Language Models in Software Development Tasks: An Experimental Analysis of Energy and Accuracy

Negar Alizadeh∗, Boris Belchev†, Nishant Saurabh∗
∗Utrecht University, Utrecht, The Netherlands
{n.s.alizadeh, n.saurabh}@uu.nl
†University of Twente, Enschede, The Netherlands
b.belchev@student.utwente.nl

Patricia Kelbert‡, Fernando Castor†
‡Fraunhofer IESE, Kaiserslautern, Germany
patricia.kelbert@iese.fraunhofer.de
†University of Twente, Enschede, The Netherlands
f.castor@utwente.nl

22nd International Conference on Mining Software Repositories (MSR 2025)

背景

生成AIの普及

- SOの調査では開発者の76%がコード支援ツールを使用
- サードパーティサービス（ChatGPT , GithubCopilot）が主流

└ 企業にとってはいくつかの不都合が

・データプライバシー，セキュリティ

機密情報，顧客情報などが外部に流出する可能性

・お金

シンプルにお金かかる

➡ ローカル展開の需要が高まっている

ローカル展開における問題

高性能GPUと大きな消費電力

ローカル展開には高性能なGPUが必要
消費電力も大きい

→ 費用
環境負荷 大

<u>LLMのエネルギー消費に関する研究が行われている</u>

先行研究

NLPタスクの学習時におけるエネルギー消費を調査

推論時におけるエネルギー消費を調査した研究は少ない

SEタスクにおけるエネルギー消費は調査されていない

目的・アプローチ

目的

- SEタスクの実行時におけるLLMのエネルギー消費と精度を調査

アプローチ

４つのSEタスク

２つのハードウェア環境

１８のモデルファミリー

３つの量子化レベル

これらを組み合わせて実験

実験設定

タスク

HumanEvalを拡張したデータセット[20]を利用

コード生成・バグ修正・ドキュメント生成・テストケース生成

ハードウェア環境

- NVIDIA A100（データセンター想定）

  全てのモデルを実行

- RTX 3070（エンドユーザー想定）

  小さいモデルのみを実行

実験設定

使用モデル

HuggingFace上の人気上位モデルを利用

コード特化モデル・汎用モデルどちらも利用

例）コード特化モデル

granite-code starcoder2 codellama　など

例）汎用モデル

phi3 llama2 deepseek-llm など

量子化

タイプ：学習後量子化

形式：GGUF (GPT-Generated Unifiled Format)

最もエネルギー効率が高い[16]

量子化レベル：4ビット，5ビット，8ビット，16ビット（元々と同じ）

RQs

RQ1

- タスク間でエネルギー消費は異なるか？

RQ2

- エネルギー効率と精度のトレードオフは存在するか？

RQ3

- アーキテクチャの特性は消費エネルギーに影響を与えるか？

RQ4

- 汎用モデルとコード特化モデルに違いはあるか

結果｜RQ1

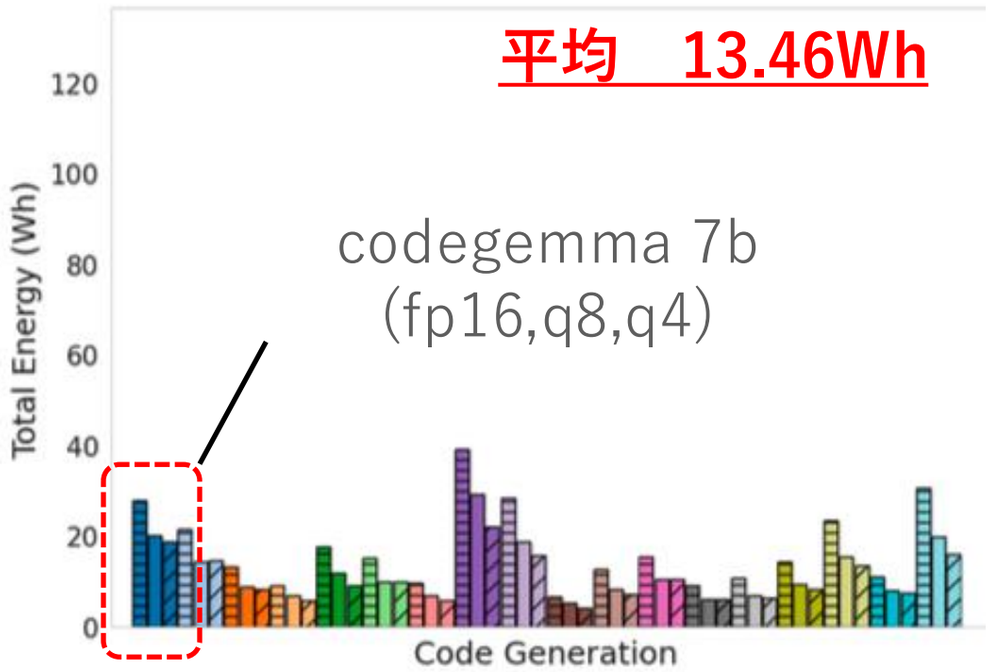
平均　13.46Wh
codegemma 7b
(fp16,q8,q4)
Total Energy (Wh)
0
20
40
60
80
100
120
Code Generation

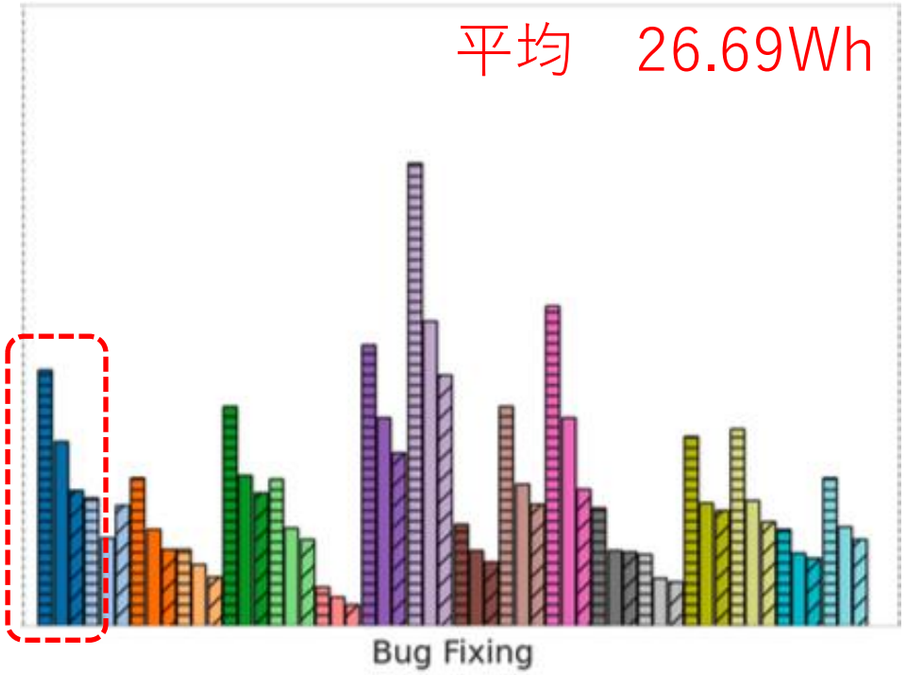
平均　26.69Wh
Bug Fixing

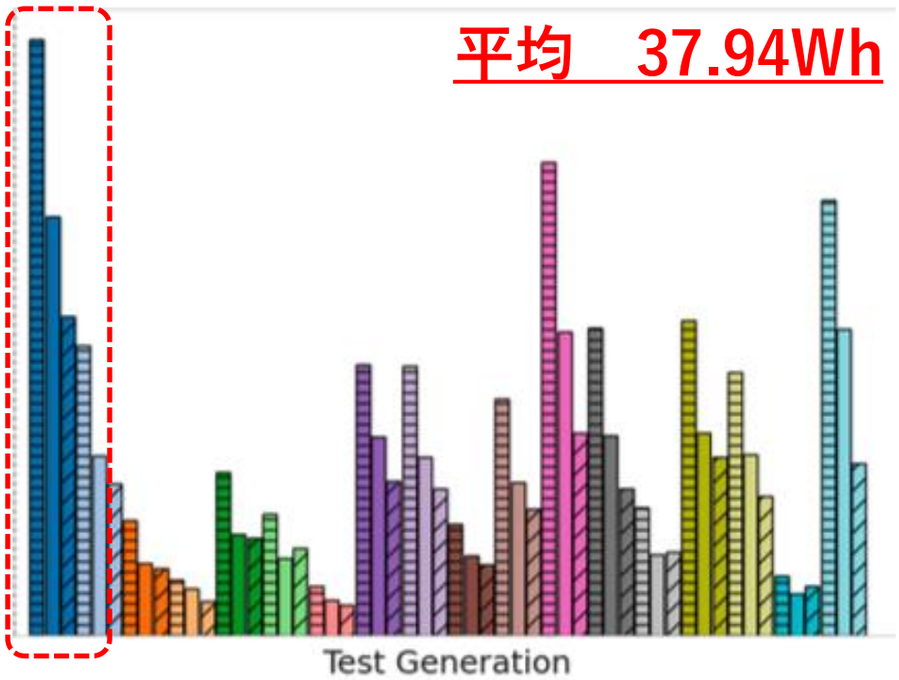
平均　37.94Wh
Test Generation

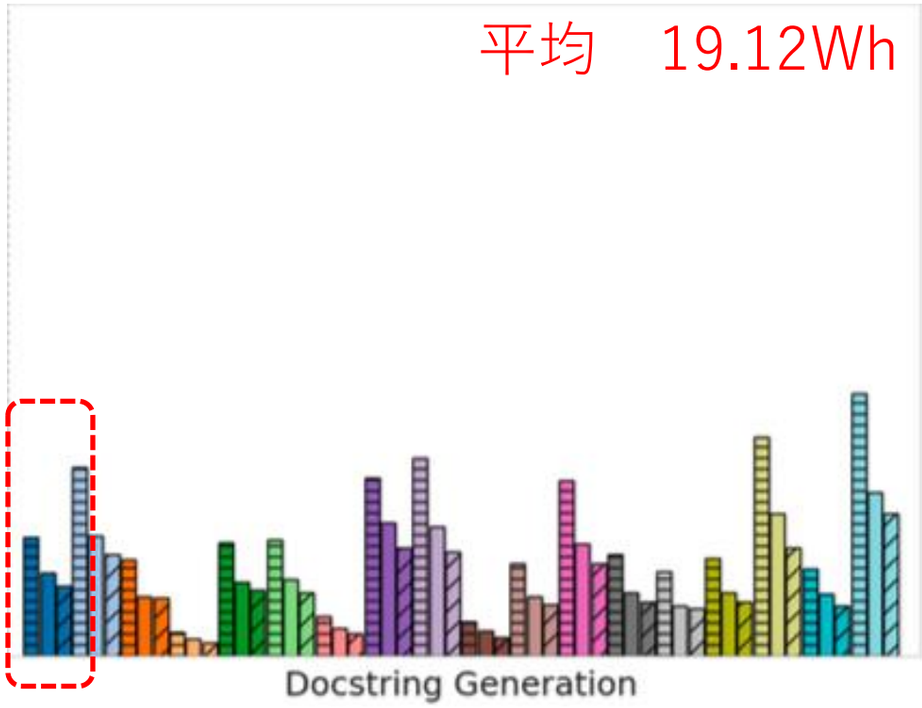
平均　19.12Wh
Docstring Generation

結果｜RQ1

エネルギー効率（tokens/J）

モデル名	コード生成	バグ修正	ドキュメント生成	テストケース生成
granite-code 20b-fp16	0.13	0.12	0.13	0.12

全タスクにわたってエネルギーあたりの出力トークン数は同じ

→ タスク間の消費エネルギー差は出力トークン数の違い

最もエネルギー効率が高かったモデル

コード生成：granite-code:3b-q4

バグ修正：gemma:2b-q4

ドキュメント生成：deepseek-coder:1.3b-q4

テスト生成：gemma:2b-q4

最もエネルギー効率がいいモデルはタスクごとに異なる

結果｜RQ1

まとめ

- タスクによって消費エネルギーは異なる

  テスト生成はコード生成の約2.8倍

- タスク間の消費エネルギー差は出力トークン数の違い

  モデル自体のエネルギー効率は変わってない

- 最もエネルギー効率のいいモデルはタスクごとに異なる

  タスクに応じたモデル選択が重要

結果｜RQ2

(A) phi3 : 3.8b-q8　(B) phi3 : 14b-fq16　(C) starcoder2 : 15b-fq16

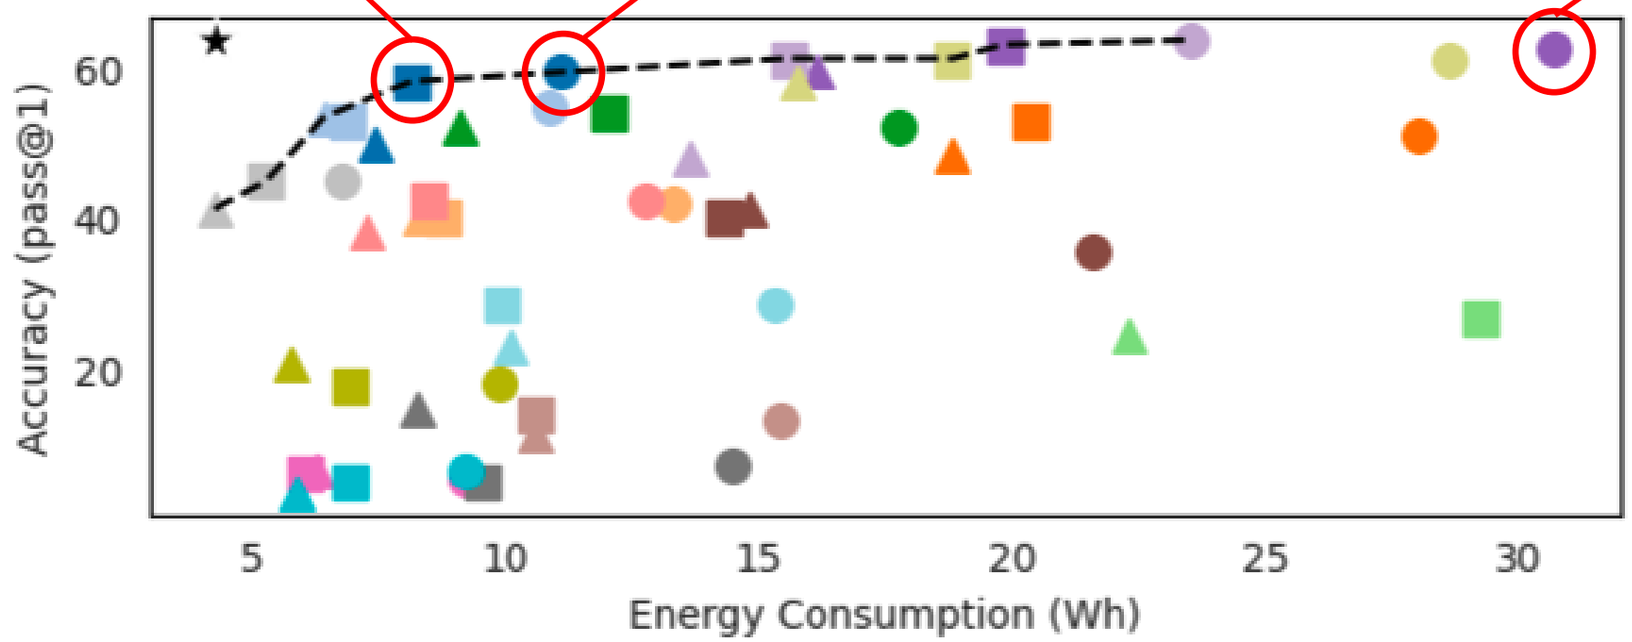

(破線は最適なモデル群)

丸：FP16
四角：8bit量子化
三角：4bit量子化

(a) Code Generation

(A) : 8.16Wh，58.53%　(B) : 23.52Wh，64.02%　(C) : 30.66Wh，62.80%

パラメータ数を２倍以上に増やし，エネルギーを約3倍消費しても

精度の向上は4-5%

結果｜RQ2

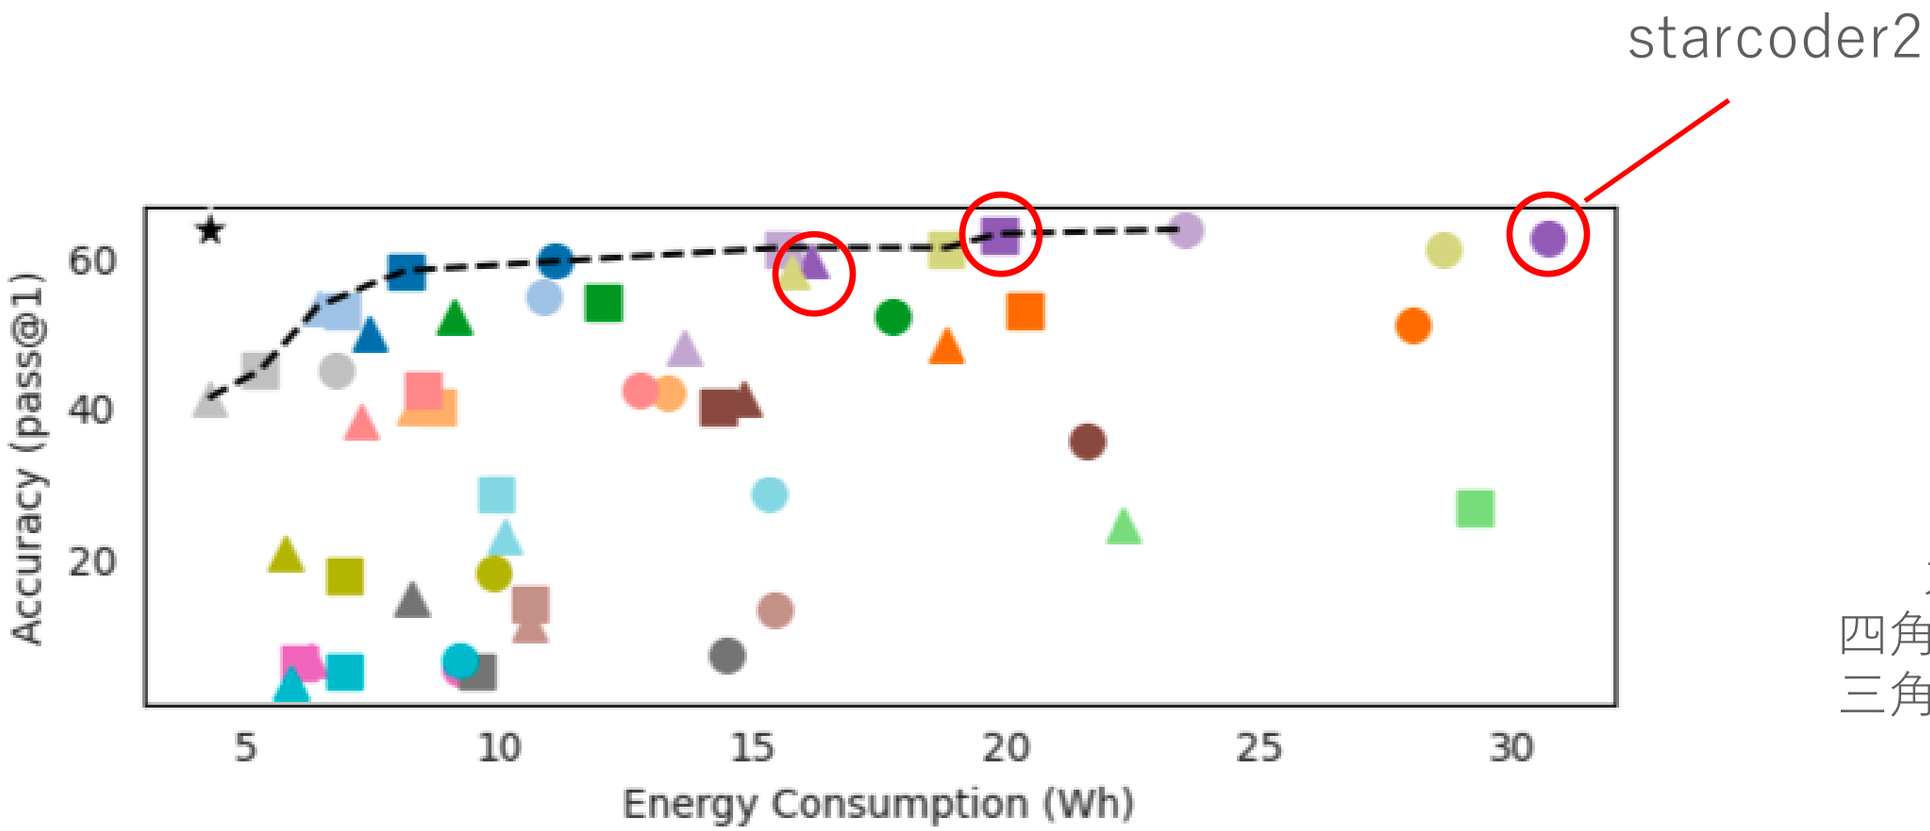

(a) Code Generation

丸：FP16
四角：8bit量子化
三角：4bit量子化

量子化しても精度の低下は**限定的**

結果｜RQ2

まとめ

・エネルギーと精度は必ずしもトレードオフではない

小型・量子化モデルが大型・FPモデルを上回る場合がある

・量子化は効果的

4-bit量子化が最も効率的

精度の低下は最小限

・ある時点以降，エネルギー増加による精度向上は限定的

結果｜RQ3

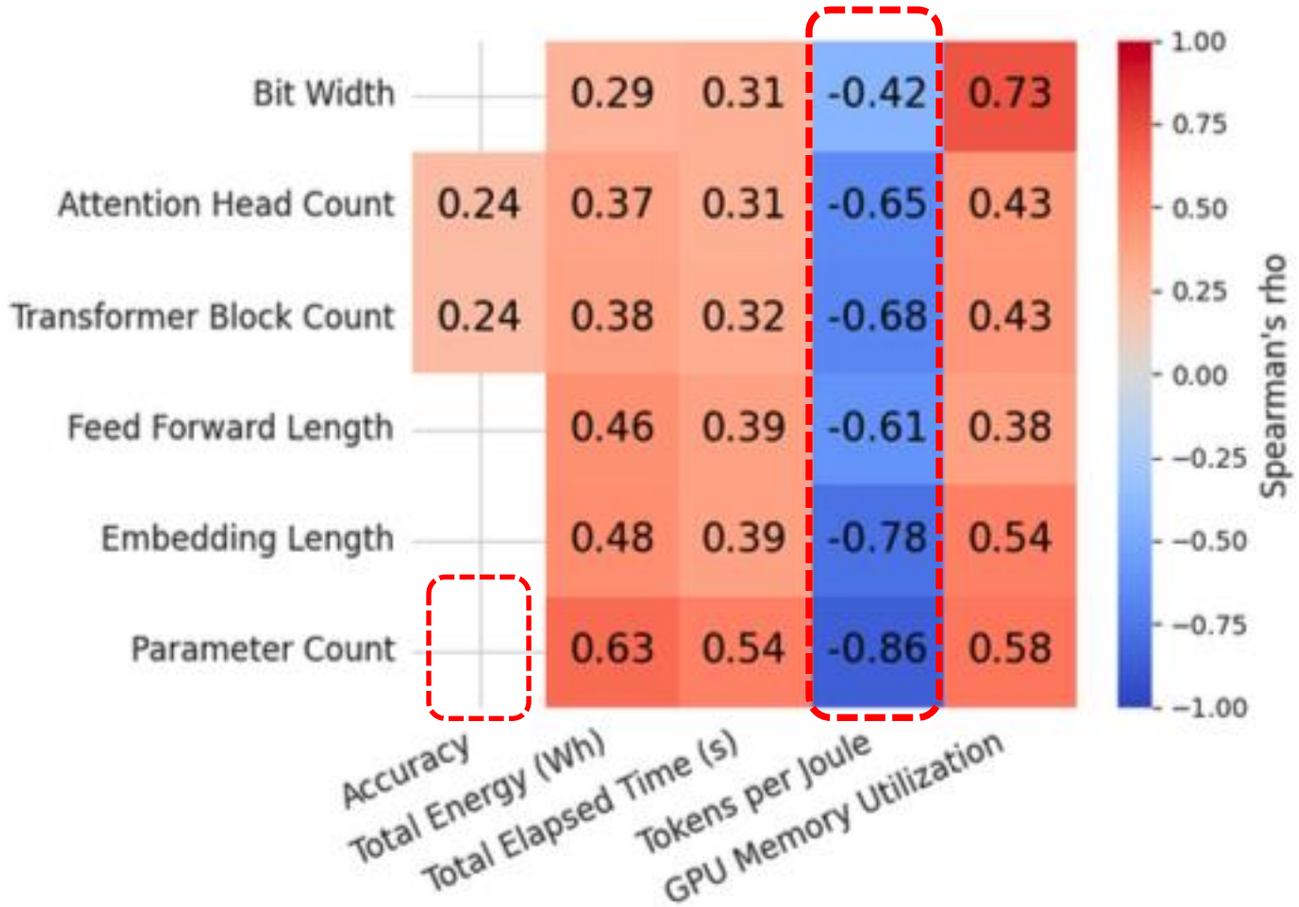

有意な相関のみを記述

- パラメータ数と精度に有意な相関なし
- パラメータ数が多いほどエネルギー消費が増加

結果｜RQ4

精度面での比較

ドキュメント生成以外のタスクでコード特化モデルが優位

エネルギー効率を考慮した分析

・バグ修正

最適モデル群の多くは汎用モデル

・テスト生成，ドキュメント生成

最適モデル群に汎用モデルとコード特化モデルが混在

・コード生成

最適モデル群は全てコード特化モデル

<u>コード特化モデルがSEタスクで最適とは限らない</u>

まとめ

- SEタスクにおけるLLMの精度とエネルギー消費のトレードオフを調査
- エネルギー消費はタスクによって大きく異なる
- 大型モデルは必ずしも小型モデルより高精度ではない
- 大型モデルの量子化版は中型モデルの完全版よりも効率的
- モデルアーキテクチャからエネルギー効率を予測可能