

# Arquitetura RF-Miner - Uma solução para localização indoor

Eduardo L. Gomes, Mauro Fonseca, Anelise Munaretto, Carlos R. Guerber

<sup>1</sup>Programa de Pós-Graduação em Engenharia Elétrica e Informática Industrial (CPGEI)  
– Universidade Tecnológica Federal do Paraná (UFRGS)  
Centro – 80.230-901 – Curitiba – PR – Brazil

{elgomes10, crguerber}@gmail.com, {maurofonseca, anelise}@utfpr.edu.br

**Abstract.** *The use of passive UHF RFID tags for indoor location has been widely studied due to its low cost. However, there is still a great difficulty to reach good results, mainly due the radio frequency variation in environments that have materials with reflective surfaces, such as metal. This paper proposes a localization architecture using passive UHF RFID tags and data mining techniques to identify the exact location indoors.*

**Resumo.** *A utilização de etiquetas RFID UHF passivas para localização indoor vem sendo amplamente estudada devido ao seu baixo custo. Porém ainda existe uma grande dificuldade em obter bons resultados, principalmente devido à variação de rádio frequência em ambientes que possuem materiais reflexivos, como por exemplo, metais. Este artigo propõe uma arquitetura de localização utilizando etiquetas RFID UHF passivas e técnicas de mineração de dados possibilitando identificar a posição exata em ambientes internos.*

## 1. Introdução

A tecnologia RFID (*Radio Frequency Identification* – Identificação por Rádio Frequência) é um método de identificação automática que utiliza sinais de rádio para identificar, rastrear e gerenciar produtos, documentos ou até mesmo animais e pessoas sem nenhum tipo de contato físico e nem mesmo campo visual. Isto só é possível devido a utilização de dispositivos conhecidos como transponders ou tags, que são etiquetas eletrônicas, passivas, semi-passivas ou ativas, classificadas do ponto de vista da fonte de alimentação.

A pesquisa de modelos de localização indoor tem utilizado preferencialmente a tecnologia RFID para sua implementação, já que a tecnologia GPS não apresenta resultados precisos em ambientes internos. Modelos de localização indoor são criados com vários objetivos diferentes e utilizando técnicas distintas de apuração da acuracidade das etiquetas. Existem trabalhos que têm como objetivo auxiliar a movimentação indoor de robôs utilizando como técnica o atributo S-CRR (*Swift Communication Range Recognition*) [Nakamori et al. 2012]. Outros possuem o mesmo objetivo, porém utilizam técnicas probabilísticas de apuração [Hori et al. 2008]. Da mesma maneira existem trabalhos que utilizam a mesma técnica S-CRR mas para atender objetivos diferentes, como o de identificar itens em um determinado local, ao invés de movimentação de robôs [Uchitomi et al. 2010].

A arquitetura apresentada no presente artigo tem como objetivo apurar a localização de itens em ambientes internos com características de armazenamento verticais, que é uma característica muito utilizada para aproveitar melhor o espaço de estocagem de produtos, comércio, bibliotecas e arquivos de documentos.

A metodologia utilizada para desenvolver a arquitetura se concentra em prover independência de atributos e hardware. Inicialmente foram identificados quais são os atributos que melhor contribuem na apuração da localização. Em seguida, foi realizado um teste em relação a influência da quantidade de antenas na arquitetura e o que cada antena contribui ou interfere na acuracidade. Finalmente foram utilizadas e comparadas algumas técnicas de mineração de dados com os algoritmos de classificação para identificar qual apresenta o melhor resultado. Para isso foi utilizado o software WEKA (*Waikato Environment for Knowledge Analysis*) testando os algoritmos de classificação K-Estrela, Árvores de Decisão J48, Redes Bayesiana (*Bayes Network*) e *K-Nearest Neighbor* (KNN) com diferentes parâmetros.

O artigo está organizado da seguinte forma, a seção 2 apresenta os trabalhos relacionados na área, em seguida a seção 3 apresenta a modelagem detalhada da arquitetura, e a seção 4 a implementação dessa arquitetura proposta. Na seção 5 são apresentados os resultados obtidos na aplicação da arquitetura em ambiente real, seguidos na seção 6 da análise dos resultados. Finalmente na seção 7 são apresentadas as conclusões do trabalho.

## **2. Localização Indoor Utilizando a Tecnologia RFID**

Um sistema tradicional de localização indoor consiste em identificar precisamente itens em um determinado espaço dentro de edificações. O sistema de localização por satélite (GPS) que é amplamente utilizado para localização externa, não tem um bom desempenho para localização em ambientes internos, pois os sinais de micro-ondas são atenuados pelo teto, parede e outros objetos, o que faz a precisão reduzir drasticamente, ou nem mesmo ser possível localizar o objeto [Huang et al. 2015].

Alternativamente outras tecnologias são pesquisadas para propor soluções viáveis a fim de atender à esta necessidade, como por exemplo: Posicionamento Magnético ou Medições Inerciais que não utilizam ondas de rádio.

Entretanto o custo também é um fator extremamente relevante para a viabilidade de implantação da arquitetura apresentada. A necessidade de identificar cada item que se deseja localizar, faz com que diversas tecnologias se tornem inviáveis do ponto de vista econômico, pois o custo se multiplica pela quantidade de itens a identificar.

Por outro lado há tecnologias que utilizam ondas de rádio, como Wi-fi (WPS), Bluetooth e RFID, as quais empregam várias técnicas distintas dentre as mais conhecidas são: Ângulo de Recepção (*Angle-of-Arrival - AoA*), Diferença de Tempo de Transmissão (*Time Difference of Arrival - TDoA*), Indicador de Intensidade do Sinal Recebido (*Received Signal Strength Indicator - RSSI*) [Akre et al. 2014].

A Tecnologia RFID UHF utilizando etiquetas passivas se demonstra uma solução viável para esta necessidade. Modelos de sistemas de localização indoor utilizando RFID para diversas finalidades já foram pesquisados. Os autores em [Akre et al. 2014] apresentaram um modelo que utiliza etiquetas RFID passivas localizadas em um espaço em duas dimensões (2-D) usando a abordagem de aprendizagem. A técnica utilizada consiste em identificar o RSSI em quatro antenas e realizar medições com potências diferentes, montando uma base de dados de aprendizagem e utilizando o algoritmo KNN para obter a localização. Em seu trabalho [Ting et al. 2011] apresentaram um modelo de localização também utilizando como atributo de medição das antenas o RSSI, porém com uma técnica

mais simples de apuração, criando uma base de dados denominada na pesquisa como *Look-Up Table* (LUT), contendo as médias das medições prévias do RSSI. Em seguida, realizaram a localização através do cálculo da distância euclidiana entre a medição atual e a base LUT. A pesquisa apresentou bons resultados, porém a precisão foi de três metros para cada etiqueta, o que pode não ser útil dependendo do modelo de negócio onde o sistema de localização será implantado.

Já [Zhang et al. 2015] procuraram extrair mais características do atributo RSSI, utilizando diversas variações da potência de transmissão, orientação de etiquetas e realizando um extenso trabalho de leituras. Assim, extraíram além do RSSI puro, sua média, desvio padrão, valor mínimo e valor máximo.

Além disso, existem estudos que utilizaram diversas técnicas combinadas para criar um modelo de localização indoor, como fizeram [Huang et al. 2015], com a finalidade de apurar o resultado de maneira mais rápida e melhorar o desempenho da localização em tempo real, empregaram uma combinação de *Kalman-Filter Drift* e *Heron-Bilateration Localization Estimative* para melhorar a eficiência e precisão de métodos tradicionais como *Proximity Pattern Matching*, *Linear-Like RSSI-to-Distance Transformation*, *Trilateração* e *Multilateração*. Entretanto utilizaram etiquetas ativas, o que aumenta consideravelmente o custo de implantação do modelo.

Assim o trabalho apresentado neste artigo propõe uma arquitetura de sistema de localização em ambientes internos, utilizando etiquetas RFID UHF passivas de alta precisão e baixo custo. Para isso o estudo se concentra na investigação da melhor configuração da arquitetura com a quantidade de antenas e na identificação dos atributos que melhor contribuem para a acuracidade da localização, derivando do Indicador de Intensidade do Sinal Recebido (RSSI) e da Quantidade de Leituras em um Período de Tempo (*Read Count*). Foram utilizadas técnicas de mineração de dados como os algoritmos de classificação K-Estrela, Árvores de Decisão J48, Redes Bayesiana e KNN, para identificar qual técnica se comporta melhor para o cenário avaliado.

### 3. Arquitetura RF-Miner

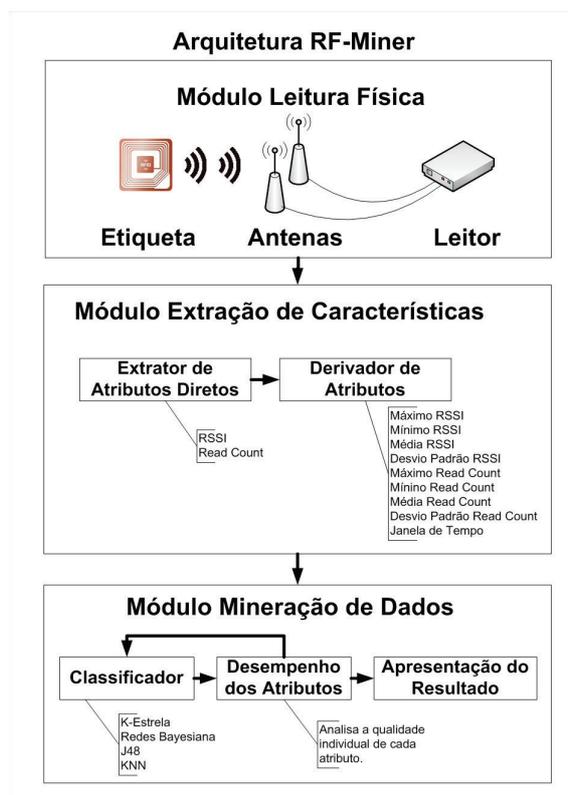
A arquitetura de localização *indoor* utilizando etiquetas RFID UHF passivas proposta neste artigo é denominada RF-Miner e está subdividida em 3 módulos conforme demonstra a Figura 1.

#### 3.1. Módulo de Leitura Física

Um sistema básico RFID é composto por 3 equipamentos: etiqueta, antenas e leitor. O módulo de leitura física nada mais é do que um sistema básico RFID que realiza as leituras e repassa a informação para o módulo de extração de características. Este módulo é independente do fabricante, pois o mesmo padroniza informações de entrada em um fluxo de saída de dados composto pela tupla *timestamp*, *RSSI*, *TagID*. É importante ressaltar que a qualidade da instalação do sistema, como qualidade de cabos e antenas bem fixadas podem interferir na apuração dos resultados.

#### 3.2. Módulo Extração de Características

É a parte lógica da arquitetura, responsável pela preparação dos atributos e formação da base de treinamento. Para permitir que o módulo realize a derivação dos atributos é ne-



**Figura 1. Arquitetura RF-Miner**

cessário configurar o parâmetro denominado Tamanho da Janela, que na prática é a quantidade de tuplas que serão utilizadas para calcular as médias, mínimos, máximos e desvio padrão. Inicialmente, o módulo recebe o parâmetro tamanho da janela e o fluxo de dados do módulo de Leitura Física e extrai as informações dos atributos diretos que são: RSSI e RC (*Read Count*), baseado no tamanho da janela. Após isso, realiza a derivação destes atributos, onde inicialmente cada leitura é atribuída em uma janela de tempo, utilizando como critério a ordem sequencial da leitura. A partir do momento que cada leitura está alocada em sua janela de tempo é realizado o cálculo da média aritmética, desvio padrão e da identificação dos valores mínimos e máximos para cada atributo (RSSI e RC), criando uma base de dados com 10 (dez) atributos para cada antena conforme demonstrado na Tabela 1.

Existem 2 (dois) atributos que não estão relacionados diretamente com a antena. O número da janela de tempo e a posição da etiqueta no momento da leitura, apresentados na Tabela 2.

Após esta etapa, a base de dados e treinamento está pronta para ser utilizada no módulo de Mineração de Dados.

### 3.3. Módulo Mineração de Dados

Usando como entrada os dados preparados e formatados pelo módulo Extração de Características, o módulo Mineração de Dados realiza a classificação utilizando um dos algoritmos disponibilizados. Por meio do processo de Desempenho dos Atributos, avalia individualmente cada atributo com o objetivo de identificar se o mesmo contribui ou

**Tabela 1. Atributos relacionados diretamente à antena**

<b>Atributo</b>	<b>Tipo de Dado</b>	<b>Descrição</b>
rss_i_antena X	Decimal	RSSI da antena
rc_antena X	Inteiro	Número de leituras da etiqueta na antena
avg_rssi_antena X	Decimal	Média aritmética do RSSI na janela de tempo
avg_rc_antena X	Decimal	Média aritmética do RC na janela de tempo
min_rssi_antena X	Decimal	Menor valor do RSSI na janela de tempo
min_rc_antena X	Decimal	Menor valor do RC na janela de tempo
max_rssi_antena X	Decimal	Maior valor do RSSI na janela de tempo
max_rc_antena X	Decimal	Maior valor do RC na janela de tempo
stddev_rssi_antena X	Decimal	Desvio padrão do RSSI na janela de tempo
stddev_rc_antena X	Decimal	Desvio padrão do RC na janela de tempo

**Tabela 2. Atributos relacionados diretamente à antena**

<b>Atributo</b>	<b>Tipo de Dado</b>	<b>Descrição</b>
Janela de tempo	Inteiro	Número da janela de tempo
Posição	Classe	Nome ou número da posição na prateleira

não para a localização naquele ambiente. Após encontrar o melhor conjunto de atributos, realiza novamente a classificação e apresenta a localização encontrada utilizando este conjunto, resultando na melhor solução encontrada para o ambiente.

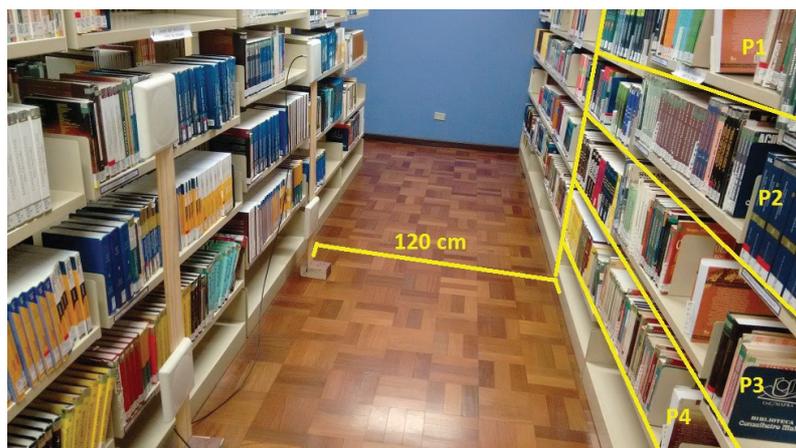
## 4. Implementação

### 4.1. Preparação do Ambiente de Testes

Para a criação do ambiente de testes foram utilizadas quatro antenas UHF mono estáticas que atuam na faixa de frequência 902 a 928 MHz com um ganho de 6 dBi. O equipamento utilizado para realização das leituras foi o *ThingMagic Mercury 6*, que é um leitor RFID UHF de alto desempenho. Suporta até 4 antenas mono estáticas, entradas e saídas digitais e conexão Wi-Fi. Com o objetivo de validar e implementar a arquitetura de localização indoor em um ambiente real, foi utilizado como estudo de caso real a Biblioteca Conselheiro Mafra da Universidade do Contestado – Campus Mafra. As etiquetas passivas foram dispostas lado a lado em 4 (quatro) prateleiras (P1, P2, P3, P4) de livros de 210 cm de largura. Foram utilizadas 28 (vinte e oito) etiquetas coladas no sentido vertical na lombada dos livros. As antenas foram dispostas a 120 cm de distância das etiquetas. A Figura 2 demonstra o ambiente de testes montado.

### 4.2. Realização das Leituras

Foram realizadas em cada célula ou *tag* alvo 100 leituras de 5 segundos divididas em 10 janelas de tempo ou seja, o parâmetro denominado Janela de Tempo utilizado nesta



**Figura 2. Ambiente de Testes**

implementação foi de tamanho 10. Em cada *tag* foi medido o RSSI em dBm e a *Read Count* para cada uma das 4 antenas totalizando 2.800 leituras. Para esta etapa o módulo de Leitura Física faz a conexão por TCP/IP com o Leitor *ThingMagic 6*, envia os comandos para iniciar as leituras e recebe as respostas das etiquetas localizadas com seus respectivos atributos diretos.

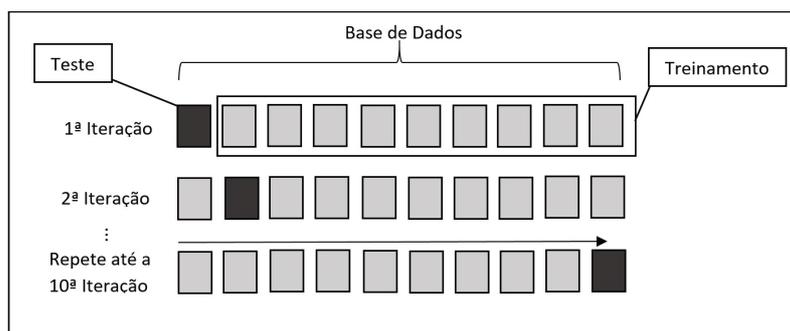
### 4.3. Formatação da Base e Preparação dos Atributos

Após a realização das leituras o módulo Extração de Características identificou para cada janela de tempo o valor máximo, mínimo, média aritmética e desvio padrão do RSSI e do *Read Count* para cada leitura e etiqueta. Organizou os atributos conforme demonstrado nas Tabelas 1 e 2, e colocou em 2.800 registros as 100 leituras para cada uma das 28 etiquetas dentro de um arquivo do tipo ARFF (*Attribute-Relation File Format*), que foi utilizado para criação da base de dados no software WEKA.

### 4.4. Mineração de Dados

O módulo Mineração de Dados utiliza para a classificação o software WEKA. A técnica utilizada para os testes foi a validação cruzada (*Cross-validation*) com o parâmetro dobra (*fold*) igual a 10. A Figura 3 demonstra o comportamento desta técnica. Inicialmente o software divide a base em 10 partes iguais. Em cada iteração utiliza 9 partes para treinamento e 1 para testes. Este processo é repetido para cada uma das 10 partes sempre trocando a qual será utilizada para testes. Com esta técnica foi possível multiplicar em 10 vezes os 2.800 registros que foram utilizados na mineração de dados. Ao todo, foram 28.000 registros, sendo 25.200 para treinamento e todos os 2.800 para testes.

Para a localização através da mineração de dados foram realizados testes com 4 algoritmos diferentes. O objetivo foi identificar o desempenho dos algoritmos na arquitetura e com quais atributos existe uma maior acuracidade. Os algoritmos avaliados foram: KNN (com o parâmetro  $K = 1, 3$  e  $5$ ), Algoritmo K-Star, Árvore de Decisão J48 e Redes Bayesianas. O módulo pode trabalhar com outros algoritmos de classificação, provando assim a generalização da arquitetura.



**Figura 3. Validação Cruzada**

## 5. Resultados

Para identificar quais atributos melhor contribuem para a localização da *tag* no modelo proposto, o módulo de Mineração de dados avaliou todos os atributos realizando três classificações para cada algoritmo adicionando individualmente cada grupo de atributos a cada classificação. Os resultados das três classificações são apresentados a seguir.

Na primeira classificação apresentada foi considerado apenas o atributo RSSI para cada antena, ou seja, um grupo de quatro atributos: RSSI da antena 1, 2, 3 e 4. Os resultados são apresentados na Tabela 3.

**Tabela 3. Classificação utilizando quatro atributos (RSSI)**

Algoritmo	Acertos	Erros	% Acerto
KNN K=1	2.660	140	95,00
K-Star	2.650	150	94,64
KNN K=3	2.650	150	94,64
KNN K=5	2.640	160	94,29
Árvore de Decisão J48	2.590	210	92,50
Redes Bayesianas	2.560	240	91,43

Na segunda classificação apresentada foram considerados os atributos RSSI em conjunto com o *Read Count* para cada antena ou seja 2 grupos de 4 atributos, totalizando oito atributos (RSSI e *Read Count* da antena 1, 2, 3 e 4). A Tabela 4 apresenta os resultados da segunda classificação.

E na terceira classificação apresentada todos os atributos foram considerados. Os atributos diretos: RSSI e *Read Count* e os atributos derivados da janela de tempo: média, mínimo, máximo e desvio padrão. Os atributos utilizados para esta classificação foram 40 no total, ou seja, 10 atributos de cada antena, como foi demonstrado na Tabela 1. A Tabela 5 apresenta os resultados obtidos na terceira classificação.

A Figura 4 apresenta o gráfico comparativo de desempenho dos algoritmos nas três situações utilizando 4 atributos, 8 atributos e 40 atributos.

Após identificar os atributos que mais contribuíram na apuração da localização das

**Tabela 4. Classificação utilizando oito atributos (RSSI e Read Count)**

Algoritmo	Acertos	Erros	% Acerto
K-Star	2.770	30	98,93
KNN K=3	2.750	50	98,21
KNN K=5	2.750	50	98,21
Redes Bayesianas	2.750	50	98,21
KNN K=1	2.740	60	97,86
Árvore de Decisão J48	2.640	160	94,29

**Tabela 5. Classificação utilizando quarenta atributos (RSSI, Read Count e janelas de tempo)**

Algoritmo	Acertos	Erros	% Acerto
Árvore de Decisão J48	2.800	0	100,00
Redes Bayesianas	2.800	0	100,00
K-Star	2.800	0	100,00
KNN K=5	2.779	21	99,25
KNN K=3	2.773	27	99,04
KNN K=1	2.764	36	98,71

etiquetas, o módulo de Mineração de Dados realizou testes considerando os atributos de uma, duas, três e quatro antenas, com o objetivo de analisar como a quantidade de antenas interfere no resultado. A Tabela 6 apresenta percentuais obtidos para cada situação.

A Figura 5 apresenta o gráfico comparativo dos percentuais de acerto em relação à quantidade de antenas.

Para validar se a arquitetura RF-Miner mantém o índice de acuracidade em tempo real, foi realizado o teste onde todos os livros foram trocados de lugar e realizado nova leitura de apenas 1 janela de tempo, que é o tempo mínimo necessário para apurar a localização de uma etiqueta, ou seja, quanto maior a janela de tempo, mais demorado irá ser a apuração do resultado, conseqüentemente haverá mais tuplas para o módulo de mineração de dados utilizar para a classificação. Na presente implementação, como foi utilizado leituras de 5 segundos e uma janela de tempo de tamanho 10 a apuração de 1 resultado de localização é de 50 segundos. A Tabela 7 apresenta os resultados de classificação em tempo real com apenas uma janela de tempo, com quatro antenas e todos os atributos.

Outra verificação foi realizada em 10 janelas de tempo após a troca dos livros. É importante ressaltar que para verificação em tempo real a cada janela de tempo que é adicionada na base de treinamento a primeira janela da base é removida, utilizando o conceito FIFO (*First in First Out*). Este procedimento foi adotado para manter a base

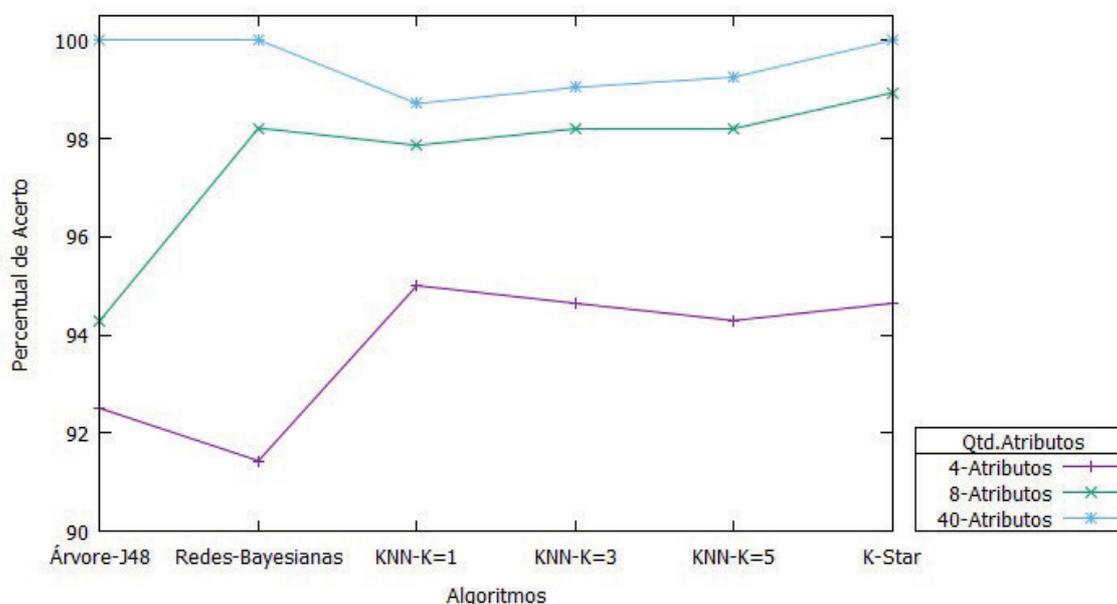


Figura 4. Comparativo de desempenho em relação à quantidade de atributos

Tabela 6. Comparativo da classificação utilizando diferentes quantidades de antenas

Algoritmo	1 Antena	2 Antenas	3 Antenas	4 Antenas
Árvore de Decisão J48	95,89%	99,96%	100,00%	100,00%
Redes Bayesianas	95,86%	100,00%	100,00%	100,00%
KNN K=1	95,21%	98,28%	98,57%	98,71%
KNN K=3	95,43%	98,46%	98,89%	99,04%
KNN K=5	95,00%	99,10%	99,25%	99,25%
K-Star	96,36%	100,00%	100,00%	100,00%

sempre atualizada mesmo diante das mudanças das etiquetas no cenário. A Tabela 8 apresenta os resultados.

## 6. Análise dos Resultados

Na primeira investigação da implementação da arquitetura RF-Miner o módulo de Mineração de Dados por meio do processo de Desempenho de Atributos identificou quais atributos contribuem para a precisão da localização. Analisando os resultados obtidos nas três amostragens apresentadas, Tabelas 3, 4 e 5, foi possível perceber que a utilização das janelas de tempo derivando os atributos RSSI e *Read Count* em mínimo, máximo, média e desvio padrão, contribuíram significativamente para uma melhor acuracidade da arquitetura. Portanto o papel do módulo de extração de características foi fundamental para o resultado final, pois foi possível obter 100% de acerto em três dos quatro classificadores utilizados na arquitetura.

Os algoritmos de classificação utilizados na arquitetura apresentaram resultados

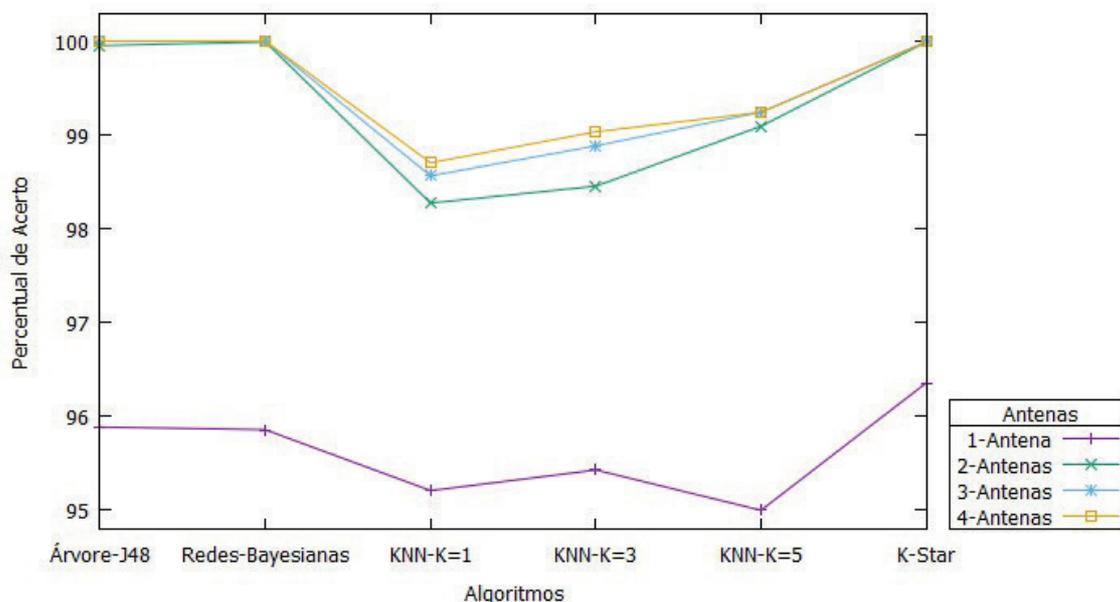


Figura 5. Comparativo de desempenho em relação à quantidade de antenas

Tabela 7. Classificação utilizando quarenta atributos (RSSI, *Read Count* e janelas de tempo) em tempo real com uma janela de tempo

Algoritmo	Acertos	Erros	% Acerto
Árvore de Decisão J48	27	1	96,43
Redes Bayesianas	25	3	89,29
K-Star	24	4	85,71
KNN K=5	22	6	78,57
KNN K=3	23	5	82,14
KNN K=1	19	9	67,85

eficientes, dos quatro algoritmos testados apenas o KNN não conseguiu 100% de acerto, embora obteve resultados acima de 99% utilizando como parâmetro K (número de vizinhos) igual a 5.

Em relação à quantidade de antenas, como esperado, foi possível perceber que quanto mais antenas melhor o resultado, porém como o custo de implementação deve ser sempre considerado, com duas antenas já é possível obter 100% de acerto na arquitetura RF-Miner. O desempenho com duas antenas é extremamente importante, pois reduz significativamente o custo de implementação da arquitetura, além de reduzir em 50% o custo das antenas, também reduz o custo dos leitores, já que leitores com capacidade para receber 2 antenas custam em torno de 30% a menos que leitores com capacidade para 4 antenas. A economia aproximada é de 40% na aquisição dos conjuntos de leitores e antenas além do menor consumo de energia para a operação do sistema.

O teste de implementação em tempo real, que considerou a leitura de apenas uma

**Tabela 8. Classificação utilizando quarenta atributos (RSSI, *Read Count* e janelas de tempo) em tempo real com dez janelas de tempo**

Algoritmo	Acertos	Erros	% Acerto
Árvore de Decisão J48	28	0	100,00
Redes Bayesianas	27	1	96,43
K-Star	28	0	100,00
KNN K=5	23	5	82,14
KNN K=3	23	5	82,14
KNN K=1	22	6	78,57

janela e mudança de posição de todos os livros, obteve bons resultados. Mas é perceptível que quanto mais tempo o livro fica na mesma posição melhor é a acuracidade, pois a verificação após dez janelas de tempo pode-se obter 100% de acertos em alguns classificadores.

## 7. Conclusões

A tecnologia RFID continua sendo muito utilizada em diversos setores, principalmente em sistemas de controle de processos, estocagem, rastreamento e antifurto. Utilizar esta versatilidade da tecnologia para implementar sistemas de localização *indoor* pode contribuir ainda mais para a viabilidade econômica de implantação do sistema.

A utilização de etiquetas passivas contribui muito com o custo de implantação, pois além de ter um preço menor em relação às etiquetas ativas, a tendência mundial é que todos os itens já possuam etiquetas desde a fabricação, percorrendo toda a cadeia de suprimentos com a mesma etiqueta que poderá ser utilizada na arquitetura. Mesmo assim deve-se analisar sempre os custos das antenas e leitores, pois devido ao fato da utilização das etiquetas passivas a distância de leitura é menor.

A arquitetura RF-Miner proposta se demonstrou uma eficiente solução para o problema de localização *indoor*. Mesmo em ambientes reais onde podem existir prateleiras de metais e outros materiais reflexivos que reduzem significativamente a acuracidade, a implementação da arquitetura apresentou excelentes resultados. O módulo que vale destacar na arquitetura RF-Miner é o de Extração de Características, pois, as técnicas de derivação dos atributos contribuíram significativamente para a precisão da implementação. Também vale destacar o módulo de Mineração de Dados, principalmente no processo de Desempenho dos Atributos, o qual sempre entrega o melhor conjunto de atributos para o algoritmo classificador realizar da melhor forma o seu papel. Estas técnicas podem ser utilizadas em outras aplicações que necessitem trabalhar com classificadores e que possuam poucos atributos diretos.

O tempo de apuração dos resultados também deve ser considerado na implementação de acordo com a regra de negócio, pois o tempo de 50 segundos pode ser muito alto e inviabilizar a aplicação. Neste caso o tamanho da janela de tempo deve ser ajustado para cada cenário, mas em casos como por exemplo a biblioteca o tempo é razoável e não interfere na aplicação.

Foi possível perceber que a qualidade da base de dados é imprescindível para o sucesso da implementação, e diante disso é necessário refinar todos os processos existentes na arquitetura, desde a qualidade de instalação dos equipamentos do módulo de leitura física até o módulo de mineração de dados para testes em outras aplicações em trabalhos futuros.

## Referências

- Akre, J.-M., Zhang, X., Baey, S., Kervella, B., Fladenmuller, A., Zancanaro, M., and Fonseca, M. (2014). Accurate 2-D localization of RFID tags using antenna transmission power control. *2014 IFIP Wireless Days (WD)*, pages 1–6.
- Hori, T., Wada, T., Ota, Y., Uchitomi, N., Mutsuura, K., and Okada, H. (2008). A multi-sensing-range method for position estimation of passive RFID tags. *Proceedings - 4th IEEE International Conference on Wireless and Mobile Computing, Networking and Communication, WiMob 2008*, pages 208–213.
- Huang, C. H., Lee, L. H., Ho, C. C., Wu, L. L., and Lai, Z. H. (2015). Real-time RFID indoor positioning system based on kalman-filter drift removal and heron-bilateration location estimation. *IEEE Transactions on Instrumentation and Measurement*, 64(3):728–739.
- Nakamori, E., Tsukuda, D., Fujimoto, M., Oda, Y., Wada, T., Okada, H., and Mutsuura, K. (2012). A new indoor position estimation method of RFID tags for continuous moving navigation systems. *2012 International Conference on Indoor Positioning and Indoor Navigation, IPIN 2012 - Conference Proceedings*, (November).
- Ting, S. L., Kwok, S. K., Tsang, A. H. C. A., and Ho, G. G. T. S. (2011). The Study on Using Passive RFID Tags for Indoor Positioning. *International Journal of . . .*, 3(1):9–15.
- Uchitomi, N., Inada, A., Fujimoto, M., Wada, T., Mutsuura, K., and Okada, H. (2010). Accurate indoor position estimation by Swift-Communication Range Recognition (S-CRR) method in passive RFID systems. *2010 International Conference on Indoor Positioning and Indoor Navigation, IPIN 2010 - Conference Proceedings*, (September):15–17.
- Zhang, X. b., Akre, J.-M. b., Baey, S. b., Fladenmuller, A. b., Kervella, B. b., Zancanaro, M. b. c., and Fonseca, M. (2015). Towards localization of RFID tags based on experimental analysis of RSSI. *IFIP Wireless Days, 2015-Janua(January)*.