

Caracterização Estática de Oportunidades de Aproximação em Instruções RISC-V

Marco Antônio de R. Zárate¹, Gislayne Garabini Damasceno¹,
Gregório Koslinski Neto¹, Liana Duenha¹

¹Faculdade de Computação – UFMS Campo Grande – MS – Brasil

{marco.zarate, gislayne-garabini, gregorio.neto, liana.duenha}@ufms.br

Resumo. A computação aproximada relaxa a exatidão computacional em troca de ganhos em desempenho e eficiência energética. Este trabalho propõe um fluxo que extrai features estáticas de vivacidade, contaminação, propagação de erro e profundidade de laços, a partir da representação intermediária MLIR/LLVM, para instruções aritméticas aproximadas em RISC-V. Correlacionando estas features com o erro e o consumo energético em quatro aplicações do AxBench, foram identificados indicadores estruturais recorrentes de oportunidades de aproximação segura, além de um contraexemplo em que erro e consumo se comportam como um trade-off quase linear. Os resultados fornecem uma caracterização fundamentada para orientar a seleção de instruções aproximáveis com baixo risco e alto potencial de economia energética.

1. Introdução

A computação aproximada é um paradigma que relaxa a exigência de exatidão computacional em troca de ganhos em desempenho, eficiência energética e área de circuito, sendo especialmente aplicável a domínios intrinsecamente tolerantes a erro [Leon et al. 2025]. Embora a literatura apresente técnicas de aproximação em diversos níveis de abstração, a exploração sistemática da aproximação ao nível da Arquitetura do Conjunto de Instruções (ISA) permanece pouco desenvolvida [Catelan et al. 2024].

Neste trabalho, propomos um fluxo de análise que extrai *features* estáticas diretamente da representação intermediária MLIR, gerada pela infraestrutura LLVM, para instruções aritméticas aproximadas em ponto flutuante e inteiras na arquitetura RISC-V. Utilizando quatro aplicações do benchmark AxBench e um amplo conjunto de configurações de aproximação simuladas, correlacionamos essas features com o erro de saída e o consumo energético observados, fornecendo uma caracterização fundamentada das propriedades estáticas mais relevantes para orientar a seleção de instruções com maior potencial de aproximação segura e energeticamente vantajosa.

2. Metodologia

As aproximações foram introduzidas em quatro aplicações do AxBench, por meio de instruções customizadas de baixo consumo energético, implementadas em circuitos aritméticos aproximados para adição, subtração e multiplicação, em ponto flutuante e em inteiros (ADDX/FADDX, SUBX/FSUBX, MULX/FMULX) [Neto et al. 2025]. Para cada aplicação, o conjunto de N instruções elegíveis define um espaço de até 2^N configurações de aproximação. Uma parte representativa desse espaço é simulada, obtendo-se, para cada configuração, o erro de saída e o consumo de energia correspondentes.

Para cada configuração, extrai-se um conjunto de *features* estáticas a partir da representação intermediária MLIR (LLVM), com base nas variáveis-alvo das instruções aproximadas ativas. As *features* compreendem propriedades de vivacidade, que indica o uso futuro da variável; contaminação, que representa a influência das operações aproximadas sobre valores relacionados; propagação de erro, que indica o alcance do erro introduzido; e profundidade de aninhamento de laços, que indica os níveis de laços percorridos. Como cada configuração aproxima múltiplas instruções simultaneamente, as *features* individuais são agregadas (soma, média ou máximo, conforme a métrica) em um único valor por *feature*, característico da configuração. O dataset resultante contém, portanto, uma linha por configuração simulada, com as *features* agregadas como entradas, associadas a duas variáveis resultantes da simulação: o consumo energético e o erro, esse último com base na métrica sugerida no AxBench para cada aplicação.


A relação entre as *features* e essas duas métricas de saída é quantificada pelo coeficiente de correlação de Pearson, calculados separadamente para cada *feature*, considerando todas as configurações de aproximação simuladas. O coeficiente de Pearson é um valor no intervalo $[-1, 1]$ que mede a força de associação *linear* entre variáveis. Os valores extremos -1 e 1 representam correlação perfeita (negativa e positiva, respectivamente) e o valor 0 representa a ausência de correlação. O uso do coeficiente de Pearson permite identificar relações lineares entre as características estáticas agregadas e os impactos de erro e de energia introduzidos pela aproximação.

3. Resultados e Discussão


A Figura 1 sintetiza os resultados para as quatro aplicações analisadas. Em Blackscholes (a) e FFT (b), as correlações são fracas a moderadas e majoritariamente favoráveis, com a contagem de multiplicações aproximadas (`fmulx_count_variaveis`) destacando-se em ambas como a *feature* de melhor relação consumo-erro, seguida de *features* de vivacidade interprocedural (`sum_interprocedural_score`), da soma das profundidade de aninhamento em laços das variáveis aproximadas (`depth_a_sum`), de contaminação (`taint_clean_count_max`) e de propagação de erro (`error_relativo_max_mean`). A análise da aplicação Jmeint (c) revela um comportamento estrutural diferente: as correlações são substancialmente mais fortes, indicando um *trade-off* quase linear entre as métricas e a ausência de oportunidades de aproximação sem custo proporcional em erro. Já o KMeans (d) evidencia uma assimetria entre tipos de operação: enquanto multiplicações aproximadas (`fmulx_count_variaveis`) seguem o padrão favorável observado nas demais aplicações, adições aproximadas (`faddx_count_variaveis`) apresentam relação de sinal oposto com o consumo, sugerindo que os dois tipos de operação devem ser tratados separadamente na seleção de instruções aproximáveis.

4. Conclusão


Os resultados apontam duas implicações práticas para a seleção de instruções aproximáveis. Primeiro, a contagem de multiplicações aproximadas mostrou-se o indicador mais consistente de oportunidade segura entre as aplicações analisadas, com relação favorável ao consumo energético e impacto baixo sobre o erro. Esta seria uma heurística prática de baixo custo para priorização inicial de candidatos. Segundo, *features* de vivacidade e de propagação de contaminação, embora fortemente associadas ao consumo, carre-




(a) Blackscholes



(b) FFT



(c) Jmeint



(d) KMeans

Figura 1. Correlação de Pearson entre *features* estáticas e as métricas de erro e consumo energético, com destaque para as três *features* mais relevantes em cada aplicação.

gam também maior correlação com o erro, devendo ser usadas como indicadores de magnitude de impacto. O caso do Jmeint, por sua vez, mostra que essas heurísticas não são universais: aplicações com forte acoplamento entre erro e consumo exigem uma triagem prévia para verificar se há, de fato, espaço para explorar oportunidades de aproximação antes de aplicar qualquer critério baseado em *features* estáticas. Como trabalhos futuros, sugere-se testes em mais aplicações além de utilizar outras métricas de correlação.

Referências

- Catelan, D., Sovernigo, F., Duenha, L., and Santos, R. (2024). An instruction-set extension to support approximate multicore processors. In *2024 International Symposium on Computer Architecture and High Performance Computing Workshops (SBAC-PADW)*, pages 23–32. IEEE.
- Leon, V., Hanif, M. A., Armeniakos, G., Jiao, X., Shafique, M., Pekmestzi, K., and Soudris, D. (2025). Approximate computing survey, part i: Terminology and software & hardware approximation techniques. *ACM Computing Surveys*, 57(7):1–36.
- Neto, G. K., Sovernigo, F., Catelan, D., Santos, R., and Duenha, L. (2025). Heuristics for energy-efficient instruction-level approximate computing. In *2025 IEEE/SBC 37th International Symposium on Computer Architecture and High Performance Computing (SBAC-PAD)*, pages 35–45. IEEE.