

Um Estimador Acurado para o Protocolo DFSA em Sistemas RFID

Júlio D. de Andrade, Paulo André da S. Gonçalves

Centro de Informática (CIn) – Universidade Federal de Pernambuco (UFPE)
50.740-560 – Recife – PE – Brasil

{jda, pasg}@cin.ufpe.br

Abstract. *DFSA (Dynamic Framed Slotted ALOHA) has been widely used as an anticollision protocol for RFID systems. Under this protocol, the size of each frame succeeding the first frame is dynamically adjusted based on an estimate of the number of competing tags in the previous frame. The estimator's accuracy plays an important role on the performance of DFSA. Among the main existing estimators for DFSA there are Vogt and Eom-Lee. The latter is more recent and more accurate for a wide range of tag populations. This paper proposes two modified versions of the Vogt's estimator: the IV-I and the IV-II. Performance evaluations show that IV-II has better accuracy than or equivalent to Eom-Lee. When better, IV-II can be up to 2.61 times more accurate than Eom-Lee, which reflects in up to 69 less time slots to finish the tag identification process.*

Resumo. *O DFSA (Dynamic Framed Slotted ALOHA) vem sendo amplamente utilizado como protocolo anticollisão em sistemas RFID. Sob tal protocolo, o tamanho de cada quadro subsequente ao quadro inicial é ajustado dinamicamente com base na população estimada de etiquetas que competiram por slots no quadro anterior. A acurácia do estimador usado tem um papel primordial no desempenho do DFSA. Dentre os principais estimadores para o DFSA encontram-se o Vogt e o Eom-Lee. Este último é mais recente e mais acurado para uma ampla faixa de quantidade de etiquetas. Este artigo propõe duas versões modificadas do estimador Vogt: o IV-I e o IV-II. Os resultados de avaliação de desempenho mostram que o estimador IV-II proposto possui acurácia equivalente ou superior à acurácia do estimador Eom-Lee. Quando melhor, o IV-II pode ser até 2,61 vezes mais acurado do que o Eom-Lee, refletindo em uma economia de até 69 slots no processo de identificação de etiquetas.*

1. Introdução

Um dos maiores desafios em sistemas RFID (*Radio Frequency IDentification*) baseados em etiquetas passivas é a resolução de colisões causadas por transmissões simultâneas de etiquetas. As etiquetas passivas são limitadas em recursos computacionais e de memória, não sendo capazes de detectar colisões de sinais nem capazes de escutar transmissões de outras etiquetas. Por causa disso, o acesso ao meio de comunicação deve ser arbitrado pelo leitor e isso é feito através do uso de um protocolo anticollisão [Klair et al. 2010].

O DFSA (*Dynamic Framed Slotted ALOHA*) é um protocolo anticollisão popular para sistemas RFID [Klair et al. 2010]. Nesse protocolo, o leitor organiza o tempo em um ou mais quadros (*frames*), onde cada quadro é subdividido em *slots* de tempo. As

etiquetas são requisitadas a transmitir em um *slot* a cada quadro até serem identificadas pelo leitor. O tamanho de cada quadro subsequente ao quadro inicial é ajustado dinamicamente com base na estimativa da população de etiquetas competindo por *slots* no quadro precedente [Andrade and Gonçalves 2011]. Assim sendo, o DFSA requer a utilização de um estimador.

A acurácia do estimador empregado tem um papel primordial no desempenho do DFSA. Em [Eom and Lee 2010] é apresentado um estimador para o DFSA. Tal estimador, doravante denominado Eom-Lee, é comparado com os principais estimadores na literatura: o *Lower Bound* [Vogt 2002], o Schoute [Schoute 1983], uma versão do Vogt [Vogt 2002], o Chen [Chen 2009] e o C-Ratio [Cha and Kim 2005]. As avaliações de desempenho mostram que o Eom-Lee possui a melhor acurácia, exceto quando o tamanho do quadro é próximo do tamanho da população de etiquetas. Nessa situação, a versão do Vogt alcança resultados similares e o Schoute leva ligeira vantagem apesar dele estar entre os piores estimadores. Além disso, os resultados mostram que o Eom-Lee permite concluir o processo de identificação de etiquetas com uma quantidade similar ou menor de *slots* do que as outras melhores propostas dependendo do tamanho da população de etiquetas no intervalo [100, 1.000] e ao se considerar um quadro inicial de 64 *slots*.

Esse artigo propõe dois estimadores de tamanho de quadro para o DFSA: o IV-I (*Improved Vogt - I*) e o IV-II (*Improved Vogt - II*). Ambos são baseados no Vogt e diferem entre si e dele na estratégia de estimação quando todos os *slots* em um quadro estão em colisão. As avaliações de desempenho dos estimadores propostos são realizadas com uma população de 100 a 1.000 etiquetas tanto para um quadro inicial de 64 *slots* quanto para um quadro inicial de 128 *slots*. Os resultados mostram que o IV-II é capaz de produzir uma acurácia equivalente ou superior à acurácia do estimador Eom-Lee. Os resultados também mostram que o IV-II permite concluir o processo de identificação de etiquetas utilizando uma quantidade equivalente ou menor de *slots* do que o Eom-Lee. Quando melhor, o IV-II pode ser até 2,61 vezes mais acurado do que o Eom-Lee, refletindo em uma economia de até 69 *slots* no processo de identificação de etiquetas.

O restante deste artigo está organizado da seguinte forma: a Seção 2 detalha os principais trabalhos relacionados no contexto deste artigo. A Seção 3 apresenta uma análise de uma função utilizada pelo estimador Vogt. As Seções 4 e 5 apresentam, respectivamente, os estimadores IV-I e IV-II propostos com seus resultados de desempenho. Por fim, a Seção 6 conclui este trabalho.

2. Trabalhos Relacionados

Esta seção detalha o funcionamento de 3 estimadores: o Vogt [Vogt 2002], o Eom-Lee [Eom and Lee 2010] e uma versão do Vogt utilizada em avaliações de desempenho em [Eom and Lee 2010]. No texto que segue, os quadros de interesse no DFSA são denominados *quadro finalizado* e *quadro posterior*. O primeiro se refere ao quadro que acabou de ser finalizado, permitindo a obtenção dos quantitativos s_v , s_s e s_c que representam, respectivamente, a quantidade *slots* vazios, a quantidade de *slots* bem sucedidos e a quantidade de *slots* em colisão.

O *quadro posterior* é aquele subsequente ao *quadro finalizado*. A avaliação da necessidade de um *quadro posterior* bem como o cálculo de seu tamanho são feitos com base nos quantitativos s_v , s_s e s_c observados no *quadro finalizado*. Se houver ao menos

1 *slot* em colisão, há necessidade de se invocar o estimador e gerar um novo quadro. Se não houver ao menos 1 *slot* em colisão, o *quadro finalizado* é o último no processo de identificação. O tamanho do *quadro posterior* é representado por \hat{f} . Para todos os estimadores descritos neste artigo, \hat{n} representa a estimativa do número de etiquetas que competiram por *slots* no *quadro finalizado*.

2.1. O Estimador Vogt

O estimador Vogt [Vogt 2002] usa conceitos de probabilidade para estimar a quantidade de etiquetas que competiram em um *quadro finalizado* de tamanho L dado $1 \leq s_c < L$. Assumindo uma distribuição binomial, a quantidade esperada de *slots* contendo transmissões de r etiquetas em um quadro de tamanho L é dada por:

$$a_r^{L,n} = L \binom{n}{r} \left(\frac{1}{L}\right)^r \left(1 - \frac{1}{L}\right)^{n-r}, \quad (1)$$

onde n representa a população de etiquetas que competem por *slots* no quadro.

Com base na Eq. (1) e nos quantitativos s_v , s_s e s_c , Vogt define a função ϵ conforme representada pela Eq. (2).

$$\epsilon(L, s_v, s_s, s_c, n) = \left\| \begin{pmatrix} a_0^{L,n} \\ a_1^{L,n} \\ a_{\geq 2}^{L,n} \end{pmatrix} - \begin{pmatrix} s_v \\ s_s \\ s_c \end{pmatrix} \right\|, \quad (2)$$

onde $\|\bullet\|$ representa a norma Euclidiana. A estimativa da quantidade de etiquetas que competiram por *slots* em um quadro de tamanho L é dada por:

$$\hat{n} = \underset{n \geq 1}{\operatorname{argmin}} \epsilon(L, s_v, s_s, s_c, n), \quad (3)$$

significando que \hat{n} é igual ao n que minimiza o valor da função ϵ . Note que Vogt propõe estimar o número de etiquetas buscando a minimização da distância entre o vetor $\langle s_v, s_s, s_c \rangle$ e o vetor contendo os valores esperados para s_v , s_s e s_c . Essa proposta se baseia na desigualdade de Chebyshev, a qual afirma que o resultado de um experimento envolvendo uma variável aleatória X é, provavelmente, próximo do valor esperado de X [Vogt 2002].

O tamanho do *quadro posterior* é definido com base no número estimado \hat{n} de etiquetas. Os tamanhos possíveis são apresentados na Tabela 1. Caso $\hat{n} \in [51, 56]$ tanto $\hat{f} = 64$ quanto $\hat{f} = 128$ são escolhas adequadas.

Tabela 1. Tamanhos de quadro em função de \hat{n} .

\hat{f}	$\hat{n} \in [x, y]$	\hat{f}	$\hat{n} \in [x, y]$
16	[1, 9]	128	[51, 129]
32	[10, 27]	256	[112, ∞]
64	[17, 56]		

A Eq. (3) não é utilizada quando o número de *slots* em colisão é igual ao tamanho do quadro. Para esse caso, Vogt considera a seguinte aproximação para o valor de \hat{n} :

$$\hat{n} = 2 * s_c , \quad (4)$$

ou seja, é considerada a estimativa dada pelo estimador conhecido como *Lower Bound* [Vogt 2002]. Esse estimador adota o limite inferior de duas etiquetas por *slot* em colisão, sendo uma aproximação grosseira. Ao utilizar o *Lower Bound*, o estimador Vogt calcula o tamanho do próximo quadro como sendo $\hat{f} = \min(2 * s_c, 256)$.

2.2. O Estimador Vogt (Eom-Lee)

Em [Eom and Lee 2010] é apresentada uma avaliação de desempenho comparativa entre diversos estimadores, incluindo uma versão modificada do estimador Vogt original. Essa versão, doravante denominada *Vogt (Eom-Lee)*, elimina duas restrições: a do tamanho dos quadros ser obrigatoriamente uma potência de 2 e a desse tamanho estar confinado em um intervalo pré-definido de quantidade de *slots* com limite superior igual a 256. Quando $1 \leq s_c < L$, a estimativa \hat{n} continua sendo dada pela Eq. (3). Contudo, o tamanho do *quadro posterior* passa a ser dado por $\hat{f} = \hat{n} - s_s$.

Quando todos os *slots* do quadro estão em colisão, o *Lower Bound* continua sendo utilizado como aproximação. Nesse caso, o tamanho do *quadro posterior* e a estimativa \hat{n} são simplesmente iguais ao dobro do tamanho do *quadro finalizado*.

2.3. O Estimador Eom-Lee

O estimador Eom-Lee [Eom and Lee 2010] utiliza um algoritmo iterativo tanto para estimar a quantidade de etiquetas competindo por *slots* em um quadro quanto o tamanho \hat{f} do quadro subsequente. O quadro a ser analisado para se estimar o tamanho do próximo quadro possui tamanho L . O valor de L é assumido ser igual ao número estimado de etiquetas que competiram no quadro multiplicado por um fator β a ser determinado. Logo, o valor de L pode ser representado por:

$$L = \beta \cdot \hat{n} . \quad (5)$$

O número de etiquetas competindo em um *slot* em colisão é assumido ser igual a γ . Considerando o tamanho do próximo quadro igual ao *backlog*¹, o valor de \hat{f} pode ser calculado como:

$$\hat{f} = \hat{n} - s_s = \gamma \cdot s_c . \quad (6)$$

Note que o problema para obter a estimativa \hat{n} está na determinação do valor de γ ou de β . A relação entre ambos é explicitada pela Eq. (7) e é determinada considerando-se o seguinte: a probabilidade de r etiquetas, dentre o universo total de etiquetas, transmitirem em um mesmo *slot* pode ser aproximada por uma distribuição binomial e; a equação de cômputo de tal probabilidade pode ser aproximada por uma distribuição de Poisson com média n/L para L suficientemente grande.

$$\gamma = \frac{1 - e^{-\frac{1}{\beta}}}{\beta(1 - (1 + \frac{1}{\beta})e^{-\frac{1}{\beta}})} . \quad (7)$$

¹Quantidade de etiquetas que ainda precisam ser identificadas.

Encontrar uma solução fechada para se determinar os valores de γ e β a partir da Eq. (7) é um desafio. Para contornar o problema, o estimador Eom-Lee utiliza um algoritmo iterativo. Sejam γ_k e β_k , respectivamente, aproximações para o valor de γ e de β na k -ésima iteração do algoritmo. Tais aproximações são obtidas de acordo com as seguintes equações:

$$\beta_k = \frac{L}{\gamma_{k-1} \cdot s_c + s_s}, \quad (8)$$

$$\gamma_k = \frac{1 - e^{-\frac{1}{\beta_k}}}{\beta_k \left(1 - \left(1 + \frac{1}{\beta_k}\right) e^{-\frac{1}{\beta_k}}\right)}. \quad (9)$$

No primeiro passo do algoritmo iterativo considera-se $\beta_1 = \infty$ e $\gamma_1 = 2$ e em cada passo k seguinte determina-se uma nova aproximação para β e γ com o auxílio das Eqs. (8) e (9), respectivamente. Quando $|\gamma_{k^*-1} - \gamma_{k^*}|$ for menor que um limiar pré-definido $\epsilon_{threshold}$, o processo iterativo é interrompido. Os valores γ_{k^*-1} e γ_{k^*} representam, respectivamente, a aproximação anterior e atual para o valor de γ . A partir de então, o tamanho \hat{f} do próximo quadro e a quantidade estimada \hat{n} de etiquetas são obtidos, respectivamente, pelas Eqs. (10) e (11), onde β_{k^*} é a aproximação mais recente para o valor de β .

$$\hat{f} = \gamma_{k^*} \cdot s_c. \quad (10)$$

$$\hat{n} = \frac{\hat{f}}{\beta_{k^*}}. \quad (11)$$

3. Análise da Função ϵ de Vogt

Esta seção apresenta, graficamente, o comportamento da função ϵ de Vogt definida pela Eq. (2) para alguns casos de estudo. Esses casos se diferenciam em relação ao quantitativo de *slots* em colisão, vazios e bem sucedidos. Esses quantitativos e o tamanho L de quadro utilizados para cada um dos casos são apresentados na Tabela 2.

Tabela 2. Casos para análise da função ϵ de Vogt.

Caso #	L	s_v	s_s	s_c	Caso #	L	s_v	s_s	s_c
1	64	0	32	32	7	64	63	0	1
2	64	32	0	32	8	64	0	0	64
3	64	14	40	10	9	128	0	0	128
4	64	44	14	6	10	256	0	0	256
5	64	4	4	56	11	512	0	0	512
6	64	0	63	1					

O *caso 1* não possui *slots* vazios e há uma quantidade idêntica de *slots* em colisão e bem sucedidos. O *caso 2* possui uma quantidade igual de *slots* vazios e em colisão, não havendo *slots* bem sucedidos. Os *casos 3 a 5* consideram todos os quantitativos dos diferentes tipos de *slot* maiores que zero ao mesmo tempo em que consideram, respectivamente, uma ocorrência significativamente maior de *slots* bem sucedidos, vazios e em

colisão. No *caso 6*, a quantidade de *slots* bem sucedidos é próxima do tamanho do quadro e não há *slots* vazios. No *caso 7*, a quantidade de *slots* vazios é próxima do tamanho do quadro, não havendo *slots* bem sucedidos. Os *casos 8 a 11* possuem todos os *slots* em colisão e se diferenciam apenas pelo tamanho do quadro.

A Figura 1 mostra como o valor da função ϵ varia em função de n para os casos definidos na Tabela 2. O mínimo da função ϵ pode ser encontrado utilizando-se um método numérico apropriado. Em particular, o mínimo da função ϵ para os *casos 1 a 7* aparece nas respectivas figuras e ocorre para n dentro do intervalo $[1, 1000]$.

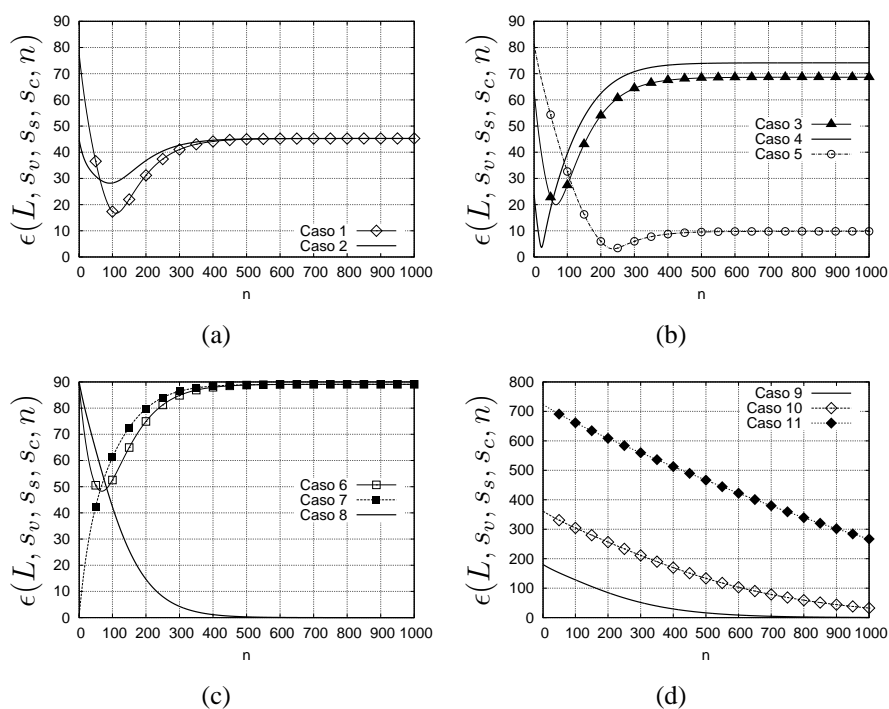


Figura 1. Comportamento da função ϵ de Vogt para os casos estudados.

Em particular aos *casos 8 a 11*, a função ϵ decresce exponencialmente à medida que n aumenta. O mínimo da função ϵ não está representado nas respectivas figuras para os casos considerados. Quando todos os *slots* estão em colisão, o mínimo da função ϵ assume o valor zero e tal mínimo ocorre quando n tende a infinito. Por limitações de espaço, uma demonstração matemática pode ser consultada em [Andrade 2012]. Pela razão exposta, Vogt utiliza a aproximação do *Lower Bound* para estimar a população de etiquetas que competiram em um quadro com todos os *slots* em colisão.

4. O Estimador IV-I Proposto

A seção anterior mostrou que a aplicação da Eq. (2) não permite encontrar, através de seu mínimo, um valor finito para a estimativa da população de etiquetas quando todos os *slots* do quadro estão em colisão. Isso ocorre porque o mínimo da função ϵ só é alcançado quando n tende a infinito. Enquanto Vogt contorna o problema utilizando a aproximação do *Lower Bound*, os estimadores propostos neste artigo o contornam utilizando outras estratégias.

Algoritmo 4.1 Estimador IV-I proposto. Entradas δ , L , s_s , s_v e s_c .

```

1: Se ( $L \neq s_c$ ) então
2:    $\hat{n} \leftarrow$  Resultado da Eq. (3);
3: Senão
4:    $n \leftarrow 2 \times L$ ;
5:    $a_0 \leftarrow L \times \left(1 - \frac{1}{L}\right)^n$ ;
6:    $a_1 \leftarrow n \times \left(1 - \frac{1}{L}\right)^{n-1}$ ;
7:    $\epsilon \leftarrow \sqrt{2} \times \sqrt{a_0^2 + a_1^2 + (a_0 \times a_1)}$ ;
8:    $\epsilon \leftarrow$  Truncar( $\delta \times \epsilon$ );
9:    $\epsilon_{anterior} \leftarrow \epsilon + 1$ ;
10:  Enquanto ( $\epsilon < \epsilon_{anterior}$ ) faça
11:     $n \leftarrow n + 1$ ;
12:     $\epsilon_{anterior} \leftarrow \epsilon$ ;
13:     $a_0 \leftarrow L \times \left(1 - \frac{1}{L}\right)^n$ ;
14:     $a_1 \leftarrow n \times \left(1 - \frac{1}{L}\right)^{n-1}$ ;
15:     $\epsilon \leftarrow \sqrt{2} \times \sqrt{a_0^2 + a_1^2 + (a_0 \times a_1)}$ ;
16:     $\epsilon \leftarrow$  Truncar( $\delta \times \epsilon$ );
17:  fim Enquanto
18:   $\hat{n} \leftarrow n - 1$ ;
19: fim Senão
20: Retorne( $\hat{n}$ );

```

O primeiro estimador proposto neste artigo é denominado IV-I (*Improved Vogt - I*) e seu pseudocódigo para estimar a população de etiquetas competindo em um quadro de interesse é apresentado pelo Algoritmo 4.1. Os parâmetros de entrada são o tamanho do quadro (L) e um fator multiplicativo (δ). O algoritmo é chamado sempre que houver ao menos um *slot* em colisão no *quadro finalizado*, ou seja, a codição $1 \leq s_c < L$ é garantida antes de se chamar o algoritmo. A estratégia do IV-I é percorrer a exponencial decrescente gerada a partir da Eq. (2) quando $L = s_c$ enquanto uma determinada condição seja satisfeita. O valor estimado \hat{n} retornado é igual ao valor de n que torna verdadeira a condição de parada decrementado de uma unidade.


O IV-I computa \hat{n} exatamente como no Vogt caso todos os *slots* não estejam em colisão. Caso contrário, o algoritmo inicia atribuindo o valor da aproximação fornecida pelo *Lower Bound* a n (linha 4). Em seguida, o valor da Eq. (2) é calculado (linhas 5-7). O valor de ϵ é, então, atualizado para a parte inteira do resultado do produto do fator multiplicativo (δ) por ϵ e um valor maior que ϵ é atribuído a $\epsilon_{anterior}$ (linhas 8-9). Ao entrar no *loop* (linhas 10-17), o valor de n é incrementado de uma unidade enquanto a condição de parada não for satisfeita. O valor de n decrementado de uma unidade é atribuído a \hat{n} , o qual é retornado como resultado final (linhas 18-20).

O tamanho \hat{f} do próximo quadro no estimador IV-I é dado por:

$$\hat{f} = \max(2, \hat{n} - s_s), \quad (12)$$

ou seja, não pode haver nenhum quadro com menos de 2 *slots*.

A Figura 2 mostra como o número estimado de etiquetas \hat{n} varia em função do tamanho L do quadro para alguns valores de δ ao se utilizar o estimador IV-I quando $L = s_c$. Os valores de L considerados estão no intervalo $[1, 1000]$. O impacto do aumento de δ é aumentar o valor da estimativa \hat{n} para um mesmo valor de L tal que $L > 1$.



(a)

Figura 2. Estimativa \hat{n} do IV-I em função de L e δ quando $L = s_c$.

4.1. Acurácia e Impacto

Esta seção avalia a acurácia do estimador de IV-I, comparando-a com a acurácia dos outros estimadores apresentados na Seção 2. A acurácia é estudada através da métrica *erro absoluto médio de estimação*. Essa métrica é definida como sendo o somatório do módulo da diferença entre o tamanho de cada quadro estimado e o *backlog* real, sendo tal resultado dividido pela quantidade total de quadros estimados ao longo do processo de identificação de etiquetas. Esta seção também estuda o impacto da acurácia dos melhores estimadores, mostrando a diferença de *slots* gerados no processo de identificação.

Os resultados apresentados são médias de 2.000 simulações para cada quantidade simulada de etiquetas que varia de 100 a 1.000 em passos de 100. Foram feitas avaliações para um quadro inicial de 64 e 128 *slots*. Um intervalo de 99% de confiança é adotado, sendo o mesmo representado em tabelas ou por barras de erros nos gráficos. Em particular ao Eom-Lee, adota-se o parâmetro $\epsilon_{threshold}$ igual a 0,001 conforme definido pelos autores.

A Tabela 3 apresenta, detalhadamente, a acurácia dos estimadores estudados para um quadro inicial de 64 e 128 *slots*. Tanto o intervalo de confiança quanto todos os valores numéricos obtidos são apresentados. Nessa tabela, as melhores acurácias na comparação entre o Vogt (Eom-Lee) e o Eom-Lee estão destacadas com um asterístico (*). O processo de marcação da melhor acurácia entre os dois estimadores, por linha da tabela, é o seguinte: primeiro, marca-se a melhor acurácia média por linha e, em seguida, marca-se a acurácia do outro estimador se ela se sobrepõe com a melhor acurácia considerando-se os intervalos de confiança.

Com base na Tabela 3, o texto seguinte compara exclusivamente o Vogt (Eom-Lee) com o Eom-Lee. Quando o tamanho do quadro inicial é igual a 64 *slots*, o seguinte pode ser observado: o Vogt (Eom-Lee) é o mais acurado na faixa de 100 a 400 etiquetas, embora o Eom-Lee tenha acurácia equivalente para 200 etiquetas e muito próxima para 100 e 300 etiquetas e; na faixa de 500 a 1.000 etiquetas, o Eom-Lee é mais acurado. Quando o tamanho do quadro inicial é igual a 128 *slots*, o seguinte pode ser notado: o Vogt (Eom-Lee) é o mais acurado na faixa de 100 a 900 etiquetas; o Eom-Lee é o mais acurado para 1.000 etiquetas e; as maiores diferenças de acurácia entre os dois estimadores só ocorrem para 800 e 1.000 etiquetas.

Tabela 3. Acurácia em nº de etiquetas dos Estimadores Estudados.

Quadro Inicial de 64 slots				
Etiquetas	Vogt	Vogt (Eom-Lee)	Eom-Lee	IV-I ($\delta = 1e4$)
100	63,59 ± 0,78	(*) 1,82 ± 0,04	1,92 ± 0,04	1,95 ± 0,05
200	93,22 ± 0,89	(*) 3,17 ± 0,08	(*) 3,25 ± 0,08	3,28 ± 0,09
300	87,92 ± 0,86	(*) 5,07 ± 0,18	6,02 ± 0,43	5,84 ± 0,40
400	108,36 ± 0,78	(*) 12,91 ± 0,56	17,21 ± 0,89	17,78 ± 0,89
500	143,08 ± 0,87	26,98 ± 0,53	(*) 22,21 ± 0,33	22,11 ± 0,37
600	185,33 ± 0,75	37,46 ± 0,42	(*) 15,68 ± 0,12	16,15 ± 0,12
700	233,12 ± 0,68	45,84 ± 0,48	(*) 7,69 ± 0,16	8,49 ± 0,13
800	286,68 ± 0,71	56,30 ± 0,75	(*) 6,16 ± 0,08	4,85 ± 0,08
900	351,87 ± 0,72	70,68 ± 1,13	(*) 13,60 ± 0,09	12,07 ± 0,09
1000	425,24 ± 0,70	90,15 ± 1,19	(*) 20,80 ± 0,13	18,97 ± 0,13
Quadro Inicial de 128 slots				
Etiquetas	Vogt	Vogt (Eom-Lee)	Eom-Lee	IV-I ($\delta = 1e2$)
100	73,23 ± 0,86	(*) 1,54 ± 0,03	(*) 1,53 ± 0,03	1,62 ± 0,04
200	115,52 ± 0,81	(*) 2,26 ± 0,04	2,38 ± 0,04	2,35 ± 0,05
300	83,61 ± 0,53	(*) 3,11 ± 0,07	(*) 3,19 ± 0,06	3,12 ± 0,06
400	93,34 ± 0,71	(*) 3,92 ± 0,09	(*) 4,00 ± 0,09	3,97 ± 0,09
500	119,75 ± 0,51	(*) 4,76 ± 0,12	5,04 ± 0,13	4,87 ± 0,13
600	155,97 ± 0,66	(*) 6,35 ± 0,21	(*) 6,37 ± 0,20	6,27 ± 0,19
700	203,71 ± 0,64	(*) 8,14 ± 0,35	9,19 ± 0,59	7,90 ± 0,25
800	260,02 ± 0,72	(*) 13,04 ± 0,73	16,52 ± 1,14	8,00 ± 0,17
900	328,42 ± 0,72	(*) 24,15 ± 1,16	(*) 25,54 ± 1,28	6,55 ± 0,21
1000	404,84 ± 0,73	38,66 ± 1,19	(*) 32,32 ± 0,84	12,07 ± 0,15

Adicionalmente, a Tabela 3 destaca em negrito as melhores acurácias obtidas para cada quantidade de etiquetas e tamanho de quadro inicial estudados. O processo de marcação das melhores acurácias, por linha da tabela, é o seguinte: primeiramente, enfatiza-se a melhor acurácia média por linha e, em seguida, ressaltam-se as acurácias equivalentes, isto é, aquelas que na mesma linha possuem alguma sobreposição com a melhor acurácia considerando-se os intervalos de confiança.

O texto seguinte faz uma comparação entre todos os estimadores estudados considerando os resultados na Tabela 3. Para um quadro inicial de 64 slots, nota-se o seguinte: o Vogt (Eom-Lee) é o mais acurado de todos na faixa de 100 a 400 etiquetas, ainda que as acurácias dos três melhores estimadores sejam muito próximas para 100 e 300 etiquetas e equivalentes para 200 etiquetas; o Eom-Lee é o mais acurado na faixa de 500 a 700 etiquetas, embora o IV-I possua acurácia equivalente para 500 etiquetas e próxima para 600 e 700 etiquetas; o IV-I é o mais acurado na faixa de 800 a 1.000 etiquetas, embora o Eom-Lee possua acurácias próximas. Quando o quadro inicial é de 128 slots, o IV-I é o mais acurado na faixa de 200 a 1.000 etiquetas e; para 100 etiquetas a acurácia do IV-I é muito próxima daquela obtida pelo Vogt (Eom-Lee) e pelo Eom-Lee, os quais são os melhores para 100 etiquetas.

As Figuras 3(a) e 3(b) apresentam, graficamente, a acurácia dos estimadores estudados para um tamanho de quadro inicial igual a 64 e 128 slots, respectivamente. Por questões de legibilidade, os intervalos de confiança não são apresentados, mas podem

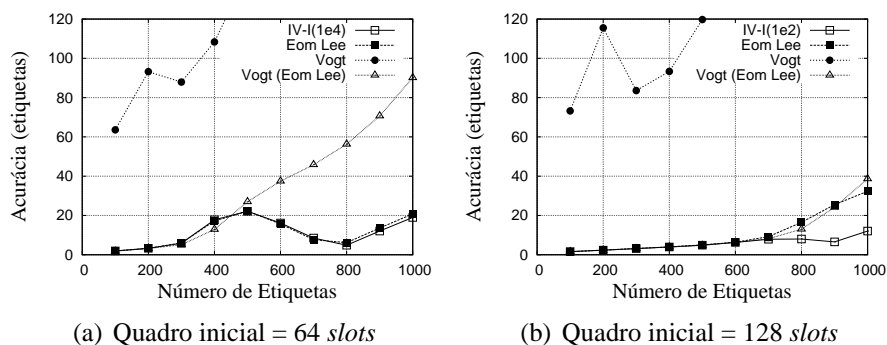


Figura 3. Acurácia dos Estimadores.

ser obtidos na Tabela 3. A Figura 3(a) reforça o seguinte para um quadro inicial de 64 slots: os estimadores IV-I, Vogt (Eom-Lee) e Eom-Lee possuem acurácias próximas no intervalo de 100 a 500 etiquetas e; acima de 500 etiquetas, as acurácias do IV-I e do Eom-Lee são as melhores e estão próximas entre si. A Figura 3(b) reforça o seguinte para um quadro inicial de 128 slots: o IV-I, o Vogt (Eom-Lee) e o Eom-Lee possuem acurácias próximas para até 700 etiquetas e; acima desse valor, o IV-I é o mais acurado entre todos os estimadores, alcançando uma acurácia 2,67 vezes maior do que a acurácia do Eom-Lee para 1.000 etiquetas.

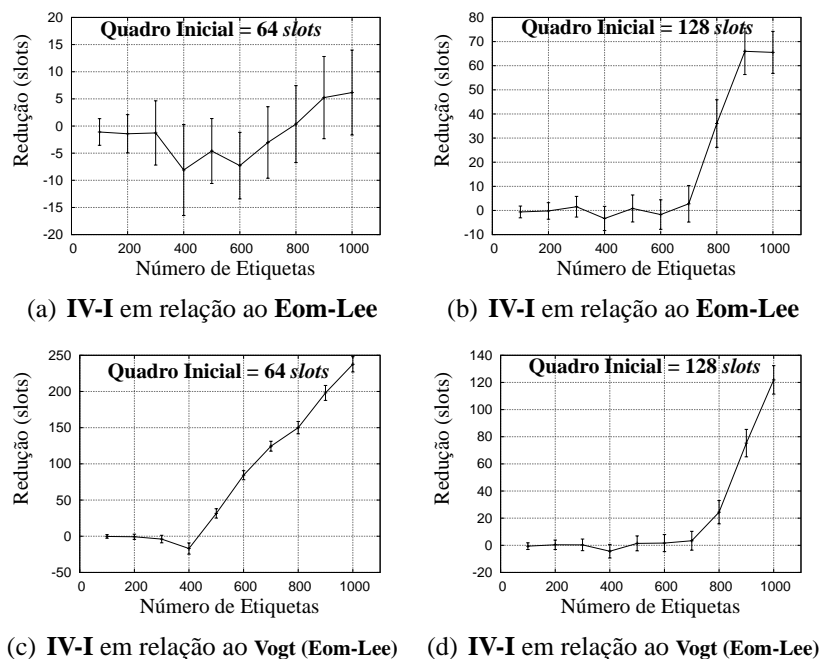


Figura 4. Redução de slots: IV-I em relação ao Eom-Lee e ao Vogt (Eom-Lee).

As Figuras 4(a) e 4(b) apresentam a redução, em número de slots, obtida pelo IV-I em relação ao Eom-Lee para um quadro inicial com 64 e 128 slots, respectivamente. Dada a incerteza, a Figura 4(a) sugere que, exceto para 600 etiquetas, o IV-I e o Eom-Lee são equivalentes em termos de quantidade de slots gerados quando o quadro inicial é de 64 slots. Já a Figura 4(b) sugere que para um quadro inicial de 128 slots, o Eom-Lee e o IV-I são equivalentes em termos de quantidade de slots gerados até uma população de

700 etiquetas. Acima desse valor, o IV-I leva vantagem, chegando a usar 66 *slots* a menos do que o Eom-Lee para concluir o processo de identificação de 900 etiquetas.

As Figuras 4(c) e 4(d) apresentam a redução, em número de *slots*, do IV-I em relação ao Vogt (Eom-Lee) para um quadro inicial igual a 64 e 128 *slots*, respectivamente. Dada a incerteza, a Figura 4(c) mostra que o IV-I só é inferior ao Vogt (Eom-Lee) quando a população de etiquetas gira em torno 400 e um quadro inicial de 64 *slots* é utilizado. A redução máxima observada do IV-I em relação ao Vogt (Eom-Lee) é de 238 *slots* para 1.000 etiquetas. A Figura 4(d) sugere que o IV-I e o Vogt (Eom-Lee) são equivalentes, em termos de quantidade de *slots* gerados, até uma população de 700 etiquetas. Acima desse valor, o IV-I é melhor, gerando até 121 *slots* a menos do que o Vogt (Eom-Lee) para concluir o processo de identificação de 1.000 etiquetas.

5. O Estimador IV-II Proposto

O estimador IV-II (*Improved Vogt - II*) propõe uma outra estratégia para estimar a população de etiquetas quando todos os *slots* do quadro estão em colisão. Nesse caso, a estimativa \hat{n} é definida por uma função linear do tamanho do quadro. Essa função é obtida a partir de aproximações para as curvas apresentadas na Figura 2 de acordo com o valor do fator multiplicativo δ .

Algoritmo 5.1 Estimador IV-II proposto. Entradas δ , L , s_s , s_v e s_c .

```

1: Se ( $L \neq s_c$ ) então
2:    $\hat{n} \leftarrow$  Resultado da Eq. (3);
3: Senão
4:   Comute para ( $\delta$ )
5:      $1e0 : n \leftarrow 2,001001000 * (L - 1) + 2$ ; interrompa;
6:      $1e1 : n \leftarrow 3,947947950 * (L - 1) + 2$ ; interrompa;
7:      $1e2 : n \leftarrow 6,851851850 * (L - 1) + 2$ ; interrompa;
8:      $1e3 : n \leftarrow 9,497497500 * (L - 1) + 2$ ; interrompa;
9:      $1e4 : n \leftarrow 12,047047047 * (L - 1) + 2$ ; interrompa;
10:     $1e5 : n \leftarrow 14,518518500 * (L - 1) + 2$ ; interrompa;
11:     $1e6 : n \leftarrow 17,011011000 * (L - 1) + 2$ ; interrompa;
12:   fim Comute
13:    $\hat{n} \leftarrow \lceil n \rceil$ ;
14: fim Senão
15: Retorne ( $\hat{n}$ );

```

O pseudocódigo para estimar a população de etiquetas competindo em um quadro de interesse utilizando-se o IV-II é apresentado pelo Algoritmo 5.1. Os parâmetros de entrada são o tamanho do quadro (L) e a referência (δ) para a reta a ser utilizada nos cálculos. O algoritmo é chamado sempre que houver ao menos um *slot* em colisão no textitquadro finalizado, ou seja, a codição $1 \leq s_c < L$ é garantida antes de se chamar o algoritmo. O algoritmo computa \hat{n} exatamente como no Vogt para L diferente de s_c . Se o quadro possuir todos os *slots* em colisão, o algoritmo obtém n a partir da equação da reta definida pela referência δ (*linhas 4 a 12*). O algoritmo retorna (*linha 15*) o valor de \hat{n} computado anteriormente (*linha 13*) como sendo igual ao valor de n arredondado para o menor inteiro maior ou igual a n . O tamanho \hat{f} do próximo quadro no estimador IV-II também é obtido através da Eq. (12).

5.1. Acurácia e Impacto

Esta seção avalia a acurácia do IV-II e a compara com a acurácia dos demais estimadores estudados. Também é estudado o impacto da acurácia dos melhores estimadores, mos-

trando a diferença na quantidade de *slots* gerados no processo de identificação. A métrica de acurácia usada e os cenários avaliados são os mesmos descritos na Seção 4.1.

A Tabela 4 destaca em negrito as melhores acurácias obtidas para cada quantidade de etiquetas e tamanho de quadro inicial. O processo de marcação das melhores acurácias, por linha da tabela, é o mesmo descrito na Seção 4.1. Para um quadro inicial de 64 *slots*, observa-se o seguinte: o Vogt (Eom-Lee) é o mais acurado na faixa de 100 a 400 etiquetas, ainda que as acurácias dos três melhores estimadores sejam equivalentes para 200 etiquetas e muito próximas para 100 e 300 etiquetas; o IV-II é o mais acurado na faixa de 500 a 1.000 etiquetas, embora o Eom-Lee possua acurácia equivalente para 500 e 700 etiquetas. Quando o quadro inicial é de 128 *slots*, o IV-II é o mais acurado na faixa de 100 a 1.000 etiquetas, embora as acurácias na faixa de 100 a 700 etiquetas sejam próximas às acurácias do Eom-Lee e do Vogt (Eom-Lee).

Tabela 4. Acurácia em nº de etiquetas dos Estimadores Estudados.

Quadro Inicial de 64 <i>slots</i>				
Etiquetas	Vogt	Vogt (Eom-Lee)	Eom-Lee	IV-II ($\delta = 1e4$)
100	63,59 ± 0,78	1,82 ± 0,04	1,92 ± 0,04	1,91 ± 0,04
200	93,22 ± 0,89	3,17 ± 0,08	3,25 ± 0,08	3,25 ± 0,08
300	87,92 ± 0,86	5,07 ± 0,18	6,02 ± 0,43	5,68 ± 0,36
400	108,36 ± 0,78	12,91 ± 0,56	17,21 ± 0,89	16,82 ± 0,85
500	143,08 ± 0,87	26,98 ± 0,53	22,21 ± 0,33	21,59 ± 0,34
600	185,33 ± 0,75	37,46 ± 0,42	15,68 ± 0,12	15,37 ± 0,13
700	233,12 ± 0,68	45,84 ± 0,48	7,69 ± 0,16	7,48 ± 0,12
800	286,68 ± 0,71	56,30 ± 0,75	6,16 ± 0,08	5,87 ± 0,09
900	351,87 ± 0,72	70,68 ± 1,13	13,60 ± 0,09	12,96 ± 0,10
1000	425,24 ± 0,70	90,15 ± 1,19	20,80 ± 0,13	19,98 ± 0,15
Quadro Inicial de 128 <i>slots</i>				
Etiquetas	Vogt	Vogt (Eom-Lee)	Eom-Lee	IV-II ($\delta = 1e2$)
100	73,23 ± 0,86	1,54 ± 0,03	1,53 ± 0,03	1,57 ± 0,03
200	115,52 ± 0,81	2,26 ± 0,04	2,38 ± 0,04	2,31 ± 0,05
300	83,61 ± 0,53	3,11 ± 0,07	3,19 ± 0,06	3,11 ± 0,06
400	93,34 ± 0,71	3,92 ± 0,09	4,00 ± 0,09	3,96 ± 0,09
500	119,75 ± 0,51	4,76 ± 0,12	5,04 ± 0,13	4,91 ± 0,13
600	155,97 ± 0,66	6,35 ± 0,21	6,37 ± 0,20	6,28 ± 0,20
700	203,71 ± 0,64	8,14 ± 0,35	9,19 ± 0,59	7,75 ± 0,25
800	260,02 ± 0,72	13,04 ± 0,73	16,52 ± 1,14	7,96 ± 0,17
900	328,42 ± 0,72	24,15 ± 1,16	25,54 ± 1,28	6,80 ± 0,21
1000	404,84 ± 0,73	38,66 ± 1,19	32,32 ± 0,84	12,36 ± 0,16

As Figuras 5(a) e 5(b) apresentam, graficamente, a acurácia dos estimadores estudados para um tamanho de quadro inicial de 64 e 128 *slots*, respectivamente. Por questões de legibilidade, os intervalos de confiança são apresentados apenas na Tabela 4. Quando o quadro inicial é de 64 *slots*, o seguinte é reforçado: o IV-II, o Vogt (Eom-Lee) e o Eom-Lee possuem acurácias próximas na faixa de 100 a 500 etiquetas e; o IV-II e o Eom-Lee são os dois mais acurados para quantitativos de etiquetas acima de 500, mas as acurácias são próximas. Para um quadro inicial de 128 *slots*, a Figura 5(b) reforça que os três melhores estimadores (IV-II, Vogt (Eom-Lee) e Eom-Lee) possuem acurácias próximas até

700 etiquetas. Acima desse valor, o IV-II é o mais acurado de todos. Sua acurácia chega a ser 2,61 vezes maior do que a acurácia do Eom-Lee para 1.000 etiquetas.

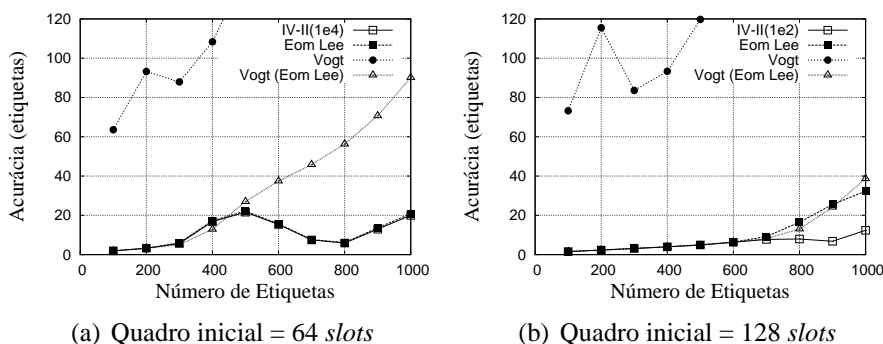


Figura 5. Acurácia dos Estimadores.




Figura 6. Redução de slots: IV-II em relação ao Eom-Lee e ao Vogt (Eom-Lee).

A Figura 6 apresenta a redução, em número de *slots*, obtida pelo IV-II em relação ao Eom-Lee e ao Vogt (Eom-Lee). Dada a incerteza, a Figura 6(a) sugere que o IV-II e o Eom-Lee são equivalentes, em termos de quantidade de *slots* gerados, quando o quadro inicial é de 64 *slots*. A Figura 6(b) sugere que para um quadro inicial de 128 *slots*, o Eom-Lee e o IV-II são equivalentes, em termos de quantidade de *slots* gerados, até uma população de 700 etiquetas. Contudo, acima desse valor, o IV-II leva vantagem, chegando a usar 69 *slots* a menos do que o Eom-Lee para concluir o processo de identificação de 1.000 etiquetas.

A Figura 6(c) mostra que o IV-II só produz poucos *slots* a mais do que o Vogt (Eom-Lee) quando a população de etiquetas está em torno 400 e um quadro inicial de 64 *slots* é utilizado. Para os demais quantitativos de etiquetas e com base nas incertezas,

o IV-II é equivalente ou melhor. A redução máxima observada com o uso do IV-II em relação ao Vogt (Eom-Lee) é de 232 *slots* para 1.000 etiquetas. A Figura 6(d) sugere que o IV-II e o Vogt (Eom-Lee) são equivalentes, em termos de quantidade de *slots* gerados, até uma população de 700 etiquetas. Acima disso, o IV-II é melhor, usando até 125 *slots* a menos do que o Vogt (Eom-Lee) para concluir a identificação de 1.000 etiquetas.

6. Conclusões

Este artigo propôs os estimadores IV-I e IV-II para o protocolo DFSA em sistemas RFID. O IV-II se mostrou muito acurado e melhor do que o IV-I no confronto direto com o Vogt, o Eom-Lee e o Vogt (Eom-Lee). Os resultados mostraram que o Eom-Lee e o IV-II são os melhores estimadores para um quadro inicial de 64 *slots* e uma população desconhecida de 100 a 1.000 etiquetas. Nessas condições, eles concluem o processo de identificação de etiquetas com uma quantidade equivalente de *slots*.

Por outro lado, o IV-II é o melhor estimador para um quadro inicial de 128 *slots* e uma população desconhecida de 100 a 1.000 etiquetas. Nessas condições, o IV-II permite usar uma quantidade equivalente ou menor de *slots* do que o Eom-Lee e o Vogt (Eom-Lee). Quando melhor, o IV-II gera até 69 *slots* a menos do que o Eom-Lee e até 125 *slots* a menos do que o Vogt (Eom-Lee). Para ambos os tamanhos de quadro inicial estudados, o IV-II foi significativamente mais acurado do que o Vogt.

É importante ressaltar que o estimador é executado no leitor ou em um servidor associado ao leitor, não havendo limitações de recursos computacionais como nas etiquetas. Mesmo assim, é importante haver um estudo aprofundado sobre os custos e o tempo de execução dos estimadores. Tal estudo será realizado em trabalhos futuros.

Referências

- Andrade, J. D. (2012). Um Método de Gerenciamento de Frames para o Protocolo DFSA em Sistemas RFID. Dissertação de Mestrado, Centro de Informática – CIn/UFPE.
- Andrade, J. D. and Gonçalves, P. A. S. (2011). Uma Função de Cálculo de Tamanho de Frames para o Protocolo DFSA em Sistemas RFID. In *Proc. of XVI Workshop de Gerência e Operação de Redes (WGRS)*, pp. 61–74, Campo Grande, MS.
- Cha, J. R. and Kim, J. H. (2005). Novel Anti-collision Algorithms for Fast Object Identification in RFID Systems. In *Proc. of the 11th International Conf. on Parallel and Distributed Systems*, vol. 2, pp. 63–67.
- Chen, W.-T. (2009). An Accurate Tag Estimate Method for Improving the Performance of an RFID Anticollision Algorithm Based on Dynamic Frame Length ALOHA. *IEEE Transactions on Automation Science and Engineering*, 6(1):9–15.
- Eom, J.-B. and Lee, T.-J. (2010). Accurate Tag Estimation for Dynamic Framed-slotted ALOHA in RFID Systems. *IEEE Communications Letters*, 14:60–62.
- Klair, D., Chin, K.-W., and Raad, R. (2010). A Survey and Tutorial of RFID Anti-Collision Protocols. *IEEE Communications Surveys Tutorials*, 12(3):400–421.
- Schoute, F. C. (1983). Dynamic Frame Length ALOHA. *IEEE Transactions on Communications*, 31:565–568.
- Vogt, H. (2002). Efficient Object Identification with Passive RFID Tags. In *Proc. of the First International Conf. on Pervasive Computing*, pp. 98–113, London, UK.