



A study on accelerating LLM inference using KV cache sharing with IOWN APN

NTT株式会社、デバイスイノベーションセンタ、田仲顕至

2025年 10月 30日

自己紹介：田仲 顕至 (Kenji Tanaka)



- Communication-efficient distributed deep learning with GPU-FPGA heterogeneous computing
Communication-efficient distributed deep learning with GPU-FPGA heterogeneous computing (IEEE Hot Interconnects 2020)
- CiraaS: cloud computing with programmable logic
CiraaS: cloud computing with programmable logic (ACM SIGCOMM'22 Poster)
- Transparent Broadband VPN Gateway: Achieving 0.39 Tbps per Tunnel with Bump-in-the-Wire
Transparent Broadband VPN Gateway: Achieving 0.39 Tbps per Tunnel with Bump-in-the-Wire (IEEE INFOCOMM'24 Oral)
- IOWN Global Forum 検討中の GPUDirect Async Kernel Initiated Network を用いた、低遅延・高効率ビデオ処理AI
IOWN Global Forum 検討中の GPUDirect Async Kernel Initiated Network を用いた、低遅延・高効率ビデオ処理AI (GTC'24 → GTC'25 → OCP Global Summit'25 Poster)
- KV Cache Sharing over IOWN All-Photonics Network: Building a Sustainable and High-Performance Nation-Wide Distributed AI for LLM Inference (OPC APAC Summit'25 Oral)
- システム全般、Smart NIC、NIC-GPU連携に関する技術領域を中心に研究活動中

背景：推論需要と電力網

- LLM 推論需要は年々拡大し、電力効率の改善が追いつかない。
- 増設のボトルネックは発電に加え、送電・変電にもある。
- 集中型DCのみでは需要の速度に追いつけない。

(参考) 千葉県印西市のデータセンター

印西市は東京都心から約 40km の場所に位置し、従来から金融機関のコンピュータセンターが立地してきた。近年、国内外の IT 企業などによるデータセンター建設が相次ぎ、電力契約の申し込みも大幅に増加した。

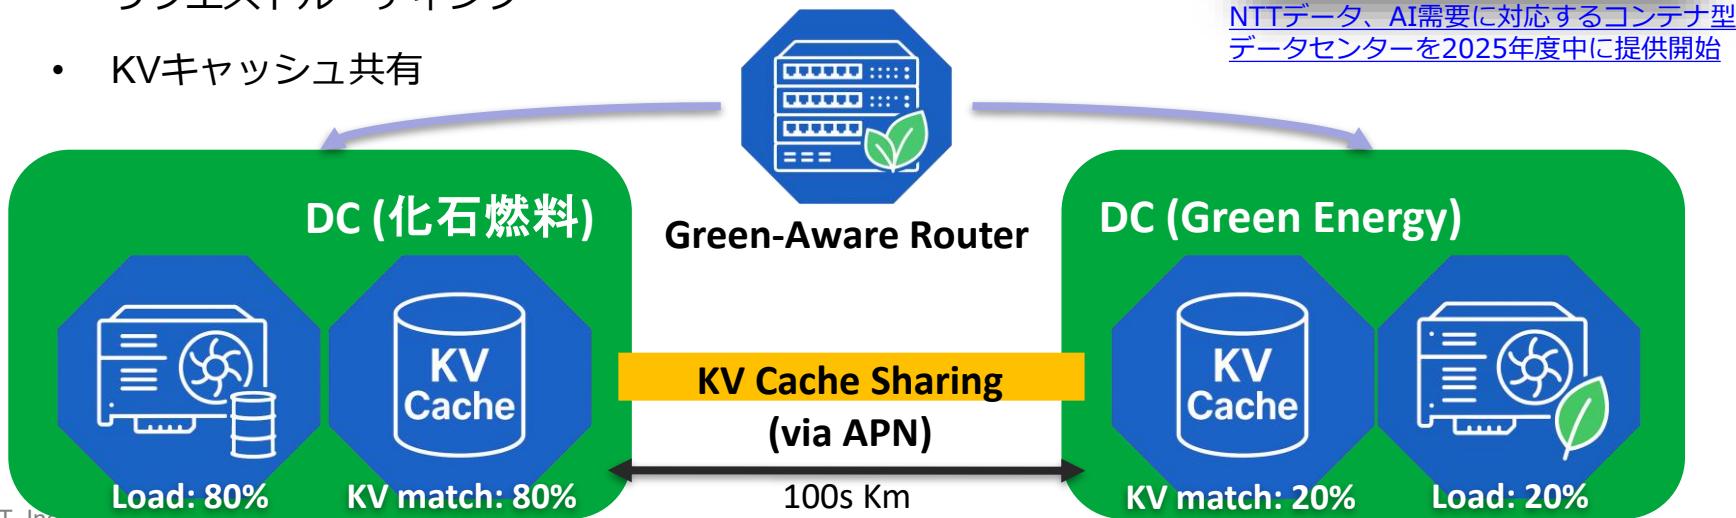
東京電力パワーグリッドは、印西地域への電力供給強化を計画し、50 万 V 送電線に接続する新京葉変電所（船橋市）から千葉ニュータウン変電所（印西市）を経て千葉印西変電所（印西市・新設）に至る 27.5 万 V の地下ケーブル線を敷設した。

地下ケーブル線を敷設するための約 10km の洞道は、シールド工法により 2 年半で建設するなど、早期の建設に努めた結果、2019 年 4 月から約 5 年間で工事を完工させることができた。千葉印西変電所の容量は 2024 年 6 月の運用開始時には 60 万 kW であり、将来的には更に増加させることを計画している。

[電力・ガス取引監視等委員会、局地的電力需要増加と送配電ネットワークに関する研究会報告書](#)より

ゴールイメージ

- 小規模DCを分散展開し電力網への負担を軽減
 - 再生可能電源近傍に展開することで CO₂ 排出量削減にも寄与
- IOWN All-Photonics Network で DC を束ね有効活用
 - リクエストルーティング
 - KVキャッシュ共有

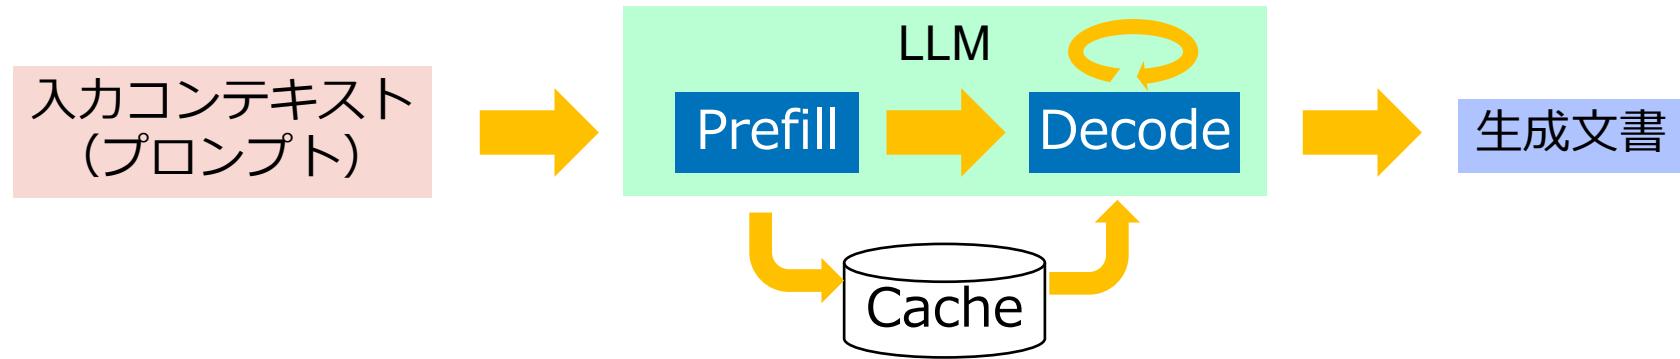




KVキャッシュの再利用・共有

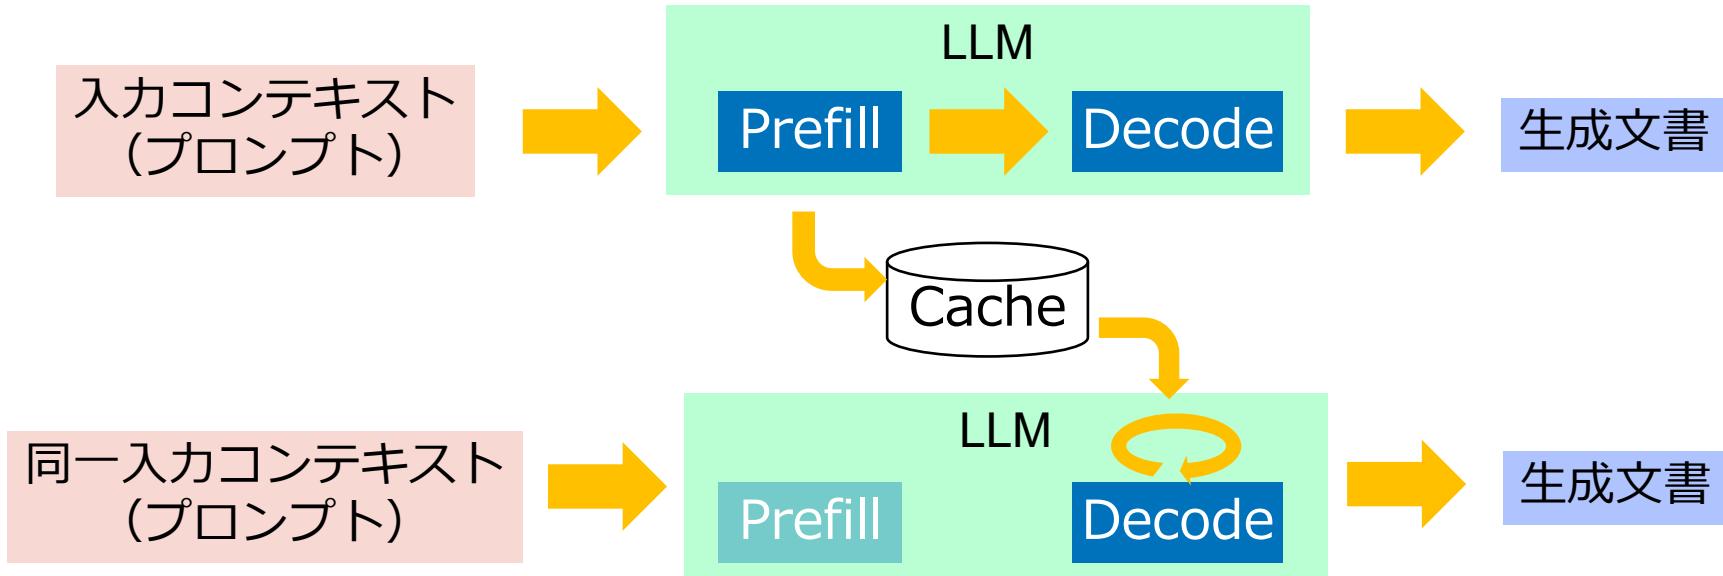
KVキャッシュとは

- KV キャッシュとは、Prefill 段階で各層が生成した Key/Value の保存である。



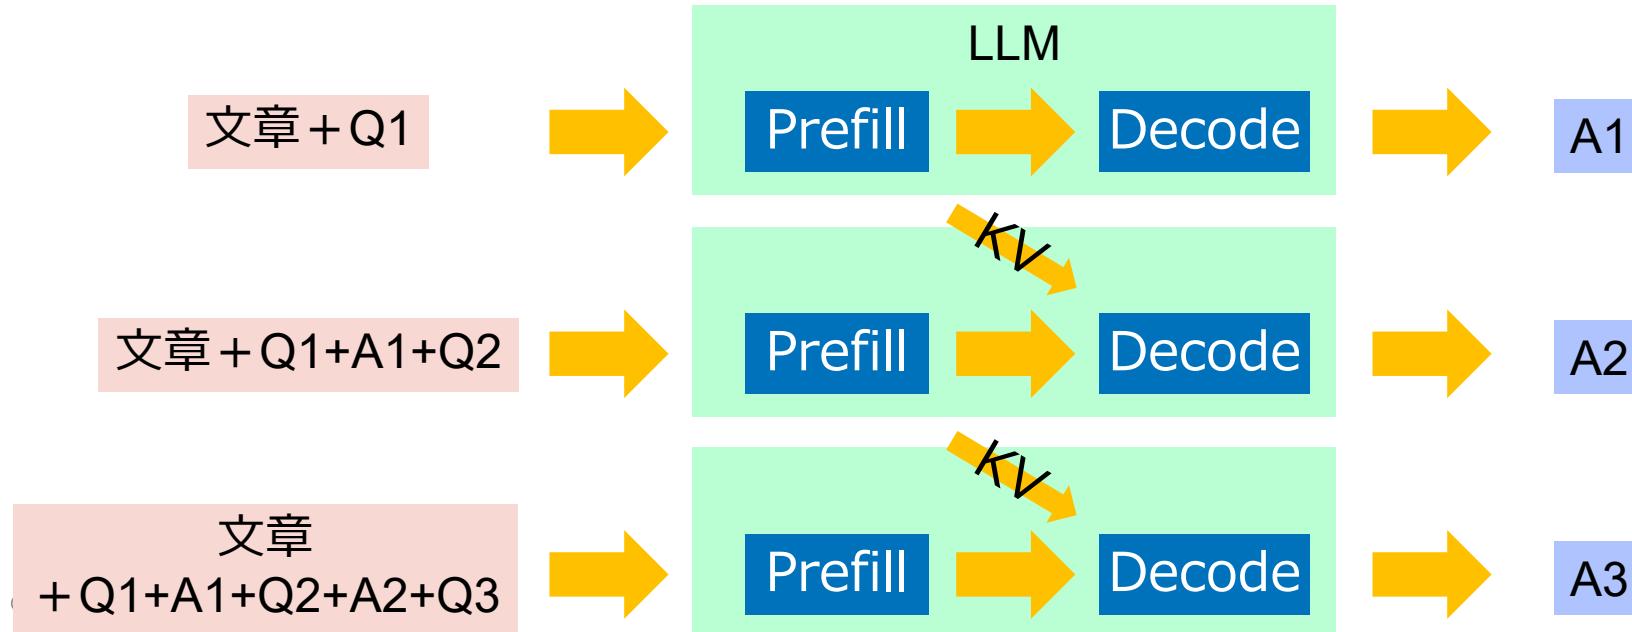
KVキャッシュとは

- KV キャッシュとは、Prefill 段階で各層が生成した Key/Value の保存である。
- KV を再利用すると、Prefill の計算を大幅に削減できる。



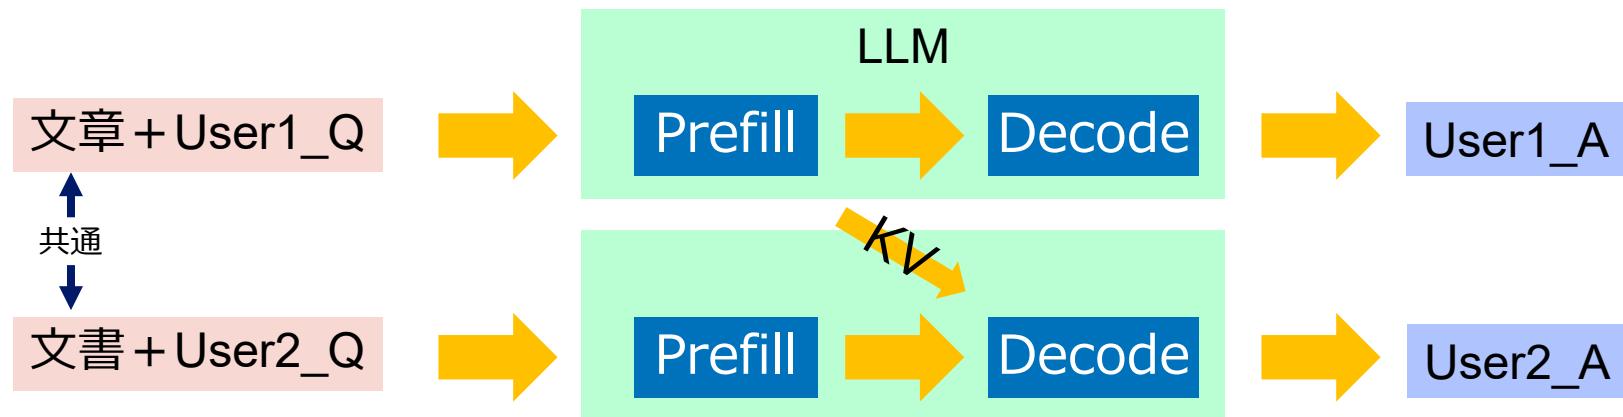
KVキャッシュの再利用とは

- KV キャッシュとは、Prefill 段階で各層が生成した Key/Value の保存である。
- 「KV再利用 = 同一ユーザ内」



KVキャッシュの共有とは

- KV キャッシュとは、Prefill 段階で各層が生成した Key/Value の保存である。
- 「KV共有 = ユーザ間」



KVキャッシュの再利用・共有の実体



- Deepseek、OpenAI API、Azure などでは KVキャッシュヒット割引を提供
- Alibaba Cloud の報告[1]によると
 - KVキャッシュ再利用率は、良いケースで 6 割
 - **KVキャッシュ共有は、ほぼ実施されていない**

[Deepseek料金表より](#)

- なぜ KVキャッシュ共有は難しいのか？

KVキャッシュの前方一致



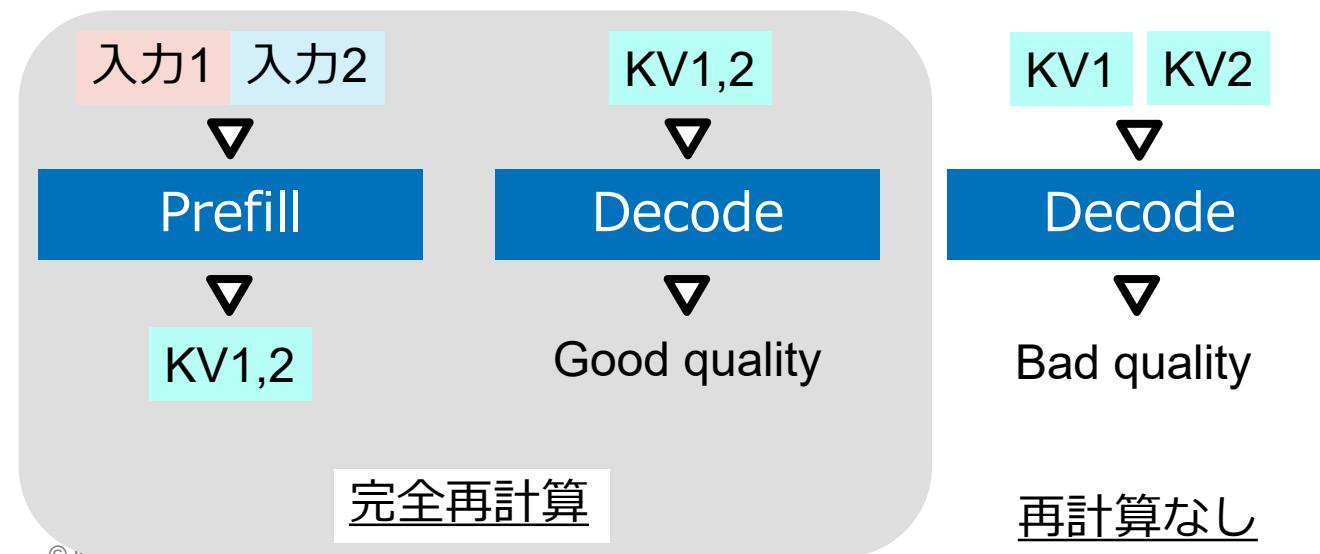
- 入力トークン列が "前方一致" しなければKVキャッシュは再利用できない
 - Transformer を含む decoder タイプのLLMでは、ある位置のトークンのKVキャッシュは、その位置より前のトークンの情報を持つため
- 通常、 “ユーザ情報” や “メモリ” を含むシステムプロンプト（ガードレール、ツール仕様書）が先頭に入るため、ユーザ間の共有は難しくなる
- コンテキストを個別にキャッシュして機械的に結合すると、コンテキスト間の関係性が破壊され精度が落ちる。

The screenshot shows the Claude Code interface with the following details:

- Claude Code v2.0.21
- Sonnet 4.5 · Claude Max
- /home/tanaka/workplace/tanaka_WS/marp_slide
- > /context
- Context Usage
- claudie-sonnet-4-5-20250929 · 74k/200k tokens (37%)
- System prompt: 2.9k tokens (1.4%)
- System tools: 13.5k tokens (6.7%)
- MCP tools: 10.2k tokens (5.1%)
- Memory files: 2.3k tokens (1.2%)
- Messages: 8 tokens (0.0%)
- Free space: 126k (63.1%)
- Autocompact buffer: 45.0k tokens (22.5%)

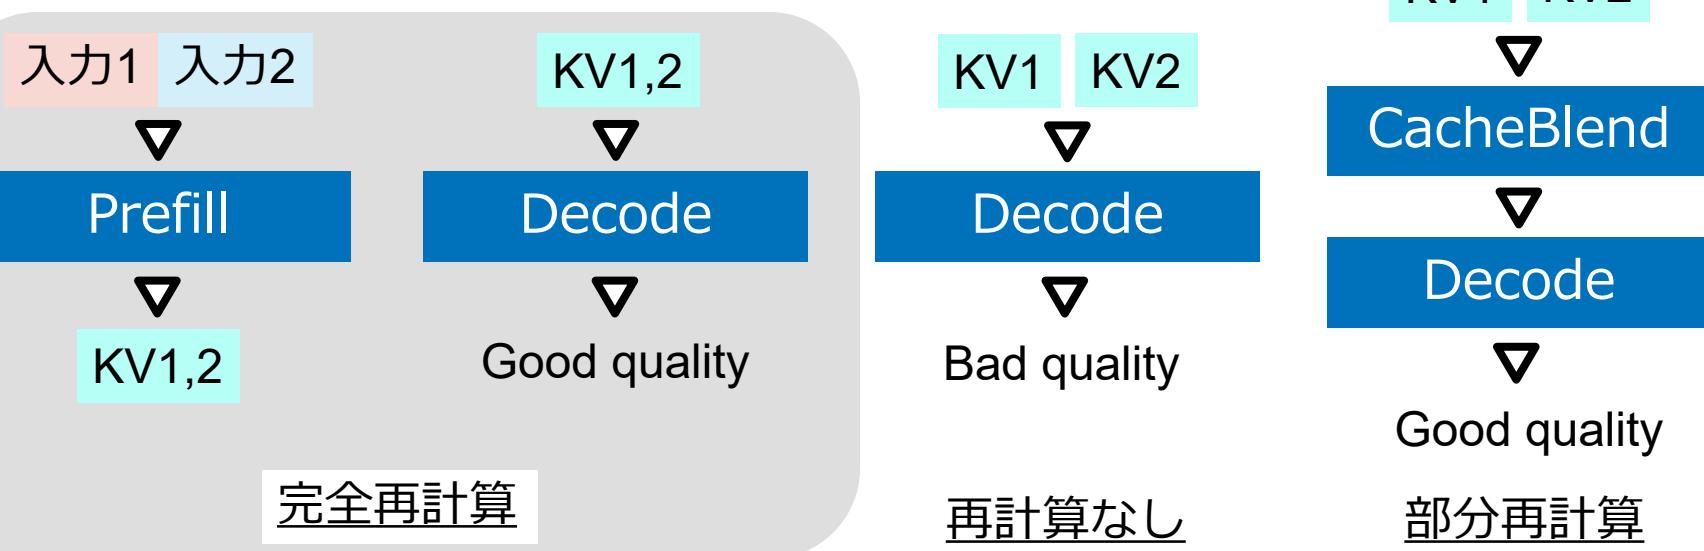
KVキャッシュ間の依存の再計算

- KVキャッシュ間の関係性には再計算が必要。再計算にはコストがかかる。
- 個別のKVキャッシュを再計算なしに再利用した場合は精度劣化



KVキャッシュ間の依存の再計算

CacheBlend では、KVキャッシュ間の関係性の強い部分のみを再計算することで、精度とコストのバランスをとる



KVキャッシュ間の依存の再計算

- CacheBlend [1] や、改良版の KVShare [2] を用いた場合、
 - 定形の入力（例：system + 文書 + 質問）では文書の100%共有が可能 [1]
 - 会話ログのような不定形入力でも共有率 >50% が可能 [2]
 - 再利用では精度劣化なし、共有でも劣化は小さい [3]
- } Prefill の大幅削減
- } 精度も維持

TTFT (s)

[1] J. Yao+, “CacheBlend: Fast Large Language Model Serving for RAG with Cached Knowledge Fusion,” EuroSys’25.

[2] H. Yang+, “KVShare: An LLM Service System with Efficient and Effective Multi-Tenant KV Cache Reuse,” arXiv:2503.16525.

CacheBlend を使う

- CacheBlend 著者らは、CacheBlend を [LMCache](#) という名のOSSで公開中
- LMCache は
 - vLLM の KVキャッシュマネージャモジュールという位置づけ
 - Nvidia Dynamoにおいても KVキャッシュマネージャとしてサポート
 - llm-d にとってのコアの KVキャッシュマネージャとして貢献
 - 本日は解説しないが、以下の強力な機能も持つ
 - › KVキャッシュの圧縮転送
 - › 計算と通信のオーバラップ
 - › NIXLとの連携

LMCache & Nvidia, Scaling KV Caches for LLMs: How
LMCache + NIXL Handle Network and Storage
Heterogeneity,"PyTorch Conference'25.

現在の取り組み

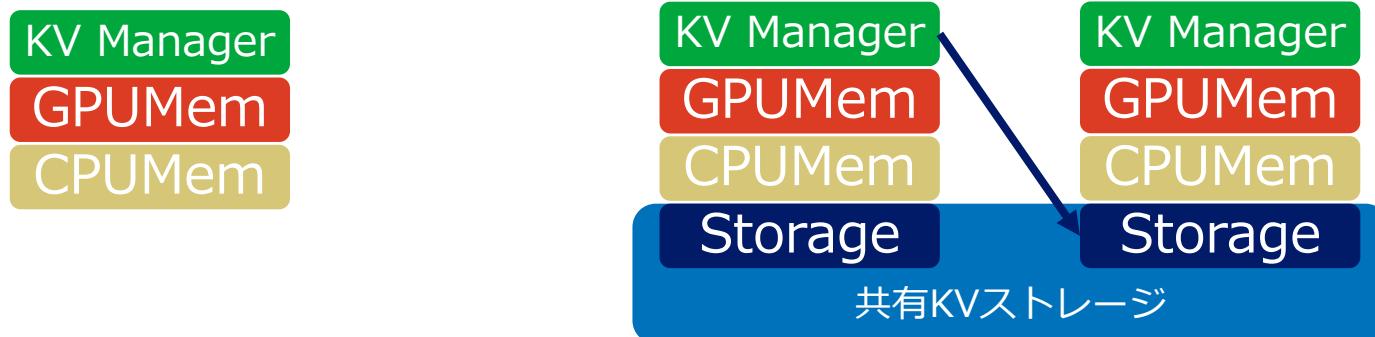
CacheBlend 登場による要求されるシステムの変化

これまで : KVキャッシュは前方一致で、読むKVキャッシュは1つ

- メモリプリーリングのような中規模の記憶空間で十分
- Hot (GPU Memory)、Warm (Host Memory) の記憶階層

CacheBlend 後 : 複数断片の再利用が可能、記憶容量の限界効用が高い

- KVキャッシュ母集団が広いほどヒット率が上がり、Prefill削減効果が上昇
- Storageを共有し、大容量な Cold (Remote Storage) なKVキャッシュストレージプールが有効？



CacheBlend 登場による要求されるシステムの変化

これまで : KVキャッシュは前方一致で、読むKVキャッシュは1つ

- メモリプリーリングのような中規模の記憶空間で十分
- Hot (GPU Memory)、Warm (Host Memory) の記憶階層

CacheBlend 後 : 複数断片の再利用が可能、記憶容量の限界効用が高い

- KVキャッシュ母集団が広いほどヒット率が上がり、Prefill削減効果が上昇
- Storageを共有し、大容量な Cold (Remote Storage) なKVキャッシュストレージプールが有効？

KV Manager

KV Manager

KV Manager

初期検討 : 共有KVストレージを実現するためのネットワーク性能と
Prefill 削減効果

共有KVストレージ

検証1：KVキャッシュリモートアクセス帯域の影響

- KVキャッシュは“入力トークン長” × “モデルサイズ” のため大容量
- アクセス帯域がパフォーマンスに与える影響を評価

モデル：Mistral-7B-Instruct-v0.2

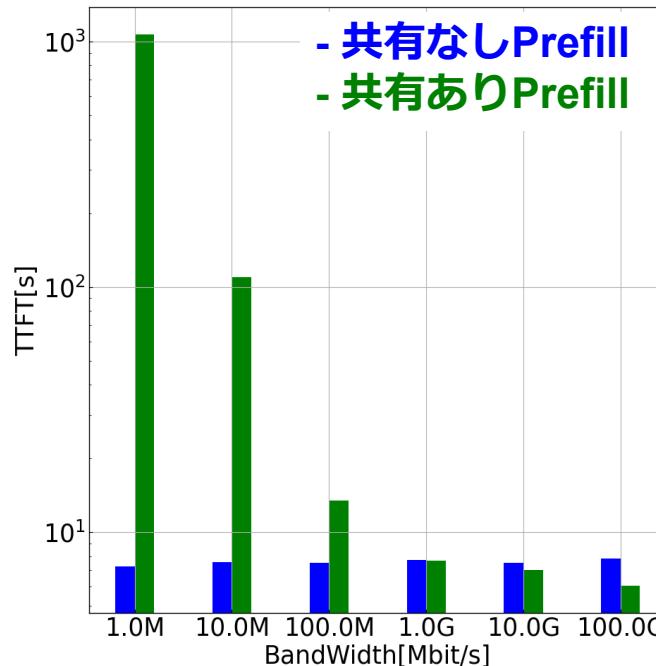
入力トークンサイズ：1K

KVキャッシュサイズ：120 MB

GPU：A100

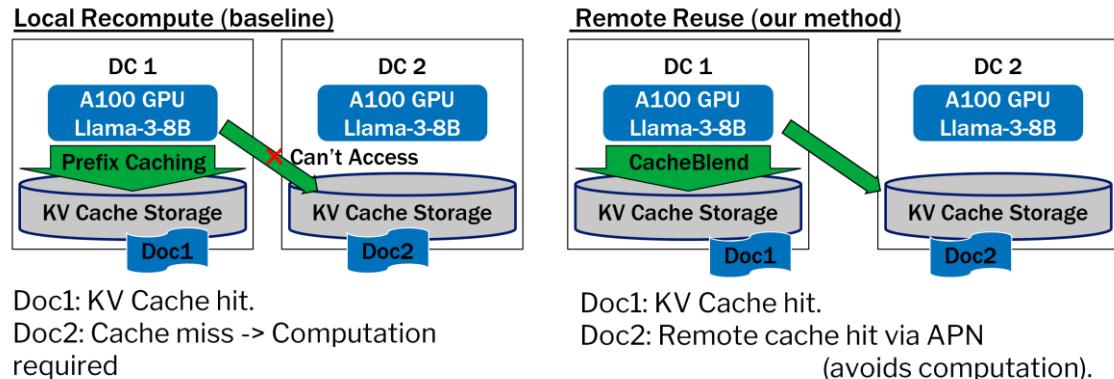
結果：

- 1G で約9割のTTFT 削減
- 10G で約8割の TTFT 削減



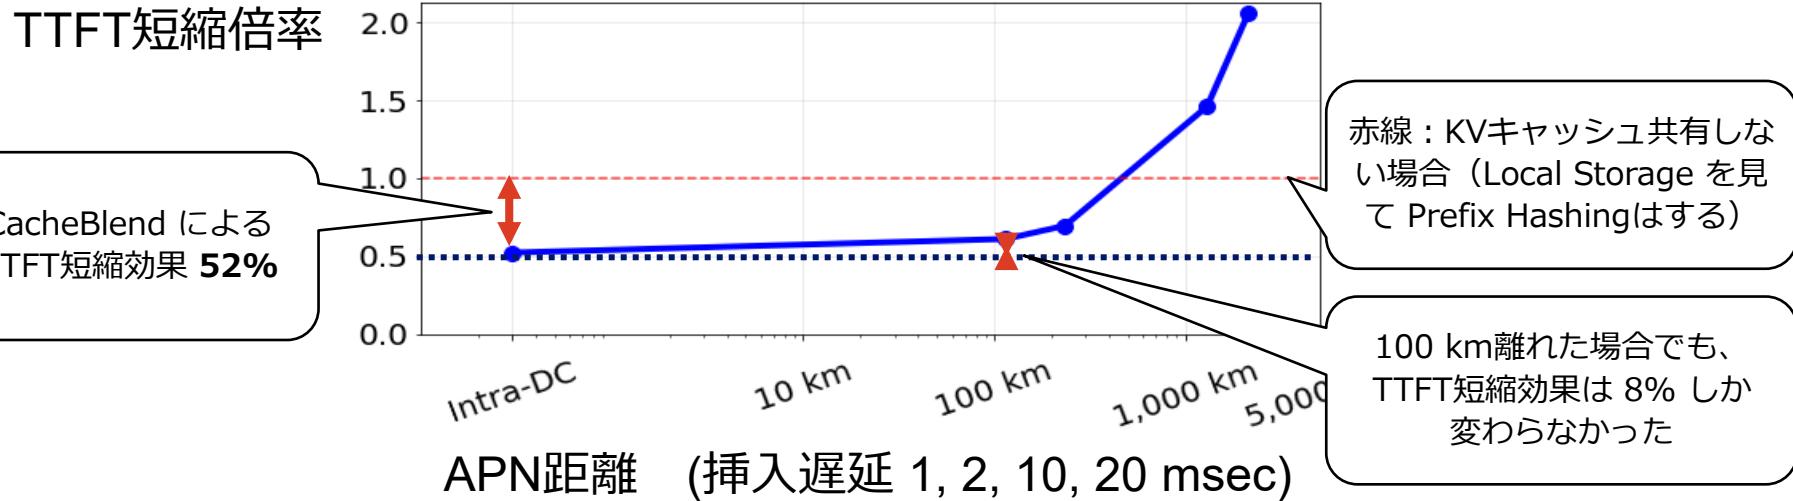
検証2：KVキャッシュリモートアクセス遅延の影響

- 前実験を踏まえ、長距離通信として APN をエミュレート
- レイテンシ（距離）が TTFT・電力効率に与える影響を評価
- 文書の KVキャッシュをユーザ間共有するシナリオ
 - モデル：Llama-3.1-8B
 - 入力トークンサイズ：平均約65K [1]
 - KVキャッシュサイズ：約8 GB
 - A100 x1 / node
 - 遅延挿入 (tc コマンド)
 - レイテンシ – 距離特性：
Open APN Report 参照 [2]



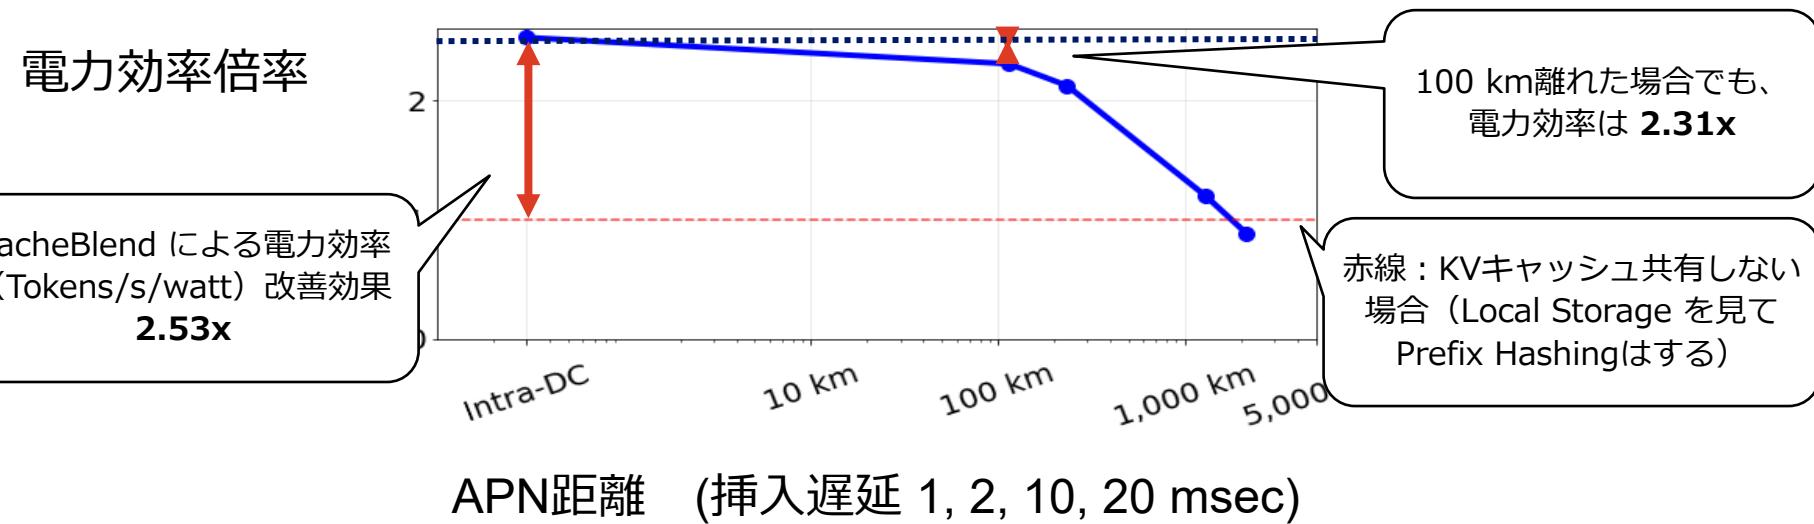
検証2：KVキャッシュリモートアクセス遅延の影響

- KVキャッシュを共有することで TTFT (Time-to-First-Token) は削減される
- ある程度 (100km) 距離を離しても、TTFT短縮効果は維持される



検証2：KVキャッシュリモートアクセス遅延の影響

- 電力効率 (Tokens/s/watt) は、KVキャッシュ共有によるPrefill計算量削減で向上
- ある程度 (100km) 距離を離しても、電力効率メリットは維持される



まとめ

- LLM推論の需要増、電力インフラへの負担増
- LLM推論の計算量を削減するKVキャッシングの再利用は大きく注目されている
- KVキャッシングの共有を可能にする CacheBlend に本発表では注目
- KVキャッシング共有時代には、大きなリモートストレージでの KVキャッシングプールが必要と考え、リモートアクセス要件をエミュレート
- 低遅延・広帯域ネットワークにて、小型DCを繋ぎKVキャッシング共有することで、100 km 圏内で DC 内比 8% オーバヘッドの推論性能を確認
- 電力インフラ負荷の低い小型分散DCを束ねた、LLM推論基盤の可能性を示した

**Innovating a Sustainable Future
for People and Planet**