

PGCOMP - Programa de Pós-Graduação em Ciência da Computação  
Universidade Federal da Bahia (UFBA)  
Av. Milton Santos, s/n - Ondina  
Salvador, BA, Brasil, 40170-110

<https://pgcomp.ufba.br>  
[pgcomp@ufba.br](mailto:pgcomp@ufba.br)

Sistemas de tempo real (RTS) são aqueles cujas ações estão sujeitas a restrições temporais, definidas em termos de prazos de execução (deadlines). Um RTS crítico é usualmente projetado para nunca deixar de cumprir seus deadlines, como é o caso dos sistemas aviônicos e espaciais. Para que isso aconteça, é fundamental que se saiba qual o tempo máximo que cada tarefa leva para ser executada nestes ambientes, parâmetro conhecido como Tempo de Execução no Pior Caso (WCET). Estimar o WCET de uma tarefa não é simples e, no caso das arquiteturas modernas, o mesmo está sujeito a imprevisíveis influências de diferentes elementos de hardware e software, que impedem a identificação de um valor absoluto de WCET. Uma das técnicas mais empregadas, nestes casos, é a Análise Temporal Probabilística Baseada em Medições (MBPTA), fundamentada em um ramo da estatística conhecido como Teoria dos Valores Extremos (EVT). Por meio da MBPTA-EVT pode-se inferir distribuições de probabilidade de pior caso e estimar WCET Probabilísticos (pWCET). O presente trabalho visa realizar uma análise experimental do uso da EVT via MBPTA para inferência de pWCET, apresentando o processo de aplicação da técnica em um ambiente real RPi e expondo os desafios e problemas encontrados durante este processo; ponto raramente exposto pela literatura. Os resultados apontam que EVT é eficaz mas que nem sempre produz modelos adequados e resultados pWCETs coerentes em uma arquitetura moderna real. Assim, a principal contribuição do trabalho é oferecer um alerta à comunidade, que pode necessitar de métodos alternativos para análise temporal. A pesquisa está inserida no contexto do projeto Kepler, uma cooperação entre o IC-UFBA e o INRIA-Paris.

Palavras-chave: Análise Temporal Probabilística Baseada em Medições (MBPTA), Teoria dos Valores Extremos (EVT), Sistemas de Tempo Real (RTS), Tempo de Execução no Pior Caso (WCET), WCET Probabilístico (pWCET).

# Avaliação experimental do uso de estatística dos valores extremos na determinação de limites de tempos de execução para projeto de sistemas de tempo real

Jamile de Barros Vasconcelos

Dissertação de Mestrado

Universidade Federal da Bahia

Programa de Pós-Graduação em  
Ciência da Computação

Maiο | 2023

MSC | 157 | 2023

Avaliação experimental do uso de estatística dos valores extremos na determinação de limites de tempos de execução para projeto de sistemas de tempo real

Jamile de Barros  
Vasconcelos

UFBA







Universidade Federal da Bahia  
Instituto de Computação

Programa de Pós-Graduação em Ciência da Computação

**AVALIAÇÃO EXPERIMENTAL DO USO DE  
ESTATÍSTICA DOS VALORES EXTREMOS  
NA DETERMINAÇÃO DE LIMITES DE  
TEMPOS DE EXECUÇÃO PARA PROJETO  
DE SISTEMAS DE TEMPO REAL**

Jamile de Barros Vasconcelos

DISSERTAÇÃO DE MESTRADO

Salvador  
30 de maio de 2023



JAMILE DE BARROS VASCONCELOS

**AVALIAÇÃO EXPERIMENTAL DO USO DE ESTATÍSTICA DOS  
VALORES EXTREMOS NA DETERMINAÇÃO DE LIMITES DE  
TEMPOS DE EXECUÇÃO PARA PROJETO DE SISTEMAS DE  
TEMPO REAL**

Esta Dissertação de Mestrado foi apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal da Bahia, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Orientador: George Marconi de Araújo Lima

Salvador  
30 de maio de 2023

Sistema de Bibliotecas - UFBA

Vasconcelos, Jamile de Barros.

Avaliação Experimental do Uso de Estatística dos Valores Extremos na Determinação de Limites de Tempos de Execução para Projeto de Sistemas de Tempo Real / Jamile de Barros Vasconcelos – Salvador, 2023.

168p.: il.

Orientador: Prof. Dr. George Marconi de Araújo Lima.

Dissertação (Mestrado) – Universidade Federal da Bahia, Instituto de Computação, 2023.

1. Análise Temporal Probabilística Baseada em Medições (MBPTA). 2. Teoria dos Valores Extremos (EVT). 3. Sistemas de Tempo Real (RTS), 4. WCET Probabilístico (pWCET). I. Lima, George. II. Universidade Federal da Bahia. Instituto de Computação. III Título.

CDD – V331

CDU – 004.4

MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DA BAHIA  
INSTITUTO DE COMPUTAÇÃO



PGCOMP - Programa de Pós-Graduação em Ciência da Computação  
<http://pgcomp.ufba.br>


---

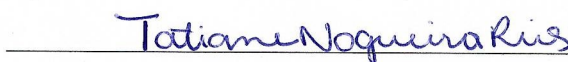
*“Avaliação experimental do uso de estatística dos valores extremos na determinação de limites de tempos de execução para projeto de sistemas de tempo real”*


Jamile de Barros Vasconcelos

Dissertação apresentada ao Colegiado do Programa de Pós-Graduação em Ciência da Computação na Universidade Federal da Bahia, como requisito parcial para obtenção do Título de Mestre em Ciência da Computação.

**Banca Examinadora**

  
Prof. Dr. George Marconi de Araújo Lima (Orientador PGCOMP)

  
Prof.<sup>a</sup>. Dr.<sup>a</sup>. Tatiane Nogueira Rios (PGCOMP)

  
Prof.<sup>a</sup>. Dr.<sup>a</sup>. Verônica Maria Cadena Lima (IME/UFBA)

---





## AGRADECIMENTOS

A realização deste trabalho contou com a importante colaboração de diferentes pessoas. Agradeço a minha mãe, sempre, presença incondicional, a Marcos, pela eterna paciência, incentivo e mirabolantes soluções computeiras, ao meu professor e orientador George Lima, pelos ensinamentos e por ter me possibilitado vivenciar tantas novas experiências e aprendizados, a professora Verônica Cadena Lima, pela valiosa consultoria nos momentos de escuridão estatística, a Liliana Cucu-Grosjean, Adriana Gogonel, projeto Kepler e INRIA, pelo *superbe séjour* em Paris, aos professores membros das bancas de qualificativo e defesa, Flávia Maristela, Rômulo Oliveira, Tatiane Nogueira e Verônica Lima, pelas ricas contribuições, aos parceiros, professores/colegas de caminhada no Brasil e na França, Kevin Zagalo, Slim Ben Amor, Tadeu Nogueira e Marwan Wehaiba, e, por fim, à CAPES, por ter viabilizado financeiramente esta pesquisa.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001.



## RESUMO

Sistemas de tempo real (RTS) são aqueles cujas ações estão sujeitas a restrições temporais, definidas em termos de prazos de execução (*deadlines*). Um RTS crítico é usualmente projetado para nunca deixar de cumprir seus *deadlines*, como é o caso dos sistemas aviônicos e espaciais. Para que isso aconteça, é fundamental que se saiba qual o tempo máximo que cada tarefa leva para ser executada nestes ambientes, parâmetro conhecido como Tempo de Execução no Pior Caso (WCET). Estimar o WCET de uma tarefa não é simples e, no caso das arquiteturas modernas, o mesmo está sujeito a imprevisíveis influências de diferentes elementos de hardware e software, que impedem a identificação de um valor absoluto de WCET. Uma das técnicas mais empregadas, nestes casos, é a Análise Temporal Probabilística Baseada em Medições (MBPTA), fundamentada em um ramo da estatística conhecido como Teoria dos Valores Extremos (EVT). Por meio da MBPTA-EVT pode-se inferir distribuições de probabilidade de pior caso e estimar WCET Probabilísticos (*Probabilistic Worst Case Execution Time* - pWCET).

O presente trabalho visa realizar uma análise experimental do uso da EVT via MBPTA para inferência de pWCET, apresentando o processo de aplicação da técnica em um ambiente real RPi e expondo os desafios e problemas encontrados durante este processo; ponto raramente exposto pela literatura. Os resultados apontam que EVT é eficaz mas que nem sempre produz modelos adequados e resultados pWCET coerentes em uma arquitetura moderna real. Assim, a principal contribuição do trabalho é oferecer um alerta à comunidade, que pode necessitar de métodos alternativos para análise temporal. A pesquisa está inserida no contexto do projeto Kepler, uma cooperação entre o IC-UFBA e o INRIA-Paris.

**Palavras-chave:** Análise Temporal Probabilística Baseada em Medições (MBPTA), Teoria dos Valores Extremos (EVT), Sistemas de Tempo Real (RTS), Tempo de Execução no Pior Caso (WCET), WCET Probabilístico (pWCET).



## ABSTRACT

Real-time systems (RTS) are those whose actions are subject to time constraints, defined in terms of execution time deadlines. A hard RTS is usually designed to never miss a deadline, as in the case of avionics and space systems. To guarantee this it is essential to know the maximum time that each task takes to be executed, a parameter known as Worst Case Execution Time (WCET). Estimating the WCET of a task is not simple and, in the case of modern architectures, it is subject to unpredictable influences caused by different hardware and software elements, which prevent the derivation of an absolute WCET value. One of the most used techniques in these cases is the Measurement-Based Probabilistic Timing Analysis (MBPTA) method based on the Extreme Values Theory (EVT) statistical area, for estimating worst-case probability distributions, called Probabilistic WCET (pWCET) .

The present work aims to carry out an experimental analysis of the use of EVT via MBPTA for pWCET inference, presenting the process of applying the technique in a real RPi environment and exposing the challenges and failures encountered during this process; a point rarely discussed in the literature. The results indicate that EVT is effective but does not always produce adequate models and consistent pWCET results in a real modern architecture. Thus, the main contribution of this work is to offer an alert to the community, which may need alternative methods for temporal analysis. This work is part of the Kepler project, a cooperation between IC-UFBA and INRIA-Paris.

**Keywords:** Measurement-Based Probabilistic Time Analysis (MBPTA), Extreme Value Theory (EVT), Real Time Systems (RTS), Worst Case Execution Time (WCET), Probabilistic WCET (pWCET).



# SUMÁRIO

<b>Capítulo 1—Introdução</b>	<b>1</b>
1.1 Sistemas de tempo real e Análise Temporal . . . . .	2
1.1.1 Análise Temporal Probabilística em arquiteturas modernas . . . . .	2
1.2 Objeto de pesquisa . . . . .	4
1.3 Organização do trabalho . . . . .	5
<b>Capítulo 2—Aplicação da EVT em Análise Temporal</b>	<b>7</b>
2.1 Amostragem . . . . .	8
2.1.1 Tamanho da amostra . . . . .	9
2.1.2 Representatividade . . . . .	9
2.1.3 Dependências . . . . .	10
2.1.4 Adequação de observações . . . . .	10
2.2 Seleção de valores . . . . .	11
2.2.1 Método BMM . . . . .	11
2.2.2 Método PoT . . . . .	12
2.3 Estimativa de parâmetros . . . . .	14
2.4 Verificação da qualidade de ajuste . . . . .	14
2.4.1 Teste Dietrich . . . . .	18
2.5 Estimativa pWCET . . . . .	18
<b>Capítulo 3—Revisão Bibliográfica</b>	<b>25</b>
3.1 Apresentação e visão geral . . . . .	25
3.2 Dados e características . . . . .	26
3.3 Plataformas . . . . .	28
3.4 Divergências . . . . .	29
<b>Capítulo 4—Resultados Experimentais</b>	<b>31</b>
4.1 Metodologia . . . . .	32
4.1.1 Cenários de testes . . . . .	32
4.1.2 Tamanho e quantidade de amostras . . . . .	33
4.1.3 Ferramentas estatísticas . . . . .	33
4.1.4 Testes GoF . . . . .	34
4.1.5 Análise dos dados amostrais . . . . .	34
4.1.6 Aplicação EVT . . . . .	35
4.2 Resultados . . . . .	35

<b>Capítulo 5—Conclusão</b>	45
<b>Referências Bibliográficas</b>	49
<b>Apêndice A—Apresentação detalhada por <i>benchmark</i></b>	57
A.1 Modelo para os resultados . . . . .	58
A.2 Resultados . . . . .	59
A.2.1 Grupo 01 . . . . .	59
A.2.1.1 <i>Bubble Sort</i> . . . . .	59
A.2.1.2 <i>Merge Sort</i> . . . . .	65
A.2.1.3 <i>Insertion Sort</i> . . . . .	72
A.2.1.4 <i>Quick Sort</i> . . . . .	78
A.2.1.5 Comparativo Grupo 01 . . . . .	84
A.2.2 Grupo 02 . . . . .	86
A.2.2.1 <i>Fft1</i> . . . . .	86
A.2.2.2 <i>Sqrt</i> . . . . .	93
A.2.2.3 <i>Fibcall</i> . . . . .	99
A.2.2.4 Comparativo Grupo 02 . . . . .	105
A.2.3 Grupo 03 . . . . .	106
A.2.3.1 <i>Cnt</i> . . . . .	106
A.2.3.2 <i>Edn</i> . . . . .	114
A.2.3.3 <i>Matmult</i> . . . . .	120
A.2.3.4 Comparativo Grupo 03 . . . . .	127
A.2.4 Grupo 04 . . . . .	129
A.2.4.1 <i>Binary Search</i> . . . . .	129
A.2.4.2 <i>Comparativo Grupo 04</i> . . . . .	135
<b>Apêndice B—Nível de retorno estimado para a probabilidade de excedência <math>10^{-5}</math></b>	139
<b>Apêndice C—Código-fonte</b>	165



## LISTA DE FIGURAS

1.1	Representação do conceito de pWCET através de CDFs e PDFs . . . . .	4
2.1	Representação das etapas EVT para estimativa pWCET (Fonte do Autor)	9
2.2	Representação da seleção de observações via o método BMM (Fonte do Autor) . . . . .	12
2.3	PDFs da família de distribuição GEV para $\xi = -0.5$ , $\xi = 0$ e $\xi = 0.5$ , com $\sigma$ e $\mu$ não informados . . . . .	12
2.4	Representação da seleção de observações via o método PoT (Fonte do Autor)	13
2.5	PDFs da família de distribuição GPD para $\xi = -0.5$ , $\xi = 0$ e $\xi = 0.5$ , com $\sigma$ não informado . . . . .	13
2.6	Histograma e gráfico de dispersão das Amostras 01 e 02 . . . . .	15
2.7	Gráficos QQ dos modelos EVT (GEV) obtidos para as amostras utilizadas como exemplo, com parâmetros estimados via MLE e tamanhos de Bloco com $n = 50$ , $n = 100$ e $n = 200$ . . . . .	16
2.8	Gráficos QQ dos modelos EVT (GEV) obtidos para as amostras utilizadas como exemplo, com parâmetros estimados via LM e tamanhos de Bloco com $n = 50$ , $n = 100$ e $n = 200$ . . . . .	17
2.9	Gráficos de faixa de limiar obtidos para as amostras utilizadas como exemplo, com intervalos de <i>thresholds</i> especificados em (27910200:27920200) para a Amostra 01 e (27947550:27948650) para a Amostra 02 . . . . .	19
2.10	Gráficos QQ dos modelos EVT (GPD) obtidos para as amostras utilizadas como exemplo, com parâmetros estimados via MLE e <i>thresholds</i> com valores = $a$ , $b$ e $c$ , especificados individualmente por modelo . . . . .	20
2.11	Gráficos QQ dos modelos EVT (GPD) obtidos para as amostras utilizadas como exemplo, com parâmetros estimados via LM e <i>thresholds</i> com valores = $a$ , $b$ e $c$ , especificados individualmente por modelo . . . . .	21
2.12	Resultado da aplicação do teste Dietrich (CI 95%) nas amostras utilizadas como exemplo . . . . .	22
4.1	Apresentação de exemplos de histogramas classificados como Padrão 01 e Padrão 02, e suas respectivas PDFs . . . . .	36
A.1	<i>Bubble Sort</i> , Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT . . . . .	61
A.2	<i>Bubble Sort</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	62

A.3	<i>Bubble Sort</i> , Amostras Extras - Modelo de histograma classificado como Padrão 02 e dispersão dos dados . . . . .	63
A.4	<i>Bubble Sort</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	64
A.5	<i>Merge Sort</i> , Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados . . . . .	66
A.6	<i>Merge Sort</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	69
A.7	<i>Merge Sort</i> , Amostras Extras - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados . . . . .	70
A.8	<i>Merge Sort</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	71
A.9	<i>Insertion Sort</i> , Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT . . . . .	74
A.10	<i>Insertion Sort</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	75
A.11	<i>Insertion Sort</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	76
A.12	<i>Quick Sort</i> , Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT . . . . .	80
A.13	<i>Quick Sort</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	81
A.14	<i>Quick Sort</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	83
A.15	<i>Fft1</i> , Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT . . . . .	89
A.16	<i>Fft1</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	90
A.17	<i>Fft1</i> , Amostras Extras - Modelo de histograma classificado como Padrão 02 e dispersão dos dados . . . . .	91
A.18	<i>Fft1</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	92
A.19	<i>Sqrt</i> , Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados . . . . .	94
A.20	<i>Sqrt</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	96
A.21	<i>Sqrt</i> , Amostras Extras - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT . . . . .	97
A.22	<i>Sqrt</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	98

A.23 <i>Fibcall</i> , Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT . . . . .	100
A.24 <i>Fibcall</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	103
A.25 <i>Fibcall</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	104
A.26 <i>Cnt</i> , Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT . . . . .	110
A.27 <i>Cnt</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	111
A.28 <i>Cnt</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	113
A.29 <i>Edn</i> , Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados . . . . .	116
A.30 <i>Edn</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	117
A.31 <i>Edn</i> , Amostras Extras - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT . . . . .	118
A.32 <i>Edn</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	119
A.33 <i>Matmult</i> , Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados . . . . .	122
A.34 <i>Matmult</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	123
A.35 <i>Matmult</i> , Amostras Extras - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT . . . . .	125
A.36 <i>Matmult</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	126
A.37 <i>Binary Search</i> - Modelo de histograma classificado como Padrão 02 e dispersão dos dados . . . . .	131
A.38 <i>Binary Search</i> , Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	132
A.39 <i>Binary Search</i> , Amostras Extras - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT . . . . .	133
A.40 <i>Binary Search</i> , Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT . . . . .	134



## LISTA DE TABELAS

2.1	Modelos que foram gerados para as amostras utilizadas como exemplo . .	15
2.2	Amostra 02 - RL (CI 95%) para as probabilidades de excedência de $10^{-5}$ a $10^{-8}$ do modelo EVT (GEV) gerado com estimativas de parâmetros via MLE e LM . . . . .	20
2.3	Amostra 02 - Parâmetros obtidos (CI 95%) do modelo EVT (GEV) gerado com estimativas via MLE e LM . . . . .	21
2.4	Amostra 02 - RL (CI 95%) para as probabilidades de excedência de $10^{-5}$ a $10^{-8}$ do modelo EVT (GPD) gerado com <i>threshold=a</i> e estimativas de parâmetros via MLE e LM . . . . .	23
2.5	Amostra 02 - Parâmetros obtidos (CI 95%) do modelo EVT (GPD) gerado com <i>threshold=a</i> e estimativas via MLE e LM . . . . .	23
4.1	Cenários de testes criados a partir da variação dos recursos <i>Eth0</i> , <i>Wifi</i> e <i>Core</i> . . . . .	33
4.2	Total de amostras e observações coletadas no experimento, classificadas por <i>benchmark</i> e tipo, se Amostra Regular ou Extra, e listagem de cenários extras medidos . . . . .	34
4.3	Amostras Regulares - Cenários que ambientaram amostragem com bom ajuste EVT e apresentação de <i>OMin Ciclos</i> e <i>OMax Ciclos</i> , classificação por <i>benchmark</i> e cenário. Uma amostra foi considerada com bom ajuste quando ao menos um dos seus modelos EVT (GEV ou GPD, via MLE ou LM) apresentou resultado visual adequado no QQ e inferência pWCET coerente . . . . .	38
4.4	Amostras Regulares - Apresentação de <i>CVs Ciclos</i> e <i>CVs Ins</i> e percentual de amostras com bom ajuste EVT, classificação por <i>benchmark</i> . Uma amostra foi considerada com bom ajuste quando ao menos um dos seus modelos EVT (GEV ou GPD, via MLE ou LM) apresentou resultado visual adequado no QQ e inferência pWCET coerente . . . . .	39
4.5	Amostras Regulares - Percentual de amostras com bom ajuste EVT por cenário, <i>benchmark</i> e método, expresso em %, onde T1 representa bom ajuste GEV e T2 bom ajuste GPD. Uma amostra foi considerada com bom ajuste quando ao menos um dos seus modelos (via MLE ou LM) apresentou resultado visual adequado no QQ e inferência pWCET coerente	40

4.6	Amostras Extras com 100 mil observações - Percentual de amostras com bom ajuste EVT por cenário, <i>benchmark</i> e método, expresso em %, onde T1 representa bom ajuste GEV e T2 bom ajuste GPD. Uma amostra foi considerada com bom ajuste quando ao menos um dos seus modelos (via MLE ou LM) apresentou resultado visual adequado no QQ e inferência pWCET coerente . . . . .	43
4.7	Amostras Extras com 500 mil observações - Percentual de amostras com bom ajuste EVT por cenário, <i>benchmark</i> e método, expresso em %, onde T1 representa bom ajuste GEV e T2 bom ajuste GPD. Uma amostra foi considerada com boa qualidade de ajuste quando ao menos um dos seus modelos EVT (via MLE ou LM) apresentou resultado visual adequado no QQ e inferência pWCET coerente . . . . .	44
A.1	<i>Bubble Sort</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	60
A.2	<i>Merge Sort</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	67
A.3	<i>Insertion Sort</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	73
A.4	<i>Quick Sort</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	79
A.5	Comparativo de resultados do Grupo 01 . . . . .	85
A.6	<i>Fft1</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	88
A.7	<i>Sqrt</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	95
A.8	<i>Fibcall</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	101
A.9	Comparativo de resultados Grupo 02 . . . . .	107
A.10	<i>Cnt</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	109
A.11	<i>Edn</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	115

A.12 <i>Matmult</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	121
A.13 Comparativo de resultados Grupo 03 . . . . .	128
A.14 <i>Binary Search</i> - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário . . . . .	130
A.15 Comparativo de resultados Grupo 04 . . . . .	137





## LISTA DE SIGLAS

<b>BDSL</b> <i>Brock, Dechert, Scheinkman and LeBaron test</i> . . . . .	11
<b>BMM</b> <i>Block Maxima Method</i> . . . . .	8
<b>CCDF</b> <i>Complementary Cumulative Distribution Function</i> . . . . .	3
<b>CLT</b> <i>Central Limit Theorem</i> . . . . .	7
<b>CRPS</b> <i>Continuous Ranked Probability Score</i> . . . . .	9
<b>CV</b> <i>Coefficient of Variation</i> . . . . .	35
<b>ET</b> <i>Exponential Tail</i> . . . . .	27
<b>EVT</b> <i>Extreme Values Theory</i> . . . . .	2
<b>GEV</b> <i>Generalized Extreme Value</i> . . . . .	8
<b>GoF</b> <i>Goodness-of-fit</i> . . . . .	10
<b>GMLE</b> <i>Generalized Maximum Likelihood Estimation</i> . . . . .	14
<b>GPD</b> <i>Generalized Pareto Distribution</i> . . . . .	8
<b>HWM</b> <i>High Water Mark</i> . . . . .	3
<b>H</b> <i>Hurst Exponent test</i> . . . . .	11
<b>i.i.d.</b> <i>independent and identically distributed</i> . . . . .	7
<b>LM</b> <i>L-Moments</i> . . . . .	14
<b>LRU</b> <i>Least Recently Used</i> . . . . .	28
<b>KPSS</b> <i>Kwiatkowsky, Phillips, Schmidt and Shin test</i> . . . . .	11
<b>KS</b> <i>Kolmogorov-Smirnov test</i> . . . . .	11
<b>MBPTA</b> <i>Measurement-Based Probabilistic Timing Analysis</i> . . . . .	2
<b>MBTA</b> <i>Measurement-Based Timing Analysis</i> . . . . .	2
<b>MDA</b> <i>Maximum Domain of Attraction</i> . . . . .	18
<b>MLE</b> <i>Maximum Likelihood Estimation</i> . . . . .	14
<b>OMin</b> <i>Valor mínimo observado</i> . . . . .	35
<b>OMax</b> <i>Valor máximo observado</i> . . . . .	35
<b>OS</b> <i>Operating System</i> . . . . .	31
<b>PDF</b> <i>Probability Density Function</i> . . . . .	4
<b>PMU</b> <i>Performance Monitor Unit</i> . . . . .	31

<b>PoT</b> <i>Peaks over Threshold</i> . . . . .	8
<b>QQ</b> <i>Quantile-quantile</i> . . . . .	15
<b>pWCET</b> <i>Probabilistic Worst Case Execution Time</i> . . . . .	2
<b>RPi</b> <i>Raspberry Pi</i> . . . . .	4
<b>RTS</b> <i>Real-Time Systems</i> . . . . .	1
<b>RL</b> <i>Return Level</i> . . . . .	18
<b>SPTA</b> <i>Static Probabilistic Timing Analysis</i> . . . . .	3
<b>SRS</b> <i>Simple Random Sampling</i> . . . . .	25
<b>STA</b> <i>Static Timing Analysis</i> . . . . .	2
<b>v.a.</b> <i>Variável aleatória</i> . . . . .	3
<b>WCET</b> <i>Worst Case Execution Time</i> . . . . .	1
$X^2$ <i>Chi-squared Test</i> . . . . .	26

# 1

## INTRODUÇÃO

Sistemas de tempo real (*Real-Time Systems* - RTS) são aqueles que devem processar e responder ações ou operações em um determinado prazo ou limite de tempo definido, conhecido como *deadline*. Os RTSs podem ser do tipo não-crítico ou crítico. Em um sistema crítico, como é o caso dos aviônicos, espaciais e hospitalares, o não cumprimento de um *deadline* pode levar à falha geral do sistema ou a graves consequências. Nos RTSs não-críticos tolera-se perdas ocasionais de *deadlines*, apesar de tais ocorrências não serem desejáveis. Jogos eletrônicos e sistemas multimídia são exemplos de RTSs não-críticos. (ABELLA et al., 2015)

Uma ação de um determinado programa, usualmente denominada tarefa (*task*), é uma sequência de instruções, trechos de códigos, associados às suas respectivas funcionalidades. Como a execução de uma tarefa em um projeto de RTS está associada ao cumprimento de *deadlines*, é fundamental que se conheça qual o tempo máximo que ela leva para ser executada; parâmetro conhecido como Tempo de Execução no Pior Caso (*Worst Case Execution Time* - WCET).

Obter o WCET de uma tarefa, no entanto, não é simples. Precisa-se considerar não apenas as instruções do seu trecho de código, mas o seu pior cenário de execução, sendo que este pode estar sujeito a variados impactos provocados por tarefas concorrentes e pelo ambiente. Por exemplo, uma instrução que lê uma variável da memória está sujeita às interferências causadas pelo acesso ao barramento interno, o estado da memória *cache* e diversos outros fatores.

Neste trabalho, a área que lida com a estimativa de WCETs é denominada Análise Temporal (*Timing Analysis*). Existem diferentes técnicas e metodologias na Análise Temporal empregadas para encontrar o WCET de uma tarefa. Em um ambiente determinístico, ou seja, previsível no tempo (*time-predictable*), este valor é obtido através da medição do tempo de execução do programa em seu pior cenário. Em ambientes com arquiteturas modernas e complexas, entretanto, não é possível identificar um valor absoluto de tempo de pior caso. Isso se deve ao fato de que, a cada execução, o programa está sujeito a diferentes e imprevisíveis influências de elementos, tais como, memória *cache*, *pipelines* e multi-processadores.

Nestes casos, uma das técnicas mais utilizadas para estimar o pior tempo de execução é a Análise Temporal Probabilística Baseada em Medições (*Measurement-Based Probabilistic Timing Analysis* - MBPTA), fundamentada em um ramo da estatística denominado Teoria dos Valores Extremos (*Extreme Values Theory* - EVT). Por meio da MBPTA-EVT pode-se inferir distribuições de probabilidade de pior caso e estimar WCET Probabilísticos (*Probabilistic Worst Case Execution Time* - pWCET), objeto de estudo deste trabalho.

## 1.1 SISTEMAS DE TEMPO REAL E ANÁLISE TEMPORAL

Compreender o comportamento temporal de um programa é um elemento fundamental para verificar os requisitos de um RTS. A chave para tal desafio é a Análise Temporal, segmento que busca caracterizar a quantidade de tempo que ele leva para ser executado em uma determinada plataforma de hardware (DAVIS; CUCU-GROSJEAN, 2019).

Existem diferentes técnicas empregadas na Análise Temporal para inferência de WCET, tais como: Análise Estática (*Static Timing Analysis* - STA), Análise Baseada em Medições (*Measurement-Based Timing Analysis* - MBTA) e Análise Híbrida (*Hybrid Analysis*).

- A STA é realizada sem executar o programa. Consiste em obter a estimativa final do WCET através de um modelo resultante da combinação da Análise de Fluxo, que estima o comportamento do código do programa, como a quantidade de vezes um *loop* itera, dependências entre instruções *if* e quais funções são chamadas, com a Análise de Baixo Nível, que analisa o hardware da plataforma (SANDELL, 2004). A qualidade dos resultados deste método depende da disponibilidade de informações precisas e suficientes sobre estes componentes que serão analisados. As propriedades que não puderem ser determinadas com precisão devem ser aproximadas, de forma conservadora, para garantir que o WCET permaneça em um limite superior válido. No entanto, tais aproximações podem levar a um pessimismo significativo (DAVIS; CUCU-GROSJEAN, 2019).
- A MBTA consiste em estimar WCET através de sucessivas execuções reais (ou via simulação) do programa, enquanto mede-se o seu tempo sob variadas possibilidades para, assim, coletar a observação de maior duração.
- A Análise Híbrida mescla elementos de ambos os métodos.

Desdobramentos destas técnicas são propostos pela Análise Temporal Probabilística, apresentada a seguir.

### 1.1.1 Análise Temporal Probabilística em arquiteturas modernas

Estimar WCET de um programa tornou-se um desafio com o advento dos processadores modernos. As novas arquiteturas passaram a contar com aceleradores de hardware, tais como, *pipelines*, *branch predictions*, execuções fora de ordem, estratégias para substituição de *cache*, *buffers* de gravação, memórias *scratchpads* e memória com múltiplos níveis de hierarquia (DAVIS; CUCU-GROSJEAN, 2019). Tais elementos representam

muitas fontes de imprevisibilidade e podem provocar interferências nos componentes do processador. Por exemplo, uma instrução que lê uma variável da memória está sujeita às interferências causadas pelo acesso ao barramento interno, o estado da memória *cache* e diversos outros fatores. Este fato faz com que o tempo de execução de um programa não seja mais uma constante mas, diferente a cada vez que ele é executado. Tal variabilidade provoca um impacto direto na identificação do seu pior caso, que, inclusive, pode nunca aparecer durante uma das variadas execuções de um programa (HECKMANN et al., 2003).

A Análise Temporal Probabilística passou a ser utilizada como uma solução para um panorama desta natureza, sendo empregada através das técnicas de Análise Temporal Probabilística Estática (*Static Probabilistic Timing Analysis* - SPTA) e MBPTA. Este trabalho tem enfoque na MBPTA, que determina limites probabilísticos para o WCET de uma tarefa.

Enquanto as técnicas tradicionais de Análise Temporal realizam uma análise para incorporar modelos de software e hardware que possibilitam a dedução analítica do WCET, as técnicas probabilísticas estimam este valor realizando múltiplas execuções do programa, sob diversos cenários. Desta forma, ao invés de obter como resultado um único valor de WCET, obtêm-se uma distribuição de probabilidade estatística formada por múltiplos valores WCET e suas correspondentes probabilidades de ocorrência (SANTINELLI; GUO, 2017), denominada pWCET.

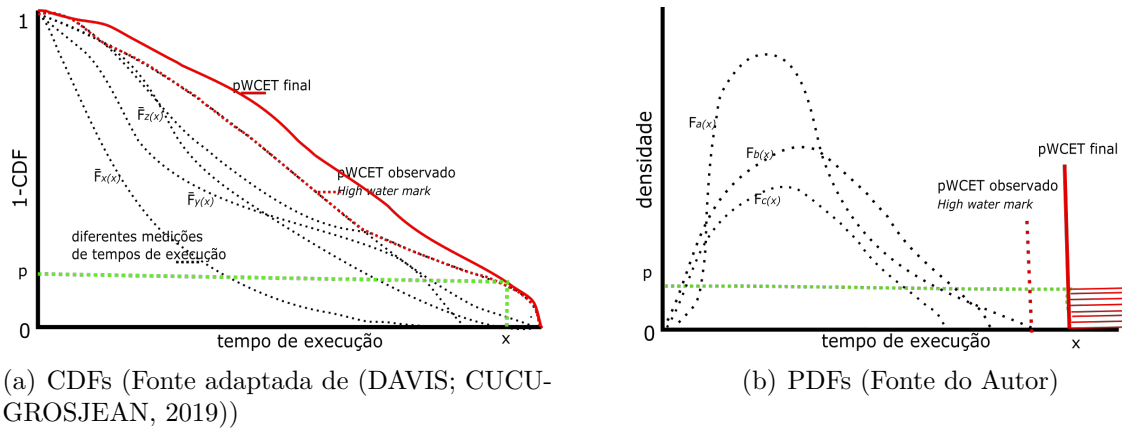
Deseja-se que pWCET estimado seja sempre seguro e justo. Seguro, ou seja, que a estimativa seja igual ou maior que o WCET real (REGHENZANI; MASSARI; FORNACIARI, 2020), e justo, o que significa que essa estimativa não ultrapasse o WCET real em mais de 10-20%, a fim de minimizar o super-provisionamento de recursos (DAVIS; CUCU-GROSJEAN, 2019).

pWCET pode ser expresso por uma função de Distribuição Acumulada Complementar (*Complementary Cumulative Distribution Function* - CCDF) ou  $(1 - CDF)$ , também conhecida como distribuição de cauda, onde  $X$  é uma Variável aleatória - v.a. que representa o tempo de execução de uma tarefa. Através desta distribuição é possível estimar a probabilidade de violação  $p$  de um dado  $x$ , ou vice-versa, o  $x$ , dada a probabilidade de violação  $p$ , sendo que esta representa a probabilidade de ocorrer um tempo de execução maior que o  $x$  observado (Equação (1.1)).

$$p = P(X > x) \tag{1.1}$$

A Figura 1.1(a) ilustra o conceito de pWCET. Apresenta várias e múltiplas distribuições obtidas através de medições dos tempo de execução de um programa sob múltiplos cenários (linhas pretas tracejadas), a distribuição pWCET observada (linha tracejada vermelha), obtida a partir das observações medidas e também conhecida como *High Water Mark* - HWM, e a distribuição pWCET final (linha sólida vermelha) (DAVIS; CUCU-GROSJEAN, 2019).

Como pode-se notar na ilustração, a distribuição pWCET pode não corresponder à distribuição de um cenário específico, mas limita as distribuições de tempo de execução de um programa independente do cenário. A distribuição pWCET final fornece um



**Figura 1.1** Representação do conceito de pWCET através de CDFs e PDFs

teto superior para as probabilidades de ocorrência dos valores extremos observados que ocorrem raramente, e podem eventualmente ser produzidos até por falhas toleráveis de operação durante a execução do programa (DAVIS; BURNS; GRIFFIN, 2017).

Por fim, o valor  $x$  é referido como a estimativa pWCET para uma probabilidade de excedência de  $p$  (DAVIS; CUCU-GROSJEAN, 2019). A estimativa pWCET pode, desta forma, ser considerada como uma tupla  $(p, x)$ , onde  $x$  é o quantil da distribuição descrita pelo modelo ajustado tal que a probabilidade de se observar um valor maior que  $x$  não é maior que  $p$ . A Figura 1.1(b) apresenta o mesmo conceito de pWCET, entretanto, demonstrado por meio da Função de Densidade de Probabilidade (*Probability Density Function* - PDF) das diferentes distribuições.

Nos dias atuais, a maioria dos métodos de MBPTA utiliza EVT como ferramenta para obter pWCETs. EVT (ver Capítulo 2) é uma área da estatística que permite realizar inferências de eventos extremos, nunca observados ou com baixa probabilidade de ocorrência, com base em observações históricas (DAVIS; CUCU-GROSJEAN, 2019).

## 1.2 OBJETO DE PESQUISA

O objetivo deste trabalho é realizar uma análise experimental do uso da EVT para estimativa de WCET através da MBPTA, a partir de observações coletadas com a execução de diferentes *benchmarks* ambientada em uma arquitetura *Raspberry Pi* - RPi.

Apesar dos diversos resultados positivos relatados na literatura que estimam pWCET via MBPTA-EVT em arquiteturas modernas, e da variedade de ferramentas computacionais disponíveis para aplicação da EVT, percebe-se uma carência de publicações que exponham os dados e modelos completos produzidos durante este processo, incluindo as situações quando a aplicação da técnica falha. Nota-se, ainda, que muitos dos cenários onde os experimentos são realizados tratam-se de ambientes excessivamente controlados e isolados, que acabam por não expor a aplicação da EVT a situações enfrentadas no mundo real.

A principal hipótese deste trabalho é que EVT oferece um conjunto de técnicas eficazes

mas que pode apresentar problemas para inferência de pWCET em plataformas modernas, pois nem sempre é possível encontrar um modelo com boa qualidade de ajuste, ainda que os dados medidos sejam representativos para a população em estudo.

Para realizar o experimento foram medidos os tempos de execução de 11 *benchmarks* com valores de entrada fixos e expostos a oito diferentes cenários, criados a partir da variação dos recursos de *Wifi*, *Ethernet* e *Core*. Os programas foram extraídos do *Mälardalen WCET Benchmarks* (GUSTAFSSON et al., 2010), um conjunto criado para apoiar o uso de ferramentas para análise de WCET. A medição dos dados produziu um montante de 700 amostras com tamanhos de 10 mil, 100 mil ou 500 mil, somando um total de 82.400.000 observações coletadas e avaliadas. Foram utilizadas as ferramentas: R (R, s.d.) e seu pacote base, além dos pacotes *extRemes* (EXTREMES, s.d.) e o teste Dietrich (DIETRICH; HAAN; HUSLER, 2002) para aplicação EVT e verificação de qualidade de ajuste, e *linux-perf* (PERF..., s.d.) para medição dos dados via Unidade de Monitoramento de Desempenho do RPi.

O trabalho está inserido no contexto do KEPLER, uma colaboração entre o Instituto de Computação da UFBA e o INRIA-Paris (*Institut national de recherche en sciences et technologies du numérique*), no âmbito do programa INRIA *Associated Teams*. O Kepler tem como o objetivo abordar temas relacionados a fundamentos probabilísticos para o tempo, como um conceito-chave para a certificação de sistemas ciberfísicos.

A principal contribuição do trabalho à colaboração, e ao estado de arte na área, consiste em emitir um alerta sobre o uso da MBPTA-EVT para inferência de pWCETs. A técnica vem sendo empregada de forma constante por grande parte da comunidade científica, mas pouco se comenta sobre problemas e restrições da sua utilização em ambientes reais.

Parte dos resultados obtidos ao longo do trabalho foi publicada no artigo "*Possible risks with EVT-based timing analysis: an experimental study on a multi-core platform*", através do *2022 XII Brazilian Symposium on Computing Systems Engineering (SBESC)*<sup>1</sup>. A publicação destacou problemas observados para utilização da MBPTA-EVT para inferência pWCET, apresentou resultados preliminares e foi premiada entre os melhores artigos do congresso. Uma versão estendida do trabalho está em fase de produção para re-submissão próxima e avaliação do *Springer Journal of Design Automation for Embedded Systems*, sendo que esta conterá os resultados completos obtidos e está sendo desenvolvida em parceria com o INRIA.

A colaboração possibilitou ainda a realização de um intercâmbio presencial, com visita da mestrandia ao INRIA-Paris durante 21 dias, quando houve a oportunidade de discussão dos resultados e pontos aqui apresentados.

### 1.3 ORGANIZAÇÃO DO TRABALHO

O trabalho está organizado em cinco capítulos. O Capítulo 2 apresenta de que forma se dá a aplicação da EVT na Análise Temporal, o Capítulo 3 faz uma revisão bibliográfica apresentando o estado de arte e a literatura relacionada a aplicação da EVT para pro-

---

<sup>1</sup>DOI: 10.1109/SBESC56799.2022.9964853, disponível em: <<https://ieeexplore.ieee.org/document/9964853/>>.

blemas em RTS, WCET e pWCET, o Capítulo 4 apresenta os resultados do experimento realizado, e, por fim, o Capítulo 5 traz a conclusão.

Os apêndices apresentam os resultados de forma detalhada por *benchmark*, os níveis de retorno (*Return Level* - RL) estimados para a probabilidade de excedência  $10^{-5}$  e o código-fonte da aplicação `linux_perf`.

Ressalta-se que a maior parte das siglas e termos técnicos foram empregados em inglês ao longo do trabalho, com intuito de facilitar a identificação destes na literatura.



# 2

## APLICAÇÃO DA EVT EM ANÁLISE TEMPORAL

EVT teve um impulso a partir dos anos 50, quando foi utilizada para prever e prevenir a reincidência de raros fenômenos fluviais após uma catástrofe com enchentes na Holanda (MATTHEWS, 2012). A partir de então ela passou a ser aplicada também para inferir eventos em diferentes áreas, como mercado financeiro, esportes, seguros, fenômenos meteorológicos em geral (SILVA; CAEIRO; OLIVEIRA, 2018; SPEARING et al., 2021; GARÇÃO, 2017; HUANG et al., 2016) e Análise Temporal em RTS críticos.

EVT é uma área da estatística que se concentra na análise de eventos extremos em distribuições de dados usando argumentos assintóticos. Por valores extremos denomina-se os valores escassos, raros ou muito maiores (máximo ou mínimo) que outros já observados (COLES, 2001). A teoria se baseia na análise das caudas das distribuições, que contêm informações sobre os valores extremos e suas probabilidades de ocorrência. Os métodos EVT são usados para extrapolar a distribuição de dados para valores além do que é observado na amostra, o que é particularmente útil para estimar a probabilidade de ocorrência de eventos extremos. EVT é capaz de prever com razoável precisão quantis extremos e probabilidades de excedência (VIOLA, 2006; SILVA; CAEIRO; OLIVEIRA, 2018).

Enquanto a teoria estatística clássica está amparada no Teorema do Limite Central (*Central Limit Theorem* - CLT), que prioriza o comportamento da distribuição em torno dos momentos centrais, a teoria estatística dos extremos baseia-se no Teorema de Tipos Extremos, de Fisher–Tippett–Gnedenko (COLES, 2001). O modelo pilar que representa EVT é focado no comportamento estatístico (Equação (2.1)), onde  $X_1, \dots, X_m$  é uma sequência de variáveis aleatórias independentes e identicamente distribuídas (*independent and identically distributed* - i.i.d.), sendo que  $X_i$  usualmente representa medições realizadas ao longo do tempo (COLES, 2001).

*Definição I: Uma variável é independente se seu valor nunca é afetado pelo estado de outra variável.*

*Definição II: Variáveis são identicamente distribuídas se tiverem a mesma distribuição de probabilidade.*

$$M_m = \max(X_1, \dots, X_m) \quad (2.1)$$

Usualmente dois métodos EVT são empregados para fazer a amostragem das observações dos máximos: o Máximo de Blocos (*Block Maxima Method* - BMM) e Picos acima do Limiar (*Peaks over Threshold* - PoT). BMM é baseado no teorema de Fisher-Tippett-Gnedenko, modela os máximos através de blocos de observações medidas e assintoticamente tende a uma distribuição de Valor Extremo Generalizado (*Generalized Extreme Value* - GEV). PoT calcula a função de distribuição dos valores que excedem um determinado *threshold* (valor limiar), é baseado no teorema de Pickands-Balkema-de Haan e assintoticamente modela uma distribuição que tende a uma distribuição de Pareto Generalizada (*Generalized Pareto Distribution* - GPD) (COLES, 2001; GUET; SANTINELLI; MORIO, 2017).

Nos dias atuais, a maioria dos métodos de MBPTA utiliza EVT para estimativas pWCETs. A técnica é aplicada em amostras que contêm observações dos tempos de execução medidos de um programa, e usualmente ocorre por meio das etapas (LIMA; DIAS; BARROS, 2016):


1. Amostragem
2. Seleção de valores
3. Estimativa de parâmetros
4. Verificação da qualidade de ajuste
5. Estimativa pWCET

A Figura 2.1 ilustra de forma resumida estas etapas, com os dados representados via suas PDFs. No primeiro gráfico pode-se observar a PDF dos tempos de execução coletados através de medições (etapa 01). A estes dados é aplicado um dos métodos da EVT (BMM ou PoT) (etapa 02) para selecionar os valores que irão formar a nova amostra, composta pelos máximos. Na etapa 03 são estimados os parâmetros da distribuição desta amostra. Na etapa 04 é testada a qualidade do ajuste EVT (etapa 04) do modelo gerado. Se o modelo não tiver boa qualidade de ajuste, o processo deve ser interrompido e a amostra descartada. Com um modelo de boa qualidade de ajuste em mãos, passa-se, por fim, à fase para estimativa pWCET (etapa 05).

O processo para aplicação da EVT e estimativa pWCET pode contar com o suporte de diferentes ferramentas computacionais estatísticas para a análise dos dados medidos, ajuste de modelos e interpretação dos resultados produzidos. As seções seguintes descrevem e trazem exemplos usando como ferramentas o software R<sup>1</sup> e seu pacote base, além dos pacotes `extRemes`<sup>2</sup> e `Teste Dietrich et al.` (DIETRICH; HAAN; HUSLER, 2002).

<sup>1</sup>Disponível em: <<https://cran.r-project.org/bin/macosx/>>.

<sup>2</sup>Informações em: <<https://cran.r-project.org/web/packages/extRemes/extRemes.pdf>>.



**Figura 2.1** Representação das etapas EVT para estimativa pWCET (Fonte do Autor)

## 2.1 AMOSTRAGEM

O passo inicial para a aplicação da EVT com fins de estimativa de pWCET é coletar uma amostra suficientemente grande e representativa, contendo observações de tempos de execução de um programa (CUCU-GROSJEAN et al., 2012). Nesta etapa alguns desafios são encontrados, tais como: o tamanho da amostra a ser coletada, a representatividade dos dados, questões de dependências entre as observações medidas e adequação destas observações.

### 2.1.1 Tamanho da amostra

Um primeiro ponto é sobre como definir o tamanho adequado da amostra. Identificar WCETs trata-se de buscar fenômenos raros. Uma amostra pequena pode causar uma estimativa incorreta da distribuição e dos seus parâmetros, e afetar também a confiabilidade de testes estatísticos (REGHENZANI; SANTINELLI; FORNACIARI, 2020). Alguns autores mensuram o tamanho adequado de uma amostra através da métrica de Pontuação de Probabilidade Classificada Contínua Média (*Continuous Ranked Probability Score - CRPS*) (SILVA; ARCARO; OLIVEIRA, 2017). CUCU-GROSJEAN et al. 2012 propõem que tal tamanho mínimo seja definido a partir de projeção de cauda EVT com  $N_{(current)} + N_{(delta)}$  observações, aumentando  $N_{(current)}$  de  $N_{(delta)}$  a cada iteração, até encontrar um limiar que convirja, detectado também através do CRPS.

Não há, entretanto, um método para definir um número mínimo de observações necessárias. Sendo assim, na maioria das vezes, o tamanho da amostra é estipulado de forma empírica (REGHENZANI; MASSARI; FORNACIARI, 2020), com amostras sendo produzidas com tamanhos grandes quanto o necessário, considerando-se a disponibilidade

e restrições de recursos (LIMA; DIAS; BARROS, 2016).

### 2.1.2 Representatividade

Amostras representativas são aquelas que refletem as características da população de onde foi extraída. Assim, uma amostra representativa para o caso da análise temporal é aquela que cobre todas as diferentes possibilidades dos elementos que podem afetar o comportamento temporal durante a execução de um programa. A questão da representatividade, entretanto, ainda é um problema em aberto (GIL et al., 2017) para a análise temporal pois, em muitos casos, não é possível obter um protocolo único de medição, que forneça uma amostra representativa de todos os possíveis cenários futuros (DAVIS; CUCU-GROSJEAN, 2019). Uma amostra não representativa pode produzir observações que não caracterizam a população pesquisada (DAVIS; CUCU-GROSJEAN, 2019). Isso pode representar um problema impeditivo para o uso da EVT e comprometer a qualidade de um pWCET estimado (CAZORLA et al., 2019). Para MAXIM et al. (2015), uma amostra é representativa se existe um determinado número  $k$  de observações coletadas que produz uma estimativa pWCET coerente. Os elementos que podem provocar impactos nas medições para a análise temporal são: os dados de entrada do programa (*input*), os variados e possíveis caminhos de execução do programa (*paths*) e os possíveis estados da máquina (software + hardware).

### 2.1.3 Dependências

Outro desafio encontrado durante a fase de coleta de dados é sobre como lidar com as relações de dependências que podem existir entre os diferentes componentes do sistema. Tal problema é frequente em RTS (GUET; SANTINELLI; MORIO, 2017) e pode afetar diretamente os tempos de execução medidos. Ele pode acontecer em diferentes casos, como, por exemplo, quando um programa composto por dois blocos executados em sequência têm seus tempos de execução impactados por algum aspecto em comum e desconhecido (BERNAT; BURNS; NEWBY, 2005), também, para programas que realizam operações como multiplicação e divisão. Neste caso, a depender da arquitetura de hardware e do estado da máquina no momento da execução da tarefa, a instrução pode levar um tempo constante para ser executada, ou pode depender de execuções anteriores impactadas por fontes como *cache* e *pipelines* (BERNAT; COLIN; PETERS, 2002).

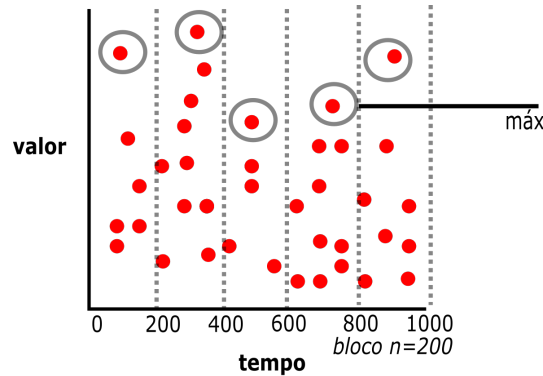
Para alguns autores (LEADBETTER; LINDGREN; ROOTZÉN, 1978; REGHENZANI; MASSARI; FORNACIARI, 2020; SANTINELLI et al., 2014; LEADBETTER, 1991; GUET; SANTINELLI; MORIO, 2017) as relações de dependências podem ser classificadas como: a) estacionárias, que implica em distribuições idênticas entre as variáveis aleatórias; b) dependência de curto alcance (*short-range*), que se concentra na relação entre medições próximas no tempo; e c) dependência de longo alcance (*long-range*), ou extrema, que apresenta significativa correlação em medições distantes no tempo.

### 2.1.4 Adequação de observações

Autores aplicam diferentes testes de aderência (*Goodness-of-fit* - GoF) para checar características de independência e homogeneidade das observações medidas. Esta ação, entretanto, não é de caráter obrigatório e não é um consenso. Tais indefinições podem acontecer pelo fato de que, apesar da confiabilidade de diferentes testes, os critérios *i.i.d.* dificilmente são verificados em medições realizadas em plataformas e aplicações realistas de tempo real (REGHENZANI; MASSARI; FORNACIARI, 2020), mas, mesmo assim, pode-se encontrar boa qualidade de ajuste EVT em amostras oriundas de tais fontes. Da mesma forma, há situações onde as observações medidas atendem os critérios *i.i.d.* mas não é possível obter bom ajuste EVT. Além disso, na prática, o critério *i.i.d.* pode ser relaxado para aplicação da EVT; certas relações de dependências podem ser minimizadas ao longo do processo de ajuste EVT, e há possibilidades de aplicação da técnica em observações estacionárias (LEADBETTER; LINDGREN; ROOTZÉN, 1978), que implica em variáveis randômicas com distribuições idênticas e uniformes, e variáveis com propriedades de dependência mais fracas (REGHENZANI; MASSARI; FORNACIARI, 2020).

Apresentamos a seguir alguns dos testes aplicados na literatura:

- *Wald-Wolfowitz Runs test* (WALD-WOLFOWITZ... , s.d.): avalia se um conjunto de dados tem origem ou não de um processo aleatório. (SILVA; ARCARO; OLIVEIRA, 2017; CUCU-GROSJEAN et al., 2012)
- *Mann-Kendall test* (MANN... , s.d.a): utilizado para checar se uma série de dados possui tendência temporal estatisticamente significativa (MADSEN, 2005).
- *Mann-Whitney test* (MANN... , s.d.b): teste não paramétrico indicado para verificar se dois grupos não pareados pertencem ou não a uma mesma população (MADSEN, 2005; ÖZARI; EREN; SAYGIN, 2019).
- *Anderson-Darling test* (ANDERSON... , 2021): testa se dados seguem uma mesma distribuição (SILVA; ARCARO; OLIVEIRA, 2017; ARCARO; SILVA; OLIVEIRA, 2018; REGHENZANI; SANTINELLI; FORNACIARI, 2020)
- *Kolmogorov-Smirnov test* - KS (KOLMOGOROV-SMIRNOV... , s.d.): avalia se dados amostrais se aproximam razoavelmente de uma determinada distribuição (SILVA; ARCARO; OLIVEIRA, 2017; CUCU-GROSJEAN et al., 2012; ARCARO; SILVA; OLIVEIRA, 2018). Ao KS pode-se ainda aplicar a correção de *Lilliefors*, para torná-lo mais confiável e menos sensível a valores extremos (ABELLA et al., 2015).
- *Turning Point test* (TURNING... , s.d.): checa a aleatoriedade de uma determinada série (SILVA; CAEIRO; OLIVEIRA, 2018).
- *Ljung-Box test* (LJUNG-BOX... , s.d.) e *autocorrelation tests* (AUTOCORRELATION... , 2016): podem ser aplicados em amostras estacionárias para checar a



**Figura 2.2** Representação da seleção de observações via o método BMM (Fonte do Autor)

independência de variáveis aleatórias ao longo do tempo (BEREZOVSKYI et al., 2014; ABELLA et al., 2015; ARCARO; SILVA; OLIVEIRA, 2018).

- *Kwiatkowsky, Phillips, Schmidt and Shin test* - KPSS (KPSS..., 2016), *Brock, Dechert, Scheinkman and LeBaron test* - BDSL (BDSL..., s.d.) e a equação *Hurst Exponent test* - H (HURST..., s.d.): para checar, respectivamente, as relações de dependências estacionárias, de curto alcance (*short-range*), e de longo alcance (*long-range*) (REGHENZANI; MASSARI; FORNACIARI, 2020; SANTINELLI; GUET; MORIO, 2017).

Para este trabalho optou-se inicialmente por checar os critérios *i.i.d.* das amostras nas quais seria realizado o estudo EVT, mas tal ação não foi mantida. Mais informações na Seção. 4.1.4.

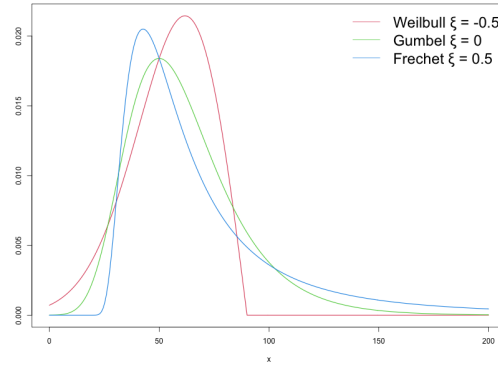
## 2.2 SELEÇÃO DE VALORES

Em posse dos dados medidos deve-se selecionar as observações que irão compor a nova amostra de máximos. Esse processo pode ser realizado através de dois métodos: BMM ou PoT.

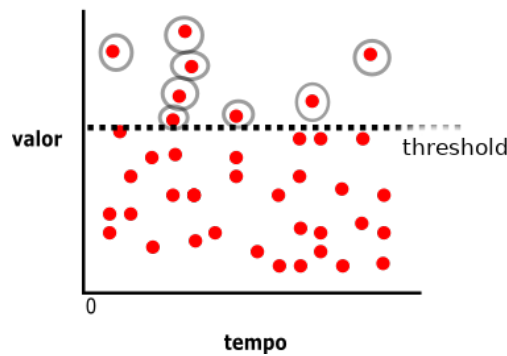
### 2.2.1 Método BMM

O método BMM consiste em criar uma nova amostra a partir dos valores da amostra original dividida em blocos de tamanhos iguais e não sobrepostos, selecionando os valores máximos (ou mínimos) de cada bloco (Figura 2.2). Em seguida, EVT tenta ajustar tais dados a distribuições de probabilidade da família GEV.

As distribuições que compõem a família GEV são Gumbel (Tipo I), Fréchet (Tipo II) e Weibull (Tipo III). Os parâmetros para descrevê-las são: locação (*location* -  $\mu$ ), escala (*scale* -  $\sigma$ ) e forma (*shape* -  $\xi$ ), que dita o comportamento assintótico da cauda da distribuição e também é denominado índice de valores extremos (COLES, 2001). O parâmetro  $\xi$  modela: uma Weibull, se  $\xi < 0$ , uma Fréchet, se  $\xi > 0$ , ou, uma Gumbel



**Figura 2.3** PDFs da família de distribuição GEV para  $\xi = -0.5$ ,  $\xi = 0$  e  $\xi = 0.5$ , com  $\sigma$  e  $\mu$  não informados



**Figura 2.4** Representação da seleção de observações via o método PoT (Fonte do Autor)

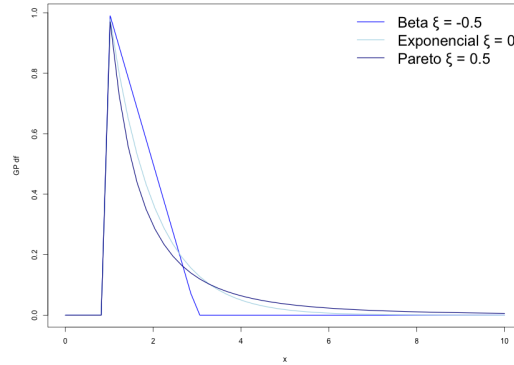
se  $\xi = 0$ . O modelo da GEV é representado pela CDF da Equação (2.2), e a Figura 2.3 exemplifica as distribuições da família GEV.

$$F(x) = \begin{cases} \exp\left[-\left(1 + \xi \frac{x-\mu}{\sigma}\right)^{\frac{-1}{\xi}}\right] & \text{se } \xi \neq 0 \\ \exp\left[-\exp\left(-\frac{x-\mu}{\sigma}\right)\right] & \text{se } \xi = 0 \end{cases} \quad (2.2)$$

Definir o tamanho dos blocos de forma adequada está entre as dificuldades existentes no método BMM. Blocos muito pequenos podem levar a uma estimativa enviesada, enquanto que blocos muito grandes podem extrair poucos valores extremos (ÖZARI; EREN; SAYGIN, 2019). Além disso, este método pode acabar por perder observações significativas quando um bloco contém mais observações extremas que os demais, mas apenas um valor máximo deverá ser considerado.

### 2.2.2 Método PoT

O segundo método EVT para seleção de observações é o PoT. Ele cria uma nova distribuição a partir das observações que excedem um determinado *threshold* (Figura 2.4), sendo modelada como uma distribuição GPD.



**Figura 2.5** PDFs da família de distribuição GPD para  $\xi = -0.5$ ,  $\xi = 0$  e  $\xi = 0.5$ , com  $\sigma$  não informado

Os parâmetros da GPD são escala (*scale* -  $\sigma$ ) e forma (*shape* -  $\xi$ ). Da mesma forma que no método BMM,  $\xi$  dita o comportamento assintótico da cauda da distribuição. O parâmetro  $\xi$  modela: uma Beta, se  $\xi < 0$ , uma Exponencial, se  $\xi = 0$ , ou, uma Pareto, se  $\xi > 0$ . O modelo da GPD é representado pela CDF da Equação (2.3), e a Figura 2.5 exemplifica as distribuições da família GPD.

$$F(x) = \begin{cases} 1 - [1 + \xi(\frac{x-\mu}{\sigma})]^{-\frac{1}{\xi}} & \text{se } \xi \neq 0 \\ 1 - \exp(-\frac{x-\mu}{\sigma}) & \text{se } \xi = 0 \end{cases} \quad (2.3)$$

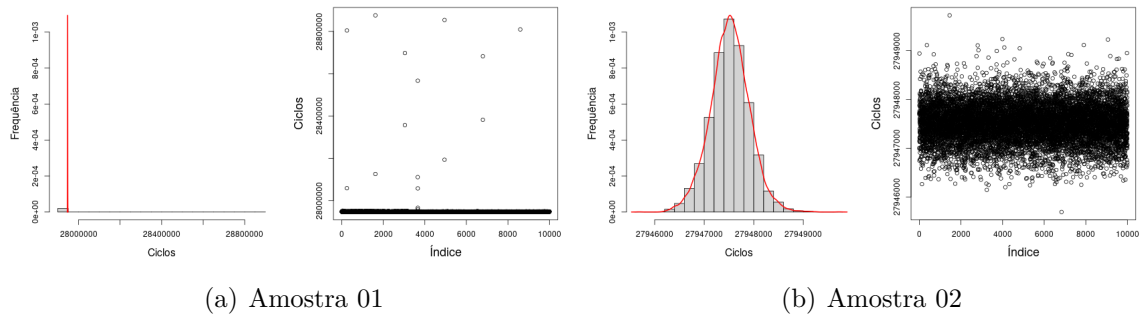
Neste método, a dificuldade reside na subjetividade que existe para definir de forma apropriada o *threshold*. Um valor muito baixo poderá levar ao enviesamento da amostra, enquanto que um valor muito alto levará a uma alta variância. Normalmente utiliza-se ferramentas gráficas para apoiar a escolha deste valor (ABELLA et al., 2015), como histogramas, gráfico de dispersão e gráfico de faixa de limiar (*Threshold range plot*). A prática adotada é escolher um *threshold* seguro o mais baixo possível, e sempre acima da média da distribuição original (COLES, 2001).

## 2.3 ESTIMATIVA DE PARÂMETROS

A estimativa dos parâmetros da distribuição GEV ou GPD pode ser feita através de diferentes métodos, tais como: Estimativa por Máxima Verossimilhança (*Maximum Likelihood Estimation* - MLE), Estimativa por Máxima Verossimilhança Generalizada (*Generalized Maximum Likelihood Estimation* - GMLE), Bayesiano (*Bayesian*) e Momentos-L (identificado neste trabalho por *L-Moments* - LM) (GILLELAND; KATZ, 2016).

O método de máxima verossimilhança estima os parâmetros que têm maior probabilidade de produzir os dados observados (SOUSA, 2018). MLE dá suporte ao CI baseado na normalidade dos erros (resíduos), que é a diferença entre as observações e a curva do modelo estimado. Ele está entre um dos métodos mais aplicados por conta da sua capacidade em se adaptar a distribuições mais complexas e por possuir boas propriedades assintóticas (BATISTA et al., 2020). Os estimadores MLE, entretanto, podem não





**Figura 2.6** Histograma e gráfico de dispersão das Amostras 01 e 02

apresentar boas propriedades quando  $-1 < \xi < -0.5$ , ou não existem quando  $\xi < -1$  (COLES, 2001).

Nessas situações, outro método para estimativa de parâmetros pode ser utilizado, como o LM, que se baseia em supor que os momentos da distribuição populacional coincidam com os momentos da amostra. O método LM não apresenta problemas de convergência, mas demanda apoio de métodos computacionais, como o *Bootstrap* (EFRON; TIBSHIRANI, 1994), para estimar erros e CIs da distribuição pWCET inferida, o que o torna um método mais custoso e que pode produzir CIs não simétricos.

Depois de estimados os parâmetros pode-se obter as probabilidades de excedência e quantis extremais, dentro dos correspondentes erros-padrão e CIs. (SILVA; CAEIRO; OLIVEIRA, 2018)

## 2.4 VERIFICAÇÃO DA QUALIDADE DE AJUSTE

Esta etapa consiste em ajustar os modelos EVT (GEV e GPD), e posteriormente verificar a qualidade destes ajustes.

Para demonstrar este e os demais itens ao longo do capítulo, foram tomadas duas amostras para exemplificação, denominadas Amostra 01 e Amostra 02. Tais amostras contam com 10.000 observações cada e são originárias do experimento realizado com o *Bubble Sort* (Seção A.2.1.1) em um ambiente real RPi. A v.a. analisada nos exemplos é *Ciclos* e representa o número de ciclos de CPU medidos durante a execução do programa, ou seja, o seu tempo de execução.

O objetivo da exemplificação é apenas demonstrar de forma prática as etapas da aplicação da EVT. Por este motivo, não serão apresentados detalhes sobre os cenários de testes que ambientaram a medição dos dados.

Antes de ajustar os modelos EVT buscou-se conhecer os dados amostrais da população. Assim, foram plotados histogramas, gráficos de dispersão e PDFs. Os diferentes aspectos visuais observados através destas ferramentas (Figura 2.6), com comportamentos distintos das duas amostras, já sinalizavam também possíveis comportamentos distintos para as tentativas de ajuste EVT.

De posse dos dados amostrais da população, buscou-se ajustar um total de 12 modelos EVT para cada amostra avaliada (Tabela 2.1), sendo seis modelos gerados através do

**Tabela 2.1** Modelos que foram gerados para as amostras utilizadas como exemplo

$Amostra_x$	Legenda	Descrição
<b>GEV</b>	MLE Bloco $n = 50$	Blocos tamanho 50 e parâmetros via MLE
	MLE Bloco $n = 100$	Blocos tamanho 100 e parâmetros via MLE
	MLE Bloco $n = 200$	Blocos tamanho 200 e parâmetros via MLE
<b>GEV</b>	LM Bloco $n = 50$	Blocos tamanho 50 e parâmetros via LM
	LM Bloco $n = 100$	Blocos tamanho 100 e parâmetros via LM
	LM Bloco $n = 200$	Blocos tamanho 200 e parâmetros via LM
<b>GPD</b>	MLE <i>Threshold a</i>	<i>Threshold</i> = $a$ e parâmetros via MLE
	MLE <i>Threshold b</i>	<i>Threshold</i> = $a$ e parâmetros via MLE
	MLE <i>Threshold c</i>	<i>Threshold</i> = $c$ e parâmetros via MLE
<b>GPD</b>	LM <i>Threshold a</i>	<i>Threshold</i> = $a$ e parâmetros via LM
	LM <i>Threshold b</i>	<i>Threshold</i> = $b$ e parâmetros via LM
	LM <i>Threshold c</i>	<i>Threshold</i> = $c$ e parâmetros via LM

método BMM e seis via PoT, ambos com estimativas de parâmetros via MLE e LM. O tamanho dos blocos dos modelos BMM foi definido em  $n = 50$ ,  $n = 100$  e  $n = 200$ , e, para os modelos PoT, foram usados três diferentes *thresholds*,  $a$ ,  $b$  e  $c$  (especificados mais adiante).

A verificação da qualidade do ajuste EVT normalmente se dá por meio do gráfico Quantil-Quantil (*Quantile-quantile* - QQ). Através desta ferramenta, detecta-se a qualidade do ajuste das observações de um conjunto de dados a uma determinada distribuição conhecida  $H$ . O gráfico apresenta os quantis empíricos dos dados contra os quantis teóricos de  $H$ . Se a real distribuição da amostra é  $H$ , então o gráfico irá convergir para uma linha reta (COLES, 2001).


Nas Figuras 2.7 e 2.8 pode-se observar os gráficos QQs obtidos com o ajuste de modelos EVT através do método BMM, devidamente legendados com o respectivo método de estimação de parâmetros aplicado.

Pode-se observar nos gráficos da Figura 2.7(a) a presença de *outliers*, e notar que os resultados obtidos para a Amostra 01 via MLE não seguem a linha reta, demonstrando que não foi possível obter boa qualidade de ajuste em nenhum dos modelos desta amostra.


No caso da Amostra 02 (Figura 2.7(b)), pode-se observar uma boa qualidade visual de ajuste EVT, com destaque para o modelo com Bloco  $n = 50$  e  $n = 100$ . Apesar das pequenas flutuações ao redor da linha, não se observa tendência aparente nos dados, o que demonstra um ajuste GEV aceitável.

Os modelos via LM apontam conclusões semelhantes, com bom ajuste para a Amostra 02 (Figura 2.8(b)), e impossibilidade de ajuste para a Amostra 01 (Figura 2.8(a)).

Modelos foram produzidos também através do método PoT (Figuras 2.10 e 2.11). A escolha dos *thresholds* no PoT é sempre uma fonte de incerteza, visto que diferentes valores podem levar a diferentes estimativas de pWCET (DAVIS; CUCU-GROSJEAN, 2019). Para apoiar uma melhor visualização dos dados e a identificação destes valores, pode-se utilizar o gráfico de faixa de limiar (Figura 2.9), que realiza uma análise gráfica da linearidade das observações que excedem os vários *thresholds* presentes na amostra. A

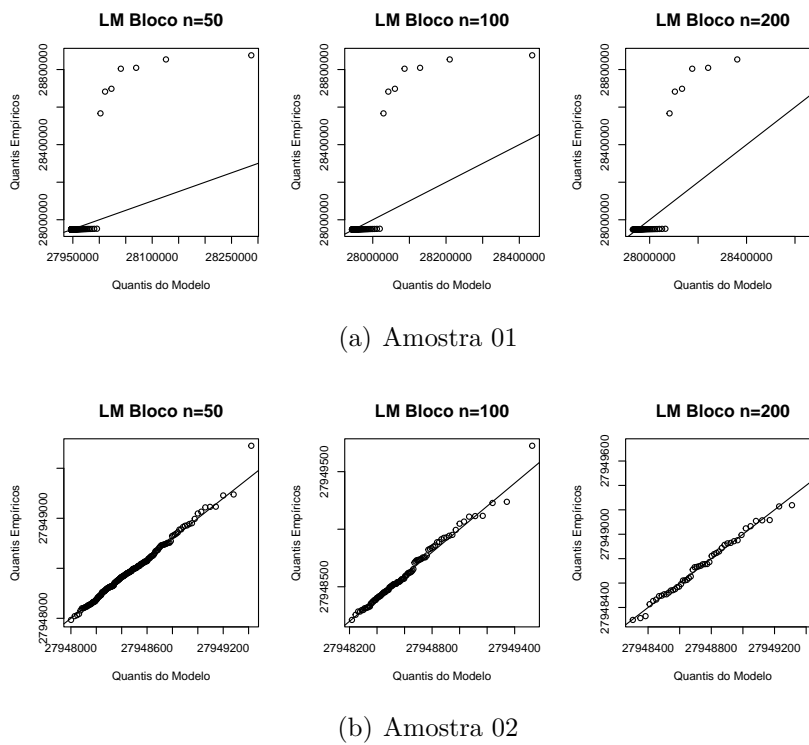


(a) Amostra 01



(b) Amostra 02

**Figura 2.7** Gráficos QQ dos modelos EVT (GEV) obtidos para as amostras utilizadas como exemplo, com parâmetros estimados via MLE e tamanhos de Bloco com  $n = 50$ ,  $n = 100$  e  $n = 200$



**Figura 2.8** Gráficos QQ dos modelos EVT (GEV) obtidos para as amostras utilizadas como exemplo, com parâmetros estimados via LM e tamanhos de Bloco com  $n = 50$ ,  $n = 100$  e  $n = 200$

definição do *threshold* por meio desta ferramenta se dá pela escolha de um valor localizado em uma região onde os dados apresentam estabilidade, mas ainda estão dentro dos limites de incerteza, à medida que o valor sobe (GILLELAND; KATZ, 2016).

A faixa de valores especificada para a Amostra 01 foi (27910200:27920200) e os *thresholds* escolhidos foram  $a = 27914200$ ,  $b = 27916400$  e  $c = 27918600$ . Para a Amostra 02, (27947550:27948650), e os *thresholds*  $a = 27947950$ ,  $b = 27948150$  e  $c = 27948650$ . Os resultados GPD obtidos apontaram conclusões semelhantes às obtidas na GEV, não tendo sido possível obter bom ajuste para a Amostra 01 (Figuras 2.10(a) e 2.11(a)) e bom ajuste para a Amostra 02 (Figuras 2.10(b) e 2.11(b)).

### 2.4.1 Teste Dietrich

Foi utilizada como ferramenta complementar para verificação da qualidade dos ajustes o teste Dietrich et al. (DIETRICH; HAAN; HUSLER, 2002), disponível no pacote *R* `TestEVC1d.r`. Através da função `MTestEVC1d` existente neste pacote, pode-se estimar e testar todas as opções que determinam se uma amostra segue uma distribuição pertencente ao domínio de atração do máximo (*Maximum Domain of Attraction* - MDA) de uma distribuição de valor extremo (HÜSLER; LI, 2006).

Ao aplicar o teste Dietrich para a Amostra 01 (Figura 2.12(a)), observou-se que os resultados estão localizados acima dos valores do quantil 0.95, representado pela linha tracejada vermelha. Para a Amostra 02 (Figura 2.12(b)), observa-se que os seus valores são menores que os correspondentes quantis de probabilidade 0.95. Desta forma, como a maior parte dos resultados se encontra fora da região de rejeição, não há razão para rejeitar a hipótese nula do teste, onde a distribuição pertence ao MDA.

Pode-se perceber que os resultados obtidos no teste Dietrich para as Amostras 01 e 02 são coerentes com as tentativas de ajustes realizadas anteriormente, através da aplicação individual dos métodos BMM e/ou PoT.


## 2.5 ESTIMATIVA PWCET

Na etapa demonstrada no item anterior, percebeu-se que o modelo GEV da Amostra 02 parece ser visualmente melhor ajustado que o GPD, com destaque para o modelo com Bloco  $n = 50$ .


Assim, essa amostra será tomada como exemplo para demonstração da etapa final de estimativa pWCET, que abrange:

- definir as probabilidades de excedência, que consiste no risco do valor máximo observado ocorrer em um determinado tempo;
- estimar o nível de retorno (*Return Level* - RL), que é o quantil extremal inferido dado todas as condições experimentais, para um determinado CI.

Para o caso da Amostra 02, pode-se observar na Tabela 2.2 os RLs estimados para as probabilidades de excedência de  $10^{-5}$ ,  $10^{-6}$ ,  $10^{-7}$  e  $10^{-8}$ , para CI 95%, dos modelos via MLE e LM. Com esses resultados, pode-se afirmar que, por exemplo, no caso do modelo com parâmetros estimados via MLE (Tabela 2.2(a)), há uma probabilidade de

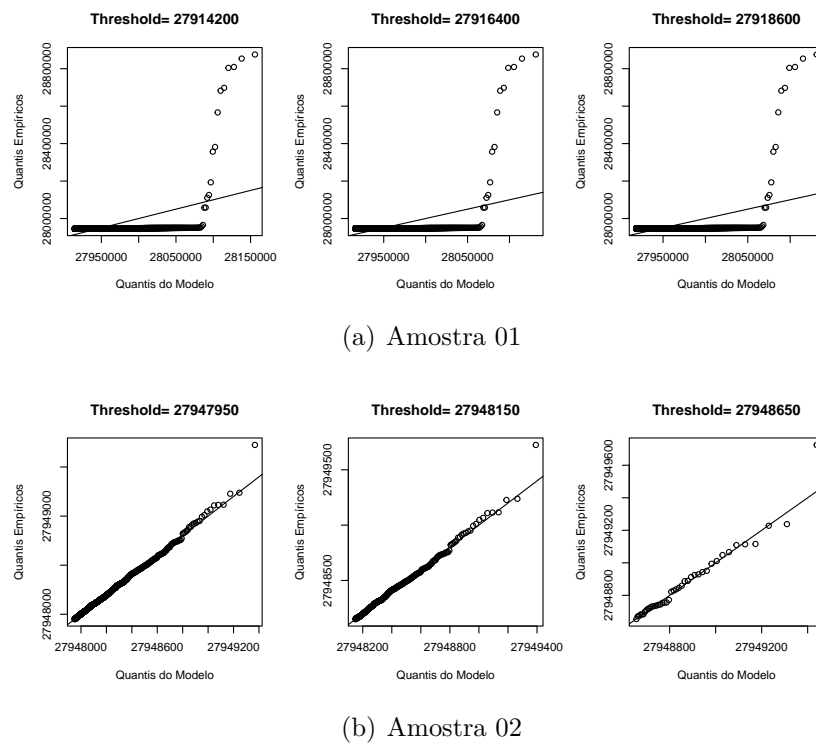


(a) Amostra 01




(b) Amostra 02


**Figura 2.9** Gráficos de faixa de limiar obtidos para as amostras utilizadas como exemplo, com intervalos de *thresholds* especificados em (27910200:27920200) para a Amostra 01 e (27947550:27948650) para a Amostra 02



**Figura 2.10** Gráficos QQ dos modelos EVT (GPD) obtidos para as amostras utilizadas como exemplo, com parâmetros estimados via MLE e *thresholds* com valores =  $a$ ,  $b$  e  $c$ , especificados individualmente por modelo



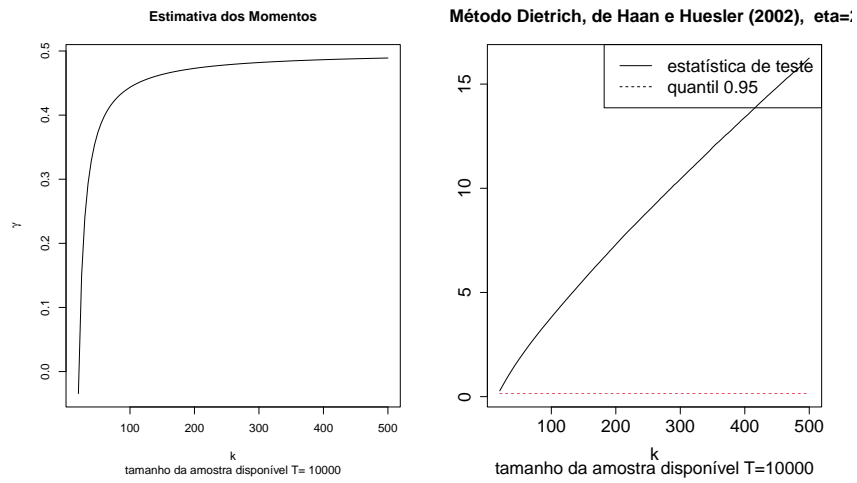
(a) Amostra 01




(b) Amostra 02

**Figura 2.11** Gráficos QQ dos modelos EVT (GPD) obtidos para as amostras utilizadas como exemplo, com parâmetros estimados via LM e *thresholds* com valores =  $a$ ,  $b$  e  $c$ , especificados individualmente por modelo





(a) Amostra 01



(b) Amostra 02

**Figura 2.12** Resultado da aplicação do teste Dietrich (CI 95%) nas amostras utilizadas como exemplo

**Tabela 2.2** Amostra 02 - RL (CI 95%) para as probabilidades de excedência de  $10^{-5}$  a  $10^{-8}$  do modelo EVT (GEV) gerado com estimativas de parâmetros via MLE e LM

(a) RL do modelo com parâmetros estimados via MLE

Prob. Exced.	CI inferior (95%)	Valor estimado	CI superior (95%)
$10^{-5}$	27949454	27950650	27951846
$10^{-6}$	27949378	27951096	27952814
$10^{-7}$	27949206	27951537	27953868
$10^{-8}$	27948940	27951973	27955006

(b) RL do modelo com parâmetros estimados via LM

Prob. Exced.	CI inferior (95%)	Valor estimado	CI superior (95%)
$10^{-5}$	27949718	27950640	27952460
$10^{-6}$	27949836	27951081	27954000
$10^{-7}$	27949933	27951516	27955871
$10^{-8}$	27950016	27951945	27958172

0,000001 de que o máximo observado exceda o valor estimado (27950650), para CI 95% (27949454:27951846).

A Tabela 2.3 complementa as informações obtidas do modelo ajustado, e lista os parâmetros estimados. A partir destes, pode-se sugerir que o modelo corresponde a uma distribuição GEV do tipo *Weibull*, tomando-se como base o parâmetro forma  $\xi = -4.690108e-03$ , estimado via MLE (Tabela 2.3(a)), ou, forma  $\xi = -5.762319e-03$ , estimado via LM (Tabela 2.3(b)).

Para fins de demonstração, apresentamos também as estimativas do modelo GPD, com o *threshold*  $a$  (escolhido arbitrariamente entre opções com *threshold*  $a$ ,  $b$  e  $c$ ) (Tabelas 2.4 e 2.5). Como esperado, por conta do bom modelo EVT obtido, as estimativas deste modelo se aproximam e apresentam resultados coerentes com o modelo GEV escolhido.

Por fim, como visto anteriormente, a Amostra 01 foi descartada pois não foi possível obter um modelo com boa qualidade de ajuste e isto impossibilitaria a estimativa de pWCET. Reforça-se, assim, a importância em realizar as etapas do processo de qualidade de ajuste EVT e descartar de imediato de amostras que não apresentarem bom ajuste.

**Tabela 2.3** Amostra 02 - Parâmetros obtidos (CI 95%) do modelo EVT (GEV) gerado com estimativas via MLE e LM

(a) Parâmetros do modelo estimado via MLE

Parâmetro	CI inferior (95%)	Valor estimado	CI superior (95%)
locação	2.794831e+07	2.794835e+07	2.794838e+07
escala	1.825625e+02	2.055221e+02	2.284817e+02
forma	-9.963539e-02	-4.690108e-03	9.025518e-02

(b) Parâmetros do modelo estimado via LM

Parâmetro	CI inferior (95%)	Valor estimado	CI superior (95%)
locação	2.794832e+07	2.794835e+07	2.794838e+07
escala	1.811767e+02	2.059290e+02	2.323695e+02
forma	-1.169176e-01	-5.762319e-03	9.918536e-02

**Tabela 2.4** Amostra 02 - RL (CI 95%) para as probabilidades de excedência de  $10^{-5}$  a  $10^{-8}$  do modelo EVT (GPD) gerado com  $threshold=a$  e estimativas de parâmetros via MLE e LM

(a) RL do modelo com parâmetros estimados via MLE

Prob. Exced.	CI inferior (95%)	Valor estimado	CI superior (95%)
$10^{-5}$	27949799	27950598	27951397
$10^{-6}$	27949863	27950882	27951900
$10^{-7}$	27949893	27951143	27952393
$10^{-8}$	27949892	27951383	27952874

(b) RL do modelo com parâmetros estimados via LM

Prob. Exced.	CI inferior (95%)	Valor estimado	CI superior (95%)
$10^{-5}$	27949725	27950332	27951500
$10^{-6}$	27949816	27950546	27952068
$10^{-7}$	27949888	27950735	27952646
$10^{-8}$	27949943	27950902	27953233

**Tabela 2.5** Amostra 02 - Parâmetros obtidos (CI 95%) do modelo EVT (GPD) gerado com  $threshold=a$  e estimativas via MLE e LM

(a) Parâmetros do modelo estimado via MLE

Parâmetro	CI inferior (95%)	Valor estimado	CI superior (95%)
escala	208.47970806	225.19174211	241.9037762
forma	-0.08661654	-0.03648812	0.0136403

(b) Parâmetros do modelo estimado via LM

Parâmetro	CI inferior (95%)	Valor estimado	CI superior (95%)
escala	210.8018973	229.15689238	247.62651712
forma	-0.1151249	-0.05463774	0.00460669



# 3

## REVISÃO BIBLIOGRÁFICA

É vasta a literatura sobre aplicação da MBPTA-EVT para inferência de WCET em arquiteturas modernas, entretanto, percebe-se que há uma carência de publicações que demonstrem o processo de aplicação da técnica de forma prática e exponham suas falhas e taxas de descarte de amostras inválidas.

De maneira geral, os trabalhos existentes encontrados: apresentam de forma teórica os conceitos e desafios para usar EVT para inferência de  $pWCET$  (CAZORLA et al., 2013; SANTINELLI et al., 2014; GIL et al., 2017; DAVIS; CUCU-GROSJEAN, 2019; GOMES, 2019), relatam experiências positivas obtidas em ambientes *single-core* (LU et al., 2011; SANTINELLI; GUO, 2017; ARCARO; SILVA; OLIVEIRA, 2018), isolados (COSTA et al., 2021), simulados (LIMA; DIAS; BARROS, 2016), ou investigam problemas e características específicas, como representatividade e relações de dependência (GUET; SANTINELLI; MORIO, 2017; NÉLIS et al., 2014), em alguns casos provocando situações em plataformas (ABELLA et al., 2014; ABELLA et al., 2014), ou avaliando impactos provocados por hardwares específicos (BEREZOVSKYI et al., 2014; HECKMANN et al., 2003; ABELLA et al., 2014). Há ainda as publicações que focam em apenas um dos métodos para ajuste EVT (BMM ou PoT) ou em uma distribuição específica (como Gumbel ou Weibull) (CUCU-GROSJEAN et al., 2012; REGHENZANI; MASSARI; FORNACIARI, 2018; BURNS; EDGAR, 2000; HANSEN; HISSAM; MORENO, 2009; MAXIM et al., 2013), testam o uso de recursos específicos, como cópulas (MELANI; NOULARD; SANTINELLI, 2013; BERNAT; BURNS; NEWBY, 2005) e testes GoF (REGHENZANI; MASSARI; FORNACIARI, 2020) para resolver problemas de dependência, e as que propõem melhorias em algoritmos, como para estimação de parâmetros (SANTINELLI; GUO, 2017). Tal literatura é apresentada a seguir em três grandes grupos: apresentação e visão geral, dados e características, diferentes plataformas e divergências.

### 3.1 APRESENTAÇÃO E VISÃO GERAL

Burns e Edgar (BURNS; EDGAR, 2000) foram os primeiros a estimar  $pWCET$  através da abordagem MBPTA-EVT, quando realizaram um experimento que mostrou a possi-

bilidade de usar técnicas probabilísticas para estimativa de tempo de pior caso ajustada a uma distribuição Gumbel. Desde então, EVT vem sendo vista por diferentes autores como um método promissor, sendo abordada em diferentes pesquisas e apontada de forma positiva para resolver o problema de estimativa de WCET e pWCET.

- Lu et al. (2011) aplicam EVT para estimar o WCET de programas executados em ambiente com um único processador. Propõem um novo mecanismo via Amostragem Aleatória Simples (*Simple Random Sampling - SRS*) para quebra de dependência entre observações, e assim, coletar amostras de análise qualificadas, além de um método para análise dos dados denominado RapidET, mecanismo para amostragem e inferência baseada na EVT e outras técnicas.
- Cazorla et al. (2013) mostram os requisitos necessários para estimar o WCET usando EVT, dando ênfase sobre como definir uma população estatística e como executar o método em arquiteturas *time-deterministic* e *time-randomised*.
- Santinelli et al. (2014) apresentam conceitos, desafios e definições relacionadas ao uso da EVT para inferência de pWCET.
- Gil et al. (2017) elencam principais desafios e mapeiam o estado de arte de métodos para estimativa de pWCET via EVT.
- Arcaro, Silva e Oliveira (2018) avaliam a confiabilidade e ajuste da aplicação MBPTA via o método PoT para estimativa de pWCET através dos modelos GPD e Exponencial.
- Davis e Cucu-Grosjean (2019) apresentam um *survey* para cobrir técnicas probabilísticas para análise temporal compreendidas entre os anos 2000 e 2018, fornecendo taxonomia de diferentes métodos, estudos de casos, mecanismos e técnicas de apoio, além de apresentarem problemas em aberto e possíveis direções para trabalhos futuros.
- Cazorla et al. (2019) apresentam um *survey* com taxonomia, motivações, direções para pesquisa e estratégias de aplicação relacionada ao uso de técnicas probabilísticas e estatísticas para análise temporal. Mapeiam o estado de arte da área, realizam comparativos e relações entre estas, além de apontarem desafios para consolidar a aplicação da técnica na indústria.
- Gomes (2019) faz uma introdução com as principais características da EVT e seu papel na modelagem de acontecimentos raros e de risco, focando em uma abordagem paramétrica de extremos univariados.

### 3.2 DADOS E CARACTERÍSTICAS

Problemas e falhas observados na aplicação da EVT são, muitas vezes, atribuídos pelos autores não à técnica em si, mas pela dificuldade em coletar amostras adequadas. Tais problemas podem ser atribuídos a alta dependência que pode existir entre os tempos

de execução medidos e à dificuldade de garantir a representatividade de uma população estudada. Diferentes experimentos vêm sendo realizados para contornar estas questões, tais como, o uso de cópulas e de testes GoF, além disso, são realizados experimentos focados em um método específico EVT (BMM ou PoT) e/ou suas respectivas distribuições derivadas.

- Edgar e Burns (2001) apresentam técnicas para inferência de WCET, introduzindo a estimação estatística de distribuição pWCET para uma tarefa. Modelos foram construídos com tempos de execução de tarefas, com observações consideradas independentes, aplicação direta da distribuição Gumbel e teste Qui-quadrado (*Chi-squared Test -  $X^2$* ) (GREENWOOD; NIKULIN, 1996) para determinar parâmetros de escala e locação.
- Bernat, Colin e Petters (2002) combinam abordagens analíticas e feitas através de medições para computar limites probabilísticos do WCET de trechos de código.
- Bernat, Burns e Newby (2005) realizam um estudo inicial sobre a aplicação de cópulas (NELSEN, 2007) para o problema da análise probabilística para estimativa de pWCET, modelando dependências em tempos de execução e usando uma sequência de componentes para os modelos analisados.
- Garrido e Diebolt (2007) têm como intuito aplicação de testes GoF para verificar a adequação de modelos e qualidade do ajuste em caudas de distribuição. Comparam estimativas paramétricas e semi-paramétricas com variações aproximadas através de *Bootstrap* paramétrico e simulações numéricas de Monte Carlo para explorar a probabilidade de cobertura e o poder do teste.
- Hansen, Hissam e Moreno (2009) aplicam EVT para obter o WCET, utilizando o método BMM para coletar valores máximos da amostra e ajustá-la à distribuição Gumbel e o teste  $X^2$  para garantir a boa qualidade do ajuste.
- Griffin e Burns (2010) ponderam que as técnicas estatísticas podem causar um disfarce da realidade, e alertam para a necessidade de ações que garantam a segurança dos resultados ao estimar o WCET usando EVT. Destacam problemas e algumas soluções para a fase de amostragem dos tempos de execução dos programas, com uso de variáveis contínuas, e panorama com valores que não cumprem a condição *i.i.d.*, devido a dependências existentes nos componentes do programa.
- Cucu-Grosjean et al. (2012) apresentam experimentos reais para estimativa de pWCET usando programas com múltiplos caminhos de execução, propõem soluções para amostras que não atendem aos critérios *i.i.d.* e contínuas e sugerem a substituição do teste  $X^2$  pelo teste *Exponential Tail* - ET para checagem de ajuste à distribuição Gumbel.
- Melani, Noulard e Santinelli (2013) criam um *framework* baseado nos fundamentos de cópulas, com intuito de explorar modelos de medição probabilística para estudo

do impacto de dependências nos tempos de execução em sistemas reais. Realizam o experimento usando diferentes estudos de caso e ambiente com um processador.

- Maxim et al. (2013) trazem uma abordagem através da distribuição Weibull, buscando obter distribuição de probabilidade de mínimos dos tempos de chegada de uma tarefa.
- Nélis et al. (2014) realizam aplicação da EVT em uma plataforma Kalray MPPA-256 (KALRAY..., s.d.) buscando modelar os tempos de execução como variáveis aleatórias, como cópulas e outras técnicas baseadas também em cópulas para resolver dependências entre os dados e, assim, estimar um pWCET.
- Guet, Santinelli e Morio (2017) investigam o impacto de dependências estatísticas na aplicação da EVT e qualidade do pWCET estimado, através de casos de teste realizados em diferentes modos operacionais com variações de elementos como atividades de I/O, sistema multi e com único *core*, *cache* e memória compartilhada, além de comparativos de ajustes via PoT ou BMM.
- Milutinovic et al. (2017) relatam a preocupação da indústria em usar técnicas probabilísticas para análise temporal. Discutem equívocos e dificuldades com as técnicas através do método MBPTA-EVT, afirmando que os maiores problemas com relação à técnica dizem respeito à forma como a mesma é aplicada. Apresentam o proMBPTA, resultado dos projetos PROARTIS e PROXIMA, como uma proposta para produzir resultados confiáveis de pWCET.
- Abella et al. (2017) avaliam a viabilidade de uso da EVT para inferência de WCET em programas de tempo real propondo um novo método denominado MBPTA-CV, aplicado em ambientes real e simulado, e que se baseia em seleção automática de parâmetros da distribuição de melhor ajuste.
- Abella et al. (2014) usam MBPTA para inferir pWCET de programas críticos e ressaltam a existência de elementos que quebram a confiabilidade de métodos de Análise Probabilística em geral. Apresentam casos realistas onde esta estimativa falha, também identificam e fornecem meios para detectar características que podem levar a estimativas de pWCET adequadas. Consideram como fontes de variabilidade: eventos aleatórios influenciados apenas por componentes de hardware e comportamento temporal determinado por instruções de um programa que usa recursos *time-randomised*.
- Reghenzani, Massari e Fornaciari (2020) destacam que a teoria probabilística ainda apresenta muitas brechas quando busca-se estimar o WCET em RTS em arquiteturas complexas. Propõem a aplicação de testes estatísticos, como KPSS, BDS e H, para garantir que as amostras coletadas estejam dentro dos critérios necessários para aplicação da EVT, garantindo, assim, estimativas seguras de pWCET.



### 3.3 PLATAFORMAS

Diferentes experimentos e estudos de caso vêm sendo propostos em ambientes com um ou múltiplos processadores (*single* ou *multi-core*), com a intenção de tornar o ambiente mais estável ou checar o comportamento da aplicação da MBPTA-EVT. Alguns checam, ou tentam, reduzir impactos negativos provocados por fontes imprevisíveis de hardware, outros testam a aplicação da técnica em diferentes plataformas, e outros propõe mudança em alguma etapa ou método relacionados à aplicação da EVT.

- Heckmann et al. (2003) trazem resultados e considerações sobre previsibilidade, através da implementação de ferramentas WCET em arquiteturas complexas como SuperSPARC, Motorola ColdFire 5307, e Motorola PowerPC 755; sujeitas a alta interferência de componentes como *cache*, *pipelines* e unidades de *branch prediction*.
- Berezovskyi et al. (2014) propõem a inferência de WCET através da abordagem MBPTA-EVT para um ambiente com aplicações paralelas em GPUs. Discutem o uso da distribuição GEV e aplicam ferramentas estatísticas para quantificar independência entre observações.
- Abella et al. (2014) apontam diferenças entre a técnica determinística STA e as técnicas probabilísticas SPTA e MBPTA para estimativa de WCET sob diferentes configurações de *cache* com *Least Recently Used* - LRU e substituição aleatória.
- Santinelli e Guo (2017) realizam um estudo de caso para estimativa de pWCET em sistemas *single* e *multi-core*, a partir de um *framework* denominado *Worst-Case Set*, que representa probabilidades de tempos de execução medidos sob múltiplas condições de execução.
- Santinelli, Guet e Morio (2017) aplicam a MBPTA-EVT, realizam testes em STRs randomizados artificialmente e *non-time randomized* e contribuem com algoritmos para melhorar a seleção de parâmetros EVT e aumentar a confiabilidade de pWCET estimado.
- Özari, Eren e Saygin (2019) propõem um método computacional com apoio do teste de Mann-Whitney (MANN; WHITNEY, 1947), para otimizar o processo de seleção de tamanhos de blocos durante a aplicação da EVT via BMM, e, assim, evitar problemas com variância ou enviesamento de dados.
- Costa et al. (2021) realizam a aplicação da técnica MBPTA-EVT, via BMM, para estimação de pWCET em um ambiente com restrições funcionais e temporais na plataforma BeagleBone (BEAGLE... , s.d.). Apresentam resultados considerados como satisfatórios.

### 3.4 DIVERGÊNCIAS

O uso da EVT para inferência de pWCET ainda provoca divergências de opiniões entre os autores.

- Vilardell et al. (2022) afirmam que EVT é carregada de incertezas para inferir pWCET de forma confiável. Como opção, propõem o uso de Desigualdade de Markov mediante aplicação de função *Power-of-k* no lugar da tradicional função identidade.
- Silva, Arcaro e Oliveira (2017) realizam uma avaliação empírica através de comparação de amostras de natureza sintética e real, com tamanhos grandes (e.g.  $10^8$ ), aumentados de forma progressiva, e com amostra definida a partir da métrica CRPS, para averiguar a confiabilidade de WCET estimados através dos modelos GEV e Gumbel. Optam pelo modelo Gumbel como o ideal para o panorama avaliado.
- Lima, Dias e Barros (2016) propõem um olhar especial sobre a aplicação da EVT para dados temporais. Questionam a eficácia do método e a forma como ele vem sendo empregado, a exemplo do uso da distribuição Gumbel ao invés da GEV, mostrando que qualquer uma das distribuições de valores extremos (Weibull, Gumbel ou Fréchet) pode ser produzida com entrada obtida de forma aleatória.

Pode-se notar que a revisão apresentada aborda variados problemas relacionados à aplicação da MBPTA-EVT. Os relatos e experimentos trazem informações sobre como driblar, aperfeiçoar ou gerir as diferentes situações e problemas encontrados durante a aplicação da técnica. Contribuem ainda para cobertura sobre o tema em projetos de RTS. Entretanto, ainda é escassa nesta mesma literatura a exposição de forma prática das taxas de descartes e outras situações de falhas e problemas do uso da EVT.

# 4

## RESULTADOS EXPERIMENTAIS

O experimento foi realizado tendo como plataforma uma arquitetura moderna RPi 3B (RASPBERRY..., s.d.), Broadcom BCM43438, Quad Core 64-bit ARMv8 Cortex-A53 1.2GHz., 1GB RAM, rede BCM43438 wireless 802.11n LAN e Bluetooth 4.1 (BLE) integrados, com sistema operacional (*Operating System* - OS) Raspbian GNU/Linux 9 (*Strech*).

Foram executados diferentes *benchmarks* e medidos os tempos de execução de seus eventos de arquitetura através da Unidade de Monitoramento de Desempenho (*Performance Monitor Unit* - PMU) do RPi. Os resultados foram colhidos via a ferramenta de análise de desempenho do Linux, `linux_perf` (v. 4.9.82) (LINUX..., s.d.), através da chamada de sistema `perf_event_open` (PERF..., s.d.).

Ao executar cada programa foi medido o evento de hardware `PERF_COUNT_HW_CPU_CYCLES`, do tipo `PERF_TYPE_HARDWARE`, que conta o número total de ciclos de *clock* de CPU processados durante uma execução. Posteriormente, este valor foi modelado como a v.a. `Ciclos`, na qual foi aplicado o estudo EVT.

Medições via contadores de desempenho podem produzir um pequeno excesso de contagem no número de instruções executadas (*retired instructions*)<sup>1</sup>. Com intuito de monitorar a eficácia deste método e averiguar se esses excessos estariam provocando impactos nas medições, aumentando `Ciclos` de forma indesejada, também foi medido o evento `PERF_COUNT_HW_INSTRUCTIONS`, que conta o número de *retired instructions*. Posteriormente, este valor foi modelado como a v.a. `Ins`.

Os *benchmarks* executados ao longo do experimento integram o *Mälardalen WCET Benchmarks*, um conjunto criado para apoiar o uso de ferramentas para análise de WCET (GUSTAFSSON et al., 2010). De forma a assegurar que a execução desses programas não sofressem variações impactadas sob o ponto de vista do código executado, foram atribuídos valores fixos às suas entradas. Assim, garante-se um único caminho de execução

---

<sup>1</sup>Excessos no número de *retired instructions* podem ser provocados pela randomização do espaço de endereço do Linux, determinismo não intencional no sistema binário ou OS e errata do processador (WEAVER; MCKEE, 2008). Este fato, entretanto, não deve provocar impactos significativos à medição final (FRANCIS-MEZGER; WEAVER, 2018; PERF..., s.d.).

(*single-path*) e, conseqüentemente, um comportamento previsível no tempo sob o ponto de vista do código do programa executado. Além disso, para que os *benchmarks* se encontrassem em condições o mais semelhante possível em relação aos outros, foram atribuídos valores iguais a estas entradas, diferenciados apenas nos casos onde os tipos dos dados eram diferentes, podendo estes tratar-se de vetores, matrizes ou um número inteiro.

Para garantir que o ambiente tivesse diferentes padrões de comportamento, e conseqüentemente, provocasse distintos impactos nas medições, a escolha dos *benchmarks* foi feita considerando as suas diferentes demandas de processamento e características. Foram testados 11 *benchmarks*, analisados individualmente e depois comparados a partir de uma reunião em quatro grandes grupos de acordo algumas de suas características (ANDRADE et al., 2021):

- Grupo 01: Acesso à memória para operações de carga e gravação (*Insertion Sort*, *Bubble Sort*, *Merge Sort* e *Quick Sort*)
- Grupo 02: Cálculos (*Fft1*, *Sqrt* e *Fibcall*)
- Grupo 03: Uso intensivo de memória e cálculos (*Cnt*, *Edn* e *Matmult*)
- Grupo 04: Computação e acesso a baixa memória (*Binary Search* e *Fibcall*)

## 4.1 METODOLOGIA

Os itens seguintes descrevem as ferramentas computacionais de apoio utilizadas, critérios para avaliação de dados e itens adicionais considerados na metodologia do experimento, tais como, cenários de testes, quantidade e tamanho das amostras populacionais.

### 4.1.1 Cenários de testes

Foram criados cenários de testes ambientados a partir da variação dos estados dos recursos de *Wifi*, *Ethernet* (*Eth0*) e *Core*, com intuito de provocar possíveis variabilidades nos tempos de execução dos *benchmarks* executados. Foram assumidos os seguintes estados:

- *On* (ativado) ou *Off* (desativado), para *Eth0*
- *On* (ativado) ou *Off* (desativado), para *Wifi*
- *Core 0* (Padrão), para execução do *benchmark* no *core* padrão utilizado pelo sistema operacional quando não há especificação da Afinidade de CPU (*CPU Affinity*), ou, *Core 3<sup>2</sup>* (Dedicado), para execução do *benchmark* de forma dedicada no *core* especificado, para *Core*

Tais variações possibilitaram a criação de oito diferentes cenários de testes, tratados como Fontes de dados (F), de 01 a 08, conforme especificado na Tabela 4.1.

---

<sup>2</sup>Escolhido de forma arbitrária.

**Tabela 4.1** Cenários de testes criados a partir da variação dos recursos *Eth0*, *Wifi* e *Core*.

	<i>Eth0</i>		<i>Wifi</i>		<i>Core</i>	
<b>Cenário</b>	<i>On</i>	<i>Off</i>	<i>On</i>	<i>Off</i>	Padrão (0)	Dedicado (3)
F01		X	X		X	
F02	X		X			X
F03	X		X		X	
F04	X			X	X	
F05		X		X	X	
F06		X	X			X
F07	X			X		X
F08		X		X		X

Testes envolvendo outros serviços também foram realizados, mas não foram considerados dentre os possíveis cenários por não provocarem impacto significativo nos resultados observados. Eles envolviam serviço de *bluetooth*, conexão via *ssh*, diferentes atribuições de prioridades ao processo do *benchmark*, modo do ambiente do OS, se gráfico ou texto, e reiniciando o estado do hardware a cada teste.

#### 4.1.2 Tamanho e quantidade de amostras

Foram coletadas cinco amostras por cenário para cada *benchmark*, cada com 10 mil observações, denominadas **Amostras Regulares**. Com intuito de realizar o mesmo experimento em amostras maiores foram coletadas ainda amostras com 100 mil e 500 mil observações, para dois ou três cenários para cada *benchmark*, denominadas **Amostras Extras**. Os cenários destas amostras foram escolhidos a partir dos resultados obtidos nas tentativas de ajuste EVT nas Amostras Regulares. Assim, obteve-se um montante de 700 amostras medidas, o que representou 82.400.000 observações avaliadas (Tabela 4.2). Para todas as amostras foram medidos *Ciclos* e *Ins*.

#### 4.1.3 Ferramentas estatísticas

A análise dos dados medidos, o ajuste de modelos para inferência e o estudo dos resultados foram realizados através da ferramenta estatística R. Dentre a variedade existente de pacotes<sup>3</sup> disponíveis para apoiar o trabalho com valores extremos no R, optou-se por utilizar o *extRemes*.

O pacote *extRemes* dispõe de funções essenciais para análise de valores extremos e apoio ao processo de aplicação da EVT, tais como: ajuste de função de distribuição de valor extremo univariada (como GEV e GPD), estimação de parâmetros via MLE e LM (neste caso, incluindo suporte de *Bootstrap* paramétrico para estimar erros e CIs), CI para parâmetros e RL, estimativas de RL de modelo ajustados, e funções para obtenção de densidade, CDF e quantis. A ferramenta também disponibiliza recursos gráficos que permitem a análise de ajuste EVT para modelos gerados, como os gráficos QQ, PDF e

<sup>3</sup>Disponível em: <<https://cran.r-project.org/web/views/ExtremeValue.html>>.

**Tabela 4.2** Total de amostras e observações coletadas no experimento, classificadas por *benchmark* e tipo, se Amostra Regular ou Extra, e listagem de cenários extras medidos

<i>Benchmark</i>	Quantidade de amostras			
	Amostras Regulares 10 mil observações	Cenários	Amostras Extras 100 mil obs.	500 mil obs.
<i>Insertion Sort</i>	40	F01 - F05	10	10
<i>Merge Sort</i>	40	F01 - F02 - F05	15	15
<i>Quick Sort</i>	40	F01 - F05 - F08	10	10
<i>Bubble Sort</i>	40	F01 - F05	10	10
<i>Fibcall</i>	40	F01 - F05 - F06	15	15
<i>Sqrt</i>	40	F01 - F08	10	10
<i>Fft1</i>	40	F01 - F05 - F06	15	15
<i>Edn</i>	40	F02 - F08	10	10
<i>Cnt</i>	40	F03 - F05	10	10
<i>Matmult</i>	40	F05 - F08	10	10
<i>Binary Search</i>	40	F01 - F08	10	10
<b>Total amostras</b>	<b>440</b>		<b>130</b>	<b>130</b>
Subtotal observações	4.400.000		13.000.000	65.000.000
<b>Total observações</b>				<b>82.400.000</b>

faixa de limiar, e RL por período de retorno. Funções do pacote base do R para produção de histogramas, autocorrelação, gráficos de densidades e de dispersão, também foram utilizadas.

Foi ainda utilizado o teste Dietrich et al. (DIETRICH; HAAN; HUSLER, 2002), voltado à verificação da qualidade do ajuste (ver Seção 2.4.1).

#### 4.1.4 Testes GoF

Optou-se inicialmente por buscar uma adequação dos dados amostrais aos critérios *i.i.d.*, pilar EVT. Foram empregadas duas ações para isso. A primeira consistiu em aplicar o teste KS para verificar se as amostras coletadas eram provenientes de uma mesma distribuição, e, a segunda, em reiniciar a máquina a cada nova medição para forçar a limpeza do estado do hardware.

Apesar dos resultados destas ações terem indicado a conformidade *i.i.d.*, observou-se que muitas das amostras testadas não puderam ter boa qualidade de ajuste após submetidas ao estudo EVT. Este fato demonstrou que não basta que os dados estejam em conformidade com os critérios *i.i.d.* para garantir que a aplicação EVT seja bem sucedida.

Como o objetivo central deste trabalho é o estudo EVT, e não aprofundar sobre a natureza dos dados amostrais, optou-se por não levar adiante medidas para checar condições *i.i.d.*

### 4.1.5 Análise dos dados amostrais

Buscando melhor compreender os resultados dos modelos EVT obtidos, foram ainda realizadas algumas análises dos dados amostrais:

- **Plotagem**

Foram plotados histogramas e gráficos de dispersão. Para fins de apresentação dos dados, os histogramas foram classificados em dois padrões, denominados: Padrão 01 e Padrão 02.

O Padrão 01 diz respeito às distribuições que apresentaram aparência visual similar a uma forma de sino, característica de uma Gaussiana, e outras características visuais desta distribuição, tais como, aparência unimodal e simétrica em torno da média, a exemplo do modelo da Figura 4.1(a)). Não foram realizados testes para confirmar a normalidade dos dados, apenas análise visual.

O Padrão 02 incluiu todas as demais distribuições, como alguns dos exemplos apresentados na Figura 4.1(b).

- **Amplitude Ciclos**

Foram observados os menores e maiores valores da v.a. **Ciclos** em cada amostra, para fins de comparação com os pWCETs estimados. Tais valores foram referenciados ao longo do trabalho como *Valor mínimo observado* - **OMin Ciclos** e *Valor máximo observado* - **OMax Ciclos**.

- **Coeficiente de Variação (Coefficient of Variation - CV)**

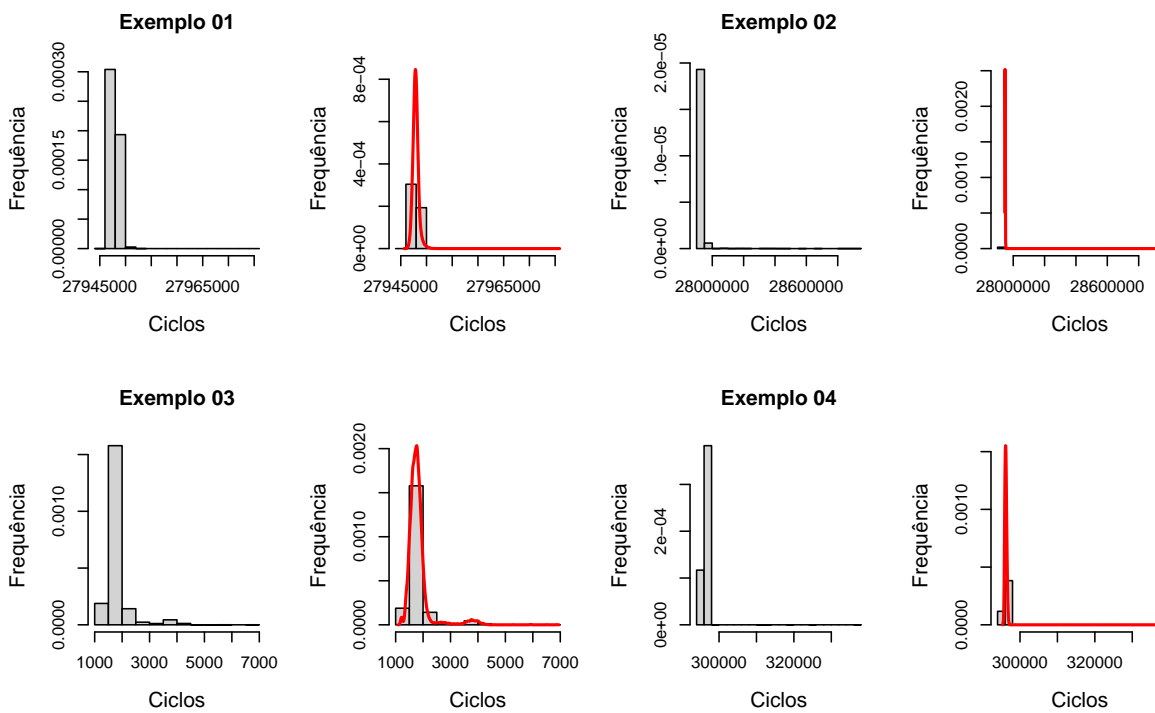

O CV é uma medida estatística de dispersão para um conjunto de amostras não negativas ou dados populacionais. Podendo ser expresso como uma porcentagem, ele descreve o desvio padrão  $s$  em relação à média  $\bar{x}$  (Equação (4.1)) (TRIOLA et al., 2006).

$$CV = \frac{s}{\bar{x}} \times 100\% \quad (4.1)$$

CVs são considerados baixos quando inferiores a 10%, médios, quando entre 10 e 20%, altos, quando entre 20 e 30%, e, muitos altos, quando superiores a 30%. Quanto menor o CV, potencialmente, mais homogêneo é o conjunto de dados (MOHALLEM et al., 2008).

Foram calculados os CVs das v.as. **Ciclos** e **Ins**.

- **CV Ciclos**: Um alto CV para **Ciclos** pode ser reflexo de um maior impacto do ambiente durante a medição.
- **CV Ins**: Como a execução dos *benchmarks* é determinística sob o ponto de vista do seu código, espera-se que o CV para **Ins** seja muito baixo e estável. Um alto CV para **Ins** pode representar uma inadequação de realizar as medições através dos contadores de desempenho utilizados neste trabalho.



**Figura 4.1** Apresentação de exemplos de histogramas classificados como Padrão 01 e Padrão 02, e suas respectivas PDFs



### 4.1.6 Aplicação EVT

A aplicação EVT foi realizada conforme as etapas apresentadas nas Seções 2.4 e 2.5.

## 4.2 RESULTADOS

Analisando e comparando todos os resultados obtidos ao longo do experimento, pode-se destacar que:

- Foi identificada a presença de *outliers* em algumas amostras. Estes valores pareciam inviabilizar os bons ajustes quando essas amostras foram submetidas à aplicação EVT. Removeu-se manualmente estes dados, com intuito de averiguar se tais valores tinham sido produzidos em decorrência de uma falha momentânea que provocou impacto na distribuição. Entretanto, re-avaliando os dados sem estes *outliers*, observou-se a presença de novos *outliers*, com valores abaixo dos inicialmente identificados, e assim por diante, quantas vezes fossem excluídos os valores fora do padrão. Concluiu-se, desta forma, que os *outliers* eram sempre sendo produzidos, em diferentes momentos, não tendo sido provocados por uma falha única e isolada.
- Foram observados diferentes tipos de distribuição dos dados amostrais da população. As distribuições com aparência visual no Padrão 01 sempre tiveram boa qualidade de ajuste EVT, assim como, de maneira geral, a maior parte das distribuições com aparência visual assimétrica positiva (classificadas dentro do Padrão 02). As demais distribuições não apresentaram padrão de comportamento com relação a apresentar ou não um bom ajuste. Pode-se, assim, sugerir que a aplicação EVT pode não ser eficaz para todos os tipos de distribuição.
- Aumentar o tamanho das amostras de 10 mil para 100 mil ou 500 mil observações não provocou um resultado único relacionado à quantidade de amostras com bom ajuste EVT. Em alguns casos, aumentar o tamanho fez crescer a quantidade de amostras com bom ajuste, em outros, reduziu o número de bons ajustes, e, ainda houve casos sem alterações. O fato indica que não há um tamanho único de amostra adequado para aplicação da EVT. Assim, supõe-se que o tamanho ideal, aquele onde seja possível obter um alto número de bons ajustes, deva ser fruto de uma análise específica para cada amostra, considerando a natureza e complexidade do código executado, os valores de entrada do *benchmark* e os impactos que o ambiente possa provocar na sua execução.
- Na maior parte dos casos, ao comparar diferentes amostras medidas para um mesmo cenário, as que apresentaram observações com **OMax Ciclos** mais baixos puderam obter bom ajuste EVT, enquanto que as com os mais altos não puderam. Não existe relação entre o número de **Ciclos** e a possibilidade ou não de obter bom ajuste, entretanto, um valor de **Ciclos** mais baixo pode indicar que a medição ficou menos tempo exposta aos impactos do ambiente, deixando-a com uma distribuição menos conturbada, o que pode torná-la mais facilmente ajustável à EVT.

- Todos os *benchmarks* testados no experimento apresentaram baixos CVs para *Ins*, demonstrando que não houve oscilações significativas no número de *retired instructions*. Este fato indica que o uso dos contadores de desempenho do RPi usando a ferramenta `linux_perf` se mostrou eficaz e confiável para medição de *Ciclos*, não tendo trazido prejuízos à amostragem.
- Como há estabilidade em *Ins* e determinismo sob o ponto de vista de todos os códigos executados ao longo do trabalho, supõe-se que as oscilações em *Ciclos* em um mesmo *benchmark* sejam decorrentes de impactos provocados pelo ambiente.

Observando os dados presentes nas Tabelas 4.3, 4.4, 4.5, 4.6 e 4.7, que demonstram os percentuais de bom ajuste EVT, pode-se destacar que:

- Apesar de os *benchmarks* terem sido agrupados por semelhanças existentes entre suas características e formas de processamento, os percentuais de bom ajuste não apresentaram resultados semelhantes por grupos. Exceto pelos *benchmarks Insertion Sort, Merge Sort e Bubble Sort*, do Grupo 01, que obtiveram alto índice de bom ajuste para os cenários F05 e F08, e nenhum bom ajuste para os demais cenários, não foi possível identificar padrões de comportamento por grupo.
- A criação de cenários de testes com variação dos recursos de *Eth0, Wifi e Core* foi parcialmente eficiente para provocar impacto nas medições. Observou-se que a oscilação no estado do recurso *Core* para *On* e *Off* não pareceu ter provocado variações nos *Ciclos* das medições. Notou-se, entretanto, que as medições ambientadas nos cenários F05 e F08, únicos com os recursos *Eth0* e *Wifi* desativados, produziram resultados com maior número de bons ajustes. O fato indica que, quando ativos, os recursos de *Eth0* e *Wifi* podem exercer interferência sobre a medição dos dados em uma arquitetura moderna, mesmo que não estejam sendo requisitados pelo *benchmark* em execução. Este fato, entretanto, não foi observado para todos os *benchmarks* testados.

Sobre o percentual final de Amostras Regulares (Tabelas 4.3 e 4.5) e Extras (Tabelas 4.6 e 4.7) com boa qualidade de ajuste EVT, considerando a ocorrência única de *Fibcall*, presente em dois grupos, pode-se destacar:

### Amostras Regulares por cenário

- Os percentuais finais de amostras regulares com bom ajuste EVT foram:
  - 6% para o cenário F01
  - 9% para o cenário F02
  - 3% para o cenário F03
  - 10% para o cenário F04

**Tabela 4.3** Amostras Regulares - Cenários que ambientaram amostragem com bom ajuste EVT e apresentação de OMin Ciclos e OMax Ciclos, classificação por *benchmark* e cenário. Uma amostra foi considerada com bom ajuste quando ao menos um dos seus modelos EVT (GEV ou GPD, via MLE ou LM) apresentou resultado visual adequado no QQ e inferência pWCET coerente

Grupo	Bench.	Ciclos		Cenário							
		OMin	OMax	F01	F02	F03	F04	F05	F06	F07	F08
01	<i>Insertion S.</i>	8753321	9269574					X			X
	<i>Merge S.</i>	813876	942457				X	X	X	X	X
	<i>Quick S.</i>	391842	471038	X			X				
	<i>Bubble S.</i>	27945691	29132891					X			X
02	<i>Fibcall</i>	592772	724631		X	X	X	X		X	X
	<i>Sqrt</i>	1164	10379								
	<i>Fft1</i>	295295	354400		X				X	X	
03	<i>Edn</i>	193942	234651								
	<i>Cnt</i>	302266	382352	X	X	X	X	X	X	X	X
	<i>Matmult</i>	540283	602303								
04	<i>B. Search</i>	555	9610	X	X		X		X		X
	<i>Fibcall</i>	592772	724631		X	X	X	X		X	X

**Tabela 4.4** Amostras Regulares - Apresentação de CVs Ciclos e CVs Ins e percentual de amostras com bom ajuste EVT, classificação por *benchmark*. Uma amostra foi considerada com bom ajuste quando ao menos um dos seus modelos EVT (GEV ou GPD, via MLE ou LM) apresentou resultado visual adequado no QQ e inferência pWCET coerente

Grupo	Benchmark	CV				Bom ajuste EVT
		Ciclos		Ins		
		Min	Max	Min	Max	
01	<i>Insertion S.</i>	0,01%	0,19%	0,00%	0,00%	21,25%
	<i>Merge S.</i>	0,11%	0,40%	0,00%	0,00%	32,50%
	<i>Quick S.</i>	0,11%	0,49%	0,01%	0,01%	5,00%
	<i>Bubble S.</i>	0,00%	0,15%	0,00%	0,00%	12,50%
02	<i>Fibcall</i>	0,09%	0,69%	0,00%	0,00%	36,25%
	<i>Sqrt</i>	23,39%	26,62%	0,16%	0,19%	0,00%
	<i>Fft1</i>	0,09%	0,36%	0,01%	0,01%	8,75%
03	<i>Edn</i>	0,50%	0,58%	0,00%	0,00%	0,00%
	<i>Cnt</i>	0,86%	0,98%	0,00%	0,00%	37,50%
	<i>Matmult</i>	0,18%	0,32%	0,00%	0,00%	0,00%
04	<i>B. Search</i>	35,92%	40,01%	0,09%	0,13%	17,50%
	<i>Fibcall</i>	0,09%	0,69%	0,00%	0,00%	36,35%

- 40% para o cenário F05
- 11% para o cenário F06
- 5% para o cenário F07
- 40% para o cenário F08
- Média final de bons ajustes: 16%

### **Amostras Regulares por grupo**

- Os percentuais finais de amostras regulares com bom ajuste EVT foram:
  - 18% para o Grupo 01
  - 15% para o Grupo 02
  - 13% para o Grupo 03
  - 27% para o Grupo 04
  - Média final de bons ajustes: 18.25%
- Considerando apenas o cenário F05, os percentuais finais de amostras regulares com bom ajuste EVT foram:
  - 60% para o Grupo 01
  - 33% para o Grupo 02
  - 33% para o Grupo 03
  - 50% para o Grupo 04
  - Média final de bons ajustes: 44%
- Considerando apenas o cenário F08, os percentuais finais de amostras regulares com bom ajuste EVT foram:
  - 58% para o Grupo 01
  - 30% para o Grupo 02
  - 33% para o Grupo 03
  - 55% para o Grupo 04
  - Média final de bons ajustes: 44%

### **Amostras Extras com 100 mil observações**

- Foram coletadas Amostras Extras para dois ou três cenários por *benchmark*. A escolha destes cenários foi realizada com base nos resultados obtidos nas Amostras Regulares, o que produziu diferentes quantidades de amostras coletadas por cenário. Assim, os percentuais finais de amostras extras com bom ajuste EVT estão descritos

**Tabela 4.5** Amostras Regulares - Percentual de amostras com bom ajuste EVT por cenário, *benchmark* e método, expresso em %, onde T1 representa bom ajuste GEV e T2 bom ajuste GPD. Uma amostra foi considerada com bom ajuste quando ao menos um dos seus modelos (via MLE ou LM) apresentou resultado visual adequado no QQ e inferência pWCET coerente

Grupo	<i>Benchmark</i>	F01		F02		F03		F04		F05		F06		F07		F08	
		T1	T2	T1	T2	T1	T2	T1	T2	T1	T2	T1	T2	T1	T2	T1	T2
01	<i>Insert S.</i>	0	0	0	0	0	0	0	0	100	60	0	0	0	0	100	80
	<i>Merge S.</i>	0	0	0	0	0	0	20	20	100	100	20	20	20	20	100	100
	<i>Quick S.</i>	20	20	0	0	0	0	20	20	0	0	0	0	0	0	0	0
	<i>Bubble S.</i>	0	0	0	0	0	0	0	0	80	40	0	0	0	0	40	40
Bom ajuste		5	5	0	0	0	0	10	10	70	50	5	5	5	5	60	55
02	<i>Fibcall</i>	0	0	20	20	20	20	40	40	100	100	0	0	20	20	100	80
	<i>Sqrt</i>	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	<i>Fft1</i>	0	0	20	20	0	0	0	0	0	0	40	40	0	20	0	0
Bom ajuste		0	0	13	13	7	7	13	13	33	33	13	13	7	13	33	27
03	<i>Edn</i>	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	<i>Cnt</i>	40	20	20	20	0	20	0	20	100	100	20	20	0	20	100	100
	<i>Matmult</i>	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Bom ajuste		13	7	7	7	0	7	0	7	33	33	7	7	0	7	33	33
04	<i>B. Search</i>	20	20	40	40	0	0	20	20	0	0	40	40	0	0	20	20
	<i>Fibcall</i>	0	0	20	20	20	20	40	40	100	100	0	0	20	20	100	80
Bom ajuste		10	10	30	30	10	10	30	30	50	50	20	20	10	10	60	50
Ajuste Geral		7	5	9	9	2	4	9	11	44	36	11	11	4	7	42	38

por cenário, e de forma proporcional ao número de *benchmarks* que testaram aquele cenário.

Os percentuais de amostras extras com 100 mil observações com bom ajuste EVT foram:

- 5% para o cenário F01, em um total de 8 *benchmarks* testados
- 0% para o cenário F02, em um total de 2 *benchmarks* testados
- 0% para o cenário F03, em um total de 1 *benchmarks* testados
- cenário F04 não testado
- 38% para o cenário F05, em um total de 8 *benchmarks* testados
- 0% para o cenário F06, em um total de 2 *benchmarks* testados
- cenário F07 não testado
- 24% para o cenário F08, em um total de 5 *benchmarks* testados

#### **Amostras Extras com 500 mil observações**

- Foi utilizado o mesmo critério de análise empregado no item anterior, para amostras extras com 100 mil observações.

Os percentuais de amostras extras com 500 mil observações com bom ajuste EVT foram:

- 8% para o cenário F01, em um total de 8 *benchmarks* testados
- 0% para o cenário F02, em um total de 2 *benchmarks* testados
- 0% para o cenário F03, em um total de 1 *benchmarks* testados
- cenário F04 não testado
- 21% para o cenário F05, em um total de 8 *benchmarks* testados
- 0% para o cenário F06, em um total de 2 *benchmarks* testados
- cenário F07 não testado
- 30% para o cenário F08, em um total de 5 *benchmarks* testados

Por fim, pode-se afirmar que, como um todo, o experimento trouxe resultados pouco satisfatórios considerando o ambiente, *benchmarks* e cenários testados.

A média de Amostras Regulares com boa qualidade de ajuste ficou em 16%. Dos resultados obtidos, os cenários ambientados com *Eth0* e *Wifi* desativados (F05 e F08) foi onde se percebeu um maior número de bons ajustes (cerca de 40%), entretanto, estes representam apenas uma parcela de 25% do experimento realizado nas Amostras Regulares. Os testes com as Amostras Extras também não trouxeram um número significativo de amostras que levaram a um bom ajuste.

Diante do exposto, os resultados obtidos neste trabalho podem indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmarks* avaliados, pois nem sempre foi possível obter modelos com boa qualidade de ajuste.

**Tabela 4.6** Amostras Extras com 100 mil observações - Percentual de amostras com bom ajuste EVT por cenário, *benchmark* e método, expresso em %, onde T1 representa bom ajuste GEV e T2 bom ajuste GPD. Uma amostra foi considerada com bom ajuste quando ao menos um dos seus modelos (via MLE ou LM) apresentou resultado visual adequado no QQ e inferência pWCET coerente

Grupo	<i>Benchmark</i>	F01		F02		F03		F04		F05		F06		F07		F08	
		T1	T2	T1	T2	T1	T2	T1	T2	T1	T2	T1	T2	T1	T2	T1	T2
01	<i>Insertion Sort</i>	0	0	-	-	-	-	-	-	0	40	-	-	-	-	-	-
	<i>Merge Sort</i>	0	0	0	0	-	-	-	-	80	20	-	-	-	-	-	-
	<i>Quick Sort</i>	0	0	-	-	-	-	-	-	40	80	-	-	-	-	20	40
	<i>Bubble Sort</i>	0	0	-	-	-	-	-	-	0	0	-	-	-	-	-	-
02	<i>Fibcall</i>	0	0	-	-	-	-	-	-	60	60	0	0	-	-	-	-
	<i>Sqrt</i>	0	0	-	-	-	-	-	-	-	-	-	-	-	-	60	60
	<i>Fft1</i>	0	0	-	-	-	-	-	-	20	20	0	0	-	-	-	-
	<i>Edn</i>	-	-	0	0	-	-	-	-	-	-	-	-	-	-	20	20
03	<i>Cnt</i>	-	-	-	-	0	0	-	-	80	20	-	-	-	-	-	-
	<i>Matmult</i>	-	-	-	-	-	-	-	-	40	40	-	-	-	-	0	0
	<i>Binary Search</i>	40	40	-	-	-	-	-	-	-	-	-	-	-	-	0	20
04	<i>Fibcall</i>	0	0	-	-	-	-	-	-	60	60	0	0	-	-	-	-

**Tabela 4.7** Amostras Extras com 500 mil observações - Percentual de amostras com bom ajuste EVT por cenário, *benchmark* e método, expresso em %, onde T1 representa bom ajuste GEV e T2 bom ajuste GPD. Uma amostra foi considerada com boa qualidade de ajuste quando ao menos um dos seus modelos EVT (via MLE ou LM) apresentou resultado visual adequado no QQ e inferência pWCET coerente

Grupo	Benchmark	F01		F02		F03		F04		F05		F06		F07		F08	
		T1	T2	T1	T2	T1	T2	T1	T2	T1	T2	T1	T2	T1	T2	T1	T2
01	<i>Insertion Sort</i>	0	0	-	-	-	-	-	-	0	0	-	-	-	-	-	-
	<i>Merge Sort</i>	0	0	0	0	-	-	-	-	0	0	-	-	-	-	-	-
	<i>Quick Sort</i>	0	0	-	-	-	-	-	-	60	60	-	-	-	-	0	0
	<i>Bubble Sort</i>	0	0	-	-	-	-	-	-	0	0	-	-	-	-	-	-
02	<i>Fibcall</i>	0	0	-	-	-	-	-	-	0	0	0	0	-	-	-	-
	<i>Sqrt</i>	40	40	-	-	-	-	-	-	-	-	-	-	-	-	100	100
	<i>Fft1</i>	0	0	-	-	-	-	-	-	40	40	0	0	-	-	-	-
03	<i>Edn</i>	-	-	0	0	-	-	-	-	-	-	-	-	-	-	20	40
	<i>Matmult</i>	-	-	-	-	-	-	-	-	0	0	-	-	-	-	0	0
04	<i>Binary Search</i>	20	20	-	-	-	-	-	-	-	-	-	-	-	-	20	20
	<i>Fibcall</i>	0	0	-	-	-	-	-	-	0	0	0	0	-	-	-	-



# 5

## CONCLUSÃO

EVT fornece um conjunto de técnicas que vem sendo empregadas por diferentes autores para estimativa de WCET por meio da MBPTA. Apesar dos resultados positivos relatados, observa-se que na literatura há poucas demonstrações do processo prático completo de aplicação da EVT, abrangendo, desde o ajuste dos modelos a partir dos dados amostrais da população, até a conclusão da verificação da qualidade do ajuste, com apresentação das taxas de descarte de amostras inválidas.

Observa-se, ainda, que muitos estudos geralmente isolam excessivamente o cenário onde os dados são produzidos, com intuito de simular um ambiente RT. Este fato pode mascarar os impactos que seriam provocados em um ambiente moderno real, que afetariam, de forma positiva ou negativa, por exemplo, questões de dependência e representatividade, o que repercute diretamente nos resultados obtidos da aplicação EVT e na qualidade final do ajuste e estimativa pWCET.

O presente trabalho buscou preencher tais lacunas e apresentar de forma clara as etapas de aplicação EVT em um ambiente moderno real RPi, com intuito de expor os desafios e problemas encontrados durante este processo. Os resultados obtidos apontam que EVT é eficaz e que pode ser usada para inferência de pWCET via MBPTA, mas que apresenta problemas que não podem ser desconsiderados, pois pode culminar na produção de modelos inadequados e/ou estimativas incoerentes.

O experimento consistiu em executar 11 *benchmarks* sob diferentes fontes de imprevisibilidade e coletar amostras via medições para, posteriormente, aplicar EVT e realizar a inferência de pWCETs. Os resultados foram avaliados individualmente, por agrupamentos de acordo com as características de cada programa e de forma global. Os testes compreenderam medir os tempos de execução (*Ciclos*) e o número de *retired instructions (Ins)* por cada programa, sob oito cenários de testes criados a partir da variação dos recursos de *Eht0*, *Wifi* e *Core*.

As amostras coletadas (Amostras Regulares) tiveram 10 mil observações e, a partir destas, novas amostras (Amostras Extras) com 100 mil e 500 mil observações foram coletadas para dois ou três cenários. Ao todo foram reunidas 440 Amostras Regulares e 250 Amostras Extras; totalizando de 79.400.000 observações. Esses dados amostrais

foram avaliados para melhor compreensão de OMin Ciclos e OMax Ciclos, CVs, PDFs, e, aos mesmos, aplicou-se a técnica EVT. Diferentes pontos foram observados.

Notou-se, inicialmente, que a natureza da distribuição dos dados pode ser um ponto crucial para que a aplicação EVT seja bem sucedida. O tamanho das amostras também se apresentou como um ponto importante para garantir melhores ajustes. Entretanto, não foi possível identificar um tamanho único, que aplicado a todas as amostras trouxesse bons resultados. Para alguns *benchmarks*, amostras maiores possibilitaram uma quantidade maior de bons ajustes, para outros, amostras menores trouxeram mais bons ajustes, ainda, houve situações sem alterações no número de bons ajustes ao variar os tamanhos entre 10 mil, 100 mil ou 500 mil observações.

A análise dos resultados também apontou indícios relacionados aos impactos dos recursos oscilados nos cenários de testes. Observou-se que os recursos de *Eth0* e *Wifi*, quando ativos, provocaram impactos em algumas distribuições dos dados, tornando-as menos, ou não, ajustáveis à EVT e, conseqüentemente, sem a possibilidade de inferência de pWCETs coerentes. Assim, as medições ambientadas com estes recursos desativados foram as que apresentaram maior quantidade de amostras que levaram a um bom ajuste. Este fato, entretanto, não pode ser considerado como decisivo, pois houve situações onde os recursos estavam desligados e não foi possível obter bom ajuste, e, casos com bom ajuste EVT mesmo com os recursos ligados durante as medições. Não foi possível observar variações nos dados medidos provocados por impactos relacionados ao recurso *Core*.

Outro ponto observado foi uma alta incidência de bons ajustes EVT nos casos onde o máximo de Ciclos da amostra esteve mais próximo do seu mínimo, ao comparar OMin Ciclos e OMax Ciclos das amostras (regulares ou extras) para um mesmo *benchmark*. Não existe relação entre a duração do tempo de execução (v.a. Ciclos) e a possibilidade ou não de obter bom ajuste EVT. Este fato, contudo, também aponta para a suposição de que as interferências do ambiente podem gerar maior oscilação em Ciclos e podem tornar as distribuições menos estáveis, o que pode representar condições mais difíceis para produzir modelos EVT com boa qualidade de ajuste.

Durante o experimento, buscou-se ainda utilizar dados que atendessem aos critérios *i.i.d.*, condição pilar para a aplicação EVT. Verificou-se, entretanto, que atender a estes critérios não é suficiente para garantir que as amostras tenham boa qualidade de ajuste.

Por fim, ao analisar a quantidade total de bons ajustes EVT nas Amostras Regulares e Extras, observou-se que os percentuais finais foram muito baixos. Os experimentos realizados com os cenários com *Eth0* e *Wifi* desativados apresentaram melhores resultados, mas estes representam apenas uma pequena parcela diante de todos os testes realizados.

Desta forma, e diante do apresentado ao longo do trabalho, conclui-se que EVT é eficaz. Contudo, ela pode apresentar problemas para inferência de pWCET em plataformas modernas, pois nem sempre é possível encontrar um modelo com bom ajuste EVT para um determinado conjunto *benchmark*-plataforma, ainda que os dados medidos sejam representativos para a população em estudo.

Como possíveis desdobramentos deste trabalho sugere-se os pontos abaixo, que envolvem metodologias para amostragem, inferência de WCET/pWCET e realização de novos experimentos. Em seguida pode-se comparar, aos resultados já obtidos, os percentuais

de bons ajustes e de taxas de descartes, e coerência de valores estimados.

- a) Uma maior investigação sobre amostragem sob impactos dos recursos de *Eth0* e *Wifi* em arquiteturas modernas, considerando casos onde estes recursos estejam ativos ou inativos, e com ou sem atividade simultânea à medição. Por exemplo, medir os tempos de execução enquanto arquivos são transferidos através da rede cabeada, ou durante navegação em ambiente web. Aplicar EVT e comparar resultados.
- b) Realização de experimentos com *benchmarks* tendo múltiplos caminhos de execução (*multi-path*) e/ou com entradas definidas a partir de uma atividade real, ao invés da utilização de dados sintéticos. Por exemplo, usar medição de tempos de execução produzidos durante o voo de drones e robôs aéreos. Aplicar EVT e comparar resultados.
- c) Inferência de pWCET através de técnicas estatísticas que podem ser aplicadas a qualquer distribuição, como é o caso da desigualdade de Chebyshev (BARANOSKI; ROKNE; XU, 2001). Através deste método, pode-se obter uma proporção de valores de uma distribuição que ficam entre a média e até  $k$  desvios padrões distante da média. Assim, é possível inferir que a probabilidade de um tempo de execução ser excedido. Comparar resultados.
- d) Experimentos para inferência de WCET e pWCET a partir de técnicas de Inteligência Artificial (*Artificial Intelligence*), a exemplo de Aprendizado de Máquina por Reforço (*Reinforcement Learning in Machine Learning*) (SUTTON, 1992), através da qual a máquina é treinada para tentar aprender qual a melhor ação a ser tomada, dependendo do contexto sob o qual está inserida. Por exemplo, criação de modelos para identificação e gestão de descarte de amostras inutilizáveis, detecção de tamanhos adequados de amostra, identificação de tamanhos de blocos e *thresholds* que produzam modelos EVT com maior quantidade de bons ajustes e análise para identificação de melhores modelos ajustados. Comparar resultados.



## REFERÊNCIAS BIBLIOGRÁFICAS

- ABELLA, J. et al. 68. Extreme Value Theory in Computer Sciences: The Case of Embedded Safety-critical Systems. In: *Current Topics on Risk Analysis: ICRA6 and RISK 2015 Conference*. [S.l.: s.n.], 2015. p. 579.
- ABELLA, J. et al. On the comparison of deterministic and probabilistic WCET estimation techniques. *Proceedings - Euromicro Conference on Real-Time Systems*, p. 266–275, 2014. ISSN 10683070.
- ABELLA, J. et al. Measurement-Based Worst-Case Execution Time Estimation Using the Coefficient of Variation. *ACM Transactions on Design Automation of Electronic Systems*, v. 22, n. 4, 2017. ISSN 15577309.
- ABELLA, J. et al. Heart of gold: Making the improbable happen to increase confidence in MBPTA. In: IEEE. *2014 26th Euromicro Conference on Real-Time Systems*. [S.l.], 2014. p. 255–265.
- ANDERSON Darling test. 2021. <<https://search.r-project.org/CRAN/refmans/sjstats/html/mwu.html>>. Acesso em Março, 2023.
- ANDRADE, T. N. C. et al. On the Selection of Relevant Hardware Events for Explaining Execution Time Behavior. In: IEEE. *2021 XI Brazilian Symposium on Computing Systems Engineering (SBESC)*. [S.l.], 2021. p. 1–8.
- ARCARO, L. F.; SILVA, K. P.; OLIVEIRA, R. S. D. On the reliability and tightness of GP and Exponential models for probabilistic WCET estimation. *ACM Transactions on Design Automation of Electronic Systems (TODAES)*, ACM New York, NY, USA, v. 23, n. 3, p. 1–27, 2018.
- AUTOCORRELATION tests. 2016. <<https://cran.r-project.org/web/packages/itsadug/vignettes/acf.html>>. Acesso em Março, 2023.
- BARANOSKI, G. V.; ROKNE, J. G.; XU, G. Applying the exponential chebyshev inequality to the nondeterministic computation of form factors. *Journal of Quantitative Spectroscopy and Radiative Transfer*, Elsevier, v. 69, n. 4, p. 447–467, 2001.
- BATISTA, N. A. M. et al. Momentos-1 na estimação dos parâmetros da distribuição generalizada de valores extremos. Universidade Federal de Alfenas, 2020.
- BDSL test. s.d. <<https://search.r-project.org/CRAN/refmans/fNonlinear/html/NonLinTests.html>>. Acesso em Março, 2023.

- BEAGLE Bone. s.d. <<https://beagleboard.org/bone>>. Acesso em Março, 2023.
- BEREZOVSKIY, K. et al. WCET measurement-based and extreme value theory characterisation of CUDA kernels. In: *Proceedings of the 22nd International Conference on Real-Time Networks and Systems*. [S.l.: s.n.], 2014. p. 279–288.
- BERNAT, G.; BURNS, A.; NEWBY, M. Probabilistic timing analysis: An approach using copulas. *Journal of Embedded Computing*, IOS Press, v. 1, n. 2, p. 179–194, 2005.
- BERNAT, G.; COLIN, A.; PETERS, S. M. WCET analysis of probabilistic hard real-time systems. In: IEEE. *23rd IEEE Real-Time Systems Symposium, 2002. RTSS 2002*. [S.l.], 2002. p. 279–288.
- BURNS, A.; EDGAR, S. Predicting computation time for advanced processor architectures. *Proceedings - Euromicro Conference on Real-Time Systems*, p. 89–96, 2000. ISSN 10683070.
- CAZORLA, F. J. et al. Probabilistic Worst-Case Timing Analysis: Taxonomy and Comprehensive Survey. *ACM Computing Surveys (CSUR)*, ACM New York, NY, USA, v. 52, n. 1, p. 1–35, 2019.
- CAZORLA, F. J. et al. Upper-bounding Program Execution time with Extreme Value Theory. *OpenAccess Series in Informatics*, v. 30, n. Wcet, p. 64–76, 2013. ISSN 21906807.
- COLES, S. *An Introduction to Statistical Modeling of Extreme Values*. London: Springer, 2001. 205 p. ISBN 9781849968744.
- COSTA, J. J. S. et al. Emprego de Medição na Estimação do Tempo de Execução no Pior Caso para Sistemas de Tempo Real. 2021.
- CUCU-GROSJEAN, L. et al. Measurement-Based Probabilistic Timing Analysis for Multi-path Programs. *Proceedings - Euromicro Conference on Real-Time Systems*, p. 91–101, 2012. ISSN 10683070.
- DAVIS, R.; CUCU-GROSJEAN, L. A Survey of Probabilistic Timing Analysis Techniques for Real-Time Systems. *LITES: Leibniz Transactions on Embedded Systems*, v. 6, n. 1, p. 1–53, 2019. ISSN 2199-2002.
- DAVIS, R. I.; BURNS, A.; GRIFFIN, D. On the Meaning of pWCET Distributions and their use in Schedulability Analysis. In: *In Proceedings Real-Time Scheduling Open Problems Seminar at ECRTS*. [S.l.: s.n.], 2017.
- DIETRICH, D.; HAAN, L. D.; HUSLER, J. Testing Extreme Value conditions. *Extremes*, Springer Nature BV, v. 5, n. 1, p. 71, 2002.
- EDGAR, S.; BURNS, A. Statistical Analysis of WCET for Scheduling. In: IEEE. *Proceedings 22nd IEEE Real-Time Systems Symposium (RTSS 2001)(Cat. No. 01PR1420)*. [S.l.], 2001. p. 215–224.

- EFRON, B.; TIBSHIRANI, R. J. *An introduction to the Bootstrap*. [S.l.]: CRC press, 1994.
- EXTREMES. s.d. <<https://cran.r-project.org/web/packages/extRemes/extRemes.pdf>>. Acesso em Março, 2021.
- FRANCIS-MEZGER, P.; WEAVER, V. M. A Raspberry Pi Operating System for Exploring Advanced Memory System Concepts. In: *Proceedings of the International Symposium on Memory Systems*. [S.l.: s.n.], 2018. p. 354–364.
- GARÇÃO, T. C. S. *Avaliação empírica do risco de mercado: estimação do Value-at-risk pela Teoria dos Valores Extremos*. Tese (Doutorado) — Universidade de Lisboa, 2017.
- GARRIDO, M.; DIEBOLT, J. The ET Test, a Goodness-of-fit Test for the Distribution Tail. *Methodology, Practice and Inference, second international conference on mathematical methods in reliability*, n. September 2007, p. 427–430, 2007.
- GIL, S. J. et al. Open Challenges for Probabilistic Measurement-Based Worst-Case Execution Time. *IEEE Embedded Systems Letters*, IEEE, v. 9, n. 3, p. 69–72, 2017.
- GILLELAND, E.; KATZ, R. W. extRemes 2.0: An Extreme Value Analysis Package in R. *Journal of Statistical Software*, v. 72, n. 8, 2016. ISSN 15487660.
- GOMES, M. I. *Desafios em Estatística de Extremos*. 2019.
- GREENWOOD, P. E.; NIKULIN, M. S. *A guide to chi-squared testing*. [S.l.]: John Wiley & Sons, 1996.
- GRIFFIN, D.; BURNS, A. Realism in Statistical Analysis of Worst Case Execution Times. *OpenAccess Series in Informatics*, v. 15, n. Wcet, p. 44–53, 2010. ISSN 21906807.
- GUET, F.; SANTINELLI, L.; MORIO, J. On the Representativity of Execution Time Measurements: Studying Dependence and Multi-Mode Tasks. In: SCHLOSS DAGSTUHL-LEIBNIZ-ZENTRUM FUER INFORMATIK. *17th International Workshop on Worst-Case Execution Time Analysis (WCET 2017)*. [S.l.], 2017.
- GUSTAFSSON, J. et al. The Mälardalen WCET Benchmarks: Past, Present and Future. In: SCHLOSS DAGSTUHL-LEIBNIZ-ZENTRUM FUER INFORMATIK. *10th International Workshop on Worst-Case Execution Time Analysis (WCET 2010)*. [S.l.], 2010.
- HANSEN, J.; HISSAM, S.; MORENO, G. A. Statistical-Based WCET Estimation and Validation. *OpenAccess Series in Informatics*, v. 10, p. 1–11, 2009. ISSN 21906807.
- HECKMANN, R. et al. The influence of processor architecture on the design and the results of WCET tools. *Proceedings of the IEEE*, IEEE, v. 91, n. 7, p. 1038–1054, 2003.

- HUANG, W. K. et al. Estimating changes in temperature extremes from millennial-scale climate simulations using generalized extreme value (GEV) distributions. *Advances in Statistical Climatology, Meteorology and Oceanography*, Copernicus GmbH, v. 2, n. 1, p. 79–103, 2016.
- HURST Exponent test. s.d. <<https://search.r-project.org/CRAN/refmans/pracma/html/hurst.html>>. Acesso em Março, 2023.
- HÜSLER, J.; LI, D. How to Use the Package TestEVC1d. R. *Department of Statistics, School of Management, Fudan University*, 3pp, 2006.
- KALRAY MPPA Architectures. s.d. <<https://www.kalrayinc.com/products/mppa-technology/>>. Acesso em Março, 2023.
- KOLMOGOROV-SMIRNOV test. s.d. <<https://search.r-project.org/CRAN/refmans/dgof/html/ks.test.html>>. Acesso em Março, 2023.
- KPSS Test for Stationarity. 2016. <<https://search.r-project.org/CRAN/refmans/tseries/html/kpss.test.html>>. Acesso em Março, 2023.
- LEADBETTER, M. R. On a Basis for ‘Peaks over Threshold’ Modeling. *Statistics & Probability Letters*, Elsevier, v. 12, n. 4, p. 357–362, 1991.
- LEADBETTER, M. R.; LINDGREN, G.; ROOTZÉN, H. Conditions for the convergence in distribution of maxima of stationary normal processes. *Stochastic Processes and their Applications*, Elsevier, v. 8, n. 2, p. 131–139, 1978.
- LIMA, G.; DIAS, D.; BARROS, E. Extreme Value Theory for Estimating Task Execution Time Bounds: A Careful Look. *Proceedings - Euromicro Conference on Real-Time Systems*, v. 2016-August, p. 200–211, 2016. ISSN 10683070.
- LINUX Perf. s.d. <<https://perf.wiki.kernel.org/index.php/Tutorial>>. Acesso em Março, 2021.
- LJUNG-BOX test. s.d. <<https://search.r-project.org/CRAN/refmans/tswge/html/ljung.wge.html>>. Acesso em Março, 2023.
- LU, Y. et al. A New Way about Using Statistical Analysis of Worst-Case Execution Times. *ACM SIGBED Review*, v. 8, n. 3, p. 11–14, 2011. ISSN 1551-3688.
- MADSEN, H. EVA—extreme value analysis—technical reference and documentation. *DHI Water and Environment. Denmark*, 2005.
- MANN, H. B.; WHITNEY, D. R. On a test of whether one of two random variables is stochastically larger than the other. *The annals of mathematical statistics*, JSTOR, p. 50–60, 1947.
- MANN Kendall test. s.d. <<https://search.r-project.org/CRAN/refmans/trend/html/mk.test.html>>. Acesso em Março, 2023.



- MANN Whitney test. s.d. <<https://search.r-project.org/CRAN/refmans/sjstats/html/mwu.html>>. Acesso em Março, 2023.
- MATTHEWS, R. *Extreme Value Theory*. BBC - The Big Idea: The Science Of Sleep, 2012. Disponível em: <[https://ethz.ch/content/dam/ethz/special-interest/math/risklab-dam/documents/BBC\\_2012.pdf](https://ethz.ch/content/dam/ethz/special-interest/math/risklab-dam/documents/BBC_2012.pdf)>.
- MAXIM, C. et al. HAL Id: hal-00766063 Estimation of Probabilistic Minimum Inter-arrival Times Using Extreme Value Theory. 2013.
- MAXIM, D. et al. Study of the Reliability of Statistical Timing Analysis for Real-time Systems. In: *Proceedings of the 23rd International Conference on Real Time and Networks Systems*. [S.l.: s.n.], 2015. p. 55–64.
- MELANI, A.; NOULARD, E.; SANTINELLI, L. Learning from Probabilities: Dependencies within Real-time Systems. In: IEEE. *2013 IEEE 18th Conference on Emerging Technologies & Factory Automation (ETFA)*. [S.l.], 2013. p. 1–8.
- MILUTINOVIC, S. et al. On uses of Extreme Value Theory fit for industrial-quality WCET analysis. In: IEEE. *2017 12th IEEE International Symposium on Industrial Embedded Systems (SIES)*. [S.l.], 2017. p. 1–6.
- MOHALLEM, D. F. et al. Avaliação do coeficiente de variação como medida da precisão em experimentos com frangos de corte. *Arquivo Brasileiro de Medicina Veterinária e Zootecnia*, SciELO Brasil, v. 60, p. 449–453, 2008.
- NÉLIS, V. et al. Another look at the pWCET estimation problem. 2014.
- NELSEN, R. B. *An introduction to copulas*. [S.l.]: Springer science & business media, 2007.
- ÖZARI, Ç.; EREN, Ö.; SAYGIN, H. A New Methodology for the Block Maxima Approach in Selecting the Optimal Block Size. *Technical Gazette*, v. 26, n. 5, p. 1292–1296, 2019.
- PERF Event Open. s.d. <[https://man7.org/linux/man-pages/man2/perf\\_event\\_open.2.html](https://man7.org/linux/man-pages/man2/perf_event_open.2.html)>. Acesso em Março, 2021.
- R. s.d. <<https://cran.r-project.org/bin/macosx>>. Acesso em Março, 2021.
- RASPBERRY Pi. s.d. <<https://www.raspberrypi.org/>>. Acesso em Março, 2023.
- REGHENZANI, F.; MASSARI, G.; FORNACIARI, W. The Misconception of Exponential Tail Upper-Bounding in Probabilistic Real Time. *IEEE Embedded Systems Letters*, IEEE, v. 11, n. 3, p. 77–80, 2018.
- REGHENZANI, F.; MASSARI, G.; FORNACIARI, W. Probabilistic-WCET reliability: On the experimental validation of EVT hypotheses. *Microprocessors and Microsystems*, Elsevier, v. 77, p. 103135, 2020.

REGHENZANI, F.; SANTINELLI, L.; FORNACIARI, W. Dealing with uncertainty in pWCET estimations. *ACM Transactions on Embedded Computing Systems (TECS)*, ACM New York, NY, USA, v. 19, n. 5, p. 1–23, 2020.

SANDELL, D. Evaluating Static Worst Case Execution Time Analysis for a Commercial Real-Time Operating System. *MSc, Mälardalen University, Västerås, Sweden*, 2004.

SANTINELLI, L.; GUET, F.; MORIO, J. Revising Measurement-Based Probabilistic Timing Analysis. In: IEEE. *2017 IEEE real-time and embedded technology and applications symposium (RTAS)*. [S.l.], 2017. p. 199–208.

SANTINELLI, L.; GUO, Z. On the Criticality of Probabilistic Worst-Case Execution Time Models. In: SPRINGER. *International Symposium on Dependable Software Engineering: Theories, Tools, and Applications*. [S.l.], 2017. p. 59–74.

SANTINELLI, L. et al. On the Sustainability of the Extreme Value Theory for WCET Estimation. In: SCHLOSS DAGSTUHL-LEIBNIZ-ZENTRUM FUER INFORMATIK. *14th International Workshop on Worst-Case Execution Time Analysis*. [S.l.], 2014.

SILVA, D.; CAEIRO, F.; OLIVEIRA, M. Modelação estatística de valores extremos: probabilidades de excedência, quantis extremos, limite superior do suporte e níveis de retorno no lançamento do disco do atletismo. *Revista da Estatística da Universidade Federal de Ouro Preto*, v. 7, 2018.

SILVA, K. P.; ARCARO, L. F.; OLIVEIRA, R. S. D. On using GEV or Gumbel models when applying EVT for probabilistic WCET estimation. In: IEEE. *2017 IEEE Real-Time Systems Symposium (RTSS)*. [S.l.], 2017. p. 220–230.

SOUSA, W. B. d. Estimadores de máxima verossimilhança: casos que não satisfazem as condições de regularidade. 2018.

SPEARING, H. et al. Ranking, and other properties, of elite swimmers using extreme value theory. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, Wiley Online Library, v. 184, n. 1, p. 368–395, 2021.

SUTTON, R. S. Introduction: The challenge of reinforcement learning. *Reinforcement learning*, Springer, p. 1–3, 1992.

TRIOLA, M. F. et al. *Elementary statistics*. [S.l.]: Pearson/Addison-Wesley Reading, 2006.

TURNING Point test. s.d. <<https://search.r-project.org/CRAN/refmans/randtests/html/turning.point.test.html>>. Acesso em Março, 2023.


VILARDELL, S. et al. Using markov's inequality with power-of-k function for probabilistic wcet estimation. In: SCHLOSS DAGSTUHL-LEIBNIZ-ZENTRUM FÜR INFORMATIK. *34th Euromicro Conference on Real-Time Systems (ECRTS 2022)*. [S.l.], 2022.

VIOLA, M. L. L. *Teoria de Valores Extremos e Cópulas: Distribuição Valor Extremo e Cópulas Arquimedianas Generalizadas Trivariadas*. Tese (Dissertação de Mestrado) — Universidade Estadual de Campinas, 2006.

WALD-WOLFOWITZ Runs test. s.d. <<https://search.r-project.org/CRAN/refmans/randtests/html/runs.test.html>>. Acesso em Março, 2023.

WEAVER, V. M.; MCKEE, S. A. Can Hardware Performance Counters be Trusted? In: IEEE. *2008 IEEE International Symposium on Workload Characterization*. [S.l.], 2008. p. 141–150.





## **APRESENTAÇÃO DETALHADA POR *BENCHMARK***

## A.1 MODELO PARA OS RESULTADOS

Os resultados do experimento foram apresentados individualmente por *benchmark* e por grupo, com base no modelo abaixo:

- Descrição do *benchmark*, apresentação dos cenários escolhidos para coleta de amostras extras e percentuais totais de bons ajustes EVT.
- Análise das Amostras (Regulares ou Extras) com relação ao ajuste EVT

**Ajustes GEV/GPD:** listagem das amostras onde foi possível (e não foi possível) obter boa qualidade de ajuste EVT. Considera-se uma amostra com boa qualidade de ajuste caso tenha sido possível obter bom ajuste para ao menos um dos modelos, GPD ou GEV.

**Teste Dietrich:** comparação dos resultados entre as tentativas de ajuste EVT e o teste Dietrich.

O teste Dietrich pode apresentar resultados dentro, parcialmente dentro, ou fora do CI. Os resultados parcialmente dentro do CI foram considerados como com bons ajustes. Entretanto, não há garantias desse ajuste. Assim, foi considerado como critério para análise geral do conjunto de amostras: **Coerente**, caso todas as amostras com bom ajuste EVT apresentaram teste Dietrich dentro, ou parcialmente dentro, do CI; **Parcialmente coerente**, caso haja pelo menos uma amostra que não tenha tido bom ajuste EVT mas o teste Dietrich apresentou resultado dentro do CI; e **Incoerente**, caso todas as amostras não tenham tido bom ajuste EVT mas Dietrich apresentou os resultados dentro do CI.

- Análise dos dados amostrais seguindo os itens descritos na Seção 4.1.5: **Plotagem, Amplitude Ciclos, CV Ciclos, CV Ins.**
- Considerações
  - Análise de impactos nas medições provocados pela variação dos cenários.
  - Observação dos CVs Ciclos e o que estes possam revelar sobre as medições.
  - Observação dos CV Ins e o que estes possam revelar sobre as medições.
  - Observação dos padrões de histogramas e relação destes com as tentativas de ajuste EVT.
  - Análise de coerência entre as tentativas de ajuste EVT (GEV/GPD) e o teste Dietrich.
  - Análise de coerência das estimativas pWCET para a probabilidade de excedência  $10^{-5}$ .
  - Parecer sobre adequação da aplicação da EVT para inferência de pWCET para o *benchmark* em questão, com base nos percentuais finais de bom ajuste EVT.

## A.2 RESULTADOS

### A.2.1 Grupo 01

O Grupo 01 é composto por quatro *benchmarks* de ordenação caracterizados por realizar acesso à memória para operações de carga e gravação. São eles: *Bubble Sort*, *Merge Sort*, *Insertion Sort* e *Quick Sort*.

**A.2.1.1 *Bubble Sort*** é um algoritmo de ordenação que testa *loops*, realiza comparações de inteiros e manipula vetores (GUSTAFSSON et al., 2010). Como descrito nas Tabelas A.1(b) e A.1(d), os resultados para este experimento apresentaram:

- 85% de amostras regulares sem bom ajuste GEV e 90% sem bom ajuste GPD
- 100% de amostras extras F01 e F05, ambas 100 mil e 500 mil, sem bom ajuste GEV/GPD

Mais detalhes podem ser observados nos itens a seguir.

#### 1. Amostras Regulares

**Ajuste GEV/GPD** Não foi possível obter bom ajuste em todas as amostras dos cenários F01, F02, F03, F04, F06 e F07. Foi possível obter bom ajuste em algumas amostras dos cenários F05 e F08 (Tabela A.1(a)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.1(a)).

- Dados amostrais

**Padrão 01** Observado em uma amostra (Tabela A.1(a)), sendo que a mesma teve bom ajuste EVT.

**Padrão 02** Observado em quase todas as amostras (Tabela A.1(a)).

Os modelos que foram classificados como Padrão 02 podem ser observados na Figura A.1, juntamente com seus respectivos gráficos de dispersão. Foi possível obter bom ajuste em todos os casos deste padrão que apresentou uma aparência visual assimétrica positiva, como o destacado na Figura A.1(b). As demais amostras, com comportamentos nos modelos da Figura A.1(a), não tiveram bom ajuste GEV/GPD.

**Amplitude Ciclos**  $OMin = 27945691$  e  $OMax = 29132891$ , considerando todas as amostras regulares, com ou sem bom ajuste EVT. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.2(a)).

**CV Ciclos** Entre 0.00142% e 0.15169% (Figura A.2(b)).

**CV Ins** Entre 0.000019% e 0.000024%.

**Tabela A.1** *Bubble Sort* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	0	0	0	5
F02	0	5	0	0	0	5
F03	0	5	0	0	0	5
F04	0	5	0	0	0	5
F05	1	4	4	2	4	5
F06	0	5	0	0	0	5
F07	0	5	0	0	0	5
F08	0	5	2	2	4	5
Total	1	39	6	4	8	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)

Padrão		Ajuste	GEV	GPD	Dietrich
01	02	Bom	15%	10%	20%
2.50%	97,50%	Sem	85%	90%	80%


(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT			Testadas
	01	02	GEV	GPD	Dietrich	
F01_100mil	0	5	0	0	0	5
F01_500mil	0	5	0	0	0	5
F05_100mil	0	5	0	0	0	5
F05_500mil	0	5	0	0	0	5
Total	0	20	0	0	0	20


(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F01	0%	100%	0%	0%	0%
F01_100mil	0%	100%	0%	0%	0%
F01_500mil	0%	100%	0%	0%	0%
F05	80%	20%	80%	40%	80%
F05_100mil	0%	100%	0%	0%	0%
F05_500mil	0%	100%	0%	0%	0%



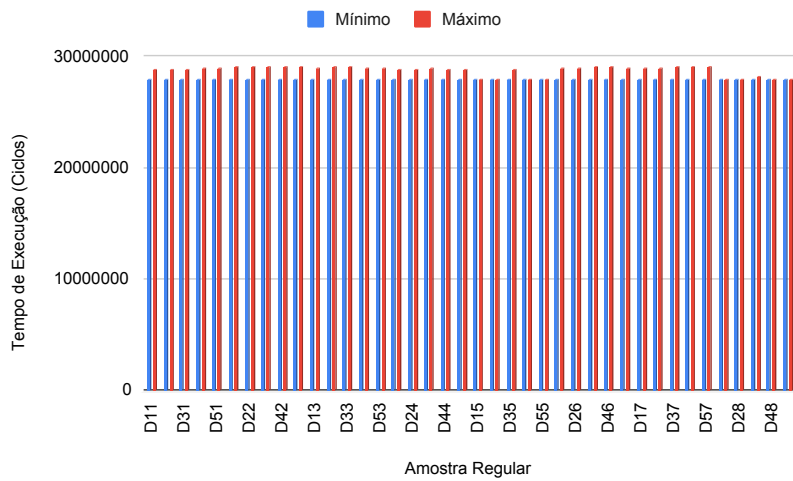


(a) Amostras que não tiveram bom ajuste EVT

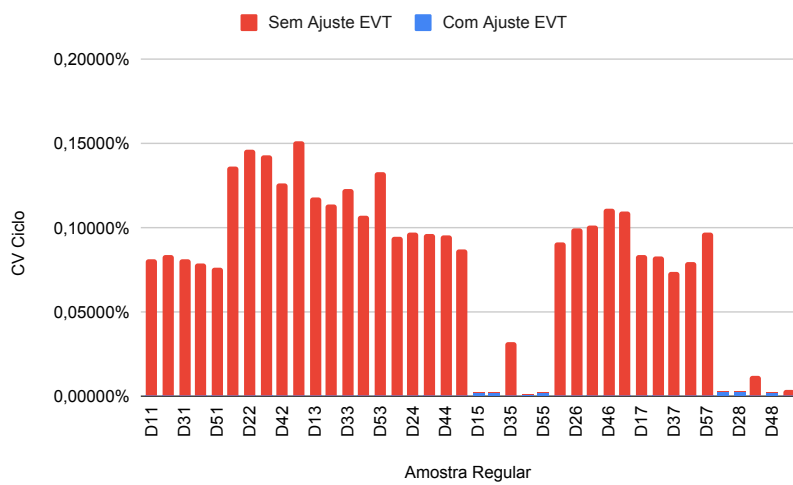


(b) Amostra que teve bom ajuste EVT

**Figura A.1** *Bubble Sort*, Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT




(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.2** *Bubble Sort*, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT



**Figura A.3** *Bubble Sort*, Amostras Extras - Modelo de histograma classificado como Padrão 02 e dispersão dos dados

## 2. Amostras Extras

Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F01 e F05, o primeiro sem bom ajuste EVT nas amostras regulares, e o segundo com bom ajuste em algumas amostras. A escolha dos cenários deu-se com intuito de checar se um aumento no tamanho da amostra poderia fornecer melhores resultados.

**Ajuste GEV/GPD** O aumento no tamanho das amostras não demonstrou impacto positivo para o experimento. Nenhuma das amostras extras teve bom ajuste EVT, incluindo o F05, onde havia sido observado bons ajustes em parte das amostras regulares (Tabela A.1(c)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.1(c)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.1(c)).

**Padrão 02** Observado em todas as amostras extras (Tabela A.1(c)), mas nenhuma com bom ajuste EVT. Foi observado um modelo diferente dos encontrados nas amostras regulares (Figura A.3).

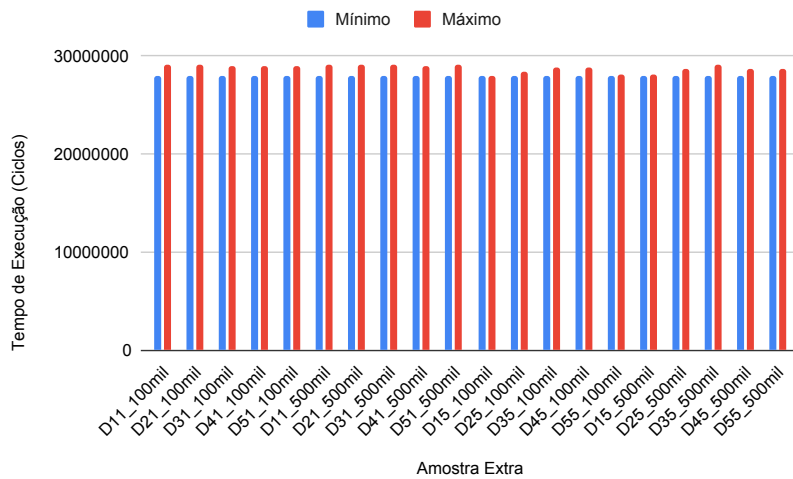
**Amplitude Ciclos**  $O_{Min} = 27945233$  e  $O_{Max} = 29173025$ , considerando todas as amostras extras, com ou sem bom ajuste. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.4(a)).

**CV Ciclos** Entre 0.0020% e 0.0924% (Figura A.4(b)).

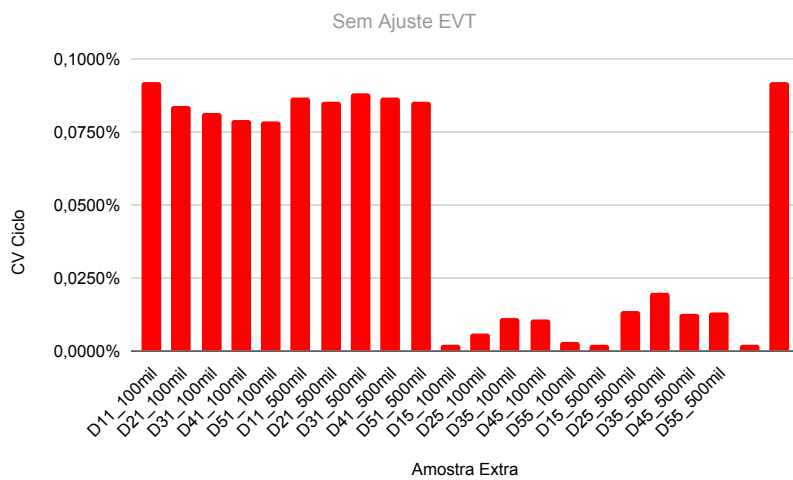
**CV Ins** Entre 0.000020% e 0.000023%.

## 3. Considerações sobre o experimento com o *Bubble Sort*

- Os cenários F05 e F08, únicos ambientados com *Eth0* e *Wifi* desativados simultaneamente, apresentaram boa qualidade de ajuste para maior parte das amostras regulares. O fato sinaliza que esses recursos podem ter provocado impacto nas demais amostras quando, ao menos um deles, esteve ativo. Esse



(a) Amplitude Ciclos




(b) CV Ciclos

**Figura A.4** *Bubble Sort*, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

aspecto, entretanto, não pode ser considerado como decisivo, pois algumas amostras destes cenários não tiveram bom ajuste EVT. A variação no *Core* parece não ter provocado impactos às medições.

- Aumentar o tamanho das amostras coletadas sob os cenários F01 e F05 não trouxe benefícios ao experimento. As amostras coletadas sob o primeiro cenário seguiram sem obter bom ajuste EVT, e as sob o segundo passaram a obter bom ajuste.
- As faixas de valores de *Ins* em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares como para as amostras extras, tendo estas bons ajustes EVT ou não. Como houve casos onde foi possível bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de *Ins* que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Dados com histograma no Padrão 01 puderam ter bom ajuste EVT, assim como os enquadrados no Padrão 02 com aparência visual assimétrica positiva. As demais distribuições não puderam ter bom ajuste.
- Amostras regulares com baixos CVs *Ciclos* tiveram bom ajuste EVT (Figuras A.2(b), mas, isso não se repetiu para as amostras extras A.4(b)). Não há relação entre o valor do tempo de execução (v.a. *Ciclos*) e o bom ajuste EVT. Contudo, tal fato pode demonstrar que amostras que sofreram um menor impacto do ambiente, e conseqüente menores *O<sub>Max</sub>*, tiveram suas distribuições mais estáveis e que isso evitou prejuízos na aplicação EVT. Apesar da ausência de bons ajustes nas amostras extras, as mesmas suspeitas podem ser aplicadas nas amostras analisadas, mas sob um aspecto um pouco diferente: amostras extras levam mais tempo para ser coletadas, o que as deixa mais susceptíveis aos impactos do ambiente.
- De maneira geral, os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes entre si.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Bubble Sort* trouxe resultados pouco satisfatórios. A média de bom ajuste GEV/GPD ficou em 12.50% nas amostras regulares e 0% nas amostras extras. Tal fato pode indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmark* em questão.

**A.2.1.2 Merge Sort** é um eficiente algoritmo de ordenação por divisão e conquista. O código executado contou com uma entrada fixa de tamanho 1.000. Como descrito nas



(a) Amostra que não teve bom ajuste EVT

(b) Amostra que teve bom ajuste EVT

**Figura A.5** *Merge Sort*, Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados

Tabelas A.2(b) e A.2(d), os resultados para este experimento apresentaram:

- 67.50% de amostras regulares sem bom ajuste GEV/GPD
- 100% de amostras extras F01, 100 mil e 500 mil, e F02, 100 mil e 500 mil, sem bom ajuste GEV/GPD
- 20% de amostras extras F05 100 mil sem bom ajuste GEV e 80% sem bom ajuste GPD
- 100% de amostras extras F05 500 mil sem bom ajuste GEV/GPD

Mais detalhes podem ser observados nos itens a seguir.

### 1. Amostras Regulares

**Ajuste GEV/GPD** Não foi possível obter bom ajuste em todas as amostras dos cenários F01, F02 e F03. Foi possível obter bom ajuste em apenas uma amostra para cada um dos cenários F04, F06 e F07. Foi possível obter bom ajuste em todas as amostras dos cenários F05 e F08 (Tabela A.2(a)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.2(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.2(a)).

**Padrão 02** Observado em todas as amostras (Tabela A.2(a)).

Os modelos que foram classificados como Padrão 02 podem ser observados na Figura A.5, juntamente com seus respectivos gráficos de dispersão. Foi possível obter bom ajuste em todos os casos deste padrão que apresentou uma aparência visual assimétrica positiva, como o destacado na Figura A.5(b). As demais amostras, com distribuição com comportamento no modelo da Figura A.5(a), não tiveram bom ajuste GEV/GPD.

**Tabela A.2** *Merge Sort* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	0	0	0	5
F02	0	5	0	0	0	5
F03	0	5	0	0	1	5
F04	0	5	1	1	1	5
F05	0	5	5	5	5	5
F06	0	5	1	1	1	5
F07	0	5	1	1	1	5
F08	0	5	5	5	5	5
Total	0	40	13	13	14	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)

Padrão		Ajuste	GEV	GPD	Dietrich
01	02				
		<b>Bom</b>	32,50%	32,50%	35,00%
0,00%	100,00%	<b>Sem</b>	67,50%	67,50%	65,00%

(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT			Total
	01	02	GEV	GPD	Dietrich	
F01_100mil	0	5	0	0	0	5
F01_500mil	0	5	0	0	0	5
F02_100mil	0	5	0	0	0	5
F02_500mil	0	5	0	0	0	5
F05_100mil	0	5	4	1	5	5
F05_500mil	0	5	0	0	2	5
Total	0	30	4	1	7	30

(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F01	0%	100%	0%	0%	0%
F01_100mil	0%	100%	0%	0%	0%
F01_500mil	0%	100%	0%	0%	0%
F02	0%	100%	0%	0%	0%
F02_100mil	0%	100%	0%	0%	0%
F02_500mil	0%	100%	0%	0%	0%
F05	0%	100%	100%	100%	100%
F05_100mil	0%	100%	80%	20%	100%
F05_500mil	0%	100%	0%	0%	40%

**Amplitude Ciclos**  $O_{Min} = 813876$  e  $O_{Max} = 942457$ , considerando todas as amostras regulares, com ou sem bom ajuste EVT. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.6(a)).

**CV Ciclos** Entre 0.10% e 0.40% (Figura A.6(b)).

**CV Ins** Entre 0.0005% e 0.001%.

## 2. Amostras Extras

Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F01, F02 e F05. A escolha dos cenários deu-se com intuito de checar se um aumento no tamanho da amostra poderia fornecer melhores resultados para F01 e F02, que apresentaram amostras regulares com bom ajuste, e averiguar qual seria o comportamento de F05, que apresentou uma totalidade de amostras regulares com bom ajuste.

**Ajuste GEV/GPD** O aumento no tamanho das amostras não alterou os resultados obtidos em F01 e F02, que seguiram sem bom ajuste GEV/GPD. O cenário F05, por sua vez, apresentou redução na quantidade de bons ajustes à medida que houve aumento no tamanho da amostra (Tabela A.2(c)).

**Teste Dietrich** Foi coerente com as tentativas de ajustes GEV/GPD (Tabela A.2(c)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.2(c)).

**Padrão 02** Observado em todas as amostras extras (Tabela A.2(c)). Foram encontrados modelos de histogramas diferentes dos observados nas amostras regulares. Os mesmos foram classificados como Padrão 02 (Figura A.7) e não puderam ser ajustados. Para as amostras com bom ajuste, os modelos observados seguiram o mesmo padrão presente nas amostras regulares (Figura A.5(b)).

**Amplitude Ciclos**  $O_{Min} = 813922$  e  $O_{Max} = 961297$ , considerando todas as amostras extras, com ou sem bom ajuste. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.8(a)).

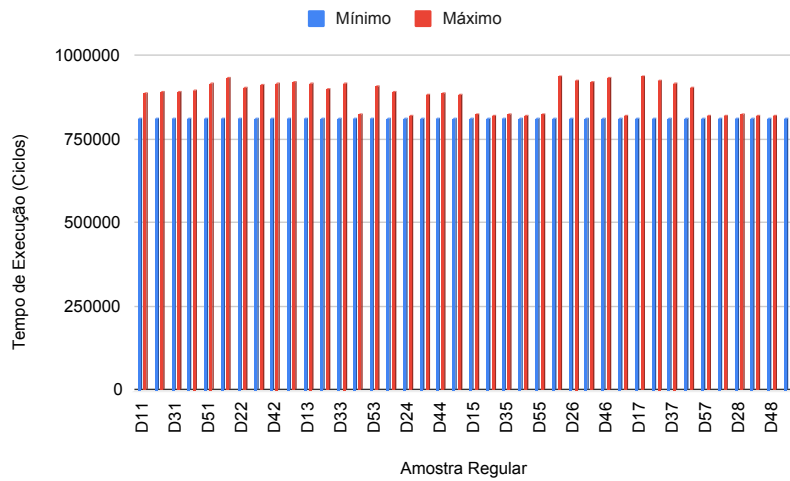
**CV Ciclos** Entre 0.07% e 0.24% (Figura A.8(b)).

**CV Ins** Entre 0.0005% e 0.0008%.


## 3. Considerações sobre o experimento com o *Merge Sort*

- Os cenários F05 e F08, únicos ambientados com *Eth0* e *Wifi* desativados simultaneamente, apresentaram boa qualidade de ajuste para as amostras regulares. O fato sinaliza que esses recursos podem ter provocado impacto nas demais amostras quando, ao menos um deles, se manteve ativo. Esse aspecto, entretanto, não pode ser considerado como decisivo, pois algumas amostras dos outros cenários com esses recursos ativos puderam ser ajustadas. A variação no *Core* parece não ter provocado impactos às medições.






(a) Amplitude Ciclos




(b) CV Ciclos

**Figura A.6** Merge Sort, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT




**Figura A.7** *Merge Sort*, Amostras Extras - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados

- Aumentar o tamanho das amostras de F01, F02 e F05 não trouxe benefícios ao experimento. Seguiram sem bom ajuste as amostras coletadas sob os cenários F01 e F02, e, as sob F05, apresentaram menor quantidade de bons ajustes à medida que o tamanho da amostra aumentou.
- As faixas de valores de *Ins* em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares como para as amostras extras, tendo estas bons ajustes EVT ou não. Como houve casos onde foi possível bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de *Ins* que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Pôde-se observar que, na maioria das amostras regulares ou amostras extras, as amostras com os mais baixos CVs *Ciclos* tiveram bom ajuste EVT. A duração do tempo de execução (v.a. *Ciclos*) não tem relação com o bom ajuste EVT, mas, tal fato pode demonstrar que amostras que sofreram um menor impacto do ambiente, e conseqüente apresentaram menores OMax, tiveram suas distribuições mais estáveis e que isso pode representar melhores condições para aplicação EVT.
- Não foram observados histogramas no Padrão 01, entretanto, algumas das distribuições observadas no Padrão 02 obtiveram bom ajuste.
- De maneira geral, os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes entre si.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Merge Sort* trouxe resultados pouco satisfatórios. A média de bom ajuste GEV/GPD ficou



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.8** Merge Sort, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

em 32.50% nas amostras regulares e 8% nas amostras extras. Tal fato pode indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmark* em questão.

**A.2.1.3 *Insertion Sort*** é um algoritmo de ordenação eficiente para problemas com poucas entradas. O código executado contou com uma entrada fixa de tamanho 1.000. Como descrito nas Tabelas A.3(b) e A.3(d), os resultados para este experimento apresentaram:

- 75% de amostras regulares sem bom ajuste GEV e 82.50% de amostras regulares sem bom ajuste GPD
- 100% de amostras extras F01 100 mil e F01 500 mil sem bom ajuste GEV/GPD
- 100% de amostras extras F05 100 mil sem bom ajuste GEV e 60% sem bom ajuste GPD
- 100% de amostras extras F05 500 mil sem bom ajuste GEV/GPD

Mais detalhes podem ser observados nos itens a seguir.

#### 1. Amostras Regulares

**Ajuste GEV/GPD** Não foi possível obter bom ajuste em todas as amostras dos cenários F01, F02, F03, F04, F06 e F07. Foi possível obter bom ajuste para todas as amostras dos cenários F05 e F08 (Tabela A.3(a)).

**Teste Dietrich** Foi coerente com as tentativas de ajustes GEV/GPD (Tabela A.3(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.3(a)).

**Padrão 02** Observado em todas as amostras (Tabela A.3(a)). Os modelos classificados como Padrão 02 podem ser observados na Figura A.9, juntamente com seus respectivos gráficos de dispersão. Foi possível obter bom ajuste em todos os casos onde este padrão apresentou uma aparência visual assimétrica positiva, como o modelo apresentado na Figura A.9(b). As amostras que apresentaram distribuição no modelo da Figura A.9(a) não tiveram bom ajuste EVT.

**Amplitude Ciclos**  $OMin = 8753321$  e  $OMax = 9269574$ , considerando todas as amostras regulares, com ou sem bom ajuste EVT. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.10(a)).

**CV Ciclos** Entre 0.009% e 0.19% (Figura A.10(b)).

**CV Ins** Entre 0.00005% e 0.00006%.

**Tabela A.3** *Insertion Sort* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	0	0	0	5
F02	0	5	0	0	0	5
F03	0	5	0	0	0	5
F04	0	5	0	0	0	5
F05	0	5	5	3	5	5
F06	0	5	0	0	0	5
F07	0	5	0	0	0	5
F08	0	5	5	4	5	5
Total	0	40	10	7	10	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)


Padrão		Ajuste	GEV	GPD	Dietrich
01	02	Bom	25,00%	17,50%	25,00%
0,00%	100,00%	Sem	75,00%	82,50%	75,00%

(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT			Testadas
	01	02	GEV	GPD	Dietrich	
F01_100mil	0	5	0	0	0	5
F01_500mil	0	5	0	0	0	5
F05_100mil	0	5	0	2	3	5
F05_500mil	0	5	0	0	0	5
Total	0	20	0	2	3	20

(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F01	0%	100%	0%	0%	0%
F01_100mil	0%	100%	0%	0%	0%
F01_500mil	0%	100%	0%	0%	0%
F05	0%	100%	100%	60%	100%
F05_100mil	0%	100%	0%	40%	60%
F05_500mil	0%	100%	0%	0%	0%



(a) Amostra que não teve bom ajuste EVT

(b) Amostra que teve bom ajuste EVT

**Figura A.9** *Insertion Sort*, Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT

## 2. Amostras Extras

Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F01 e F05. A escolha dos cenários deu-se com intuito de checar se um acréscimo no tamanho da amostra poderia alterar os resultados obtidos nas amostras regulares, o primeiro sem bom ajuste EVT, e o segundo com bom ajuste.

**Ajuste GEV/GPD** O aumento no tamanho das amostras não trouxe resultados positivos significativos para o experimento. O cenário F01 seguiu sem possibilidade de ajuste, e o cenário F05 teve piores resultados à medida que o tamanho da amostra cresceu (Tabela A.3(c)).

**Teste Dietrich** Foi coerente com as tentativas de ajustes GEV/GPD (Tabela A.3(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.3(c)).

**Padrão 02** Observado em todas as amostras extras (Tabela A.3(c)). Não foram observados modelos diferentes dos presentes nas amostras regulares.


**Amplitude Ciclos** OMin = 8753332 e OMax = 9303537, considerando todas as amostras extras, com ou sem bom ajuste EVT. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.11(a)).

**CV Ciclos** Entre 0.006% e 0.13% (Figura A.11(b)).


**CV Ins** Entre 0.00004% e 0.00005%.

## 3. Considerações sobre o experimento com o *Insertion Sort*

- Os cenários F05 e F08, únicos ambientados com *Eth0* e *Wifi* desativados simultaneamente, apresentaram boa qualidade de ajuste para as amostras regulares. O fato sinaliza que esses recursos podem ter provocado impacto nas demais

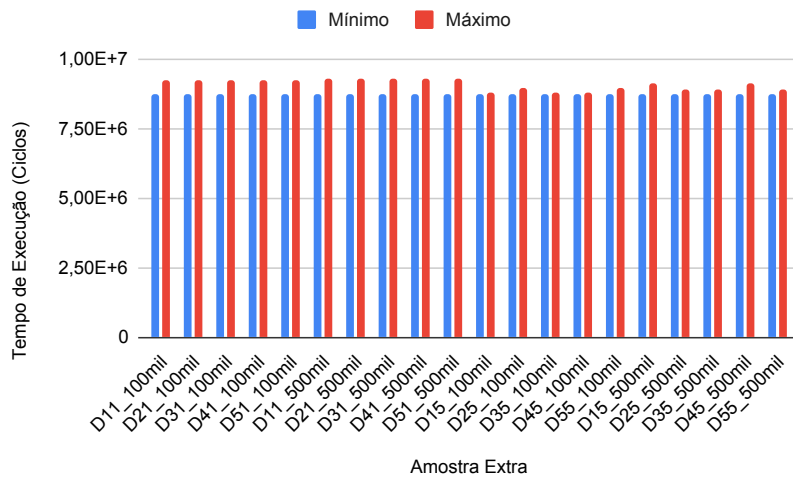


(a) Amplitude Ciclos




(b) CV Ciclos

**Figura A.10** *Insertion Sort*, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.11** *Insertion Sort*, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT



amostras quando, ao menos um deles, esteve ativo. Esse aspecto, entretanto, não pode ser considerado como decisivo, pois algumas amostras dos outros cenários com esses recursos ativos puderam ser ajustadas. A variação no *Core* parece não ter provocado impactos às medições.

- As faixas de valores de *Ciclos* em todas as amostras regulares em F05 e F08, seus valores máximos, mínimos e CVs se mostraram estáveis e todas essas amostras puderam ser ajustadas. Nos demais cenários, todos sem bom ajuste, estes valores oscilaram e apresentaram resultados mais altos. Tal fato demonstra um aumento em *Ciclos* para amostras ambientadas com, ao menos um dos recursos de *Eth0* ou *Wifi*, ativo. A duração do tempo de execução (v.a. *Ciclos*) não tem relação com a garantia de bom ajuste EVT, mas, tal fato pode demonstrar que amostras que sofreram um menor impacto do ambiente, e conseqüente apresentaram menores valores máximos, tiveram suas distribuições mais estáveis e que isso pode representar melhores condições para aplicação da EVT. O comportamento não se repetiu nas amostras extras.
- Aumentar o tamanho das amostras não produziu resultados melhores. Houve menos ajustes para as amostras coletadas sob o cenário F05 à medida que o tamanho da amostra cresceu, e a impossibilidade de ajuste foi mantida para as sob F01.
- As faixas de valores de *Ins* em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares como para as amostras extras, tendo estas bons ajustes ou não. Como houve casos onde foi possível bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de *Ins* que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Não foram observados histogramas no Padrão 01, entretanto, algumas das distribuições observadas no Padrão 02 obtiveram bom ajuste.
- De maneira geral, os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes entre si.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Insertion Sort* trouxe resultados pouco satisfatórios. A média de bons ajustes GEV/GPD ficou em 21.25% nas amostras regulares e 5% nas amostras extras. Tal fato pode indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmark* em questão.

**A.2.1.4 *Quick Sort*** é um algoritmo de ordenação recursivo de divisão e conquista. O código executado contou com uma entrada fixa de tamanho 1.000. Como descrito nas Tabelas A.4(b) e A.4(d), os resultados para este experimento apresentaram:

- 95% de amostras regulares sem bom ajuste GEV/GPD
- 100% de amostras extras F01 100 mil e F01 500 mil sem bom ajuste GEV/GPD
- 60% de amostras extras F05 100 mil sem bom ajuste GEV e 20% sem bom ajuste GPD
- 40% de amostras extras F05 500 mil sem bom ajuste GEV/GPD
- 80% de amostras extras F08 100 mil sem bom ajuste GEV e 60% sem bom ajuste GPD
- 100% de amostras extras F08 500 mil sem bom ajuste GEV/GPD

Mais detalhes podem ser observados nos itens a seguir.

#### 1. Amostras Regulares

**Ajuste GEV/GPD** Não foi possível obter bom ajuste em todas as amostras dos cenários F02, F03, F05, F06, F07 e F08. Foi possível obter bom ajuste em uma amostra nos cenários F01 e F04 (Tabela A.4(a)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.4(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.4(a)).

**Padrão 02** Observado em todas as amostras (Tabela A.4(a)).

Os modelos que foram classificados como Padrão 02 podem ser observados na Figura A.12, juntamente com seus respectivos gráficos de dispersão. Foi possível obter bom ajuste em todos os casos deste padrão que apresentou uma aparência visual assimétrica positiva, como o destacado na Figura A.12(b). Este modelo teve uma aparência muito próxima ao do Padrão 01, mas a aparente leve assimetria o fez ser classificado como Padrão 02. Os modelos da Figura A.12(a) não puderam ser ajustados.

**Amplitude Ciclos**  $OMin = 391842$  e  $OMax = 471038$ , considerando todas as amostras regulares, com ou sem bom ajuste EVT. Percebeu-se estabilidade em todos os valores mínimos e oscilações nos máximos das amostras sem bom ajuste (Figura A.13(a)).

**CV Ciclos** Entre 0.10% e 0.48% (Figura A.13(b)).

**CV Ins** Estável em torno de 0.012%.

**Tabela A.4** *Quick Sort* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	1	1	1	5
F02	0	5	0	0	1	5
F03	0	5	0	0	0	5
F04	0	5	1	1	1	5
F05	0	5	0	0	0	5
F06	0	5	0	0	0	5
F07	0	5	0	0	0	5
F08	0	5	0	0	0	5
Total	0	40	2	2	3	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)

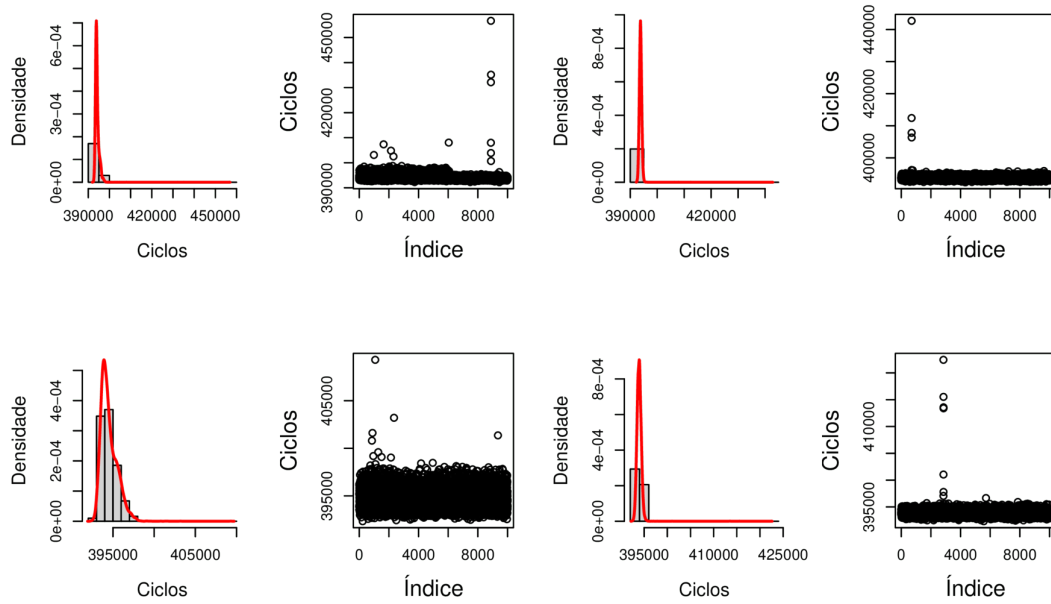
Padrão		Ajuste	GEV	GPD	Dietrich
01	02				
0,00%	100,00%	<b>Bom</b>	5%	5%	7,50%
		<b>Sem</b>	95%	95%	92,50%

(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT


Cenário	Padrão		Bom ajuste EVT			Testadas
	01	02	GEV	GPD	Dietrich	
F01_100mil	0	5	0	0	5	5
F01_500mil	0	5	0	0	5	5
F05_100mil	0	5	2	4	5	5
F05_500mil	0	5	3	3	3	5
F08_100mil	0	5	1	2	2	5
F08_500mil	0	5	0	0	0	5
Total	0	20	6	9	20	30

(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F01	0%	100%	20%	20%	20%
F01_100mil	0%	100%	0%	0%	100%
F01_500mil	0%	100%	0%	0%	100%
F05	0%	100%	0%	0%	0%
F05_100mil	0%	100%	40%	80%	100%
F05_500mil	0%	100%	60%	60%	60%
F08	0%	100%	0%	0%	0%
F08_100mil	0%	100%	20%	40%	40%
F08_500mil	0%	100%	0%	0%	0%




(a) Amostras que não tiveram bom ajuste EVT




(b) Amostra que teve bom ajuste EVT

**Figura A.12** *Quick Sort*, Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.13** *Quick Sort*, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

## 2. Amostras Extras

Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F01, F05 e F08. A escolha dos cenários deu-se com intuito de checar se um acréscimo no tamanho da amostra poderia fornecer melhores resultados, pois foi possível obter apenas um bom ajuste para as amostras regulares em F01, e nenhum para os F05 e F08.

**Ajuste GEV/GPD** O aumento no tamanho das amostras trouxe resultados positivos para parte do experimento. Foram observados bons ajustes EVT para as amostras F05 100 mil, F05 500 mil e F08 100 mil, sendo que os cenários F05 e F08 não haviam produzido qualquer bom ajuste nas amostras regulares. Não foram, entretanto, identificadas melhorias para o cenário F08 500 mil, que não teve bom ajuste GEV/GPD (Tabela A.4(c)). O cenário F01, com um bom ajuste nas amostras regulares, não teve nenhum bom ajuste nas amostras extras.

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.4(c)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.4(c)).

**Padrão 02** Observado em todas as amostras extras (Tabela A.4(c)). Não foram observados modelos de histograma diferentes dos encontrados nas amostras regulares. Como nestas amostras, as amostras extras com o modelo da Figura A.12(b) tiveram bom ajuste EVT, e as com o modelo da Figura A.12(a) não tiveram bom ajuste.


**Amplitude Ciclos**  $OMin = 392012$  e  $OMax = 467914$ , considerando todas as amostras extras, com ou sem bom ajuste. Percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.14(a)).

**CV Ciclos** Entre 0.10% e 0.26% (Figura A.14(b)).


**CV Ins** Estável em torno de 0.012%.

## 3. Considerações sobre o experimento com o *Quick Sort*

- Não foi possível observar um cenário com mais ou menos bons ajustes EVT nas amostras regulares como consequência do processo de variação dos cenários de execução. Por outro lado, pode-se observar, seja nas amostras regulares ou amostras extras, que **Ciclos** acima de 400.000 estão associados a amostras onde não foi possível obter bom ajuste EVT, e, os abaixo deste valor, associados às com bom ajuste. A duração do tempo de execução (v.a. **Ciclos**) não tem relação com um bom ajuste EVT, mas, tal fato pode demonstrar que amostras que ficaram menos tempo sob o impacto do ambiente, e consequente apresentaram valores mínimos com menor variação e mais baixos valores máximos, tiveram suas distribuições mais estáveis e que isso pode representar melhores condições para aplicação da EVT. As amostras extras, por sua vez,



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.14** *Quick Sort*, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

tiveram em quantidade razoável de bons ajustes para as amostras com *Eth0* e *Wifi* inativos (cenários F05 e F08), exceto em F08 500 mil, sem bom ajuste, assim como as amostras extras em F01.

- As faixas de valores de *Ins* em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares como para as amostras extras, tendo estas bons ajustes ou não. Como houve casos onde foi possível obter bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de *Ins* que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Não foram observados dados amostrais com o Padrão 01. Todas as amostras regulares e amostras extras no Padrão 02 que apresentaram o modelo com aparência visual com leve assimetria positiva puderam ser ajustadas, as demais, não.
- Os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Quick Sort* não trouxe resultados satisfatórios para a utilização da EVT como ferramenta para estimativa de pWCET. A média de bons ajustes GEV/GPD ficou em 5% para as amostras regulares e 25% para as amostras extras. Apesar de alguma melhoria observada com o aumento do tamanho de algumas amostras, os baixos percentuais de bom ajuste podem representar a inadequação de uso da EVT para o conjunto plataforma-*benchmark* em questão.

**A.2.1.5 Comparativo Grupo 01** A Tabela A.5 demonstra alguns dos resultados observados para os experimentos do Grupo 01. Com base nestes e nos dados apresentados ao longo da seção, pôde-se observar que:

- Não foi observado um comportamento único com relação aos impactos sofridos pela variação nos cenários de testes e taxas de bons ajustes EVT que pudesse ser classificado como um padrão de resultado para o grupo.
- Nos experimentos onde os valores de *Ciclos* foram mais altos (*Bubble Sort* e *Insertion Sort*) as únicas amostras regulares que tiveram bom ajuste foram as nos cenários F05 e F08, únicos com os recursos de *Eth0* e *Wifi* desativados. Nos *benchmarks* que tiveram execução mais rápidas (*Merge Sort* e *Quick Sort*), não foram percebidos impactos nas medições resultantes da variação dos recursos avaliados (*Core*, *Eth0*, *Wifi*). Nestes casos, houve bom ajuste EVT em amostras variadas de



**Tabela A.5** Comparativo de resultados do Grupo 01

(a) Resultados observados nas Amostras Regulares apresentando valores de OMin e OMax Ciclos, CV Ins e percentual de bom ajuste EVT, classificação por *benchmark*

<i>Bench.</i>	Ciclos				Ins		Bom ajuste EVT	
	OMin	OMax	CV		CV		GEV	GPD
			Min	Max	Min	Max		
<i>Insertion S.</i>	8753321	9269574	0,009%	0,189%	0,000%	0,000%	25,00%	17,50%
<i>Merge S.</i>	813876	942457	0,108%	0,402%	0,001%	0,001%	32,50%	32,50%
<i>Quick S.</i>	391842	471038	0,108%	0,486%	0,012%	0,013%	5,00%	5,00%
<i>Bubble S.</i>	27945691	29132891	0,001%	0,152%	0,000%	0,000%	15,00%	10,00%

(b) Listagem de Amostras Regulares e Extras com qtdd. de padrões identificados e de amostras com bom ajuste EVT. Classificação por cenário e *benchmark*. Para as Amostras Regulares, apresenta-se apenas os cenários com ao menos um bom ajuste EVT, para as Amostras Extras, todos os cenários medidos

<i>Bench.</i>	Amostra	Cenário	Padrão		GEV	GPD	Dietrich	Testadas
			01	02				
<i>Insertion S.</i>	Regular	F05	0	5	5	3	5	5
		F08	0	5	5	4	5	5
	Extra	F01_100mil	-	-	-	-	-	-
		F01_500mil	-	-	-	-	-	-
		F05_100mil	0	5	0	2	3	5
	F05_500mil	-	-	-	-	-	-	
<i>Merge S.</i>	Regular	F04	0	5	1	1	1	5
		F05	0	5	5	5	5	5
		F06	0	5	1	1	1	5
		F07	0	5	1	1	1	5
		F08	0	5	5	5	5	5
	Extra	F01_100mil	-	-	-	-	-	-
		F01_500mil	-	-	-	-	-	-
		F05_100mil	0	5	4	1	5	5
	F05_500mil	-	-	-	-	-	-	
<i>Quick S.</i>	Regular	F01	1	4	1	1	1	5
	Extra	F05_100mil	4	1	2	4	5	5
		F05_500mil	3	2	3	3	3	5
		F08_100mil	2	3	2	2	2	5
		F08_500mil	-	-	-	-	-	-
<i>Bubble S.</i>	Regular	F05	4	1	4	2	4	5
		F08	4	1	2	2	4	5
	Extra	F01_100mil	-	-	-	-	-	-
		F01_500mil	-	-	-	-	-	-
		F05_100mil	-	-	-	-	-	-
	F05_500mil	-	-	-	-	-	-	

diferentes cenários, levantando a suspeita de que não houve tempo suficiente para que os recursos provocassem impacto relevante nas medições.

- Percebe-se um baixo CV para *Ins* em todos os experimentos. Como há bom ajuste em várias das amostras coletadas, o fato demonstra que as medições de *Ciclos* não foram impactados de forma significativa por um acréscimo no número de instruções ocasionado por contadores de desempenho, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Como há estabilidade em *Ins* e determinismo sob o ponto de vista do código executado, sugere-se que as oscilações em *Ciclos* estão diretamente relacionadas aos impactos do ambiente.
- Os modelos que apresentaram distribuições com aparência visual no Padrão 01 apresentam bom ajuste EVT. As distribuições no Padrão 02 puderam ou não ser ajustadas, demonstrando que pode ou não haver boa qualidade de ajuste EVT para determinadas distribuições.
- Aumentar o tamanho das amostras não demonstrou certeza de melhorias ao experimento. Em alguns casos trouxe benefícios, em outros, malefícios, e, em outros, não provocou mudanças, deixando a escolha do tamanho adequado de uma amostra como um evidente problema em aberto.
- O experimento com o Grupo 01 não trouxe bons resultados e apresentou baixo percentual de bom ajuste EVT, com 17.81% de bom ajuste das amostras regulares e 9.5% de bom ajuste para as amostras extras.

## A.2.2 Grupo 02

O Grupo 02 é composto por três *benchmarks* caracterizados pela realização de cálculos. São eles: *Fft1*, *Sqrt* e *Fibcall*.

**A.2.2.1 *Fft1*** realiza a transformada rápida de Fourier de 1024 pontos, usando o algoritmo de Cooley-Turkey. A fim de garantir o determinismo do código executado, o mesmo é implementado para um valor inteiro fixo. Como descrito nas Tabelas A.6(b) e A.6(d), os resultados para este experimento apresentaram:

- 92.50% de amostras regulares sem bom ajuste GEV e 90% sem bom ajuste GPD
- 100% de amostras extras F01 100 mil e F01 500 mil sem bom ajuste GEV/GPD
- 80% de amostras extras F05 100 mil sem bom ajuste GEV/GPD
- 60% de amostras extras F05 500 mil sem bom ajuste GEV/GPD
- 100% de amostras extras F06 100 mil e F06 500 mil sem bom ajuste GEV/GPD

Mais detalhes podem ser observados nos itens a seguir.

## 1. Amostras Regulares

**Ajuste GEV/GPD** Não foi possível obter bom ajuste para todas as amostras dos cenários F01, F03, F04, F05 e F08, e foi possível bom ajuste em uma amostra de F02 e F07, e duas de F06 (Tabela A.6(a)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.6(a)).

- Dados amostrais

**Padrão 01** Observado em apenas uma amostra (Tabela A.6(a)), sendo que a mesma apresentou bom ajuste EVT.

**Padrão 02** Observado em todas as demais amostras (Tabela A.6(a)).

Os modelos que foram classificados como Padrão 02 podem ser observados na Figura A.15, juntamente com seus respectivos gráficos de dispersão. Foi possível obter bom ajuste em todos os casos deste padrão que apresentou uma aparência visual assimétrica positiva, como o destacado na Figura A.15(b). Este modelo teve uma aparência muito próxima ao do Padrão 01, mas a aparência visual com leve assimetria o fez ser classificado como Padrão 02. As demais amostras, com distribuição com comportamento no modelo da Figura A.15(a), não tiveram bom ajuste GEV/GPD.

**Amplitude Ciclos**  $O_{Min} = 295295$  e  $O_{Max} = 354400$ , considerando todas as amostras regulares, com ou sem bom ajuste EVT. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.16(a)).

**CV Ciclos** Entre 0.08627% e 0.36178% (Figura A.16(b)).

**CV Ins** Entre 0.00770% e 0.00814%.

## 2. Amostras Extras

Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F01, F05 e F06. A escolha dos cenários deu-se com intuito de checar se um acréscimo no tamanho da amostra poderia fornecer melhores resultados, pois as amostras regulares de F01 e F05 não tiveram bom ajuste, e as de F06 foram as que apresentaram os melhores resultados, com apenas dois bons ajustes.

**Ajuste GEV/GPD** O aumento no tamanho das amostras trouxe resultados positivos apenas para o experimento em F05 100 mil e F05 500 mil, que antes não teve bom ajuste e passou a ajustar uma e três amostras, respectivamente. O cenário F01 não sofreu alterações, seguindo sem bom ajuste, e, F06, apresentou piores resultados, pois antes ajustou algumas amostras e passou a não ajustar nenhuma (Tabela A.6(d)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.6(d)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.6(c)).

**Tabela A.6** *Fft1* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	0	0	0	5
F02	1	4	1	1	1	5
F03	0	5	0	0	0	5
F04	0	5	0	0	0	5
F05	0	5	0	0	0	5
F06	0	5	2	2	2	5
F07	0	5	0	1	1	5
F08	0	5	0	0	0	5
Total	1	39	3	3	4	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)


Padrão		Ajuste	GEV	GPD	Dietrich
01	02	Bom	7,50%	10,00%	10,00%
2,50%	97,50%	Sem	92,50%	90,00%	90,00%

(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT


Cenário	Padrão		Bom ajuste EVT			Testadas
	01	02	GEV	GPD	Dietrich	
F01_100mil	0	5	0	0	0	5
F01_500mil	0	5	0	0	0	5
F05_100mil	0	5	1	1	1	5
F05_500mil	0	5	2	2	3	5
F06_100mil	0	5	0	0	0	5
F06_500mil	0	5	0	0	0	5
Total	0	30	3	3	4	30

(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F01	0%	100%	0%	0%	0%
F01_100mil	0%	100%	0%	0%	0%
F01_500mil	0%	100%	0%	0%	0%
F05	0%	100%	0%	0%	0%
F05_100mil	0%	100%	20%	20%	20%
F05_500mil	0%	100%	40%	40%	60%
F06	0%	100%	40%	40%	40%
F06_100mil	0%	100%	0%	0%	0%
F06_500mil	0%	100%	0%	0%	0%




(a) Amostras que não tiveram bom ajuste EVT




(b) Amostra que teve bom ajuste EVT

**Figura A.15** *Fft1*, Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT

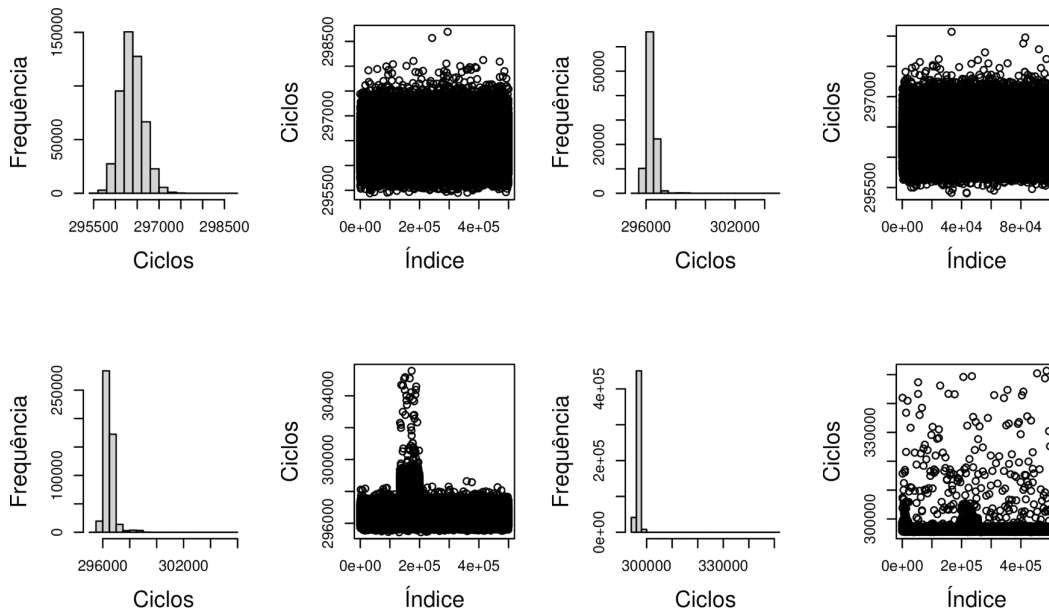


(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.16** *Fft1*, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT



**Figura A.17** *Fft1*, Amostras Extras - Modelo de histograma classificado como Padrão 02 e dispersão dos dados

**Padrão 02** Foram observados diferentes modelos para o Padrão 02 (Figura A.17) e, em nenhum dos casos houve ajuste (Tabela A.6(d)). Amostras que puderam ser ajustadas apresentaram o mesmo modelo presente nas amostras regulares (Figura A.15(b)).


**Amplitude Ciclos**  $OMin = 295285$  e  $OMax = 359241$ , considerando todas as amostras extras, com ou sem bom ajuste. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.18(a)).

**CV Ciclos** Entre 0.08717% e 0.29846% (Figura A.18(b)).


**CV Ins** Entre 0.00076% e 0.00798%.

### 3. Considerações sobre o experimento com o *Fft1*

- Observou-se que as amostras regulares e amostras extras que apresentaram os mais baixos CVs puderam ser ajustadas. Essas mais baixas oscilações sugerem que houve um menor impacto do ambiente durante as medições. As amostras regulares tiveram em comum o fato de terem sido rodados no *Core* dedicado, entretanto, não pode-se afirmar que esta influência foi exclusiva, pois nenhuma amostra do cenário F08, um dos com *Core* dedicado, pôde ser ajustada. No caso das amostras extras, CVs menores puderam ser observados apenas nas amostras dos cenários F05, sem *Eth0* e *Wifi*, e também foram as únicas ajustadas. Não há relação entre a duração do tempo de execução (v.a. *Ciclos*) e um bom ajuste EVT. Os pontos observados podem apenas representar um



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.18** *Fft1*, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT




maior ou menor impacto do ambiente, motivado ou não pela variação dos recursos analisados. Além disso, o fato pode demonstrar que amostras que sofreram um menor impacto do ambiente tiveram suas distribuições mais estáveis e que isso pode representar melhores condições para aplicação da EVT.

- Aumentar o tamanho das amostras foi positivo apenas para uma parte do experimento. Para as amostras coletadas sob os cenários F01 e F06, bons ajustes deixaram de existir mas, para as sob F05, amostras passaram a ser ajustadas.
- Todas as amostras com histogramas no Padrão 01 puderam ser ajustadas. As amostras no Padrão 02 que tiveram seus modelos com aparência visual com leve assimetria positiva puderam ser ajustadas, as demais, não.
- As faixas de valores de *Ins* em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares como para as amostras extras, tendo estas bons ajustes ou não. Como houve casos onde foi possível obter bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de *Ins* que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Fft1* trouxe resultados pouco satisfatórios. A média de bons ajustes GEV/GPD ficou em 8.75% para as amostras regulares e 10% para as amostras extras. Tal fato pode indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmark* em questão.

**A.2.2.2 *Sqrt*** opera a função de raiz quadrada implementada pela série de Taylor. Para garantir determinismo sobre o ponto de vista do código executado, foi considerado um valor inteiro fixo como entrada do programa. Como descrito nas Tabelas A.7(b) e A.7(d), os resultados para este experimento apresentaram:

- 100% de amostras regulares sem bom ajuste GEV/GPD
- 100% de amostras extras F01 100 mil sem bom ajuste GEV/GPD
- 60% de amostras extras F01 500 mil sem bom ajuste GEV/GPD
- 40% de amostras extras F08 100 mil sem bom ajuste GEV/GPD
- 0% de amostras extras F08 500 mil sem bom ajuste GEV/GPD



**Figura A.19** *Sqrt*, Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados

Mais detalhes podem ser observados nos itens a seguir.

### 1. Amostras Regulares

**Ajuste GEV/GPD** Não foi possível obter bom ajuste nas amostras de todos os cenários (Tabela A.7(a)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.8(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.7(a)).

**Padrão 02** Observado em todas as amostras (Tabela A.7(a)) sendo que não foi possível obter bom ajuste EVT em todos os casos.

Os modelos que foram classificados como Padrão 02 podem ser observados na Figura A.19, juntamente com seus respectivos gráficos de dispersão.

**Amplitude Ciclos** OMin = 1164 e OMax = 10379, considerando todas as amostras regulares, com ou sem bom ajuste EVT. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.20(a)).

**CV Ciclos** Valor acima do desejado, entre 23.38736% e 26.62098% (Figura A.20(b)).

**CV Ins** Entre 0.15647% e 0.18796%.

### 2. Amostras Extras

Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F01 e F08. A escolha dos cenários deu-se com intuito de checar se um acréscimo no tamanho da amostra poderia fornecer melhores resultados, pois as amostras regulares destes cenários não tiveram bom ajuste EVT.

**Ajuste GEV/GPD** O aumento no tamanho das amostras trouxe resultados positivos para o experimento. As amostras extras do cenário F08 puderam ser integralmente ajustadas, e, as do cenário F01 500 mil, parcialmente (Tabela A.7(c)), sendo que as amostras regulares destes cenários não haviam apresentado bom ajuste.

**Tabela A.7** *Sqrt* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	0	0	0	5
F02	0	5	0	0	0	5
F03	0	5	0	0	0	5
F04	0	5	0	0	0	5
F05	0	5	0	0	0	5
F06	0	5	0	0	0	5
F07	0	5	0	0	0	5
F08	0	5	0	0	0	5
Total	0	40	0	0	0	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)


Padrão		Ajuste	GEV	GPD	Dietrich
01	02				
0,00%	100,00%	<b>Bom</b>	0,00%	0,00%	0,00%
		<b>Sem</b>	100,00%	100,00%	100,00%

(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT


Cenário	Padrão		Bom ajuste EVT			Testadas
	01	02	GEV	GPD	Dietrich	
F01_100mil	0	5	0	0	0	5
F01_500mil	2	3	2	2	2	5
F08_100mil	3	2	3	3	3	5
F08_500mil	5	0	5	5	5	5
Total	10	10	10	10	10	20

(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F01	0%	100%	0%	0%	0%
F01_100mil	0%	100%	0%	0%	0%
F01_500mil	40%	60%	40%	40%	40%
F08	0%	100%	0%	0%	0%
F08_100mil	60%	40%	60%	60%	60%
F08_500mil	100%	0%	100%	100%	100%

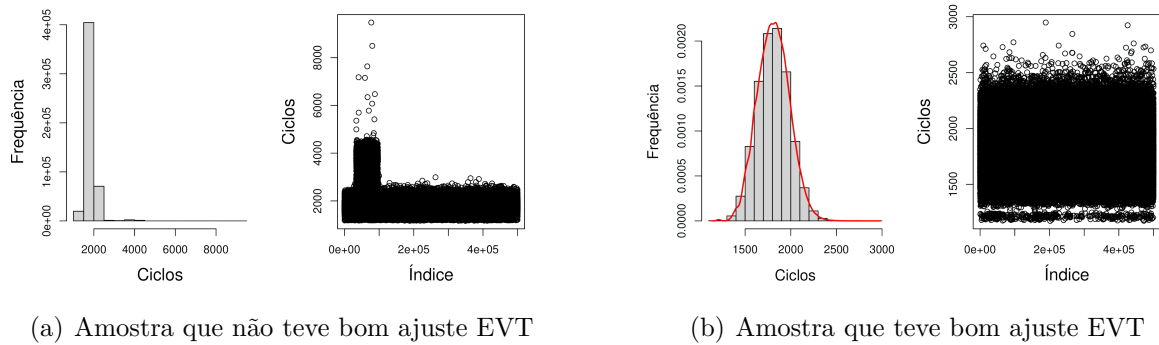


(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.20** *Sqrt*, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT



**Figura A.21** *Sqrt*, Amostras Extras - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.7(c)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.7(c)).

**Padrão 02** Observado em todas as amostras extras (Tabela A.7(c)). Foram observados diferentes modelos dos encontrados nas amostras regulares para o Padrão 02 (Figura A.21). Todas as amostras no modelo da Figura A.21(a) não puderam ser ajustadas, e todos no modelo da Figura A.21(b) puderam. Este modelo teve uma aparência muito próxima ao do Padrão 01, mas a aparência com visual com leve assimetria o fez ser classificado como Padrão 02.


**Amplitude Ciclos**  $OMin = 1163$  e  $OMax = 9470$ , considerando todas as amostras extras, com ou sem bom ajuste. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.22(a)).

**CV Ciclos** Acima do desejado, entre 9.48193% e 27.25198% (Figura A.22(b)).


**CV Ins** Entre 0.15099% e 0.16652%.

### 3. Considerações sobre o experimento com o *Sqrt*

- As faixas de valores de **Ciclos** para cada amostra, seus valores máximos, mínimos e CVs tiveram uma oscilação acima do esperado, tanto para as amostras regulares, como para as amostras extras. Todas as amostras regulares não puderam ser ajustadas, sendo impossível identificar impactos nas medições destas amostras provocados pela variação dos cenários.
- Aumentar o tamanho da amostra trouxe resultados positivos ao experimento, entretanto, percebeu-se que apenas puderam ser ajustadas as amostras extras onde os CVs **Ciclos** foram mais baixos. Não há relação entre a duração do tempo de execução (v.a. **Ciclos** e o bom ajuste EVT, entretanto, **Ciclos** com valores mais altos podem indicar um maior impacto do ambiente, motivado



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.22** *Sqrt*, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

ou não pela variação dos recursos analisados. Além disso, pode-se sugerir que amostras que sofreram um maior impacto do ambiente tiveram suas distribuições menos estáveis, mais conturbadas, e que isso pode representar piores condições para aplicação da EVT.


- As faixas de valores de *Ins* em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares como para as amostras extras, tendo estas bons ajustes ou não. Como houve casos onde foi possível obter bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de *Ins* que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes.
- Não foram observados histogramas no Padrão 01, entretanto, algumas das distribuições observadas no Padrão 02 obtiveram bom ajuste.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Sqrt* trouxe resultados pouco satisfatórios. A média de bons ajustes GEV/GPD ficou em 0% para as amostras regulares e 50% para as amostras extras. Tal fato pode indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmark* em questão.

**A.2.2.3 *Fibcall*** conta com uma entrada de 1.000 inteiros *n* e calcula, de forma iterativa, o *n*ésimo valor da sequência de Fibonacci de cada valor. Para garantir o resultado determinístico sob o ponto de vista do código executado, foi atribuído um vetor fixo como entrada para o programa.


Como descrito nas Tabelas A.8(b) e A.8(d), os resultados para este experimento apresentaram:

- 62.50% de amostras regulares sem bom ajuste GEV e 65% sem bom ajuste GPD
- 100% de amostras extras F01 100 mil e F01 500 mil sem bom ajuste GEV/GPD
- 40% de amostras extras F05 100 mil sem bom ajuste GEV/GPD
- 100% de amostras extras F05 500 mil sem bom ajuste GEV/GPD
- 100% de amostras extras F06 100 mil e F06 500 mil sem bom ajuste GEV/GPD

Mais detalhes podem ser observados nos itens a seguir.



(a) Amostras que não tiveram bom ajuste EVT



(b) Amostra que teve bom ajuste EVT

**Figura A.23** *Fibcall*, Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT

### 1. Amostras Regulares

**Ajuste GEV/GPD** Não foi possível obter bom ajuste em todas as amostras dos cenários F01 e F06. As amostras F05 e F08 puderam ser ajustadas em sua totalidade, e F02, F03, F04 e F07 tiveram uma ou duas Amostras com bom ajuste EVT (Tabela A.8(a)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.8(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.8(a)).

**Padrão 02** Observado em todas as amostras (Tabela A.8(a)).

Os modelos que foram classificados como Padrão 02 podem ser observados na Figura A.23, juntamente com seus respectivos gráficos de dispersão. Foi possível obter bom ajuste em todos os casos deste padrão que apresentou uma aparência visual assimétrica positiva, como o destacado na Figura A.23(b). As demais amostras, com comportamentos como os modelos da Figura A.23(a), não tiveram bom ajuste.

**Amplitude Ciclos** OMin = 592772 e OMax = 724631, considerando todas as amostras regulares, com ou sem bom ajuste EVT. Como esperado,



**Tabela A.8** *Fibcall* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	0	0	0	5
F02	0	5	1	1	1	5
F03	0	5	1	1	1	5
F04	0	5	2	2	2	5
F05	0	5	5	5	5	5
F06	0	5	0	0	0	5
F07	0	5	1	1	1	5
F08	0	5	5	4	5	5
Total	0	40	15	14	15	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)

Padrão		Ajuste	GEV	GPD	Dietrich
01	02				
0,00%	100,00%	<b>Bom</b>	37,50%	35,00%	37,50%
		<b>Sem</b>	62,50%	65,00%	62,50%

(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT			Testadas
	01	02	GEV	GPD	Dietrich	
F01_100mil	0	5	0	0	0	5
F01_500mil	0	5	0	0	0	5
F05_100mil	0	5	3	3	3	5
F05_500mil	0	5	0	0	0	5
F06_100mil	0	5	0	0	0	5
F06_500mil	0	5	0	0	0	5
Total	0	30	3	3	3	30

(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F01	0%	100%	0%	0%	0%
F01_100mil	0%	100%	0%	0%	0%
F01_500mil	0%	100%	0%	0%	0%
F05	0%	100%	100%	100%	100%
F05_100mil	0%	100%	60%	60%	60%
F05_500mil	0%	100%	0%	0%	0%
F06	0%	100%	0%	0%	0%
F06_100mil	0%	100%	0%	0%	0%
F06_500mil	0%	100%	0%	0%	0%

percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.24(a)).

**CV Ciclos** Entre 0.09465% e 0.68956% (Figura A.24(b)).

**CV Ins** Entre 0.00026% e 0.00073%.

## 2. Amostras Extras

Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F01, F05 e F06. A escolha dos cenários deu-se com intuito de checar se um acréscimo no tamanho da amostra poderia fornecer melhores resultados para F01 e F06, únicos sem qualquer bom ajuste EVT, e, observar o comportamento de F05, que teve todas as amostras regulares ajustadas.

**Ajuste GEV/GPD** O aumento no tamanho das amostras não trouxe resultados positivos para o experimento. F01 e F06 seguiram sem bom ajuste GEV/GPD e, F05 teve piores resultados, com uma queda na taxa de bons ajustes para 100 mil e a perda total de bons ajustes para 500 mil (Tabela A.8(c)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.8(c)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.8(c)).

**Padrão 02** Não foram observados modelos diferentes dos presentes nas amostras regulares. Como ocorrido nas regulares, os modelos nos padrões da Figura A.23(b) puderam ser ajustados, e no padrão da Figura A.23(a) não puderam.


**Amplitude Ciclos**  $O_{Min} = 592758$  e  $O_{Max} = 711494$ , considerando todas as amostras extras, com ou sem bom ajuste. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.25(a)).

**CV Ciclos** Entre 0.05808% e 0.21449% (Figura A.25(b)).


**CV Ins** Entre 0.00024% e 0.00033%.

## 3. Considerações sobre o experimento com o *Fibcall*

- O recurso *Eth0* estava desativado e *Wifi* ativo nas amostras regulares em F01 e F06 e não foi possível ajustar qualquer uma dessas amostras, entretanto, nas regulares F05 e F08 ambos os recursos estavam desativados e todas as amostras foram ajustadas. Assim, não foi possível detectar impactos determinantes provocados pela variação dos recursos testados com a troca de cenários. Não foram observados impactos específicos em função da variação do *Core*.
- Observou-se que, de maneira geral, CVs mais altos estavam associados às amostras regulares ou amostras extras que não tiveram bom ajuste EVT. Não há relação entre a duração do tempo de execução (v.a. **Ciclos** com o bom ajuste EVT, mas, tal fato pode demonstrar que as amostras que sofreram um menor impacto do ambiente, e conseqüentemente apresentaram menores valores

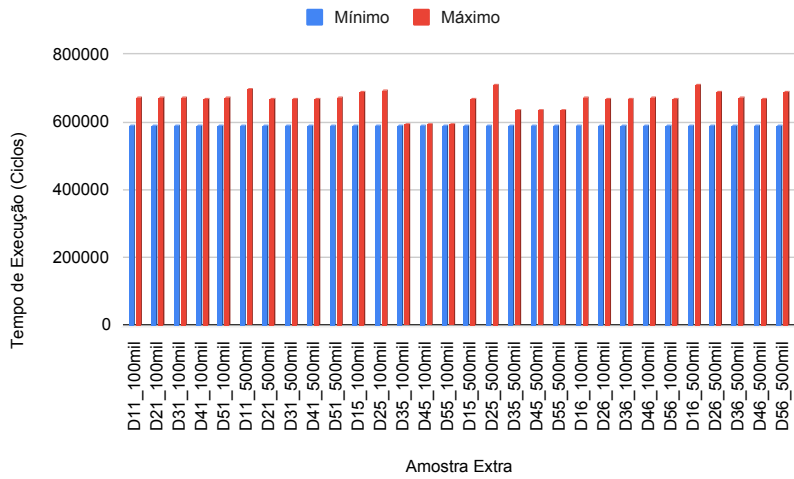


(a) Amplitude Ciclos




(b) CV Ciclos

**Figura A.24** *Fibcall*, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.25** *Fibcall*, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

máximos, tiveram suas distribuições mais estáveis e que isso pode representar melhores condições para a aplicação da EVT.

- Não foram observados histogramas no Padrão 01, entretanto, algumas das distribuições observadas no Padrão 02 obtiveram bom ajuste.
- As faixas de valores de *Ins* em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares como para as amostras extras, tendo estas bons ajustes ou não. Como houve casos onde foi possível obter bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de *Ins* que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- De maneira geral, os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes entre si.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Observou-se que o aumento no tamanho da amostra não trouxe melhorias para o experimento. Amostras coletadas sob os cenários F01 e F06 seguiram não sendo ajustadas e, no caso das sob F05, o número de bons ajustes caiu à medida que as amostras aumentaram de tamanho.
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Fibcall* trouxe resultados pouco satisfatórios. A média de bons ajustes GEV/GPD ficou em 36.25% para as amostras regulares e 10% para as amostras extras. Tal fato pode indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmark* em questão.

**A.2.2.4 Comparativo Grupo 02** A Tabela A.9 demonstra alguns dos resultados observados para os experimentos do Grupo 02. Com base nestes e nos dados apresentados ao longo da seção, pode-se observar que:

- Não foi observado um comportamento único com relação aos impactos sofridos pela variação nos cenários de testes e taxas de bons ajustes EVT que pudesse ser classificado como um padrão de resultado para o grupo.
- Foi possível ajustar amostras de diferentes cenários, não tendo sido possível identificar impactos específicos resultantes da variação dos recursos de *Core*, *Eth0* ou *Wifi*.
- Pôde-se observar que, no caso do *Fft1* e *Fibcall*, as amostras regulares e amostras extras com os CVs mais baixos puderam ser ajustadas. No *Sqrt*, o padrão aconteceu

nas amostras extras, mas não houve ajustes nas amostras regulares. Este fato coincide com um CV para *Ciclos* acima do esperado nestas amostras, com valor médio em torno de 25%. A duração do tempo de execução (v.a. *Ciclos*) não tem relação direta com a possibilidade ou não de obter bom ajuste EVT, entretanto, a sua alta variabilidade (com conseqüente altos valores máximos), pode significar que tais amostras tiveram suas distribuições mais afetadas pelo ambiente.

- Percebe-se um baixo CV para *Ins* em todos os experimentos. Como há bom ajuste em várias das amostras coletadas, o fato demonstra que as medições de *Ciclos* não foram impactadas de forma significativa por um acréscimo *Ins* ocasionado por contadores de desempenho, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Como há estabilidade em *Ins* e determinismo sob o ponto de vista do código executado, sugere-se que as oscilações em *Ciclos* estão diretamente relacionadas aos impactos do ambiente.
- Os modelos que apresentaram distribuições com aparência visual no Padrão 01 apresentam bom ajuste EVT. As distribuições no Padrão 02 puderam ou não obter bom ajuste, demonstrando que pode não haver boa qualidade de ajuste EVT para determinadas distribuições.
- Aumentar o tamanho das amostras demonstrou melhorias para o experimento com o *Sqrt* e para uma pequena parte de *Fft1*. No geral, não foram observadas melhorias significativas.
- Em geral, o experimento com o Grupo 02 não trouxe bons resultados e apresentou baixo percentual de bom ajuste EVT, com 15% para as amostras regulares e 23.33% para as amostras extras.

### A.2.3 Grupo 03

O Grupo 03 é composto por três *benchmarks* caracterizados pelo uso intensivo de memória e cálculos. São eles: *Cnt*, *Edn* e *Matmult*.

**A.2.3.1 *Cnt*** conta o número de valores negativos existentes em uma matriz. Para garantir o determinismo sob o ponto de vista do código executado, foram atribuídos valores fixos como entrada para o programa. Como descrito nas Tabelas A.10(b) e A.10(d), os resultados para este experimento apresentaram:

- 65% de amostras regulares sem bom ajuste GEV e 60% sem bom ajuste GPD
- 100% de amostras extras F03 100 mil e F03 500 mil sem bom ajuste GEV/GPD
- 20% de amostras extras F05 100 mil sem bom ajuste GEV e 80% sem bom ajuste GPD

**Tabela A.9** Comparativo de resultados Grupo 02

(a) Resultados observados nas Amostras Regulares apresentando valores de OMin e OMax Ciclos, CV Ins e percentual de bom ajuste EVT, classificação por *benchmark*

<i>Bench.</i>	Ciclos				Ins		Bom ajuste EVT	
	OMin	OMax	CV		CV		GEV	GPD
			Min	Max	Min	Max		
<i>Fibcall</i>	592772	724631	0,095%	0,690%	0,000%	0,001%	37,50%	35,00%
<i>Sqrt</i>	1164	10379	23,387%	26,621%	0,156%	0,188%	0,00%	0,00%
<i>Fft1</i>	295295	354400	0,086%	0,362%	0,008%	0,008%	7,50%	10,00%

(b) Listagem de Amostras Regulares e Extras com qtdd. de padrões identificados e de amostras com bom ajuste EVT. Classificação por cenário e *benchmark*. Para as Amostras Regulares, apresenta-se apenas os cenários com ao menos um bom ajuste EVT, para as Amostras Extras, todos os cenários medidos

<i>Bench.</i>	Amostra	Cenário	Padrão		GEV	GPD	Dietrich	Testada
			01	02				
<i>Fibcall</i>	Regular	F02	0	5	1	1	1	5
		F03	0	5	1	1	1	5
		F04	0	5	2	2	2	5
		F05	0	5	5	5	5	5
		F07	0	5	1	1	1	5
		F08	0	5	5	4	5	5
	Extra	F01_100mil	-	-	-	-	-	-
		F01_500mil	-	-	-	-	-	-
		F05_100mil	0	5	3	3	3	5
		F05_500mil	-	-	-	-	-	-
		F06_100mil	-	-	-	-	-	-
		F06_500mil	-	-	-	-	-	-
<i>Sqrt</i>	Regular	Nenhum	-	-	-	-	-	
	Extra	F01_100mil	-	-	-	-	-	
		F01_500mil	2	3	2	2	2	5
		F08_100mil	3	2	3	3	3	5
		F08_500mil	5	0	5	5	5	5
<i>Fft1</i>	Regular	F02	1	4	1	1	1	5
		F06	2	3	2	2	2	5
		F07	0	5	0	1	1	5
	Extra	F01_100mil	-	-	-	-	-	-
		F01_500mil	-	-	-	-	-	-
		F05_100mil	1	0	1	1	1	5
		F05_500mil	3	0	2	2	3	5
		F06_100mil	-	-	-	-	-	-
		F06_500mil	-	-	-	-	-	-

- 40% de amostras extras F05 500 mil sem bom ajuste GEV e 20% sem bom ajuste GPD

Mais detalhes podem ser observados nos itens a seguir.

## 1. Amostras Regulares

**Ajuste GEV/GPD** Foi possível obter bom ajuste para, ao menos, uma amostra para cada um dos cenários, sendo que nos cenários F05 e F08 foi possível ajustar todas as amostras (Tabela A.10(a)).

**Teste Dietrich** Foi parcialmente coerente com as tentativas de ajuste GEV/GPD. Demonstrou resultado dentro do CI, ou parcialmente dentro, para as amostras com bom ajuste EVT, mas, apresentou uma exceção nas amostras D21 e D51, para as quais o resultado esteve dentro do CI mas não foi possível obter bom ajuste EVT (Tabela A.10(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.10(a)).

**Padrão 02** Observado em todas as amostras (Tabela A.10(a)).

Os modelos que foram classificados como Padrão 02 podem ser observados na Figura A.26, juntamente com seus respectivos gráficos de dispersão. Foi possível obter bom ajuste em todos os casos deste padrão que apresentou uma aparência visual assimétrica positiva, como os destacados na Figura A.26(b), e não foi possível obter bom ajuste para os modelos da Figura A.26(a).

**Amplitude Ciclos**  $OMin = 302266$  e  $OMax = 382352$ , considerando todas as amostras regulares, com ou sem bom ajuste EVT. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.27(a)).

**CV Ciclos** Entre 0.85640% e 0.97954% (Figura A.27(b)).

**CV Ins** Entre 0.00071% e 0.00324%.

## 2. Amostras Extras

Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F03 e F05. A escolha dos cenários deu-se com intuito de checar se um aumento no tamanho da amostra poderia fornecer melhores resultados para F03, que apresentou poucos bons ajustes para as amostras regulares, e averiguar qual seria o comportamento do cenário F05, que pôde obter bons ajustes para a totalidade de amostras regulares.

**Ajuste GEV/GPD** O aumento no tamanho das amostras trouxe piores resultados para o experimento. F03 passou a não ter bons ajustes, e F05 apresentou uma quantidade menor de bons ajustes (Tabela A.2(c)).



**Tabela A.10** *Cnt* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	2	1	5	5
F02	0	5	1	1	2	5
F03	0	5	0	1	2	5
F04	0	5	0	1	4	5
F05	0	5	5	5	5	5
F06	0	5	1	1	2	5
F07	0	5	0	1	4	5
F08	0	5	5	5	5	5
Total	0	40	14	16	29	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)


Padrão		Ajuste	GEV	GPD	Dietrich
01	02				
0,00%	100,00%	<b>Bom</b>	35,00%	40,00%	72,50%
		<b>Sem</b>	65,00%	60,00%	27,50%

(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT


Cenário	Padrão		Bom ajuste EVT			Testadas
	01	02	GEV	GPD	Dietrich	
F03_100mil	0	5	0	0	0	5
F03_500mil	0	5	0	0	0	5
F05_100mil	0	5	4	1	5	5
F05_500mil	0	5	3	4	5	5
Total	0	20	7	5	10	20

(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F03	0%	100%	0%	20%	40%
F03_100mil	0%	100%	0%	0%	0%
F03_500mil	0%	100%	0%	0%	0%
F05	0%	100%	100%	100%	100%
F05_100mil	0%	100%	80%	20%	100%
F05_500mil	0%	100%	60%	80%	100%




(a) Amostras que não tiveram bom ajuste EVT




(b) Amostras que tiveram bom ajuste EVT

**Figura A.26** *Cnt*, Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.27** *Cnt*, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.10(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.10(c)).

**Padrão 02** Não foram observados modelos diferentes dos presentes nas amostras regulares. Como ocorrido nestas, os modelos semelhantes aos observados na Figura A.26(b) puderam ser ajustados, e os semelhantes aos da Figura A.26(a) não puderam.

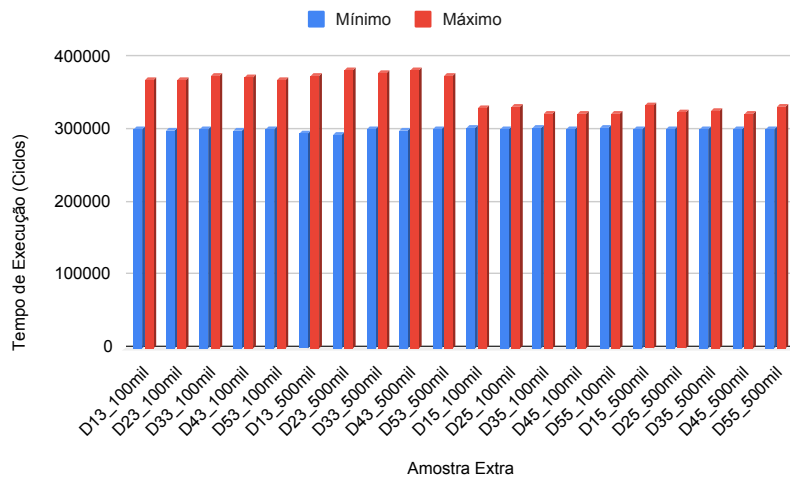
**Amplitude Ciclos** OMin = 295824 e OMax = 384505, considerando todas as amostras extras, com ou sem bom ajuste. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.28(a)).

**CV Ciclos** Entre 0.56526% e 0.95883% (Figura A.28(b)).


**CV Ins** Entre 0.00072% e 0.00231%.

### 3. Considerações sobre o experimento com o *Cnt*

- Foi possível ao menos um bom ajuste em todas as amostras regulares, entretanto, percebe-se que os cenários F05 e F08 foram os que apresentaram maior quantidade de Amostras com bom ajuste EVT. Tais cenários eram os únicos ambientados com *Eth0* e *Wifi* desativados simultaneamente. O fato sinaliza que esses recursos, quando ativos, podem provocar impacto nas medições que trazem prejuízos às distribuições dos dados amostrais e, conseqüentemente, ao bom ajuste EVT. A variação no *Core* parece não ter provocado impactos às medições.
- Aumentar o tamanho das amostras não trouxe benefícios ao experimento. As amostras extras coletadas sob os cenários F03 passaram a não apresentar bons ajustes, enquanto que as amostras extras coletadas sob F05 tiveram menos bons ajustes que os observados nas amostras regulares sob o mesmo cenário.
- As faixas de valores de **Ins** em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares como para as amostras extras, tendo estas bons ajustes ou não. Como houve casos onde foi possível obter bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de **Ins** que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Pôde-se observar que, na maioria das amostras regulares ou amostras extras, as amostras com os mais baixos CVs **Ciclos** tiveram bom ajuste EVT. A duração do tempo de execução (v.a. **Ciclos**) não tem relação com o bom ajuste EVT, mas, tal fato pode demonstrar que amostras que sofreram um menor impacto do ambiente, e conseqüente apresentaram menores valores máximos, tiveram suas distribuições mais estáveis e que isso pode representar melhores condições



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.28** *Cnt*, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

para aplicação da EVT. Entretanto, vale ressaltar que algumas amostras extras com altos Ciclos também puderam ser ajustadas, e algumas com Ciclos mais baixos não puderam.

- Não foram observados histogramas no Padrão 01 e algumas das distribuições observadas no Padrão 02 obtiveram bom ajuste.
- De maneira geral, os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes entre si.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Cnt* trouxe resultados pouco satisfatórios. A média de bons ajustes GEV/GPD ficou em 37.50% para as amostras regulares e 30% para as amostras extras. Tal fato pode indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmark* em questão.

**A.2.3.2 *Edn*** realiza cálculos de filtro de resposta de impulso finito (FIR). Para garantir o determinismo sob o ponto de vista do código executado, foi atribuído um valor fixo para a entrada do programa. Como descrito nas Tabelas A.11(b) e A.11(d), os resultados para este experimento apresentaram:

- 100% de amostras regulares sem bom ajuste GEV/GPD
- 100% de amostras extras F02 100 mil e F02 500 mil sem bom ajuste GEV/GPD
- 80% de amostras extras F08 100 mil sem bom ajuste GEV/GPD
- 80% de amostras extras F08 500 mil sem bom ajuste GEV/GPD e 60% sem bom ajuste GEV/GPD

Mais detalhes podem ser observados nos itens a seguir.

#### 1. Amostras Regulares

**Ajuste GEV/GPD** Não foi possível obter bom ajuste em nenhuma das amostras regulares (Tabela A.11(a)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.11(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.11(a)).

**Padrão 02** Observado em todas as amostras (Tabela A.11(a)).

Os modelos que foram classificados como Padrão 02 podem ser observados na Figura A.29, juntamente com seus respectivos gráficos de dispersão. Não foi possível obter bom ajuste em todos os casos deste padrão.

**Tabela A.11** *Edn* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	0	0	0	5
F02	0	5	0	0	0	5
F03	0	5	0	0	0	5
F04	0	5	0	0	0	5
F05	0	5	0	0	0	5
F06	0	5	0	0	0	5
F07	0	5	0	0	0	5
F08	0	5	0	0	0	5
Total	0	40	0	0	0	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)


Padrão		Ajuste	GEV	GPD	Dietrich
01	02				
0,00%	100,00%	<b>Bom</b>	0,00%	0,00%	0,00%
		<b>Sem</b>	100,00%	100,00%	100,00%

(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT			Testadas
	01	02	GEV	GPD	Dietrich	
F02_100mil	0	5	0	0	0	5
F02_500mil	0	5	0	0	2	5
F08_100mil	1	4	1	1	1	5
F08_500mil	1	4	1	2	2	5
Total	2	18	2	3	5	20

(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F02	0%	100%	0%	0%	0%
F02_100mil	0%	100%	0%	0%	0%
F02_500mil	0%	100%	0%	0%	40%
F08	0%	100%	0%	0%	0%
F08_100mil	20%	80%	20%	20%	20%
F08_500mil	20%	80%	20%	40%	40%



**Figura A.29** *Edn*, Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados

**Amplitude Ciclos**  $O_{Min} = 193942$  e  $O_{Max} = 234651$ , considerando todas as amostras regulares, com ou sem bom ajuste EVT. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.30(a)).

**CV Ciclos** Entre 0.49939% e 0.58455% (Figura A.30(b)).

**CV Ins** Entre 0.00102% e 0.00109%.

## 2. Amostras Extras

Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F02 e F08. A escolha dos cenários deu-se com intuito de checar se um acréscimo no tamanho da amostra poderia fornecer melhores resultados que os obtidos nas medições regulares, que não tiveram bom ajuste EVT.

**Ajuste GEV/GPD** O aumento no tamanho das amostras trouxe resultados positivos para F08, que passou a ajustar algumas amostras, mas não provocou alterações em F02, que seguiu sem bons ajustes (Tabela A.11(c)).


**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.11(c)).

- Dados amostrais


**Padrão 01** Observado em duas amostras, todas com bom ajuste EVT (Tabela A.11(c)).

**Padrão 02** Observado em quase todas as amostras extras (Tabela A.11(c)). Foram observados modelos diferentes dos presentes nas amostras regulares, classificados como Padrão 02 (Figura A.31). Foi possível obter bom ajuste em todos os casos que apresentou uma aparência visual assimétrica positiva, como os destacados na Figura A.31(b). Um destes modelos teve uma aparência muito próxima ao do Padrão 01, mas a aparência com visual com leve assimetria o fez ser classificado como Padrão 02. Os demais modelos (Figura A.31(a)) não puderam ser ajustados.






(a) Amplitude Ciclos




(b) CV Ciclos

**Figura A.30** *Edn*, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT



(a) Amostra que não teve bom ajuste EVT



(b) Amostra que teve bom ajuste EVT

**Figura A.31** *Edn*, Amostras Extras - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT

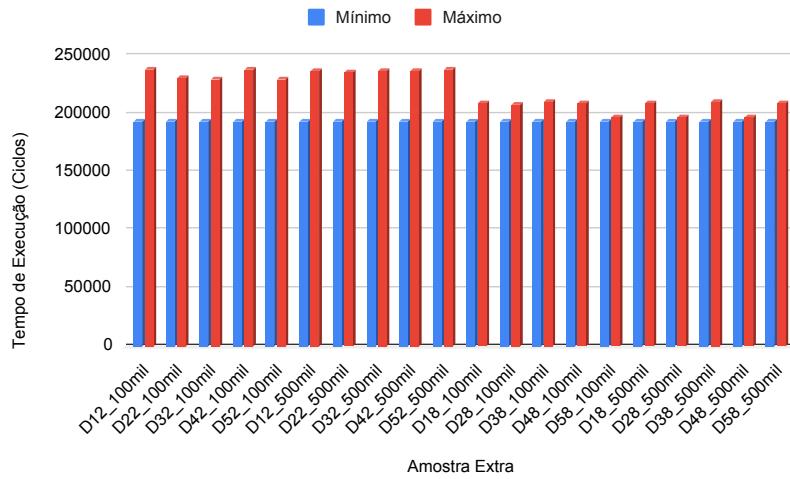
**Amplitude Ciclos** OMin = 193946 e OMax = 239461, considerando todas as amostras extras, com ou sem bom ajuste. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.32(a)).

**CV Ciclos** Entre 0.17218% e 0.55885% (Figura A.32(b)).


**CV Ins** Entre 0.00102% e 0.00108% .

### 3. Considerações sobre o experimento com o *Edn*

- Os CVs **Ciclos** se mantiveram em níveis aceitáveis. Percebe-se, entretanto, que eles foram mais baixos nas amostras que puderam ser ajustadas, referentes às amostras coletadas sob o cenário F08 (sem *Eth0* e *Wifi*). Não há relação entre **Ciclos** com o bom ajuste EVT, mas, tal fato pode demonstrar que amostras que sofreram um menor impacto do ambiente, e conseqüentemente apresentaram menores OMax, tiveram suas distribuições mais estáveis e que isso pode representar melhores condições para a aplicação da EVT. Não foram percebidos impactos relevantes relacionados à variação do *Core*.
- Aumentar o tamanho das amostras foi positivo para parte do experimento. Bons ajustes passaram a ser possíveis para as amostras coletadas sob o cenário F08 mas, não foram observadas melhorias para as sob F02.
- As faixas de valores de **Ins** em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.32** *Edn*, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

como para as amostras extras, tendo estas bons ajustes ou não. Como houve casos onde foi possível obter bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de *Ins* que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.

- Todas as amostras com histogramas no Padrão 01 puderam ser ajustadas. Parte das amostras no Padrão 02 puderam ser ajustadas, parte não.
- Os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Edn* trouxe resultados pouco satisfatórios. A média de bons ajustes GEV/GPD ficou em 0% para as amostras regulares e 13% para as amostras extras. Tal fato pode indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmark* em questão.

**A.2.3.3 *Matmult*** realiza a multiplicação de duas matrizes. Para garantir o determinismo sob o ponto de vista do código executado, foram atribuídos valores fixos à entrada do programa. Como descrito nas Tabelas A.12(b) e A.12(d), os resultados para este experimento apresentaram:

- 100% de amostras regulares sem bom ajuste GEV/GPD
- 60% de amostras extras F05 100 mil sem bom ajuste GEV/GPD
- 100% de amostras extras F05 500 mil, F08 100 mil e F08 500 mil sem bom ajuste GEV/GPD

Mais detalhes podem ser observados nos itens a seguir.

#### 1. Amostras Regulares

**Ajuste GEV/GPD** Não foi possível obter bom ajuste para todas as amostras regulares coletadas (Tabela A.12(a)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.12(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.12(a)).

**Tabela A.12** *Matmult* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	0	0	0	5
F02	0	5	0	0	0	5
F03	0	5	0	0	0	5
F04	0	5	0	0	0	5
F05	0	5	0	0	0	5
F06	0	5	0	0	0	5
F07	0	5	0	0	0	5
F08	0	5	0	0	0	5
Total	0	40	0	0	0	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)

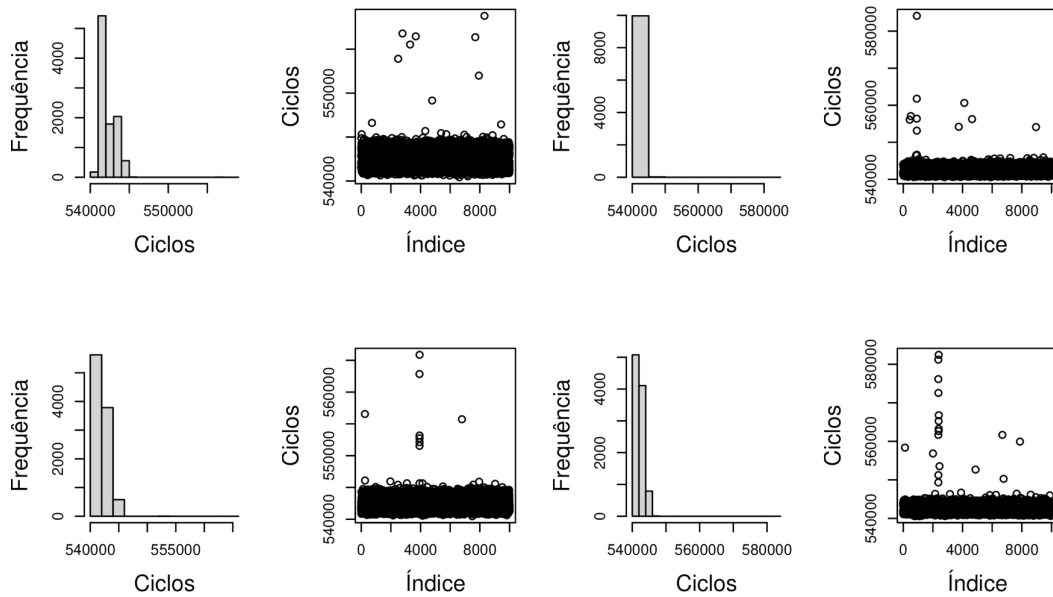
Padrão		Ajuste	GEV	GPD	Dietrich
<b>01</b>	<b>02</b>	<b>Bom</b>	0,00%	0,00%	0,00%
0,00%	100,00%	<b>Sem</b>	100,00%	100,00%	100,00%

(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT			Testadas
	1	2	GEV	GPD	Dietrich	
F05_100mil	0	5	2	2	2	5
F05_500mil	0	5	0	0	0	5
F08_100mil	0	5	0	0	0	5
F08_500mil	0	5	0	0	0	5
Total	0	20	2	2	2	20

(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F05	0%	100%	0%	0%	0%
F05_100mil	0%	100%	40%	40%	40%
F05_500mil	0%	100%	0%	0%	0%
F08	0%	100%	0%	0%	0%
F08_100mil	0%	100%	0%	0%	0%
F08_500mil	0%	100%	0%	0%	0%



**Figura A.33** *Matmult*, Amostras Regulares - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados

**Padrão 02** Observado em todas as amostras (Tabela A.12(a)) sem bom ajuste EVT.

Os modelos que foram classificados como Padrão 02 podem ser observados na Figura A.33, juntamente com seus respectivos gráficos de dispersão.

**Amplitude Ciclos** OMin = 540283 e OMax = 602303, considerando todas as amostras regulares, com ou sem bom ajuste EVT. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.34(a)).

**CV Ciclos** Entre 0.18334% e 0.31538% (Figura A.34(b)).


**CV Ins** Entre 0.00042% e 0.00048%.

## 2. Amostras Extras


Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F05 e F08. A escolha dos cenários deu-se com intuito de checar se um aumento no tamanho da amostra poderia fornecer melhores resultados, pois as amostras regulares destes cenários não tiveram bom ajuste EVT.

**Ajuste GEV/GPD** O aumento no tamanho das amostras trouxe poucos resultados positivos. Com exceção de duas amostras em F05 10 mil, todas as demais extras não tiveram bom ajuste (Tabela A.12(c)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.12(c)).



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.34** *Matmult*, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

- Dados amostrais

**Padrão 01** Não observado (Tabela A.12(c)).

**Padrão 02** Observado em todas as amostras extras (Tabela A.12(c)). Modelos diferentes de histograma encontrados nas amostras regulares apareceram nas amostras extras (Figura A.35). Não foi possível obter bom ajuste para os modelos ilustrados na Figura A.35(a) mas foi possível obter bom ajuste no modelo da Figura A.35(b), que apresentava histograma no Padrão 01. A aparência visual com leve assimetria positiva deste modelo o fez ser classificado como Padrão 02.

**Amplitude Ciclos**  $O_{Min} = 540120$  e  $O_{Max} = 607753$ , considerando todas as amostras extras, com ou sem bom ajuste. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.36(a)).

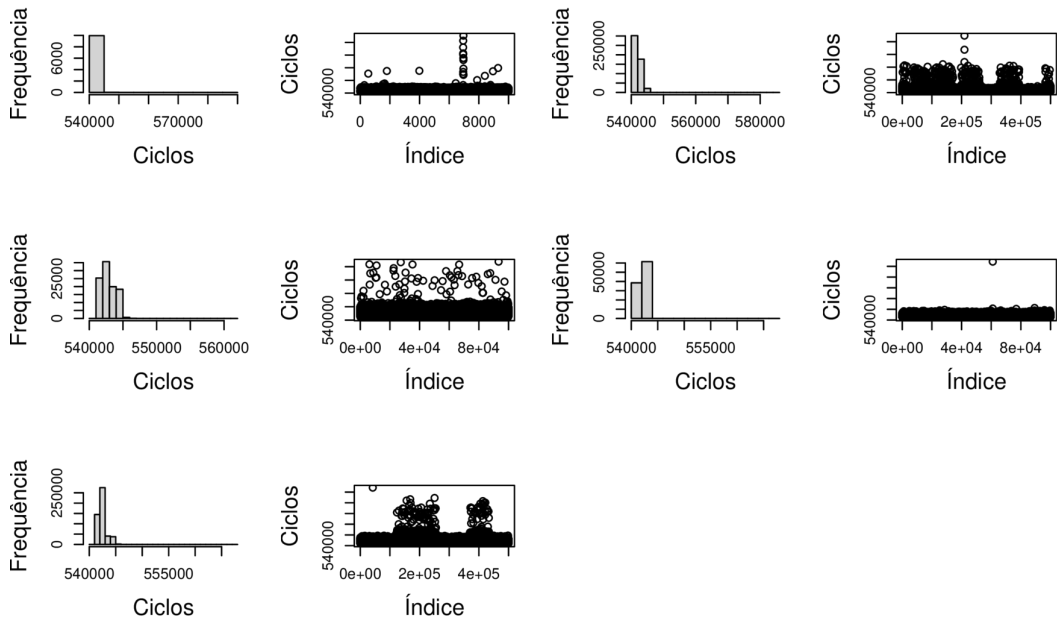
**CV Ciclos** Entre 0.067% e 0.193% (Figura A.36(b)).

**CV Ins** Entre 0.00049% e 0.00051%.


### 3. Considerações sobre o experimento com o *Matmult*

- Não foi possível identificar impactos em função da variação dos cenários, pois não houve bom ajuste nas amostras regulares e poucos bons ajustes nas amostras extras.
- Aumentar o tamanho das amostras trouxe poucas melhorias ao experimento pois demonstrou muito baixo acréscimo de bons ajustes para as amostras coletadas sob o cenário F05, e não demonstrou alterações para as sob F08.
- As faixas de valores de **Ins** em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares como para as amostras extras, tendo estas bons ajustes ou não. Como houve casos onde foi possível obter bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de **Ins** que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Os bons ajustes foram percebidos nas amostras extras com os mais baixos CVs **Ciclos**. Não há relação entre a duração do tempo de execução (v.a. **Ciclos** e o bom ajuste EVT, mas, tal fato pode demonstrar que as amostras que sofreram um menor impacto do ambiente, e conseqüentemente apresentaram menores valores máximos, tiveram suas distribuições mais estáveis e que isso pode representar melhores condições para a aplicação da EVT. Observou-se este mesmo comportamento nas amostras regulares, mas, sob outro viés. Não foi possível obter bom ajuste EVT em nenhuma amostra regular, e observou-se que os CVs mais baixos estavam na mesma faixa de valor que os mais altos das amostras extras, sendo que foi semelhante a faixa de valores máximos e mínimos das amostras regulares e amostras extras.






(a) Amostras que não tiveram bom ajuste EVT




(b) Amostra que teve bom ajuste EVT

**Figura A.35** *Matmult*, Amostras Extras - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.36** *Matmult*, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

- Não foram observados histogramas no Padrão 01. Algumas das distribuições observadas no Padrão 02 obtiveram bom ajuste, outras não.
- De maneira geral, os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes entre si.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Matmult* trouxe resultados pouco satisfatórios. A média de bons ajustes GEV/GPD ficou em 0% para as amostras regulares e 10% para as amostras extras. Tal fato pode indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmark* em questão.

**A.2.3.4 Comparativo Grupo 03** A Tabela A.13 demonstra alguns dos resultados observados para os experimentos do Grupo 03. Com base nestes e nos dados apresentados ao longo da seção, pode-se observar que:

- Não foi observado um comportamento único com relação aos impactos sofridos pela variação nos cenários de testes e taxas de bons ajustes EVT que pudesse ser classificado como um padrão de resultado para o grupo.
- Não foi percebido um comportamento padrão nos experimentos deste grupo com relação aos bons ajustes e CVs, ou relacionados a impactos nas medições ocasionados pela variação dos cenários.
- Percebe-se um baixo CV para *Ins* em todos os experimentos. Como há bons ajustes em várias das amostras coletadas, o fato demonstra que as variações em *Ciclos* não foram impactados de forma significativa por um acréscimo de *Ins* ocasionado por contadores de desempenho.
- Os modelos que apresentaram distribuições com aparência visual no Padrão 01 apresentam bom ajuste EVT. As distribuições no Padrão 02 puderam ou não ser ajustadas, demonstrando que pode ou não haver boa qualidade de ajuste EVT para determinadas distribuições.
- Aumentar o tamanho das amostras não demonstrou certeza de melhorias ao experimento. Em alguns casos trouxe benefícios, em outros, malefícios, e, em outros, não provocou mudanças, deixando a escolha do tamanho adequado de uma amostra como um evidente problema em aberto.
- O experimento com o Grupo 01 não trouxe bons resultados e apresentou baixo percentual geral de bom ajuste EVT, com 12.5% de bom ajuste para as amostras regulares e 17.67% de bom ajuste para as amostras extras.

**Tabela A.13** Comparativo de resultados Grupo 03

(a) Resultados observados nas Amostras Regulares apresentando valores de OMin e OMax Ciclos, CV Ins e percentual de bom ajuste EVT, classificação por *benchmark*

<i>Benchmark</i>	Ciclos				Ins		Bom ajuste EVT	
	OMin	OMax	CV		CV		GEV	GPD
			Min	Max	Min	Max		
<i>Edn</i>	193942	234651	0,4994%	0,5846%	0,0010%	0,0011%	0,00%	0,00%
<i>Cnt</i>	302266	382352	0,8564%	0,9795%	0,0007%	0,0032%	35,00%	40,00%
<i>Matmult</i>	540283	602303	0,1833%	0,3154%	0,0004%	0,0005%	0,00%	0,00%

(b) Listagem de Amostras Regulares e Extras com qtdd. de padrões identificados e de amostras com bom ajuste EVT. Classificação por cenário e *benchmark*. Para as Amostras Regulares, apresenta-se apenas os cenários com ao menos um bom ajuste EVT, para as Amostras Extras, todos os cenários medidos

<i>Benchmark</i>	Amostra	Cenário	Padrão		GEV	GPD	Dietrich	Testadas
			01	02				
<i>Cnt</i>	Regular	F01	0	5	2	1	5	5
		F02	0	5	1	1	2	5
		F03	0	5	0	1	2	5
		F04	0	5	0	1	4	5
		F05	0	5	5	5	5	5
		F06	0	5	1	1	2	5
		F07	0	5	0	1	4	5
		F08	0	5	5	5	5	5
		F08	0	5	1	1	1	5
	Extra	F03_100mil	-	-	-	-	-	-
F03_500mil		-	-	-	-	-	-	
F05_100mil		0	5	4	1	5	5	
F05_500mil		0	5	3	4	5	5	
<i>Edn</i>	Regular	Nenhum	-	-	-	-	-	
	Extra	F02_100mil	-	-	-	-	-	-
		F02_500mil	-	-	-	-	-	-
		F08_100mil	1	4	1	1	1	5
		F08_500mil	1	4	1	2	2	5
<i>Matmult</i>	Regular	Nenhum	-	-	-	-	-	
	Extra	F05_100mil	0	5	2	2	2	5
		F05_500mil	-	-	-	-	-	-
		F08_100mil	-	-	-	-	-	-
		F08_500mil	-	-	-	-	-	-

### A.2.4 Grupo 04

O Grupo 04 é composto pelos *benchmarks Binary Search* e *Fibcall*, caracterizados pela processamento com computação e acesso à baixa memória (ANDRADE et al., 2021). A seguir são apresentados os resultados para o *Binary Search* e comparativo entre os *benchmarks* do grupos. Os resultados do *Fibcall* podem ser retomados na Seção A.2.2.3.

**A.2.4.1 *Binary Search*** é um eficiente algoritmo para encontrar um item em uma lista ordenada. Para garantir o determinismo sob o ponto de vista do código executado, foi atribuído um valor fixo à entrada do programa. Como descrito nas Tabelas A.14(b) e A.14(d), os resultados para este experimento apresentaram:

- 82.50% de amostras regulares sem bom ajuste GEV/GPD
- 60% de amostras extras F01 100 mil sem bom ajuste GEV/GPD
- 80% de amostras extras F01 500 mil sem bom ajuste GEV/GPD
- 100% de amostras extras F08 100 mil sem bom ajuste GEV e 80% sem bom ajuste GPD
- 80% de amostras extras F08 500 mil sem bom ajuste GEV/GPD

Mais detalhes podem ser observados nos itens a seguir.

#### 1. Amostras Regulares

**Ajuste GEV/GPD** Foi possível obter bom ajuste em ao menos uma das amostras dos cenários F01, F02, F04, F06 e F08. As demais não apresentaram bons ajustes (Tabela A.14(a)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.14(a)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.14(a)).

**Padrão 02** Todos as amostras apresentaram um mesmo modelo de histograma. Este foi classificado como Padrão 02 e pode ser observado na Figura A.37 juntamente com seu respectivo gráfico de dispersão. Em alguns casos foi possível obter bom ajuste, em outros não.

**Amplitude Ciclos**  $OMin = 555$  e  $OMax = 9610$ , considerando todas as amostras regulares, com ou sem bom ajuste EVT. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos (Figura A.38(a)).

**CV Ciclos** Entre 35.91922% e 40.00652% (Figura A.38(b)).

**CV Ins** Entre 0.08631% e 0.12758%.

**Tabela A.14** *Binary Search* - Percentuais finais e quantidade de modelos com bom ajuste GEV, GPD e em teste Dietrich, e de histogramas no Padrão 01 e Padrão 02, 5 amostras testadas por cenário

(a) Amostras Regulares - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		GEV	GPD	Dietrich	Testadas
	01	02				
F01	0	5	1	1	2	5
F02	0	5	2	2	2	5
F03	0	5	0	0	1	5
F04	0	5	1	1	1	5
F05	0	5	0	0	1	5
F06	0	5	2	2	2	5
F07	0	5	0	0	0	5
F08	0	5	1	1	1	5
Total	0	40	7	7	10	40

(b) Amostras Regulares - Percentuais de padrões identificados e de ajustes EVT (bons ou sem ajuste)


Padrão		Ajuste	GEV	GPD	Dietrich
<b>01</b>	<b>02</b>	<b>Bom</b>	17,50%	17,50%	25,00%
0,00%	100,00%	<b>Sem</b>	82,50%	82,50%	75,00%

(c) Amostras Extras - Qtdd. de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT			Testadas
	01	02	GEV	GPD	Dietrich	
F01_100mil	1	4	2	2	2	5
F01_500mil	2	3	1	1	2	5
F08_100mil	0	5	0	1	1	5
F08_500mil	1	4	1	1	1	5
Total	4	16	4	5	6	20

(d) Amostras Extras - Percentuais de padrões identificados e de bons ajustes EVT

Cenário	Padrão		Bom ajuste EVT		
	01	02	GEV	GPD	Dietrich
F01	0%	100%	20%	20%	40%
F01_100mil	20%	80%	40%	40%	40%
F01_500mil	40%	60%	20%	20%	40%
F08	0%	100%	20%	20%	20%
F08_100mil	0%	100%	0%	20%	20%
F08_500mil	20%	80%	20%	20%	20%



**Figura A.37** *Binary Search* - Modelo de histograma classificado como Padrão 02 e dispersão dos dados

## 2. Amostras Extras

Amostras extras com tamanhos 100 mil e 500 mil foram coletadas para os cenários F01 e F08. A escolha dos cenários deu-se com intuito de checar se um acréscimo no tamanho da amostra poderia fornecer melhores resultados, pois houve apenas um bom ajuste nas amostras regulares para cada um destes cenários.

**Ajuste GEV/GPD** O aumento no tamanho das amostras não trouxe melhoria significativa para o experimento. O cenário F01 100 mil teve uma leve melhora, com duas amostras com bom ajuste, ao invés de uma, e os demais seguiram com apenas uma amostra com bom ajuste (Tabela A.14(c)).

**Teste Dietrich** Foi coerente com as tentativas de ajuste GEV/GPD (Tabela A.14(c)).

- Dados amostrais

**Padrão 01** Não observado (Tabela A.14(c)).

**Padrão 02** Observado em todas as amostras extras (Tabela A.14(c)). Foram observados diferentes modelos para o Padrão 02, o primeiro (Figura A.39(a)) sem bom ajuste EVT, e, o segundo, com bom ajuste (Figura A.39(b)).


**Amplitude Ciclos**  $OMin = 549$  e  $OMax = 10022$ , considerando todas as amostras extras, com ou sem bom ajuste. Como esperado, percebeu-se estabilidade nos valores mínimos e oscilações nos máximos, sendo que estas foram acima do esperado (Figura A.40(a)).

**CV Ciclos** Entre 21.37569% e 40.77344%, muito acima do considerado normal (Figura A.40(b)).


**CV Ins** Entre 0.09392% e 0.11598%.

## 3. Considerações sobre o experimento com o *Binary Search*

- As faixas de valores dos CVs tiveram uma oscilação muito acima do esperado, tanto para as amostras regulares, como para as amostras extras.




(a) Amplitude Ciclos




(b) CV Ciclos

**Figura A.38** *Binary Search*, Amostras Regulares - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT






(a) Amostras que não tiveram bom ajuste EVT




(b) Amostras que tiveram bom ajuste EVT

**Figura A.39** *Binary Search*, Amostras Extras - Modelos de histogramas enquadrados como Padrão 02 e dispersão dos dados, classificados por amostras que tiveram ou não bom ajuste EVT



(a) Amplitude Ciclos



(b) CV Ciclos

**Figura A.40** *Binary Search*, Amostras Extras - Amplitude Ciclos e CVs Ciclos de amostras que tiveram ou não bom ajuste EVT

- De maneira geral, *Ciclos* teve baixos valores. O fato pode dificultar a avaliação dos impactos de *Eth0*, *Wifi* e *Core*, pois, pode não haver tempo suficiente para esses recursos se manifestarem a ponto de impactar as medições. Assim, como esperado, não foi possível observar impactos nas variações dos recursos, com bons ajustes (e sem bons ajustes) sendo observados em diferentes cenários, sob diferentes tamanhos de amostras.
- Aumentar o tamanho das amostras não trouxe melhorias aparentes ao experimento. A quantidade de amostras extras que tiveram bom ajuste (ou sem bom ajuste) manteve-se praticamente de forma semelhante às observadas nas amostras regulares.
- As faixas de valores de *Ins* em cada amostra, e seus CVs, se mantiveram estáveis e/ou dentro de níveis baixos e aceitáveis, tanto para as amostras regulares como para as amostras extras, tendo estas bons ajustes ou não. Como houve casos onde foi possível obter bom ajuste GEV/GPD, pode-se constatar que a variação na contagem de *Ins* que ocorre nas medições via contadores de desempenho não afetou de forma significativa o número real de instruções do programa, apontando, assim, para a confiabilidade do mecanismo de medição utilizado.
- Não foram observados histogramas no Padrão 01, entretanto, algumas das distribuições observadas no Padrão 02 obtiveram bom ajuste.
- Os resultados atestando ou negando a possibilidade de obter bom ajuste via os métodos GEV e GPD, e teste Dietrich, foram coerentes entre si.
- Observou-se coerência entre as estimativas obtidas para a probabilidade de excedência de  $10^{-5}$  e os máximos medidos nas amostras com bom ajuste EVT (Apêndice B).
- Por fim, pode-se afirmar que, como um todo, o experimento com o *Binary Search* trouxe resultados pouco satisfatórios. A média de bons ajustes GEV/GPD ficou em 17.50% para as amostras regulares e 23% para as amostras extras. Tal fato pode indicar problemas em algumas das fases de aplicação EVT no contexto de derivação de pWCET, para o conjunto plataforma-*benchmark* em questão.

**A.2.4.2 Comparativo Grupo 04** A Tabela A.15 demonstra alguns dos resultados observados para os experimentos do Grupo 04. Com base nestes e nos dados apresentados ao longo da seção, pode-se observar que:

- Não foi observado um comportamento único com relação aos impactos sofridos pela variação nos cenários de testes e taxas de bons ajustes EVT que pudesse ser classificado como um padrão de resultado para o grupo.
- Pode-se observar que amostras tiveram bons ajustes em diferentes cenários. Desta forma, os experimentos não destacaram impactos nas medições resultantes da variação dos recursos avaliados.

- Percebe-se que os CVs *Ciclos* se mantiveram acima do desejado no caso do *Binary Search*. Este fato não impossibilitou que algumas amostras pudessem ter bom ajuste.
- Percebe-se um baixo CV para *Ins* em todos os experimentos. Como há bom ajuste EVT em algumas das amostras coletadas, o fato demonstra que as variações em *Ciclos* não foram impactadas de forma significativa por um acréscimo no número de instruções ocasionado por contadores de desempenho.
- Como há estabilidade em *Ins* e determinismo sob o ponto de vista do código executado, sugere-se que as oscilações em *Ciclos* estão diretamente relacionadas aos impactos do ambiente.
- Não foram observadas distribuições com aparência do Padrão 01. Houve modelos no Padrão 02 que puderam obter bom ajuste e outros que não puderam.
- Aumentar o tamanho das amostras não trouxe melhorias significativas para o experimento.
- O experimento com o Grupo 04 não trouxe bons resultados e apresentou baixo percentual de bom ajuste EVT, com 26.92% para as amostras regulares e 16.5% para as amostras extras.

**Tabela A.15** Comparativo de resultados Grupo 04


(a) Resultados observados nas Amostras Regulares apresentando valores de OMin e OMax Ciclos, CV Ins e percentual de bom ajuste EVT, classificação por *benchmark*

<i>Benchmark</i>	Ciclos				Ins CV		Bom ajuste EVT	
	OMin	OMax	Min	Max	Min	Max	GEV	GPD
<i>Binary Search</i>	555	9610	35,919%	40,007%	0,086%	0,128%	17,50%	17,50%
<i>Fibcall</i>	592772	724631	0,095%	0,690%	0,000%	0,001%	37,50%	35,00%

(b) Listagem de Amostras Regulares e Extras com qtdd. de padrões identificados e de amostras com bom ajuste EVT. Classificação por cenário e *benchmark*. Para as Amostras Regulares, apresenta-se apenas os cenários com ao menos um bom ajuste EVT, para as Amostras Extras, todos os cenários medidos

<i>Benchmark</i>	Amostra	Cenário	Padrão		GEV	GPD	Dietrich	Testadas
			01	02				
<i>B. Search</i>	Regular	F01	0	5	1	1	2	5
		F02	0	5	2	2	2	5
		F04	0	5	1	1	1	5
		F06	0	5	2	2	2	5
		F08	0	5	1	1	1	5
	Extra	F01_100mil	0	5	2	2	2	5
		F01_500mil	0	5	1	1	2	5
		F08_100mil	0	5	0	1	1	5
		F08_500mil	0	5	1	1	1	5
<i>Fibcall</i>	Regular	F02	0	5	1	1	1	5
		F03	0	5	1	1	1	5
		F04	0	5	2	2	2	5
		F05	0	5	5	5	5	5
		F07	0	5	1	1	1	5
		F08	0	5	5	4	5	5
	Extra	F01_100mil	-	-	-	-	-	-
		F01_500mil	-	-	-	-	-	-
		F05_100mil	0	5	3	3	3	5
		F05_500mil	-	-	-	-	-	-
		F06_100mil	-	-	-	-	-	-
		F06_500mil	-	-	-	-	-	-





**NÍVEL DE RETORNO ESTIMADO PARA A  
PROBABILIDADE DE EXCEDÊNCIA  $10^{-5}$**

<b>LEGENDA</b>	
<b>Exemplo</b>	
<b>D11</b>	Amostra 01 de medição ambientada no Cenário F01 Amostra Regular
<b>D43_100mil</b>	Amostra 04 de medição ambientada no Cenário F03 Amostra Extra de tamanho 100 mil
<b>D25_500mil</b>	Amostra 02 de medição ambientada no Cenário F05 Amostra Extra de tamanho 500 mil

**BUBBLE SORT****Amostras Regulares**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D11	0.8831606	28869253	30738146 220132807 480427083
D21	0.8625099	28845659	31178030 232738519 693863148
D31	0.8702737	28875760	32597095 228846983 563937090
D41	0.8949909	29029046	31515532 208641786 488444533
D51	0.8890262	28982107	31159933 203201334 469883584

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D12	0.8280942	29083649	33818005 289230760 1177518688
D22	0.7887693	29087168	37261492 304041786 1243272216
D32	0.7812367	29095876	35165006 270025451 1009820725
D42	0.8312745	29079821	33694734 286396599 706846778
D52	0.7907541	29095576	33820104 309406036 1136966651

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D13	0.8702314	29030095	32944238 265419205 652778811
D23	0.8906858	29078419	31507488 241196481 591789135
D33	0.8763034	29110605	31591917 267727412 754241724
D43	0.9051268	28984187	31295411 208582833 508845456
D53	0.8478318	29039792	32891792 297965988 810306984

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D14	0.7979733	28901503	33616951 228805845 796091186
D24	0.8153951	28854346	33406130 241571297 800149563
D34	0.8134325	28990611	33307378 245217353 865026124
D44	0.8157229	28857905	32845252 232622182 844732361
D54	0.8284896	28852901	32452785 217006042 622284792

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15	-0.131794774	27951807	27951449 27952534 27955033
D25	-0.004631662	27952102	27951853 27954280 27961881
D35	0.953559801	28814200	28314537 54764413 72279752
D45	0.081925370	27949725	27949857 27952047 27957945
D55	-0.160887670	27952546	27951338 27952610 27955044



Grupo 01

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D16	0.8333672	29019796	32097996	241084795 588852616
D26	0.8249955	29032931	33065282	262813916 913158692
D36	0.8008217	29083080	33640457	249801932 999080241
D46	0.8069885	29084180	33726906	286968293 900786297
D56	0.7800317	28974701	36042053	257810827 951125209

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D17	0.8900622	29039176	31057337	230158662 560518447
D27	0.8814237	29036788	30437507	224752397 408441136
D37	0.9129963	29060362	30766991	183150307 313486069
D47	0.8976879	29052755	31317000	210364437 434268943
D57	0.8769727	29132891	31802919	277695716 802066658

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D18	-0.01395282	27952724	27952470	27954906 27960355
D28	-0.10052841	27952313	27952363	27953750 27957560
D38	0.88821979	28276714	28221323	42881080 71004356
D48	0.47137276	27953544	27973115	28150416 29142989
D58	0.06738848	27955648	27956410	27962806 27983613

**Amostras Extras**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D11_100mil	0.18002207	29048174	29064201	31778601 83741486
D21_100mil	-0.28488066	29050992	29000712	29156010 31142573
D31_100mil	0.06464724	29048836	28997297	30018327 61273106
D41_100mil	-0.04161057	29059245	28986137	29602382 41585013
D51_100mil	-0.19519842	29173025	28992259	29285574 33256724

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D11_500mil	-0.181955825	29080838	29109344	29270614 29714779
D21_500mil	-0.075648304	29091450	29134101	29455723 30412102
D31_500mil	-0.060757954	29155889	29174007	29525168 30549025
D41_500mil	-0.140935360	29044652	29095524	29266451 29802958
D51_500mil	-0.002373867	29070770	29133839	29520119 31016294

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D15_100mil	0.7878390	27975746	27955608	35830030 56945866
D25_100mil	0.9730039	28450010	27958081	132559971 186518095
D35_100mil	0.9733992	28905272	27968677	225615135 249428844
D45_100mil	0.9717854	28866114	27965085	225896437 337756661
D55_100mil	0.9611233	28152539	27957412	82618015 92823249

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D15_500mil	0.8491289	28130596	28279807	67632355 145020670

D25_500mil	0.9032761	28659685	28365908	120075430	208100638
D35_500mil	0.8584956	29118421	29296337	228062196	680039993
D45_500mil	0.8788973	28629077	28497434	123896324	304623324
D55_500mil	0.8237728	28674513	29227938	140212516	383390850

## MERGE SORT

## Amostras Regulares

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D11	0.6208745	890721	887876.4 2084091 7993681
D21	0.6617210	894352	908084.0 2600039 11278109
D31	0.6949480	894332	920392.4 2820216 16059628
D41	0.6881447	897225	928450.4 2967769 14632277
D51	0.8178838	918791	989604.4 7272524 23387057

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D12	0.7535434	922772	956359.9 5050606 15545175
D22	0.7981738	921159	1000063.2 7302731 39872312
D32	0.8221838	917030	1035846.4 8259311 28627710
D42	0.7474084	909005	919310.5 4221453 18821013
D52	0.6925265	934570	934021.6 3458423 11360674

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D13	0.7997960	920322	1001000.5 7677053.1 17934433
D23	0.6773194	902631	908975.1 2776310.0 14377849
D33	0.6686614	919706	943878.5 3062641.8 14732362
D43	0.3051809	825540	836429.4 890247.4 1117584
D53	0.7260781	909782	944548.0 3573164.5 14184266

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D14	0.7189641	894916	977114.2 4444847.3 20184112
D24	0.2693875	823551	829850.3 862749.8 1003754
D34	0.5701553	885592	871931.9 1703162.0 7910294
D44	0.6760201	888651	908140.9 2687310.6 17038758
D54	0.7417026	887861	960192.5 4675872.0 26573853

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15	0.2903859	828323	834316.5 886463.5 1086143.9
D25	0.1514986	824722	828034.6 844303.6 897512.9
D35	0.3194009	827380	835803.2 907370.9 1390706.2
D45	0.1354325	823243	825619.9 838070.9 877582.6
D55	0.2438804	826323	831190.0 864084.7 1039376.7

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D16	0.86236003	942457	1116333.1 16550282.3 40133086.7

Grupo 01

<b>D26</b>	0.71951773	929780	937169.8	4025386.4	16133926.8
<b>D36</b>	0.84085961	924372	1087366.6	13856308.3	38670063.0
<b>D46</b>	0.85076626	934786	1078474.5	12858155.2	40434080.5
<b>D56</b>	0.07052504	822326	823612.4	829398.9	844247.5

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D17</b>	0.7043248	939213	934226.4	4113564.5	21450073.4
<b>D27</b>	0.7413359	926805	920626.7	4320621.7	16815900.6
<b>D37</b>	0.8120771	919331	1009507.3	8506603.5	28024933.4
<b>D47</b>	0.6711197	907160	904132.8	2881222.6	13123332.4
<b>D57</b>	0.2253671	824908	826615.8	848915.8	950538.9

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D18</b>	0.20399458	824174	827954.7	847717.9	965905.5
<b>D28</b>	0.10818150	826529	827451.5	840141.4	889176.8
<b>D38</b>	0.19814966	824293	828067.7	846092.8	921609.7
<b>D48</b>	0.05630541	823693	824342.2	831080.5	851671.9
<b>D58</b>	0.19544460	824682	827145.9	847160.4	932270.1

**Amostras Extras**

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D11_100mil</b>	0.7769200	898073	1344665	17919394	69647723
<b>D21_100mil</b>	0.7367498	914495	1380273	18401979	86256596
<b>D31_100mil</b>	0.6638844	895691	1397337	12373852	67636603
<b>D41_100mil</b>	0.7024366	909047	1384605	13067706	56182185
<b>D51_100mil</b>	0.6540860	911109	1469827	11510944	66229214

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D11_500mil</b>	0.5567860	953545	2827896	9740933	36887333
<b>D21_500mil</b>	0.5950083	911355	2827896	9740933	36887333
<b>D31_500mil</b>	0.5736499	920570	2885850	9009136	40362521
<b>D41_500mil</b>	0.5864888	920884	2988354	9584866	36565892
<b>D51_500mil</b>	0.5766069	935698	2844416	9211664	30752278

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D12_100mil</b>	0.6474053	937341	1475075	14345529	92330182
<b>D22_100mil</b>	0.7425610	930589	1456980	21684508	104318736
<b>D32_100mil</b>	0.6958804	925885	1485519	17320427	61798447
<b>D42_100mil</b>	0.8001344	929119	1661783	25922243	98714493
<b>D52_100mil</b>	0.7934174	931915	1394167	25879724	80005202

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D12_500mil</b>	0.6406574	945797	3378432	12075253	48555830
<b>D22_500mil</b>	0.5856077	938294	3378432	12075253	48555830
<b>D32_500mil</b>	0.5823522	932876	3356505	11520583	37813122

Grupo 01

D42_500mil	0.6068284	943610	3877712	13141292	64933547
D52_500mil	0.5631979	948543	3411331	10771022	39397344

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15_100mil	0.09626671	827909	832446.8 850425.2 893066.9
D25_100mil	0.35111836	827661	847345.0 955576.9 1708319.6
D35_100mil	-0.13805997	820816	820984.3 821969.0 824701.7
D45_100mil	-0.02801209	821379	821515.7 823532.1 828617.4
D55_100mil	-0.03548633	820901	820842.9 822592.6 826243.8

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15_500mil	0.3026449	860925	872301.0 933219.3 1079132.8
D25_500mil	0.4383726	859987	884171.7 1019439.9 1537053.2
D35_500mil	0.5530484	961297	927660.6 1244170.9 2484712.6
D45_500mil	0.3876135	859546	854775.9 908392.9 1099602.7
D55_500mil	0.1934982	860693	830875.5 839341.2 856485.8

## INSERTION SORT

## Amostras Regulares

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D11	0.9164504	9238683	9642432 62324258 133482839
D21	0.9199956	9264981	9360727 46031803 96396784
D31	0.9168480	9232089	9398483 61216873 128963443
D41	0.9233318	9247036	9300739 45709518 79275589
D51	0.9153839	9238606	9359426 46115814 72831168

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D12	0.9198741	9230450	9185854 44779868 78910286
D22	0.9168427	9228979	9364576 60971867 138502840
D32	0.9231581	9269574	9416334 46171512 84631656
D42	0.9174772	9232877	9385674 44547142 90071668
D52	0.9124823	9235917	9641267 63525037 131107198

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D13	0.9098800	9244264	9639969 68895128 187349450
D23	0.9023760	9236484	10063096 80182837 190876624
D33	0.9220904	9220150	9282699 43669919 78952711
D43	0.9187929	9244112	9486143 61614663 97282754
D53	0.9264574	9223011	9106270 43371507 79276585

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D14	0.9147114	9214756	9631886 60326625 116426973
D24	0.9205907	9218556	9259213 44251686 89315986
D34	0.9207196	9226457	9180945 44503124 95170367

Grupo 01

<b>D44</b>	0.9046089	9233155	10064824	79109339 196541514
<b>D54</b>	0.9047191	9213512	9594393	70415770 142779392

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>	
<b>D15</b>	0.06989010	8761486	8762832	8770583 8794811
<b>D25</b>	0.04407495	8761425	8762358	8768718 8784256
<b>D35</b>	-0.00736549	8761939	8761403	8765822 8775480
<b>D45</b>	-0.20445326	8759477	8759633	8760738 8762777
<b>D55</b>	-0.03030362	8761526	8761562	8765726 8776033

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>	
<b>D16</b>	0.9160290	9206792	9330014	43578008 87361194
<b>D26</b>	0.9076338	9240965	9904484	71679553 144731728
<b>D36</b>	0.9164305	9230482	9328223	43319343 78247877
<b>D46</b>	0.9189958	9227891	9434919	59610532 93948366
<b>D56</b>	0.9198425	9209456	9206156	42943047 62648969

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>	
<b>D17</b>	0.9188193	9231512	9209152	44690004 70786830
<b>D27</b>	0.9151316	9229532	9248369	44647512 96437373
<b>D37</b>	0.9162615	9219164	9479881	60640361 137754438
<b>D47</b>	0.9189309	9250008	9455349	62396888 110820645
<b>D57</b>	0.9149924	9235908	9352029	43129895 79192932

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>	
<b>D18</b>	0.03756461	8760741	8761639	8767373 8783131
<b>D28</b>	-0.07670860	8760618	8760527	8763197 8768520
<b>D38</b>	-0.04410138	8760525	8760611	8763336 8769331
<b>D48</b>	-0.08250264	8761536	8760609	8762750 8768106
<b>D58</b>	-0.01763503	8760312	8760938	8764432 8773573

**Amostras Extras**

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>	
<b>D11_100mil</b>	-0.2055132	9243110	9236086	9266638 9727046
<b>D21_100mil</b>	-0.6325212	9247123	9242395	9252173 9311096
<b>D31_100mil</b>	-0.0181259	9247922	9241410	9316818 11274344
<b>D41_100mil</b>	-0.3460297	9247746	9240863	9263182 9518809
<b>D51_100mil</b>	-0.1881078	9249666	9242228	9278537 9975313

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>	
<b>D11_500mil</b>	0.11706056	9298223	9297868	9484839 10837162
<b>D21_500mil</b>	0.08061417	9288481	9298193	9449557 10137984
<b>D31_500mil</b>	-0.00207289	9286779	9297882	9398123 9839970
<b>D41_500mil</b>	0.08652749	9298275	9306168	9471288 10170445
<b>D51_500mil</b>	0.11548764	9303537	9307759	9528671 10597995

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15_100mil	-0.2035283	8765355	8763208 8770879 8863851
D25_100mil	0.9647072	8948088	8763099 57029785 88843608
D35_100mil	0.6199986	8767206	8760611 10141464 25500304
D45_100mil	0.2946736	8761813	8760433 8839501 11657498
D55_100mil	0.9662315	8948153	8763348 55556721 70589523

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15_500mil	0.8853263	9114952	9320776 67489237 137003173
D25_500mil	0.8944105	8911684	8886740 32807858 58692056
D35_500mil	0.8690593	8911470	8976128 42333058 89707429
D45_500mil	0.9162120	9098459	8984702 55654500 105729010
D55_500mil	0.9168224	8914474	8908484 31606588 50762834

**QUICK SORT**

**Amostras Regulares**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D11	0.69987190	458185	473545.6 2088739.9 10745146.2
D21	0.63554411	440986	466716.3 1600667.9 7650415.0
D31	0.46981676	456657	470238.9 965831.3 3847421.5
D41	0.09097484	396005	396115.8 398091.5 404143.4
D51	0.81711882	442696	450000.4 2700157.5 7879661.2

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D12	0.40654444	409293	411581.1 510132.9 1095873.3
D22	0.73750289	459915	479171.9 2712096.9 8269715.8
D32	0.83949776	442042	467821.8 4292890.7 15388562.7
D42	0.08861867	396555	396331.0 398486.3 405168.7
D52	0.66974816	422317	429616.9 1041016.5 3427954.3

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D13	0.6905189	448020	472106.2 2070229.0 8463326.2
D23	0.3894397	453732	443366.0 658843.3 2159858.3
D33	0.8047343	440173	439853.6 2152424.4 5719804.0
D43	0.2038999	407903	403484.5 421694.2 489172.8
D53	0.7960418	471038	526188.1 5262507.5 19432544.0

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D14	0.3868742	406770	411412.6 493980.9 954191.0
D24	0.4148054	439616	458101.9 763403.9 3305040.8
D34	0.8601602	453331	444039.5 2984225.8 6104320.9
D44	0.8273527	446541	463044.0 3091208.5 10397936.5
D54	0.1208446	396489	396935.5 400088.8 410872.9

Grupo 01

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15	0.3425303	410759	408191.9 462560.3 717108.2
D25	0.2946630	407482	412758.8 473531.4 784723.9
D35	0.3894217	408496	412475.6 494963.6 1000232.6
D45	0.5183849	407667	427123.9 732239.4 2983444.6
D55	0.4977129	407180	419466.0 624886.1 2171869.6

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D16	0.6320003	439556	456678.3 1487623.0 9827706
D26	0.4396744	443884	457383.3 835154.8 3206552
D36	0.8408149	450837	459868.6 2732640.7 8361853
D46	0.8081559	454876	474902.8 2756073.1 10577768
D56	0.8257726	455942	454222.9 2907773.8 8754372

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D17	0.6201570	443088	447013.9 1136142 5771316
D27	0.7238595	452590	501903.6 2979782 13960403
D37	0.7031369	456219	467637.2 2431299 16223821
D47	0.6734647	422436	425609.6 1008109 3857746
D57	0.7950662	440177	444060.5 2089498 6595012

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D18	0.55168883	410066	437435.1 834065.7 4253221.4
D28	-0.47897293	405727	398957.1 399418.9 400286.1
D38	0.02625847	406096	402924.9 412420.7 434398.2
D48	0.33012138	408474	407858.1 461356.0 779878.8
D58	0.47675887	407768	419038.7 593631.6 1683535.3

**Amostras Extras**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D11_100mil	0.09626671	445512	648030.6 3574863 28513629
D21_100mil	0.35111836	451694	711149.7 6167843 29218963
D31_100mil	-0.13805997	444899	720906.5 9884214 50663072
D41_100mil	-0.02801209	453378	665197.7 4780728 31551992
D51_100mil	-0.03548633	447016	733059.2 8896697 42055535

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D11_500mil	0.3026449	457172	1481619 7208287 24392024
D21_500mil	0.4383726	463560	1481619 7208287 24392024
D31_500mil	0.5530484	458085	1524691 7904345 34550428
D41_500mil	0.3876135	458556	1375470 5859988 24458494
D51_500mil	0.1934982	448272	1615600 7950918 30043847

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
---------	-------	--------	---

D15_100mil	0.1428562	397357	397750.1	401391.4	415227.9
D25_100mil	0.1724449	397909	398634.6	405018.6	424297.1
D35_100mil	0.5188484	411754	410284.1	570843.6	2029967.6
D45_100mil	0.1383429	397158	397877.6	402206.6	417637.8
D55_100mil	0.2376239	397925	399069.4	409453.0	446173.3

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15_500mil	0.1595183	397972	398107.9 401877.7 418337.8
D25_500mil	0.2085930	397922	398175.0 400811.3 412630.1
D35_500mil	0.1453767	397814	397738.8 400637.4 412469.8
D45_500mil	0.7228918	456756	505656.3 8102119.5 27942164.8
D55_500mil	0.6925822	452966	500173.7 6511237.4 28926235.3

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D18_100mil	0.3186109	410051	442277.7 615390.0 1723148.5
D28_100mil	0.5986142	410946	474151.9 1516837.0 5928546.1
D38_100mil	0.7885244	467914	461617.2 3059496.7 8426397.7
D48_100mil	0.1426084	398087	398513.0 403789.7 423108.6
D58_100mil	0.0643431	397780	398197.0 401342.6 412141.0

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D18_500mil	0.6551169	409937	578784.3 1394859.2 4608354.9
D28_500mil	0.5579892	457493	443120.3 579944.6 985202.1
D38_500mil	0.6289039	445300	481461.8 787807.4 1768988.7
D48_500mil	0.4331208	432722	418047.9 460721.5 646610.7
D58_500mil	0.3448958	412989	408470.1 424867.5 475775.9



Grupo 02

**FFT1**

**Amostras Regulares**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D11	0.7075038	323748	348195.8	1328024.4 6064627.5
D21	0.7084665	326052	332363.1	1197967.1 5492269.6
D31	0.7313686	325803	346334.1	1421471.3 4894810.3
D41	0.3317482	304526	303553.8	325144.7 480939.6
D51	0.6979425	326259	336645.6	1133238.5 5998815.7

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D12	0.86229045	345264	350293.0	2419559.8 5390748
D22	0.87111322	350621	342554.8	2575481.8 6931160
D32	-0.08553522	297297	297359.0	297720.5 298478
D42	0.85051793	340952	340354.7	2173732.8 7094899
D52	0.85736255	344231	335080.3	2288625.0 5620623

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D13	0.4313311	304649	309660.6	385335.9 1027514
D23	0.7427547	331617	359720.0	1974602.1 9247555
D33	0.7718942	336944	356551.9	2172148.4 8539722
D43	0.7594470	337247	346920.5	2052036.1 8473142
D53	0.7315353	332627	340560.7	1575826.2 6955041

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D14	0.7202593	313371	317377.6	762988.6 2727157
D24	0.8457292	336763	336679.7	1971323.5 5826391
D34	0.6848775	311868	314721.3	645764.6 2800032
D44	0.7248197	314284	315741.1	792294.1 3204247
D54	0.7843380	326529	322332.4	1321576.8 4460417

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D15	0.4331149	303713	307615.2	364350.7 708024.3
D25	0.6340856	306099	324989.2	805310.6 3713889.2
D35	0.6196414	305959	329140.1	862129.0 3109619.9
D45	0.6131863	305671	331357.2	880349.3 4091035.2
D55	0.5323191	305661	316555.6	502589.6 1862217.0

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D16	-0.04515748	297363	297430.2	298011.6 299274.4
D26	0.79893694	327395	328463.9	1406040.0 4071228.8
D36	0.85556468	344478	333354.0	2310766.8 5867996.8
D46	0.03691991	297470	297515.9	298346.8 300629.3
D56	0.80229572	323712	326293.1	1299966.9 5020886.9

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D17	0.85460565	336408	327595.4 2024882 6203356.0
D27	0.85236683	338991	332180.3 2136465 4560640.0
D37	0.76989872	324549	327460.5 1218746 4472380.8
D47	0.05171069	297754	297596.3 298569 301313.9
D57	0.87605236	354400	348194.2 2808010 6954992.0

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D18	0.5060370	305119	312267.7 454453.2 1500044.5
D28	0.5839212	305496	330613.7 726840.1 3045281.2
D38	0.3594801	303268	305856.7 341802.6 542345.9
D48	0.4429128	304413	309471.1 387437.5 953305.6
D58	0.5059726	305440	315358.6 452279.3 1629420.0

#### Amostras Extras

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D11_100mil	0.1467347	332239	317581.7 462658.8 9516376.2
D21_100mil	-0.4793957	334471	329735.8 341560.4 486234.0
D31_100mil	-0.1839023	332101	327718.9 358402.0 787699.5
D41_100mil	-0.6445480	335772	332745.3 344383.2 413788.7
D51_100mil	-1.1030268	674800	672091.2 676250.2 691862.9

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D11_500mil	0.2790604	347940	372787.7 814526.4 3910956
D21_500mil	0.3303879	338448	369979.7 899007.2 6175126
D31_500mil	0.3167902	341265	362511.2 815423.4 4426404
D41_500mil	0.2792693	344771	380813.8 846407.4 4859568
D51_500mil	0.3575379	349749	369240.6 1033745.6 5693176

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15_100mil	-0.65510166	307194	306236.5 307253.3 310107.8
D25_100mil	0.07876899	308117	306826.6 353479.8 758024.6
D35_100mil	-0.29854521	306410	305883.4 308746.1 322334.4
D45_100mil	0.85982714	304701	298710.0 1859522.2 4505117.3
D55_100mil	0.10713971	298070	297926.4 300769.3 330425.9

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15_500mil	0.07876794	298692	298954.9 300851.9 306402.7
D25_500mil	0.62419108	305566	354785.9 1173794.1 6179812.0
D35_500mil	0.64372151	307034	357263.9 1365439.6 8131282.4
D45_500mil	0.03672546	298431	298522.3 299754.7 302630.4
D55_500mil	0.18831365	299065	299279.0 303831.9 324654.9

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
---------	-------	--------	---

Grupo 02

D16_100mil	-0.1843699	344385	335983.0	386754.4	1420944.7
D26_100mil	-0.4959855	347833	341120.7	365679.2	529498.5
D36_100mil	-0.5253902	353665	346682.6	360006.0	459261.6
D46_100mil	-0.3934540	349336	342536.9	367594.5	514495.5
D56_100mil	-0.7737174	354310	347474.4	354563.8	404539.3

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D16_500mil	-0.6848855	356745	354283.7 358825.5 367112.5
D26_500mil	-0.3306885	359241	356672.4 368629.5 402216.4
D36_500mil	-0.2193428	357406	355475.4 376948.7 421597.9
D46_500mil	-0.2302346	351326	355855.1 373779.6 427576.5
D56_500mil	-0.3251798	350247	351886.2 364361.0 395469.3

**FIBCALL**

**Amostras Regulares**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D11	0.5078668	639028	635930.4 1024963 3815078
D21	0.7237046	662698	703154.7 3843870 17100990
D31	0.6957331	674379	688091.5 2632335 13448209
D41	0.6831244	659615	674551.0 2248330 8680491
D51	0.6815521	670683	677597.3 2428629 11250235

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D12	0.842123588	721037	832750.7 13452950.9 37233550
D22	0.722080242	684459	694583.1 3152352.4 10577028
D32	0.729499777	689473	699517.9 3337192.3 17989051
D42	0.706149182	689842	703662.4 3036904.6 14331180
D52	0.006618924	599302	599378.0 603441.1 612598

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D13	0.770828396	670796	737711.6 5509881 20590507
D23	0.006103238	600181	599725.5 604266 615109
D33	0.752226009	672432	748981.7 5247029 23465251
D43	0.685762640	673050	668044.2 2457583 9836373
D53	0.679303130	664828	681361.4 2205542 12028379

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D14	0.02151449	598982	599620.6 605098.8 619969.4
D24	0.66427893	669125	670340.2 2155162.4 7831828.2
D34	0.64369446	670176	675237.2 2038139.9 11025905.7
D44	0.66917908	674408	673861.1 2320370.9 10896587.9
D54	-0.07808883	598612	599095.1 601509.7 607571.9

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
---------	-------	--------	---

Grupo 02

D15	0.18977140	599914	603072.8	623895.6 715395.3
D25	0.07909984	598909	600378.1	607552.4 628751.4
D35	0.04061051	599287	600471.9	606769.0 623790.4
D45	0.11553177	598748	600914.2	610435.9 641853.0
D55	0.19235812	600393	603161.7	621904.6 690491.3

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D16	0.8614818	720585	808082.6	13563968 33375477
D26	0.7800885	674757	719086.9	5071923 18031666
D36	0.8272953	724631	769917.2	8549635 27307846
D46	0.8422972	706483	793823.6	12152559 31537233
D56	0.8115013	710555	785293.3	7913844 29050579

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D17	0.2547133	600848	605501.4	635388.2 764075.1
D27	0.7390366	696574	693300.2	3862673.5 23509025.8
D37	0.7618889	702163	737284.8	4342664.3 16390290.5
D47	0.6195154	653455	662579.8	1653299.7 8970993.2
D57	0.5544420	633991	652890.6	1394672.0 5531476.7

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D18	0.1171595	599467	600219.9	609665.0 636098.9
D28	0.1015847	598715	600691.2	608598.8 632114.4
D38	0.1450639	601301	600084.4	611572.5 646275.1
D48	0.1508773	598597	601854.0	613629.7 667522.9
D58	0.1098708	598499	600430.6	609373.9 642776.2

#### Amostras Extras

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D11_100mil	-1.793296	674800	674537.8	674985.7 679146.9
D21_100mil	-2.208351	671241	672663.6	672723.2 675720.8
D31_100mil	-1.186453	676751	673955.4	680630.2 711370.9
D41_100mil	-1.547098	673287	670632.2	673070.7 690651.8
D51_100mil	-1.103027	675382	671460.8	676250.2 692110.3

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D11_500mil	-0.3452707	701168	681551.1	696070.4 728319.7
D21_500mil	-0.6374009	672013	674714.7	679284.8 687163.3
D31_500mil	-0.7883977	672062	673344.6	676454.9 682642.5
D41_500mil	-0.8427886	672234	673618.6	675907.2 680073.2
D51_500mil	-0.3960002	673485	677109.6	687452.1 708417.8

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D15_100mil	0.92160306	691225	603699.0	35822526.6 75682082.8
D25_100mil	0.91681631	696858	603285.0	40250852.1 83476849.3

Grupo 02

D35_100mil	-0.59728044	597514	597395.5	597639.9	598826.9
D45_100mil	-0.08857369	597941	597587.2	599704.6	627387.3
D55_100mil	-0.12777585	597985	597693.2	599247.7	621039.5

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15_500mil	0.8486031	669708	666929.4 12168033 22752947
D25_500mil	0.7448572	711494	671842.2 7329684 36150316
D35_500mil	0.5267891	639049	622133.4 1476180 6485518
D45_500mil	0.4924745	637781	631695.9 1222021 9781324
D55_500mil	0.7345842	637089	662293.8 4956027 22832169

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D16_100mil	-0.8491124	673021	672549.0 673312.1 678041.5
D26_100mil	-1.6659515	671370	671386.3 672452.4 684932.6
D36_100mil	-0.1181313	671401	668122.8 690161.8 1039442.7
D46_100mil	-2.2993578	673958	673530.2 673637.2 678695.3
D56_100mil	-2.2072603	671949	671574.9 671771.4 676066.6

D16_500mil	-0.3346378	710557	685270.8 700788.4 734810.9
D26_500mil	-0.4496330	691128	677488.3 686951.1 705217.1
D36_500mil	-0.6463183	673004	673763.5 677987.8 686048.7
D46_500mil	-0.4709320	671781	676475.6 684080.3 701349.9
D56_500mil	-0.3004601	692267	682724.7 700980.0 751011.5

**SQRT**

**Amostras Regulares**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D11	0.05274310	6734	5442.383 7627.548 13234.539
D21	-0.10645162	6683	4996.324 5988.323 7712.682
D31	0.08595515	7456	6422.229 9581.597 20258.811
D41	-0.67412109	4424	4303.852 4359.242 4450.914
D51	0.03699865	8107	5689.765 7995.405 14206.991

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D12	-0.08226386	6632	5035.243 5912.721 8206.126
D22	0.44045015	10379	12174.726 69468.191 507871.451
D32	0.05269892	6906	5123.195 6721.825 11225.351
D42	0.28048837	7931	7150.262 20561.860 93121.028
D52	-0.53879462	5091	4389.557 4476.118 4612.128

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D13	0.07280935	6344	5680.094 8084.157 16241.15
D23	0.03780106	6877	5549.055 7411.811 12502.66

Grupo 02

D33	0.24334229	9154	7691.815	19494.106	71908.24
D43	-0.10996127	7623	4988.626	5715.564	7746.39
D53	-0.01317171	8646	5371.033	6927.674	10763.86

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D14	0.03368415	7895	5685.141	7793.830	14019.357
D24	0.12673000	8057	5790.575	9002.123	21395.997
D34	-0.49808815	5264	4438.376	4533.369	4684.574
D44	-0.14031703	6249	4827.502	5412.705	6534.592
D54	0.02670784	7511	5368.256	7187.880	11158.145

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D15	0.2184586	6866	8284.042	17910.101	66161.634
D25	-0.2704939	6949	4691.108	5022.628	5612.375
D35	-0.1606478	7094	5162.722	5941.190	7367.984
D45	-0.3185541	6144	4622.268	4889.652	5347.015
D55	-0.4851016	6038	4420.863	4532.825	4724.107

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D16	-0.5441842	6064	4396.194	4499.776	4659.141
D26	-0.33106452	6463	4653.651	4921.297	5435.432
D36	-0.81818273	5019	4263.748	4302.924	4371.894
D46	0.07424895	8003	5660.340	7975.871	15798.813
D56	-0.46282238	5661	4397.838	4514.136	4729.598

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D17	0.1729483	8244	6910.280	13580.522	38772.364
D27	-0.2396281	7000	4607.208	4919.257	5524.800
D37	-0.8584325	4436	4203.986	4235.717	4290.555
D47	0.2744538	8252	9227.542	26935.351	115977.826
D57	-0.1218770	7358	4811.695	5452.976	6920.207

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D18	-1.06544826	4401	4229.482	4253.749	4308.541
D28	-0.05898118	7424	5712.069	7257.579	10866.321
D38	-0.05964232	6188	4988.074	5877.588	7958.925
D48	-0.06123773	6416	5139.390	6137.015	8486.985
D58	-0.03968076	6400	5202.752	6377.770	9059.367

#### Amostras Extras

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D11_100mil	0.5085755	8534	25819.56	232235.87	1809228.7
D21_100mil	0.2030502	8231	14265.59	46284.63	165130.3
D31_100mil	0.4164323	8046	15496.57	109137.05	899695.3
D41_100mil	0.3890200	7807	14546.34	85194.54	552878.1

Grupo 02

D51_100mil	0.5221026	8012	26505.00	309375.60	2553236.4
------------	-----------	------	----------	-----------	-----------

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D11_500mil	0.64394737	9470	73117.799	377037.600	1403756.451
D21_500mil	0.54366613	8782	21196.782	69444.804	349694.400
D31_500mil	0.55178343	8485	85658.606	303210.430	1231446.139
D41_500mil	0.02510723	2948	3131.924	3429.082	3964.447
D51_500mil	0.06191824	2922	3215.425	3616.241	4280.169

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D18_100mil	0.59931321	9244	36365.572	446935.082	3183662.564
D28_100mil	0.48305890	7990	25119.461	225503.670	1753396.439
D38_100mil	0.03930713	2764	2922.804	3581.273	5598.389
D48_100mil	0.01068271	2728	2863.824	3437.830	4844.577
D58_100mil	0.15276121	2757	3109.917	4543.374	10595.654

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D18_500mil	0.006205390	2988	3050.232	3332.041	3723.941
D28_500mil	0.102674072	2897	3384.844	4024.385	4963.492
D38_500mil	0.078056137	2946	3252.563	3756.940	4652.668
D48_500mil	0.007956123	2840	3048.044	3317.925	3743.663
D58_500mil	0.071832115	2824	3170.700	3645.089	4467.348

CNT				
Amostras Regulares				
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D11	0.4525764	361180	362440.3	1055359.9 10847087.4
D21	0.2301654	345367	342114.8	447475.5 1245814.7
D31	0.2848480	343096	340860.7	515292.0 1884524.7
D41	0.1377923	330890	335632.1	383399.5 652179.4
D51	0.3343236	362457	350855.7	672781.5 2881676.2
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D12	0.55274131	378696	367178.1	1682493.1 16504112.0
D22	0.31886362	348938	346796.1	533006.7 2046946.1
D32	-0.01709388	327885	327213.9	339334.1 391607.6
D42	0.48897638	376505	370410.5	1325962.9 10613892.4
D52	0.32257006	355041	347714.7	551569.2 2070555.6
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D13	0.1073838	326193	328329.7	358071.7 561757
D23	0.4428068	358905	369754.0	1004857.7 7602124
D33	0.4173649	370038	356347.8	845220.6 4612792
D43	0.4612008	376943	359490.8	1114788.2 7679006
D53	0.4593481	372123	366106.2	1107999.6 11892924
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D14	0.4310536	364482	355827.6	902759.2 5101632
D24	0.2908586	354971	342325.3	513008.5 1741236
D34	0.4116676	374751	368647.0	1005021.1 8352671
D44	0.2144938	345696	339755.4	437027.3 1160762
D54	0.3921190	356717	354620.7	735580.2 3716526
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D15	0.12699157	330242	332562.0	377470.1 650045.7
D25	0.08767330	327522	331576.9	361914.0 519321.5
D35	0.07180405	330064	331442.7	358168.6 477531.6
D45	0.16110038	329566	330267.3	373786.5 622222.3
D55	-0.07239553	327032	327778.6	338891.5 378751.5
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D16	0.5039829	360804	363376.4	1188456.8 9333631.8
D26	0.3779651	364668	346343.1	713796.1 4550948.1
D36	0.4052166	368343	353007.8	796940.6 4663051.2
D46	0.1092021	326402	327388.3	355649.8 489848.5
D56	0.4618349	361814	383274.7	1194187.1 6616909.6



Grupo 03

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D17	0.4745712	382352	366101.9	1315346.9	8835069.3
D27	0.4152112	366825	364738.5	886091.2	6307659.5
D37	0.2014253	331157	333671.6	400435.5	819933.7
D47	0.2711342	342258	336907.0	467504.9	1548599.9
D57	0.4953611	364887	378796.0	1329245.2	12411412.2

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D18	0.13764889	329931	332064.4	370699.1	572229.2
D28	0.02152165	327297	329174.0	347116.0	405602.2
D38	0.02604404	326308	326968.8	342645.1	405493.7
D48	-0.10179553	327783	326937.1	335339.5	359002.0
D58	0.09448766	330884	331499.1	359035.6	490996.5

**Amostras Extras**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D13_100mil	0.5634818	371091	523634.2	3229539.7	31624050
D23_100mil	0.2863271	370502	415407.5	813420.3	2497635
D33_100mil	0.3552497	376464	463483.3	1185106.3	5689094
D43_100mil	0.6829177	375377	815933.0	8846283.4	40285835
D53_100mil	0.6634341	370544	654264.3	6478237.6	41899096

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D13_500mil	0.5950672	376488	1578314.3	5619792	24495609
D23_500mil	0.4920200	383470	1095089.6	2968516	10467461
D33_500mil	0.4329115	380637	1002991.5	2046515	6884039
D43_500mil	0.4237516	384505	968300.6	1991174	5966124
D53_500mil	0.5876813	377029	1482766.7	5246175	20146100

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D15_100mil	-0.19277348	331737	331223.7	334377.7	340379.9
D25_100mil	0.31390938	333745	363227.1	574632.7	1526705.9
D35_100mil	-0.02689487	323692	322111.2	326041.5	335614.9
D45_100mil	0.06924701	324129	326094.7	336494.0	367144.0
D55_100mil	-0.07990220	324878	323131.6	326993.0	336258.8

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)		
D15_500mil	0.0793519369	335330	363718.4	386366.4	428107.7
D25_500mil	0.0007223144	326874	326833.0	330423.9	335725.0
D35_500mil	0.0366568526	328728	327921.2	332452.7	339536.0
D45_500mil	-0.0555484452	324750	324997.2	327291.5	329869.6
D55_500mil	0.0499361295	334607	330587.1	336365.4	346774.4

**MATMULT**

Amostras Regulares				
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D11	0.7274741	558791	626389.1	2417757 11198191
D21	0.7728520	584131	639387.5	3781768 16036195
D31	0.7047717	565865	590552.5	1622783 4881678
D41	0.7704578	581295	644505.9	3668627 12408303
D51	0.6907939	557036	605999.8	1875017 7770070
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D12	0.7766519	598687	642461.6	3603757 15874564
D22	0.7670330	585349	658114.4	3936891 15519691
D32	0.7947372	602303	636138.0	4522032 12963091
D42	0.7217555	588469	663494.8	3815731 14649620
D52	0.8021539	596696	677502.0	4496987 26422586
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D13	0.7741035	584371	626395.4	3275909 13376699
D23	0.7348972	558938	600419.7	2138631 11047879
D33	0.8093150	601281	687281.9	5687832 28465113
D43	0.7563015	582447	651508.7	3703787 13418808
D53	0.7135977	581582	660579.9	3464789 15377890
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D14	0.7576032	573599	616671.2	2445012 9074987
D24	0.7473738	581614	681109.8	4119331 20214934
D34	0.7712085	579767	652266.9	3701237 11866371
D44	0.7675985	582200	641358.8	3462832 12355897
D54	0.6220439	557219	584994.0	1165286 4256081
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D15	0.6534224	555895	590371.0	1386418 5549574
D25	0.7495484	558337	628365.9	2797688 9933771
D35	0.6891289	561321	597767.4	1694511 6855961
D45	0.6204219	557543	577471.4	1060688 3924438
D55	0.7212178	558968	611966.4	2233407 8151556
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D16	0.7903846	583127	618089.6	3165626 10603760
D26	0.7386722	580381	607947.2	2159076 7519831
D36	0.7354447	582719	604541.8	2292500 9624670
D46	0.6973496	557134	594704.2	1644432 7585427
D56	0.7764253	587611	610422.9	3016399 9884511
Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	

Grupo 03

D17	0.7856856	585673	653246.3	4164825	14559089
D27	0.7900499	584359	629951.0	3395447	10872274
D37	0.7112824	560194	603947.6	1975693	9516652
D47	0.7883638	592605	603888.5	2883919	13429995
D57	0.7710804	581843	649647.8	3896950	12684017

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D18	0.6906925	558126	617531.0 1959850.0 7349485
D28	0.6855772	558466	595646.1 1678777.9 6015886
D38	0.7103943	558816	632976.7 2617416.8 9108360
D48	0.5937967	558992	573113.6 1001375.4 3883366
D58	0.5260368	555859	569294.9 762550.6 1968900

**Amostras Extras**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15_100mil	-0.3352079	561879	561384.8 566552.4 586363.0
D25_100mil	0.5000024	561861	561911.5 1916078.6 23000569.2
D35_100mil	0.8499951	567173	551933.8 5399523.5 18126080.6
D45_100mil	0.2395812	545110	544965.2 555886.7 754242.2
D55_100mil	-0.1017496	544889	544697.9 545929.7 554381.2

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D15_500mil	0.5282391	567077	567810.3 789703.4 2369563
D25_500mil	0.6530442	567242	668140.9 3012647.1 15371235
D35_500mil	0.1906847	567073	591654.8 714689.6 1120416
D45_500mil	0.5802572	565110	563579.2 833466.3 2464009
D55_500mil	0.7934118	607753	613900.9 3375974.6 13090195

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D18_100mil	0.6570348	561506	770193.9 1387295.2 3902099.1
D28_100mil	0.1902594	579041	573559.0 588770.1 614462.7
D38_100mil	0.6179470	561133	725234.5 1138916.0 2730224.2
D48_100mil	0.5701966	558596	690499.0 968733.5 2076197.9
D58_100mil	0.4754668	561528	648062.6 781037.0 1185005.8

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D18_500mil	0.2634069	584744	605891.9 620973.2 643218.5
D28_500mil	0.5574088	604365	681166.4 787784.3 1036627.7
D38_500mil	0.1393851	558364	547675.6 548476.5 549525.1
D48_500mil	0.1111002	555692	546663.8 547259.2 548086.9
D58_500mil	0.5258549	587385	677430.9 762792.6 944384.1

**EDN**

**Amostras Regulares**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D11	0.5111584	208488	239972.5	611157.0 3963967
D21	0.5643755	215616	265590.3	891637.5 4204209
D31	0.4948000	208083	237237.4	508769.9 2696401
D41	0.5240021	209002	234951.1	614217.8 3562229
D51	0.4412018	205797	225333.7	392756.7 1631663

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D12	0.5766062	224594	248672.6	837504.1 5324435.9
D22	0.5793811	223136	263920.5	994575.5 4547047.2
D32	0.4345777	208353	216698.8	336999.7 969241.6
D42	0.5568080	220814	257574.0	843249.0 4639442.8
D52	0.5564951	227210	242033.2	755319.4 5818541.1

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D13	0.6175166	232141	257469.5	1103341.1 5851617
D23	0.5301557	208911	231729.0	543773.8 2811000
D33	0.6451736	234651	267801.9	1572473.0 7050315
D43	0.5564115	214590	240747.3	771532.4 3964651
D53	0.5923650	223965	261512.1	1030541.0 4812278

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D14	0.5049644	219913	241589.3	661211.0 2624880
D24	0.4740310	208711	228010.7	439074.8 1900901
D34	0.5969013	219784	255156.3	1001153.2 5561929
D44	0.4928499	213947	236152.5	663430.0 4112043
D54	0.5308079	214641	247727.6	710519.8 3473676

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D15	0.5235863	208972	239603.3	629169.9 3126372
D25	0.5350130	208850	252765.8	736154.9 6760318
D35	0.5388113	209952	245294.2	676913.4 3982758
D45	0.4653736	208115	223882.2	421948.2 1800709
D55	0.5092212	208832	235177.6	596280.5 2717619

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D16	0.4745745	206646	225622.0	463344.5 2061971
D26	0.6398173	219749	262871.6	1368412.4 8869326
D36	0.4705066	213663	227212.2	464598.6 2594320
D46	0.5163959	208873	245390.9	769848.2 3833634
D56	0.5655101	215571	253591.4	901957.2 4693142

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)	
D17	0.5898097	218905	239502.6	769390.5 4144058
D27	0.5555755	210312	259979.5	869389.6 5456226

Grupo 03

D37	0.5606916	219369	265897.4	1005028.8 9301330
D47	0.4825355	208631	224885.9	441107.2 3638476
D57	0.5514817	221174	268675.6	924952.9 5669972

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D18	0.4555730	208796	232748.9 425841.0 1999542
D28	0.4967518	209013	242785.3 661197.2 3212256
D38	0.5339553	209720	242376.4 628708.5 3604194
D48	0.4706806	209386	243400.7 560073.8 2869682
D58	0.5132074	209719	245460.9 665455.4 3058821

**Amostras Extras**

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D12_100mil	0.2884865	239461	221369.7 716501.6 20873950.5
D22_100mil	-0.6023208	231221	228484.2 235298.1 333591.4
D32_100mil	-0.5881000	229969	227375.7 234088.0 319895.6
D42_100mil	-0.6027233	238785	229420.4 242187.0 409553.2
D52_100mil	-0.7417140	231102	229397.9 234003.8 269207.8

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D12_500mil	-0.4066928	238122	236272.0 241255.6 252125.8
D22_500mil	-0.1441433	236956	237480.1 259356.4 331249.2
D32_500mil	-0.2928171	238346	238256.8 248979.5 279029.6
D42_500mil	-0.2136535	237286	237821.8 251223.5 290235.0
D52_500mil	-0.4653225	238452	234259.2 239359.4 249277.8

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D18_100mil	-0.43826825	210344	209756.1 211055.5 226806.8
D28_100mil	0.17824251	209177	204619.6 341453.4 4647511.6
D38_100mil	0.05519393	210778	209820.5 218482.8 576044.9
D48_100mil	0.21598777	209658	204511.1 386915.9 8713302.3
D58_100mil	-0.29788656	197440	197353.4 197674.0 203841.1

Amostra	shape	máximo	CI inf. (95%) - VI.estimado - CI sup. (95%)
D18_500mil	0.6110646	209990	230751.3 1953414.2 19122756.3
D28_500mil	0.1824624	197978	198140.8 203121.3 236271.4
D38_500mil	0.6986818	210887	244410.4 3079376.3 23365343.2
D48_500mil	0.2203200	198285	198417.0 206023.4 278053.5
D58_500mil	0.6853925	210094	237133.8 2808720.1 17372809.4

FIBCALL				
Resultados apresentados no Grupo 02				
BINARY SEARCH				
Amostras Regulares				
Amostra	shape	máximo	CI inf. (95%) - VI. estimado - CI sup. (95%)	
D11	-0.2721331	5900	4442.414	4815.148 5444.188
D21	0.1419308	8864	6474.519	13079.631 36205.835
D31	-0.6177390	4398	4045.414	4133.787 4271.504
D41	0.1194543	8639	7181.048	13128.033 34692.260
D51	-0.1237014	6567	4603.207	5351.476 6683.870
Amostra	shape	máximo	CI inf. (95%) - VI. estimado - CI sup. (95%)	
D12	-0.3438315	4456	4095.837	4270.363 4566.167
D22	0.1276109	9610	6142.675	10377.267 26064.115
D32	-0.1281443	6655	4670.973	5485.638 7157.945
D42	-0.5500227	4285	4119.586	4222.029 4393.518
D52	0.1875718	8621	7249.373	16112.566 45097.602
Amostra	shape	máximo	CI inf. (95%) - VI. estimado - CI sup. (95%)	
D13	-0.35501895	5651	4231.497	4453.969 4872.373
D23	-0.25596752	5921	4486.615	4881.941 5542.126
D33	-0.01066238	7949	4967.554	6562.707 10832.418
D43	0.23834424	7938	7661.693	18581.715 68111.176
D53	-0.09318364	7616	5015.908	6232.351 8822.538
Amostra	shape	máximo	CI inf. (95%) - VI. estimado - CI sup. (95%)	
D14	0.008820895	5218	4679.541	6315.265 12219.440
D24	-0.123012024	7119	4780.648	5615.317 7237.617
D34	0.187952883	8052	7192.429	14979.223 45871.977
D44	-0.317883399	5774	4256.226	4502.177 4964.767
D54	-0.471016949	4361	4092.445	4204.143 4386.227
Amostra	shape	máximo	CI inf. (95%) - VI. estimado - CI sup. (95%)	
D15	-0.33521141	5125	4296.714	4567.087 4985.131
D25	-0.25075875	5740	4355.706	4738.873 5419.415
D35	-0.33024833	5322	4228.661	4457.157 4831.762
D45	0.02780559	6769	5453.995	7706.647 13517.118
D55	-0.07662043	6376	4964.142	6056.255 8413.973
Amostra	shape	máximo	CI inf. (95%) - VI. estimado - CI sup. (95%)	
D16	-0.50048318	4203	4075.949	4179.467 4319.967
D26	-0.32696330	4461	4210.823	4412.575 4757.658
D36	-0.13372118	5738	4625.447	5292.219 6731.728

Grupo 04

<b>D46</b>	-0.27452784	5121	4347.720	4621.622	5129.267
<b>D56</b>	-0.04478862	7661	5033.253	6218.417	8777.941

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D17</b>	0.09630749	8542	5676.473	9507.435	22307.256
<b>D27</b>	-0.05358834	5327	4504.581	5518.703	7764.454
<b>D37</b>	-0.15332388	5660	4550.960	5178.987	6393.042
<b>D47</b>	0.03252886	9100	5451.199	7803.831	14587.591
<b>D57</b>	-0.09368389	7883	4806.653	5824.988	8149.196

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D18</b>	-0.33017837	4184	4074.852	4280.224	4650.698
<b>D28</b>	0.07331793	6641	5567.031	8533.994	18038.674
<b>D38</b>	-0.23218198	6615	4380.705	4774.957	5609.308
<b>D48</b>	0.29729135	7890	9377.521	29625.857	161992.438
<b>D58</b>	-0.34872264	5641	4181.925	4405.993	4773.036

**Amostras Extras**

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D11_100mil</b>	-0.47001614	2726	8972.066	11337.415	29566.36
<b>D21_100mil</b>	0.06313713	4137	6555.959	36997.167	608175.54
<b>D31_100mil</b>	0.17632266	3048	2804.025	8069.771	169571.80
<b>D41_100mil</b>	0.35126398	8377	3218.403	46461.197	1259453.14
<b>D51_100mil</b>	0.06700889	9457	2595.215	4182.707	61412.92


<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D11_500mil</b>	0.6105514	9154	22637.304	636293.285	4343660.48
<b>D21_500mil</b>	0.4875903	4173	5426.591	55834.529	478051.11
<b>D31_500mil</b>	0.5456006	8935	18774.920	404527.716	4436359.06
<b>D41_500mil</b>	0.6359730	8631	16919.139	707272.733	4613473.69
<b>D51_500mil</b>	0.1753183	3020	3460.139	7037.602	31229.82

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D18_100mil</b>	0.01578436	8794	7822.235	23307.19	406255.11
<b>D28_100mil</b>	0.12750804	6898	5707.554	38455.37	837163.06
<b>D38_100mil</b>	0.54062896	4666	3231.644	239499.22	3810315.97
<b>D48_100mil</b>	-0.37417755	9124	7761.294	10461.70	32848.13
<b>D58_100mil</b>	0.59671130	5292	3471.091	471403.13	5820407.90

<b>Amostra</b>	<b>shape</b>	<b>máximo</b>	<b>CI inf. (95%) - VI.estimado - CI sup. (95%)</b>		
<b>D18_500mil</b>	0.25801238	9291	16356.127	101248.616	689087.87
<b>D28_500mil</b>	0.09957265	10022	12653.390	40521.316	192674.22
<b>D38_500mil</b>	0.67186114	8405	20692.287	832308.379	4695456.68
<b>D48_500mil</b>	0.13170671	2935	3129.223	5470.835	19201.98
<b>D58_500mil</b>	0.69422608	9115	21964.768	1111685.753	7481803.88







## CÓDIGO-FONTE

```
// Codigo de autoria compilacao Malardalen WCET Benchmarks,  
// Manual Linux perf_event_open, adaptacao Tadeu Nogueira,  
// George Lima e Jamile Vasconcelos.  
  
#define _GNU_SOURCE  
#include <sched.h>  
#include <sys/wait.h>  
#include <stdlib.h>  
#include <stdio.h>  
#include <unistd.h>  
#include <sys/syscall.h>  
#include <string.h>  
#include <sys/ioctl.h>  
#include <linux/perf_event.h>  
#include <linux/hw_breakpoint.h>  
#include <asm/unistd.h>  
#include <errno.h>  
#include <stdint.h>  
#include <inttypes.h>  
#include <time.h>  
  
// Vetor com input fixo com 1000 numeros aleatorios fixos  
int arr[1000] = {121, 173, 555, ...}  
int arr_size = 1000;  
  
// function to save data in saida_bsort_CI.csv  
void save_data(uint64_t val_cycles, uint64_t val_instruction){  
  
    FILE *arq;
```

```

    arq = fopen("saida_bsort_CI.csv", "a");

    if(arq == NULL){
        printf("ERROR_OPEN_FILE");
    }

    fprintf(arq, "%"PRIu64";%"PRIu64"\n", val_cycles, val_instruction);
    fclose(arq);
}

/* Sorts an array of integers of size bsort_SIZE in ascending
   order with bubble sort. */
int bsort_BubbleSort( int arr[], int bsort_SIZE )
{
    int Sorted = 0;
    int Temp, Index, i;

    for ( i = 0; i < bsort_SIZE - 1; i ++ ) {
        Sorted = 1;

        for ( Index = 0; Index < bsort_SIZE - 1; Index ++ ) {
            if ( Index > bsort_SIZE - i )
                break;
            if ( arr[ Index ] > arr[ Index + 1 ] ) {
                Temp = arr[ Index ];
                arr[ Index ] = arr[ Index + 1 ];
                arr[ Index + 1 ] = Temp;
                Sorted = 0;
            }
        }

        if ( Sorted )
            break;
    }

    return 0;
}

struct read_format {
    uint64_t nr;
    struct {
        uint64_t value;
        uint64_t id;
    }
};

```

```

    } values [];
};

int main( int argc , char ** argv){

    struct perf_event_attr pea;
    int fd_cycles , fd_instruction;
    uint64_t id_cycles , id_instruction;
    uint64_t val_cycles , val_instruction;

    char buf[4096];
    struct read_format* rf = (struct read_format*) buf;
    int i;

    cpu_set_t set;

    CPU_ZERO(&set);
    CPU_SET(0,&set);
    sched_setaffinity(getpid(), sizeof(set), &set);

    // cycles
    memset(&pea, 0, sizeof(struct perf_event_attr));
    pea.type = PERF_TYPE_HARDWARE;
    pea.size = sizeof(struct perf_event_attr);
    pea.config = PERF_COUNT_HW_CPU_CYCLES;
    pea.disabled = 1;
    pea.exclude_kernel = 1;
    pea.exclude_hv = 1;
    pea.read_format = PERF_FORMAT_GROUP | PERF_FORMAT_ID;
    fd_cycles = syscall(__NR_perf_event_open, &pea, 0, -1, -1, 0);
    ioctl(fd_cycles, PERF_EVENT_IOC_ID, &id_cycles);

    // instructions
    memset(&pea, 0, sizeof(struct perf_event_attr));
    pea.type = PERF_TYPE_HARDWARE;
    pea.size = sizeof(struct perf_event_attr);
    pea.config = PERF_COUNT_HW_INSTRUCTIONS;
    pea.disabled = 1;
    pea.exclude_kernel = 1;
    pea.exclude_hv = 1;
    pea.read_format = PERF_FORMAT_GROUP | PERF_FORMAT_ID;
    fd_instruction = syscall(__NR_perf_event_open, &pea, 0, -1, fd_cycles,
    ioctl(fd_instruction, PERF_EVENT_IOC_ID, &id_instruction);

```

```
//execution
ioctl(fd_cycles , PERF_EVENT_IOC_RESET, PERF_IOC_FLAG_GROUP);
ioctl(fd_cycles , PERF_EVENT_IOC_ENABLE, PERF_IOC_FLAG_GROUP);

bsort_BubbleSort(arr , arr_size);

//end measure
ioctl(fd_instruction , PERF_EVENT_IOC_DISABLE, PERF_IOC_FLAG_GROUP);

    read(fd_cycles , buf , sizeof(buf));
for (i = 0; i < rf->nr; i++) {
    if (rf->values[i].id == id_cycles) {
        val_cycles = rf->values[i].value;
    } else if (rf->values[i].id == id_instruction) {
        val_instruction = rf->values[i].value;
    }
}

save_data(val_cycles , val_instruction);

close(fd_cycles);
close(fd_instruction);
}
```