012].

Usualmente, sistemas ubíquos são construídos sobre frameworks ou middlewares responsáveis por gerenciar informações oriundas de sensores de ambiente (e.g., temperatura, luminosidade, umidade) [Bringel Filho et al. 2010]. Com isso, é possível fornecer serviços adaptados as condições do ambiente e necessidades dos usuários, i.e., sensibilidade ao contexto [Baldauf et al. 2007, Bringel Filho and Agoulmine 2011].

A camada de sensoriamento presente nestes frameworks e middlewares de gestão contextual é, em geral, constituída de vários sensores sem fio [Bringel Filho et al. 2010], alimentados energeticamente por baterias [Anastasi et al. 2009]. Isso requer recarga ou substituição de suas fontes de energia, a fim de garantir alta disponibilidade ao sistema. Uma vez que sistemas ubíquos podem ser implantados em qualquer lugar e devem estar disponíveis a qualquer momento, caso venham a ser implantados em regiões de difícil acesso como florestas, áreas instáveis em consequência de movimentos tectônicos ou atividades vulcânicas, é indesejável e as vezes inviável a interferência humana ativa in-loco na camada de monitoramento (i.e., sensores sem fio). Neste cenário, é possível utilizar sensores alimentados por placas solares para ampliar a autonomia dos dispositivos e reduzir intervenções humanas. Entretanto, mesmo com recargas solares, dependendo da quantidade de energia consumida, as baterias não conseguem armazenar energia suficiente até a próxima recarga (período de sol). Para mitigar isso, pode ser aplicada redução dos dados, a qual tem efeitos positivos também na transmissão e recepção das coletas, diminuindo a quantidade de informação a ser enviada em locais que podem não ser equipados com infraestrutura de comunicação. Adiciona-se a isso, ainda, o fato de que o custo energético associado a transmissão é o principal fator redutor do tempo de vida dos nós sensores e, por consequência, do sistema ubíquo [Dietrich and Dressler 2009]. Portanto, é necessário a implementação de mecanismos capazes de reduzir a quantidade e frequência do envio de informações pelos nós sensores da camada de sensoriamento, minimizando assim o gasto energético dos nós sensores e prolongando o tempo de vida dos sistemas ubíquos.

Com base nisso, este artigo propõe um mecanismo de redução de dados guiado pelo erro de predição (chamado somente de *erro*), a fim de prolongar o tempo de vida de sistemas ubíquos, ajustando-se ao ruído para diminuir o impacto da compressão (modelagem de dados coletados). Este mecanismo pode ser integrado a qualquer camada de sensoriamento de frameworks e middlewares de gestão de informações contextuais, o que não é foco deste trabalho. Entretanto, nós utilizamos a framework definida em [Bringel Filho et al. 2010] para desenvolvermos a camada de sensoriamento em nosso estudo de caso. O nosso mecanismo suporta os requisitos de Qualidade da Informação de Contexto (QoC) associados com a informação gerada durante a redução de dados, tais como precisão e atualização (indicadores de QoC definidos em [Bringel Filho et al. 2010]). Assim, o mecanismo foi integrado a uma plataforma de sensores baseado em Arduino¹ para o monitoramento da temperatura interna e externa de colmeias de abelhas (camada de sensoriamento). Este monitoramento constante, visa auxiliar pesquisadores em apicultura da Embrapa Meio-Norte, no entendimento do fenômeno de migração de abelhas [Meitalovs et al. 2009, Zacepins 2012] que causam prejuízo a regiões produtoras de mel, como no Estado do Piauí [Carvalho et al. 2011d, Carvalho et al. 2011c].

¹<http://www.arduino.cc/>

2. Trabalhos Correlatos

A sobreposição temporal de dados coletados no ambiente, que são enviados ao nó sorvedouro durante um dia, causa desperdício de energia, o que diminui o tempo de vida de sistemas ubíquos. A correlação entre estes dados pode ser explorada para melhorar o desempenho do consumo de energia nos dispositivos. A redução de dados é uma forma de diminuir o envio destes dados. Isso pode ser feito com a modelagem dos dados coletados pelos sensores, o que permite gerar parâmetros de função linear [Carvalho et al. 2011b, Carvalho et al. 2011a]. Tais parâmetros são enviados ao destinatário, que podem reconstruir o sinal da mesma forma que ele é reduzido na origem (dispositivos que coletam). Os mecanismos de redução de dados podem ser implementados de diversas formas, tais como em [Wei and Wassell 2011, Debono and Borg 2008, Hongbo et al. 2011, Li et al. 2010, Chong et al. 2007, Santini and Romer 2006]. Além desses, alguns surveys têm sido dedicados a entender tais mecanismos [Bakhtiar et al. 2012, Sathe et al. 2013], na tentativa de melhorar o consumo de energia da rede. Por meio da predição de dados, é possível reconstruir sinais no destinatário com base nos parâmetros da modelagem, mas isso pode gerar ruídos (erros) indesejados, que afetam o indicador de QoC para precisão em sistemas ubíquos [Bringel Filho et al. 2010]. A predição tem sido adotada em vários trabalhos de redução de dados, tais como [Debono and Borg 2008, Hongbo et al. 2011, Wei and Wassell 2011]. O objetivo principal dessas soluções é eliminar dados sobrepostos temporalmente na origem do problema, que são os dispositivos com sensores. Em [Carvalho et al. 2011b, Carvalho et al. 2011a] os parâmetros da função de regressão linear, chamados de α e β , são calculados pelos dispositivos contendo sensores e os mesmos são enviados ao sorvedouro, para posterior reconstrução do sinal comprimido na origem.

Diante disso, nossa proposta visa reduzir dados usando predição por meio de função de regressão linear, mas adaptando a janela de amostras de coletas de acordo com o *erro* gerado pelo próprio procedimento. A janela de amostras é a quantidade de dados coletados que devem estar correlacionados para que a predição obtenha o maior sucesso possível, ou seja, com menos *erro*. O tamanho da janela de amostras (w), afeta o indicador de QoC para atualização [Bringel Filho et al. 2010], uma vez que valores altos, podem gerar retardo na aplicação. Ao incorporar tais indicadores de QoC em nosso mecanismo, tornamos a aplicação de sistemas ubíquos mais eficiente em termos de energia, sem comprometer sua acurácia (precisão) e nem a atualização.

3. Solução Proposta

Técnicas eficientes de redução de dados (e.g., baseadas em equações não lineares) normalmente demandam por poder computacional não presente em sensores sem fio, comumente utilizados em sistemas ubíquos. Portanto, é necessário implementar um mecanismo de redução de dados alternativo, e.g., baseado em Regressão Linear Simple - RLS [Carvalho et al. 2012]. O mecanismo proposto neste artigo é uma evolução da solução proposta previamente pelos autores em [Carvalho et al. 2011b, Carvalho et al. 2011a, Carvalho et al. 2012]. A modificação proposta é guiar o mecanismo de redução de dados por meio do *erro* de predição, i.e., quanto menor o *erro*, melhor será a predição dos dados coletados pelo sensor. Com isso, diminui-se a quantidade de dados transmitidos entre os nós sensores e aumenta-se a confiabilidade da informação reconstruída no nó sorvedouro, prolongando o tempo de vida de sistemas ubíquos.

Data: amostras de temperatura de acordo com w
Result: enviar coeficientes α e β , e w
initialization;
while *true* **do**
 Temp = readTemp();
 Measurement = Temp;
 if *Flag* **then**
 NextTemp = Measurement;
 Measurement = LastTemp;
 LastTemp = NextTemp;
 end
 if *erro* == -1 **OR** *erro* > l_{erro} **then**
 α, β = linearRegression(Measurement, WindowHead, WindowTail);
 if *erro* > l_{erro} **then**
 sendToBaseStation(α, β , (WindowTail-WindowHead-1));
 WindowHead = WindowTail;
 WindowTail = WindowTail+1;
 Flag = true;
 LastTemp = Temp;
 end
 else
 WindowTail = WindowTail+1;
 end
 erro = calculateErro(α, β , Measurement);
end

Algorithm 1: RLS guiada pelo Erro de Predição (*erro*)

3.1. Regressão Linear Simples (RLS) Guiada pelo Erro de Predição

O Algoritmo 1 descreve um trecho de código de nossa abordagem modificada de [Carvalho et al. 2012]. Com a RLS, utilizamos os coeficientes (parâmetros estimados) para prever valores que se aproximam de uma reta, onde o ruído resultante disso, pode interferir na confiabilidade das informações recuperadas pelo nó sorvedouro. Este ruído, que chamamos de erro de predição (ou simplesmente *erro*) de uma janela de amostras (tamanho w), é usado para guiar o mecanismo de forma adaptativa. Enquanto *erro* não atingir um determinado limiar (l_{erro}), w aumenta de tamanho a cada checagem. Se o *erro* atingir l_{erro} , será usado o último w para gerar os coeficientes (α e β) da função de regressão, os quais são enviados ao sorvedouro. Dessa forma, o mecanismo torna-se mais preciso e de acordo com os requisitos suportados pela aplicação (definido em l_{erro}). Assim, evita-se que a aproximação na reconstrução dos dados gere valores com ruído elevado. O *erro* é calculado por meio da diferença entre o valor da amostra real e o seu valor a ser predito, conforme a Equação 1.

$$erro = \sum_{i=1}^n y_{i_{predito}} - y_{i_{real}} \quad (1)$$

onde i é o índice de w , variando $i = 1, 2, \dots, n$, com n sendo o valor máximo de w . n é importante para controlar o tamanho da janela e não comprometer a capacidade de memória do dispositivo, o qual deve ser definido pelo projetista ou administrador do sistema de monitoramento. Note que o mecanismo de predição e mais detalhes podem ser encontrados em nosso trabalho anterior [Carvalho et al. 2012].

Nosso mecanismo, segue as seguintes considerações: i) o valor inicial de w (w_0) é determinado previamente de acordo com os requisitos da aplicação; ii) toda vez que o mecanismo detectar que l_{erro} foi atingido, a janela retorna ao valor inicial, i.e., $w = w_0$; iii) caso o l_{erro} não seja atingido a cada verificação, w será incrementado em uma unidade até atingir n . Quando $n = w$, então a janela de amostras fica com tamanho fixo.

4. Experimentos

Para avaliar o desempenho de nossos mecanismos de redução de dados, foi desenvolvido um sistema de monitoramento de colmeias de abelhas com base no framework definido em [Bringel Filho et al. 2010]. A partir disso, implantamos o monitoramento de colmeia na Embrapa Meio-Norte, em Teresina no Estado do Piauí (Brasil) para gerar os dados de coletas de temperatura dentro e fora de uma caixa de colmeia de abelhas. Os resultados de desempenho que seguem nesta Seção, são baseados nos experimentos que realizamos com esses dados coletados. Tais dados serviram de entrada de amostras para analisar o comportamento das técnicas de RLS sem e com adaptação.

Os resultados baseiam-se nas métricas de Consumo de Energia, Erro Quadrático Médio (*EQM*) da predição e Quantidade de Dados Enviados pelo nó sensor. Note que o *EQM* é obtido a partir da média do *erro* individual de cada janela de amostras de tamanho w . O consumo de energia mostra o quanto nosso mecanismo é mais eficiente em termos de gasto da energia, onde comparamos a RLS sem modificação alguma, com a RLS adaptativa baseada no erro de predição (*erro*). O *EQM* descreve qual o desempenho do mecanismo quando aplicamos a técnica de RLS, onde podemos inferir a qualidade dos dados gerados pelo procedimento de recuperação dos dados no sorvedouro. Além disso, a quantidade de pacotes enviados pelo nó sensor no mecanismo de redução de dados é importante para que possamos identificar quantos dados deixaram de ser transmitidos na rede e assim, reduziram os gastos com energia.

4.1. Dados de Colmeias de Abelha

O monitoramento de colmeias de abelhas é normalmente realizado por instrumentos como estações meteorológicas, que produzem dados de uma determinada área. Portanto, as informações para avaliar o comportamento das abelhas, e a produção e qualidade dos produtos apícolas, são baseadas em dados da área a qual a colmeia está inserida e não das colmeias isoladamente. Portanto, algumas características desse comportamento das abelhas dentro e fora de suas colmeias devem ser analisadas de forma a subsidiar diagnósticos mais precisos dos fatores que provocam o abandono destas colmeias, sendo este, atualmente, um dos principais fatores de redução na produção apícola.

Propostas de medição de microclima de colmeias são fundamentais para entender o comportamento das abelhas e a produção apícola [Zacepins 2012]. Devido as condições inóspitas das regiões produtoras do Piauí, nós propomos um sistema ubíquo de monitoramento baseado em sensores sem fio, capaz de observar a temperatura dentro e fora da

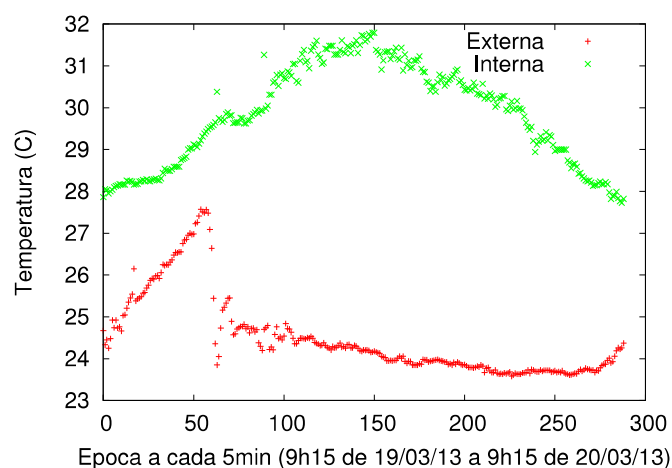


Figura 1. Dados Coletados Dentro e Fora da Colmeia na Embrapa Meio-Norte

colmeia. Os dados provenientes das colmeias foram coletados pelo nosso sistema de monitoramento durante 24 horas (Figura 1), a fim de observar o comportamento do nosso mecanismo com informações provenientes de todos os horários de um dia. Conforme pode ser visto, a temperatura dentro da colmeia segue características diferentes da temperatura fora da colmeia. Isso acontece porque as abelhas criam um microclima interno, para termoregular o ambiente em que vivem a abelha rainha e suas crias. Por outro lado, a temperatura externa segue características diferentes, de acordo com as condições climáticas da região. A resposta desse procedimento das abelhas, ao realizarem termoregulação interna, é uma das formas de descobrir os problemas dos apicultores. Para tanto, é fundamental o monitoramento constante (coleta com frequência alta, e.g. a cada 5 min por época), gerando uma grande quantidade de amostras para serem enviadas ao sorvedouro.




Figura 2. Comparação com a RLS Adaptativa Guiada pelo Erro de Predição (*erro*) para Monitoramento Dentro da Colmeia

4.2. Resultados

Para avaliar o desempenho do nosso mecanismo de redução de dados, implementamos a RLS sem e com adaptação, usando a linguagem de programação Python. Os dados de entrada para avaliar esses dois mecanismos consistem em 288 amostras coletadas ($60\text{min} / 5\text{min} * 24\text{h} = \text{número de épocas}$) pelo nosso sistema de monitoramento embutido em dispositivos contendo os dois sensores de temperatura (interna e externa), o qual foi implantado na colmeia da Embrapa Meio-Norte. A Figura 2 mostra os resultados da comparação da RLS adaptativa para monitoramento dentro da colmeia. Como nosso mecanismo verifica o erro de predição (*erro*) gerado para um tamanho da janela de amostras w , menos coeficientes da função de regressão linear são criados e *erro* tende a diminuir devido a correlação destas amostras. O limiar (l_{erro}) ajusta o mecanismo guiado pelo *erro* e assim, tornamos a RLS mais robusta, economizando mais energia e ainda assim, obedecendo aos requisitos da aplicação em relação ao ruído suportável (afeta o indicador de QoC para precisão). Ao analisarmos os resultados obtidos pela RLS sem adaptação, percebemos que o *erro* é menor, mas esse mecanismo consome mais energia que a RLS adaptativa, inclusive podendo comprometer a qualidade das informações recuperadas no sorvedouro, por ter um w fixo (afeta o indicador QoC para atualização).




Figura 3. Comparação com a RLS Adaptativa Guiada pelo Erro de Predição (*erro*) para Monitoramento Fora da Colmeia

A Figura 3 mostra os resultados da comparação da RLS adaptativa para monitoramento fora da colmeia. Similarmente ao monitoramento dentro da colmeia, nosso mecanismo identifica o aumento de *erro* e inibi informações com muito ruído (afeta o indicador QoC para precisão). Esta inibição acontece porque ao atingir l_{erro} , nosso mecanismo utiliza o tamanho w da janela de amostras (afeta o indicador de QoC para atualização), contendo os últimos dados coletados no ambiente. Contudo, o valor do limiar é variável de acordo com a aplicação e alguns testes para identificar qual seria o melhor valor de l_{erro} foram realizados. Os resultados das três métricas quando alteramos o limiar podem ser vistos nas Tabelas 1 e 2.

Ao aumentarmos w , *erro* diminui, juntamente com a quantidade de pacotes enviados na rede, permitindo um menor consumo de energia. Entretanto, ao alcançarmos

Tabela 1. Resultados da RLS Guiada pelo Erro de Predição (*erro*) no Monitoramento Dentro da Colmeia

Janela	Media Erro	Num Pkts	EQM	Energia(0,5mJ/pkt)
2	0,1715	30	0,0518	15
5	0,1473	17	0,0387	8,5
10	0,1559	8	0,0415	4
20	0,1557	8	0,0436	4

um valor de w mais alto (e.g. acima de 10), o mecanismo não consegue obter melhor eficiência. Isso acontece porque dependendo da quantidade de amostras e do tipo de aplicação, a correlação entre os valores de uma mesma janela de amostras enfraquecem suas relações e torna o mecanismo mais ruidoso. Portanto, não irá fazer diferença se aumentarmos w após isso acontecer. Entretanto, houve uma redução de 89,58% a 97,22% no número de pacotes enviados na rede e na energia consumida, para o monitoramento de temperatura interno a colmeia.

Tabela 2. Resultados da RLS Guiada pelo Erro de Predição (*erro*) no Monitoramento Fora da Colmeia

Janela	Media Erro	Num Pkts	EQM	Energia(0,5mJ/pkt)
2	0,1785	22	0,0450	11
5	0,1475	10	0,0298	5
10	0,2363	10	0,0731	5
20	0,2249	6	0,0676	3

Da mesma forma, pode ser observado nos resultados para o mecanismo usado no monitoramento fora da colmeia. A diferença dos resultados em relação ao monitoramento dentro da colmeia, é que a temperatura externa sofreu uma variação brusca em virtude de algumas horas de chuva (ver Figura 3 entre a época 50 e a 100). Com isso, o comportamento do mecanismo foi um pouco diferente, refletindo em resultados, também, um pouco diferentes, mas dentro do esperado, mantendo a mesma tendência. Entretanto, houve uma redução de 92,36% a 97,91% no número de pacotes enviados na rede e na energia consumida, para o monitoramento de temperatura fora da colmeia.

5. Conclusão

Sistemas ubíquos requerem mecanismos de redução de dados adaptativos, a fim de diminuir o ruído e aumentar o tempo de vida da rede. Isso pode ser alcançado usando regressão linear com base em predição de dados coletados. O funcionamento deste tipo de mecanismo consiste em modelar os dados coletados em parâmetros de função linear, a qual chamamos de coeficientes. Assim, ao invés de enviar os dados coletados pelos sensores ao sorvedouro, somente esses coeficientes trafegam na rede, onde o destinatário pode recuperar o sinal comprimido. O ruído (*erro*) causado por tais mecanismos pode inviabilizar a adoção dos mesmos. Portanto, é importante realizar a predição guiada pelo seu erro, evitando situações em que se ultrapassa os requisitos de acurácia da aplicação.

Quanto mais energia conseguimos economizar usando redução de dados, mais ruídos podemos estar adicionando ao sistema ubíquo. Então, propomos neste artigo um mecanismo que seja capaz de economizar energia e controlar por meio de uma janela adaptativa, a acurácia e atualização da aplicação. Nosso mecanismo, que chamamos de SLR adaptativo, foi desenvolvido usando conceitos de indicadores de QoC para suportar a camada de sensoriamento presente em um framework de gestão contextual. Os resultados obtidos demonstram sua capacidade de diminuir a quantidade de pacotes a serem enviados na rede e assim reduz o consumo de energia, sendo guiado pelo erro de predição (afeta o indicador QoC para precisão) de um determinado tamanho de amostras (afeta o QoC para atualização). Em nossos experimentos, o mecanismo de RLS adaptativo, conseguiu reduzir cerca de 97,22% dos pacotes enviados na rede e conseqüentemente a quantidade de energia consumida, com uma janela de amostras de tamanho 20, ou seja, uma hora e meia para atualização (100min) com erro médio de 0,2249. Por outro lado, conseguiu reduzir cerca de 89,58% dos pacotes enviados na rede, com uma janela de amostras de tamanho 2, ou seja, 10min para atualização com erro médio de 0,1785.

6. Agradecimento

Os autores agradecem o apoio e parceria do Núcleo de Pesquisas com Abelhas (NUPA) da Embrapa Meio-Norte.

Referências

- Anastasi, G., Conti, M., Francesco, M. D., and Passarella, A. (2009). Energy conservation in wireless sensor networks: A survey.
- Bakhtiar, Q., Makki, K., and Pissinou, N. (2012). Data reduction in low powered wireless sensor networks. *Wireless Sensor Networks - Technology and Applications, Chapter 8*, pages 171–186.
- Baldauf, M., Dustdar, S., and Rosenberg, F. (2007). A survey on context-aware systems. *Int. J. Ad Hoc Ubiquitous Comput.*, 2:263–277.
- Bringel Filho, J. and Agoulmine, N. (2011). A quality-aware approach for resolving context conflicts in context-aware systems. *9th IEEE/FIP International Conference on Embedded and Ubiquitous Computing*.
- Bringel Filho, J., Miron, A., Satoh, I., Gensel, J., and Martin, H. (2010). Modeling and measuring quality of context information in pervasive environments. *24th IEEE International Conference on Advanced Information Networking and Applications*, 24:690–697.
- Caceres, R. and Friday, A. (2012). Ubicomp systems at 20: Progress, opportunities, and challenges. *IEEE Pervasive Computing*, 11:14–21.
- Carvalho, C., Cronemberger, I., Silva, W., Silva, T., Leal, L., Lemos, M., and Bringel Filho, J. (2012). Smart grid communication data reduction to enhanced bandwidth usage. In *International Workshop on ADVANCES in ICT Infrastructures and Services, ADVANCE2012*.
- Carvalho, C., Gomes, D., De Souza, J., and Agoulmine, N. (2011a). Multiple linear regression to improve prediction accuracy in wsn data reduction. In *Network Operations and Management Symposium (LANOMS), 2011 7th Latin American*, pages 1–8.

- Carvalho, C., Gomes, D. G., Agoulmine, N., and de Souza, J. N. (2011b). Improving prediction accuracy for wsn data reduction by applying multivariate spatio-temporal correlation. *Sensors*, 11(11):10010–10037.
- Carvalho, C. d., Santos, W., Nunes, L., Souza, B., Carvalho-Zilse, G., and ALVES, R. (2011c). Offspring analysis in a polygyne colony of *melipona scutellaris* (hymenoptera: Apidae) by means of morphometric analyses. In *Sociobiology*, volume 57, pages 347–354.
- Carvalho, C. d., Souza, B., Dias, C., Alves, R., Melo, A., Soares, A., and Carvalho-Zilse, G. (2011d). Five egg-laying queens in a single colony of brazilian stingless bees (*melipona scutellaris latreille*). In *Acta Amazonica*, volume 41, pages 123–126.
- Chong, L., Kui, W., and Jian, P. (2007). An energy-efficient data collection framework for wireless sensor networks by exploiting spatiotemporal correlation. *Parallel and Distributed Systems, IEEE Transactions on*, 18(7):1010–1023.
- Debono, C. and Borg, N. (2008). The implementation of an adaptive data reduction technique for wireless sensor networks. *Signal Processing and Information Technology, ISSPIT 2008, IEEE International Symposium on*, pages 402–406.
- Dietrich, I. and Dressler, F. (2009). On the lifetime of wireless sensor networks. *ACM Trans. Sen. Netw.*, 5(1):5:1–5:39.
- Hodges, S., Villar, N., Scott, J., and Schmidt, A. (2012). A new era for ubicomp development. *IEEE Pervasive Computing*, 11:5–9.
- Hongbo, J., Shudong, J., and Chonggang, W. (2011). Prediction or not: An energy-efficient framework for clustering-based data collection in wireless sensor networks. *Parallel and Distributed Systems, IEEE Transactions on*, 22(6):1064–1071.
- Li, J., Deshpande, A., and Khuller, S. (2010). On computing compression trees for data collection in wireless sensor networks. *Proceedings of the 29th conference on Information communications, INFOCOM'10*, pages 2115–2123.
- Meitalovs, J., Histjaves, A., and Stalidzans, E. (2009). Automatic microclimate controlled beehive observation system. In *8th International Scientific Conference, Engineering for Rural Development, Latvia University of Agriculture*, pages 265–271.
- Santini, S. and Romer, K. (2006). An adaptive strategy for quality-based data reduction in wireless sensor networks. *Proc. INSS*.
- Sathe, S., Papaioannou, T., Jeung, H., and Aberer, K. (2013). A survey of model-based sensor data acquisition and management. *Managing and Mining Sensor Data, Springer US*, pages 9–50.
- Wei, C. and Wassell, I. (2011). Energy efficient signal acquisition via compressive sensing in wireless sensor networks. *Wireless and Pervasive Computing (ISWPC), 6th International Symposium on*, pages 1–6.
- Zacepins, A. (2012). Application of bee hive temperature measurements for recognition of bee colony state. In *International Conference on Applied Information and Communication Technologies (AICT2012)*, pages 465–468, Jelgava, Latvia.