Investigando o Uso de Modelos de Linguagem de Grande Escala para o Escalonamento de Tarefas

Lívia Mayumi Kawasaki Alves[1], **Guilherme Piêgas Koslovski**[1]

[1]Universidade do Estado de Santa Catarina (UDESC) – Joinville, SC – Brasil

Resumo. *Os Large Language Models (LLMs) revolucionaram a área de Processamento de Linguagem Natural (PLN), sendo atualmente possível adaptar tais modelos para realizar atividades complexas em diversas áreas. Especificamente, a técnica de fine-tuning permite que os modelos pré-treinados aprimorem o conhecimento para funções específicas. Em ambientes de alto desempenho, o escalonamento é uma atividade complexa e consiste no processo de alocar recursos do sistema para diversas tarefas, atendendo a objetivos específicos. A escolha da ordem de alocação é fundamental para a eficiência desse ambiente. Nesse sentido, este artigo visa propor uma análise do uso de LLMs ajustados com fine-tuning para auxiliar no escalonamento de tarefas comunicantes.*

1. Introdução

Large Language Models (LLMs) representam um salto significativo em sistemas computacionais capazes de compreender e gerar textos em linguagem humana. Eles são ferramentas poderosas em Processamento de Linguagem Natural (PLN), capazes de realizar tarefas como tradução, resumo e conversação. Avanços na arquitetura dos *transformers*, no poder computacional e nos dados impulsionaram seu sucesso. Esses modelos aproximam-se do desempenho do nível humano, tornando-os valiosos para pesquisas e implementações práticas. O rápido desenvolvimento dos LLMs estimulou inovações nas estratégias e nas técnicas de *fine-tuning* [Parthasarathy et al. 2024]. Especificamente, o *fine-tuning* usa um modelo pré-treinado como base. O processo envolve um novo treinamento em um conjunto de dados menor e específico. Esta abordagem baseia-se no conhecimento pré-existente do modelo, melhorando o desempenho em tarefas específicas com dados e requisitos computacionais reduzidos.

O presente trabalho investiga a aplicação de LLMs como ferramenta auxiliar na realização de uma atividade gerencial comum em ambientes de alto desempenho e que demanda alto custo operacional: o escalonamento de tarefas. O escalonamento de tarefas refere-se a ação de alocar servidores para atender as solicitações dos usuários, considerando vários parâmetros como tempo de execução, memória e interdependências de tarefas, definindo o sequenciamento da execução [Brucker 2006]. Entre os algoritmos de escalonamentos conhecidos estão FCFS (*First Come First Serve*), *Shortest Remaining Time*, *Shortest-Area First*, entre outros, sendo que a escolha impacta diretamente no tempo de espera e no uso dos servidores.

Por isso, é um tema amplamente estudado. A otimização dessa tarefa é computacionalmente desafiadora, pois os métodos tradicionais apresentam limitações em termos de escalabilidade. Motivando, dessa forma, o estudo de outras alternativas utilizando técnicas de inteligência artificial [Abgaryan et al. 2024]. Nesse contexto, o objetivo deste trabalho é propor a integração de *Fine-tuning* nos modelos pré-treinados para otimizar o processo de escalonamento de tarefas a fim de analisar e comparar os resultados.

2. Unindo Escalonamento e LLMs

Como o estudo foca na resposta gerada pelos modelos para decidir o escalonamento, tais modelos devem seguir a estrutura *Generative Pre-trained Transformer* (GPT) que apresenta três componentes principais: *(i)* generativo, eles aprendem as relações entre as variáveis de um conjunto de dados para gerar novos dados; *(ii)* pré-treinado, ou seja, são treinados usando uma grande base de dados, podendo assim economizar tempo e melhorar o desempenho; e *(iii) transformer*, uma arquitetura de rede neural artificial capaz de lidar com dados sequenciais [Yenduri et al. 2024]. Especificamente, a arquitetura do *transformer* apresenta dois componentes principais: o codificador e o decodificador. O primeiro processa a entrada e o segundo gera a saída. Ambos utilizam mecanismos de atenção para capturar relações entre palavras, e de *feedforward*, que permite que o modelo capture e transforme informações complexas de maneira não linear. Entre esses processos, estão as etapas de soma e normalização que somam a saída de uma camada à sua entrada original e aplicam a normalização para estabilizar o treinamento. Antes de executar todos os mecanismos citados, é necessário converter as palavras em representações numéricas, através do que é chamado de *embedding*, e usar a técnica de codificação posicional que fornece informações sobre a ordem das palavras. As últimas etapas de um *transformer* são a transformação linear, que mapeia a saída para o espaço dimensional do vocabulário, e a aplicação da função *softmax*, que transforma os valores em probabilidade [Prince 2023].

A entrada provida aos modelos nesse estudo foi um arquivo de texto que simula a alocação de tarefas em um *Data Center* (DC) composto por servidores, tarefas agendadas e tarefas na fila, incluindo as informações dos recursos de cada um deles. O arquivo fornece detalhes representando um recorte temporal de métricas e demais informações gerenciais, que podem ser obtidas de rastros de execução publicamente disponíveis. Assim, é possível reproduzir as conclusões do presente estudo.

Inicialmente, os modelos assimilam os padrões do comportamento das tarefas submetidas e escalonadas em servidores do DC, e determinam uma política de escalonamento, gerando uma saída da ordem de execução. A partir da saída, são recortadas as informações pertinentes, ou seja, quais tarefas foram escalonadas e como foram escalonadas (o resumo dos recursos após a decisão). Esses resultados são então passados para um simulador que gerencia a alocação das tarefas em servidores ao longo do tempo, registrando as métricas de desempenho, como o tempo de execução, a utilização dos recursos do DC, e o número de tarefas na fila e em execução.

3. Desenvolvimento e resultados preliminares

Inicialmente, realizou-se o treinamento de um modelo GPT próprio usando um fragmento da entrada dada aos modelos já treinados para alimentar o modelo. O código realiza todos os processos desde processamento de dados até a geração de texto. Além desse modelo, os testes foram executados com outros já consolidados e publicamente disponibilizados.

Através do *Hugging Face*, plataforma que fornece ferramentas de inteligência artificial como modelos e *datasets* para treino, foi possível realizar o teste para os modelos descritos: *gpt2-large, EleutherAI/gpt-neo-1.3B, meta-llama/Llama-3.2-1B-Instruct, microsoft/phi-1.5* e *deepseek-ai/deepseek-coder-1.3b-instruct*.

O teste consistiu em executar cada modelo com os mesmos contextos, gerando saídas em arquivos *json* utilizados posteriormente pelo simulador que gerencia o

escalonamento. Após a simulação foram obtidos os resultados ilustrados pelos gráficos da Figura 1, onde as linhas vermelhas (LLM) representam o modelo treinado pelos autores e as outras cinco, os modelos do *Hugging Face* citados anteriormente.

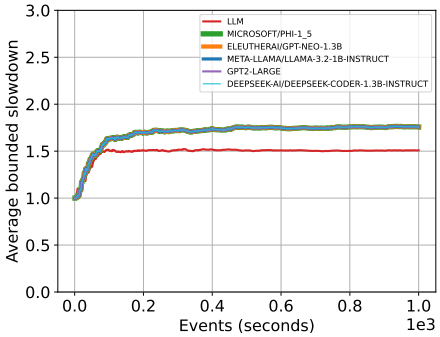

(a) bsld time consolidation

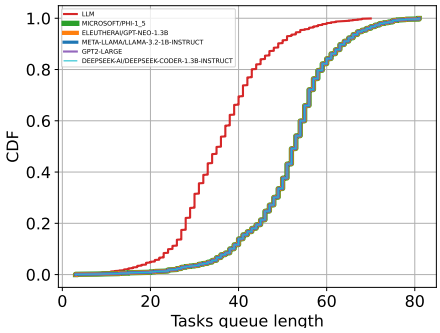

(b) tasks queue consolidation

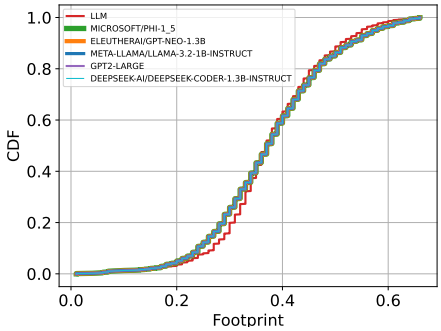

(c) footprint consolidation

Figure 1. Resultados do experimento

A Figura 1(a) apresenta no eixo y o valor médio do *bounded slowdown (bsld)* pelo tempo em segundos no eixo x. O *bsld* é medido por $bsld_t = \max\left\{\frac{w_t+p_t}{\max(p_t,\tau)}, 1\right\}$, sendo t tarefa, w_t tempo de espera, p_t tempo de processamento solicitado e τ uma constante definida em 10 segundos para evitar que tarefas muito pequenas acarretem em valores excessivamente altos [Feitelson and Rudolph 1998]. Notou-se que o LLM se saiu ligeiramente melhor com *bsld* menor comparado aos outros modelos. A Figura 1(b) mostra no eixo x a quantidade de tarefas na fila e no eixo y o *Cumulative Distribution Function* (CDF) que representa a porcentagem de valores que estão inseridos nos intervalos específicos de x. Nessa métrica, o LLM se mostrou melhor com menores comprimentos de fila, e com os valores de CDF crescendo mais rapidamente. Já na Figura1(c) é possível entender a utilização de recursos dos servidores pelas tarefas, com o eixo x representando o *footprint* e o eixo Y, o CDF. Nesse caso, os seis modelos apresentaram comportamento parecido.

Em geral, o modelo treinado apresentou resultados relativamente melhores que os outros modelos pré-treinados. Porém, é conhecido que estes foram treinados em dados de uso geral como livros e sites, portanto, eles podem não ter sido expostos, durante o pré-treinamento, a dados semelhantes ao contexto apresentado, e por isso ter tido dificuldades em gerar resultados significativos e diferentes entre si.

Em vista disso, propõe-se a implementação da etapa de *fine-tuning* no estudo. Esse passo é importante para adaptar o conhecimento dos modelos para tarefas específicas, melhorando o desempenho deles de forma mais rápida e com recursos computacionais reduzidos [Parthasarathy et al. 2024]. A implementação dessa técnica mostra melhoria no desempenho dos LLMs efetivamente nos problemas de escalonamento, podendo até superar as abordagens tradicionais [Abgaryan et al. 2024]. Para a futura execução, faz-se necessário discutir e definir as configurações e os critérios ideais do processo considerando o cenário do estudo. Aplicando essa técnica tanto no modelo treinado quanto nos pré-treinados, será possível analisar o desempenho e a capacidade real de cada um, comparando as vantagens e desvantagens em cada caso.

4. Conclusão

Este trabalho contribuiu para a exploração da aplicação de LLMs no escalonamento de tarefas comunicantes. Analisou-se que o treinamento de um modelo próprio para aplicações na área de escalonamento pode superar, em alguns casos, as limitações de outros modelos pré-treinados. Ademais, propôs-se a integração da técnica de *fine-tuning* para adaptar os modelos para contextos específicos e melhorar seu desempenho. Os resultados parciais indicam que os LLMs apresentam potencial para isso. Os trabalhos futuros envolvem a implementação da solução proposta, para o estudo dos resultados com o intuito de realizar uma análise comparativa. Espera-se, dessa forma, resultados que possam contribuir na busca por soluções eficientes para escalonar tarefas em ambientes de alto desempenho.

Agradecimentos: Este trabalho recebeu apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Fundação de Amparo à pesquisa e Inovação (FAPESC), desenvolvido no Laboratório de Processamento Paralelo e Distribuído (LabP2D).

Referências

Abgaryan, H., Harutyunyan, A., and Cazenave, T. (2024). Llms can schedule. *arXiv preprint arXiv:2408.06993*.

Brucker, P. (2006). *Scheduling Algorithms*. Springer.

Feitelson, D. G. and Rudolph, L. (1998). Metrics and benchmarking for parallel job scheduling. In Feitelson, D. G. and Rudolph, L., editors, *Job Scheduling Strategies for Parallel Processing*, pages 1–24, Berlin, Heidelberg. Springer Berlin Heidelberg.

Parthasarathy, V. B., Zafar, A., Khan, A., and Shahid, A. (2024). The ultimate guide to fine-tuning llms from basics to breakthroughs: An exhaustive review of technologies, research, best practices, applied research challenges and opportunities.

Prince, S. J. (2023). *Understanding Deep Learning*. MIT Press.

Yenduri, G., Ramalingam, M., Selvi, G. C., Supriya, Y., Srivastava, G., Maddikunta, P. K. R., Raj, G. D., Jhaveri, R. H., Prabadevi, B., Wang, W., Vasilakos, A. V., and Gadekallu, T. R. (2024). Gpt (generative pre-trained transformer)— a comprehensive review on enabling technologies, potential applications, emerging challenges, and future directions. *IEEE Access*, 12:54608–54649.