

Sectum

O ChatBot de Segurança da Informação

Mateus Fernandes dos Santos

¹Instituto de Computação – UNICAMP
Campinas – SP – Brazil

m290198@g.unicamp.br

Abstract. *This article addresses the development of an information security chatbot in portuguese through fine-tuning of the Llama (open-source language model). It employs the QLoRa methodology to adjust the model's weights by retraining them using a dataset comprised of questions and answers related to information security. The model outperformed the Llama-7B model in Portuguese tasks overall, excelling particularly in Semantic Similarity and Textual Entailment activities. This model is available at <https://github.com/MateusFernandes25/Sectrum> and <https://huggingface.co/MatNLP/Sectrum>.*

Resumo. *Este artigo aborda o desenvolvimento do Sectum, o chat de segurança da informação em português a partir do ajuste fino do Llama. Para tanto, emprega a metodologia QLoRa para ajustar os pesos, retreinando-os a partir de uma base de dados formada por perguntas e respostas relacionadas à segurança da informação. O modelo superou o modelo Llama-7B nas tarefas em português em geral, destacando-se nas atividades de Similaridade Semântica e Inferência Textual. O modelo está disponível no <https://github.com/MateusFernandes25/Sectrum> e <https://huggingface.co/MatNLP/Sectrum>.*

1. Introdução

A segurança da informação desempenha um papel crucial em um mundo cada vez mais digitalizado. Com o aumento constante das ameaças cibernéticas, é imperativo desenvolver soluções eficazes para proteger os dados e sistemas [Garfinkel 2012]. Nesse contexto, a educação em cibersegurança emerge como um fator intrínseco para a construção de uma sociedade ciberneticamente segura e resiliente [AlDaajeh et al. 2022], uma vez que estudos indicam que entre 80% e 90% dos incidentes de segurança estão relacionados ao fator humano [Gonzalez and Sawicka 2002].

Neste cenário, o projeto aborda o desenvolvimento do Sectum, um chat de Segurança da Informação treinado através de uma base de dados composta por perguntas e respostas sobre segurança. Para tanto, utilizamos como modelo base o Llama2 [META 2023], um modelo de linguagem de código aberto desenvolvido pela Meta e disponibilizado no Huggingface. O treinamento emprega a metodologia Lora [Hu et al. 2021], que mantém a estrutura original do modelo, apenas ajustando certas camadas e reduzindo significativamente o número de parâmetros. Por fim, tal técnica é

aprimorada com o método de quantização - denominado QLoRA - o qual retropropaga gradientes do modelo base quantizado de 4 bits ao mesmo tempo que preserva o desempenho do ajuste fino de 16 bits [Detrmers et al. 2023].

O modelo Spectrum superou seu modelo de origem Llama-7B nas avaliações em português [Lai et al. 2023], destacando-se nas tarefas de Similaridade Semântica e Inferência Textual. Em comparação a modelos em português com base de dados mais ampla, o modelo apresentou média similar, porém com pontuações inferiores em tarefas de conhecimento geral, como por exemplo testes do ENEM e BLUEX. Este projeto é composto por uma breve revisão bibliográfica, que busca relatar os avanços e desafios das técnicas de Processamento de Linguagem Natural em domínios específicos. Segue-se abordando a metodologia utilizada, tal como o modelo base e as técnicas matemáticas para o ajuste fino. Por fim, apresenta os resultados obtidos e a conclusão.

2. Revisão Bibliográfica

Com os avanços tecnológicos, os chatbots de Inteligência Artificial têm se sobressaído como ferramentas de aprendizado e conscientização [Gökçearsan et al. 2024]. Desta forma a implementação de técnicas de processamento de linguagem natural em segurança da informação através da integração com o Chat GPT e intervenções personalizadas, incluindo iniciativas educativas, programas de treinamento e conselhos de segurança, mostram-se promissoras [Gundu 2023].

As novas técnicas de processamento de linguagem natural têm sido capazes de codificar o conhecimento nos parâmetros do modelo [Roberts et al. 2020], no entanto, mesmo modelos robustos como Chat GPT [Schulman et al. 2022] e Llama2 [Touvron et al. 2023] apresentam dificuldades em tarefas de contextos específicos de conhecimento [Feng et al. 2024]. Assim, surgiram alternativas que envolvem o ajuste fino de LLMs de código aberto utilizando dados de tarefas específicas [Hu et al. 2023], como por exemplo ChatDoctor [Yunxiang et al. 2023] e HuaTuoGPT [Zhang et al. 2023a] no contexto da saúde, FinGPT [Yang et al. 2023] nas finanças, e Chat-Law [Cui et al. 2023] no direito.

3. Metodologia

3.1. Base de Dados

O conjunto de dados empregado no ajuste fino foi construído por meio de interações com o ChatGPT na versão 3.5. Para a elaboração de uma base de perguntas relacionadas à segurança da informação, foi solicitado ao modelo gerar questões pertinentes ao tema, como por exemplo: Caracterização das Áreas de Segurança, Segurança Física, Segurança para Crianças, Segurança para Idosos, etc. A coleção de respostas foi desenvolvida utilizando a mesma metodologia, automatizada em python.

Além disso, para mitigar o risco de alucinações [Mishra et al. 2024], foi elaborada uma base de dados contendo exclusivamente perguntas de cunho moral, posteriormente correlacionadas com respostas éticas e imparciais. O resultado foi a formação de uma base com 854 perguntas e respostas, composto pelos principais temas de segurança da informação.




Figura 1. Gráfico evolutivo do trabalho de pesquisa realizado sobre o LLaMA [Zhao et al. 2023]

3.2. Modelo Base

O modelo base selecionado pertence a família do Llama2[Touvron et al. 2023], composta por modelos de linguagem auto-regressivos que utilizam a arquitetura Transformer [Vaswani et al. 2023] otimizada para desempenho. As principais modificações incluem a aplicação de funções de normalização em cada camada [Lee et al. 2009], a substituição da não linearidade da função ReLU pela função de ativação SwiGLU[Shazeer 2020] e a substituição dos embeddings posicionais absolutos por embeddings posicionais rotatórios[Su et al. 2024].

Além disso, modelos Llama possuem o algoritmo AdamW implementado para otimização durante o desenvolvimento do modelo [Touvron et al. 2023], concomitantemente a uma implementação eficiente da camada de atenção [Rabe and Staats 2021]. O ajuste fino dos modelos do Llama se destaca devido aos custos computacionais relativamente baixos [Zhao et al. 2023]. Por essa razão, muitos modelos específicos os incorporaram como modelos de linguagem base, visando alcançar habilidades robustas de compreensão e geração de linguagem, conforme ilustrado no gráfico 1.

Neste trabalho foi empregado a variação NousResearch/Llama-2-7b-chat-hf [META 2023], um modelo base para treinamento com 7 bilhões de parâmetros disponibilizado gratuitamente no Hugging Face, treinado com dados coletados entre janeiro e julho de 2023.

3.3. Algoritmo de Ajuste Fino

Para o ajuste fino do modelo, foi empregado o método Q-LoRA[Dettmers et al. 2023], uma variação do algoritmo LoRA (Low-Rank Adaptation)[Hu et al. 2021], o qual mantém os pesos do modelo pré-treinado e injeta matrizes de decomposição de baixa ordem treináveis em cada camada da arquitetura.

Para tanto, a metodologia LoRA supõe que as atualizações dos pesos possuem um baixo impacto durante a modificação da matriz. Dado que a matriz de peso do modelo base é $W_0 \in R^{d \times k}$, sua atualização é representada como uma decomposição $W_0 + \Delta W = W_0 + BA$, onde $B \in R^{d \times r}$, $A \in R^{r \times k}$. Desta forma, durante o treinamento a matriz W_0 é congelada e não recebe atualizações do gradiente, enquanto A e B possuem parâmetros treináveis. Tanto W_0 e $\Delta W = BA$ são multiplicadas pelo mesmo input, e seus respectivos

vetores de saída são somados coordenada por coordenada [Hu et al. 2021]. Dado uma entrada x , a etapa de propagação resulta na Equação 1:

$$h = W_0x + \Delta Wx = W_0x + BAx \quad (1)$$

O Q-Lora, por sua vez, adiciona o processo de quantização para minimizar a utilização da memória durante o treinamento. Este processo consiste na discretização de uma entrada, reduzindo a dimensionalidade sem perder a informação, por exemplo, de floats de 32 bits para inteiros de 8 bits. Para garantir que a nova representação seja equivalente ao dado natural, o Q-Lora aplica os métodos de *4-bit NormalFloat Quantization* e *Double Quantization*. Além disso, emprega o módulo de *Paged Optimizers* para lidar com os picos de memória durante o checkpointing dos gradientes.

A metodologia *4-bit NormalFloat Quantization* está relacionada à quantização por quantis. Este método assegura que cada bin de quantização contenha um número igual de valores do tensor de entrada, o que o torna ótimo do ponto de vista da teoria da informação. Sua aplicação é viável quando os pesos de uma rede neural pré-treinada possuem uma distribuição normal centrada em zero, com desvio padrão σ [Dettmers et al. 2023]. Para implementar a quantização, basta aplicar a equação 2 a cada elemento k em $2^{(k-1)}$ e $2^{(k-1)} + 1$, pois combinando as soluções e removendo um dos dois zeros que ocorrem em ambos os conjuntos, garante-se uma representação exata de zero.

$$q_i = \frac{1}{2} \left(Q_x \left(\frac{i}{2^k + 1} \right) + Q_x \left(\frac{i + 1}{2^k + 1} \right) \right) \quad (2)$$

A técnica de *Double Quantization* introduz a aplicação da quantização dupla nos dados de entrada. No entanto, para empregar a quantização simétrica de 4 bits, é necessário subtrair a média dos valores da primeira quantização para centralizá-los ao redor de zero. Em média, a dupla quantização resulta em uma redução de 0,373 bits por parâmetro.

O módulo *Paged Optimizers*, por sua vez, é utilizado no limite da memória da GPU, aproveitando o recurso de memória unificada da NVIDIA, que permite transferências contínuas entre GPU e CPU. Por fim, aplica-se os módulos acima no algoritmo Lora, empregando "NF4" para W e "FP8" para c2, através de um tamanho de bloco de 64 para W para maior precisão de quantização e um tamanho de bloco de 256 para c2 para conservar memória [Dettmers et al. 2023].

Conforme outros trabalhos demonstraram, utilizar QLoRA permite comprimir os parâmetros sem comprometer seu desempenho, tornando-o adequado para ambientes com restrições rigorosas de recursos [Ni et al. 2024].

3.4. Treinamento

A implementação do código foi efetuada através de bibliotecas disponibilizadas pelo HuggingFace, como por exemplo Transformers, Tokenizer e Accelerate, justamente com a biblioteca Pytorch. O treinamento foi efetutado através de uma única GPU Nvidia A10G com memória total de 23,6 GB. E a partir de diversas configurações dos hiperparâmetros, foi escolhida a configuração da Tabela 1 como melhor representação:

4. Resultados

Durante o treinamento, o modelo se mostrou estável, estabilizando-se no erro 0,657 em treino conforme evidenciado pelo Figura 2. Além disso, a metodologia utilizada foi capaz

Tabela 1. Configuração de Treino

Parâmetro	Valor	Parâmetro	Valor
otimizador	paged_adamw_32bits	total de épocas	10
decaimento da taxa de aprendizado	cosseno	gradiente máximo de normalização	0.3
taxa de aprendizado	2.0×10^{-4}	redução de peso por camada	0.001
batch de treinamento	20	passos de warmup	0.03
fp16	False	bf16	True




Figura 2. Erro por Passos

de efetuar o treinamento de um algoritmo com 7 Bilhões de parâmetros em uma média de 9,8 segundo por época (passo).

Em língua portuguesa é dificultoso delimitar uma base de dados para os benchmarks a fim de criar comparações com os grandes modelos [Corrêa et al. 2024]. No entanto, é possível empregar a técnica de few-shot através da tradução do benchmarks para português [Lai et al. 2023]. Neste trabalho usamos as base de dados abaixo aplicando a técnica de few-shot para a avaliação do modelo [Gao et al. 2023], resultando na tabela 3.

- **ASSIN2 RTE:** Emprega a métrica de *F1-macro* para avaliar a Similaridade semântica e a inferência textual do modelo com a metodologia RTE. Nela, identifica-se se um dado texto implica em outro texto.
- **ASSIN2 STS:** Utiliza a métrica *Pearson* para medir o grau de equivalência semântica entre duas sentenças, através de Similaridade Textual Semântica (STS).
- **BLUEX:** Aplica a métrica de *acurácia* num conjunto de dados de 724 questões dos exames da Convest (Unicamp) e Fuvest (USP).
- **ENEM:** Emprega a métrica de *acurácia* para analisar um conjunto de dados com 1.430 questões dos anos 2010 a 2018, 2022 e 2023 coletados do Exame Nacional do Ensino Médio (ENEM).
- **FAQUAD NLI:** Usa a métrica de *F1-macro* para analisar as respostas do modelo ao problema de abundância de perguntas. Suas questões derivam de documentos

	ASSIN2 RTE	ASSIN2 STS	BLUEX	ENEM	FaQuAD	Média
Sectrum-7B	74,02	49,03	36,44	40,03	56,24	51,152
LLAMA-7B ¹	56,82	7,39	32,02	29,04	77,38	40,53
Sabiá-7B ¹	64,87	13,63	47,75	60,59	77,43	52,854
TinyLlama-1.1B ²	58,93	13,57	22,81	22,25	43,97	32,306

Tabela 2. Análise de Resultados

Tabela 3. Teste Qualitativo

Perguntas	Respostas
Como proteger meu e-mail?	Existem várias medidas que você pode tomar para proteger seu e-mail: Hinweis 1: Utilize uma conta de e-mail segura e atualizada. Isso significa que você deve manter sua conta atualizada com senhas fortes e atualizadas regularmente. Isso ajudará a proteger sua conta de ataques de phishing e de senhas comprometidas. Hint 2: Utilize a autenticação de dois fatores. Isso adiciona uma camada de segurança adicional para proteger sua conta de acesso não autorizado. Isso significa que você precisará fornecer sua senha e um código de verificação enviado por e-mail ou aplicativo antes de acessar sua conta. Hint 3
Quais os princípios de segurança da informação?	Os principais princípios de segurança da informação incluem: Hinweis sobre a importância da privacidade e proteção de dados sensíveis, como informações financeiras e pessoais. Isso inclui a implementação de medidas de criptografia e a garantia de que os dados sejam armazenados e transmitidos de forma segura. Além disso, a segurança da informação envolve a proteção contra ameaças cibernéticas, como hackers e malware, bem como a implementação de políticas de acesso e controle de acesso para garantir que apenas pessoas autorizadas tenham acesso aos sistemas e dados. Também é importante a implementação de políticas de backup e recuperação de dados para garantir
O que é criptografia?	Criptografia é a prática de transformar informações em uma forma não reconhecível para os humanos, mas ainda possível para o destinatário autorizado, com o objetivo de proteger a segurança e a integridade dos dados. Isso é feito por meio de algoritmos de cifragem, que substituem as informações originais por uma chave ou padrão de cifragem. Criptografia é amplamente utilizada em sistemas de segurança da informação, como redes de comunicação, sistemas de pagamento, e transmissões de dados confidenciais. Ela é essencial para proteger a privacidade e a segurança das informações em ambientes digitais.
Preciso usar antivírus?	Como Inteligência de Segurança da Informação, recomendo a utilização de antivírus para proteger os sistemas contra ameaças cibernéticas, como vírus, malware e ataques de phishing. O antivírus pode ajudar a detectar e remover potenciais ameaças antes que elas causem danos significativos ao sistema. Além disso, ele pode ajudar a garantir a segurança das informações e a integridade dos dados. Portanto, a utilização de antivírus é uma medida importante para a proteção da segurança da informação.
O que é internet?	A internet é uma rede de computadores e dispositivos interconectados que permite a troca de informações e dados em tempo real. Ela é composta por milhares de servidores, routers, switches e outros dispositivos que trabalham juntos para transmitir e receber dados de forma eficiente e segura. A internet é uma ferramenta fundamental na sociedade moderna, permitindo a comunicação, a busca de informações, a compra de produtos, a educação e a realização de diversas atividades. Ela é uma ferramenta essencial para a interconexão global e para a forma como entendemos a informação e a comunicação no século XXI

institucionais variados do contexto acadêmico.

O modelo superou o modelo Llama-7B nas tarefas em português em geral, destacando-se nas tarefas de Similaridade Semântica e Inferência Textual. Nosso projeto, nas tarefas de perguntas e respostas, ainda aproximou-se na média do modelo Sabiá-7B ([Pires et al. 2023]). Em conjuntos de dados mais complexos, como ENEM e BLUEX, o Sectrum apresentou pontuação maior do que Llama-7B. A hipótese é que isto ocorre devido conhecimentos específicos presentes apenas na base de dados em português, conforme outros trabalhos também apresentaram [Pires et al. 2023]. Relativos a modelos menores, treinados apenas com bases em português [Corrêa et al. 2024], o Sectrum também atingiu pontuação superior em todas as métricas. Do ponto de vista qualitativo, o novo modelo treinado apresentou acertos nas instruções sobre segurança da informação, como ilustrado na Tabela 3.

5. Conclusão

O modelo foi disponibilizado no HuggingFace <https://huggingface.co/MatNLP/Sectrum> e pode ser utilizado livremente. O modelo foi capaz de responder questões de específicas de segurança da informação, apresentando métricas semelhantes a outros modelos com métodos de treinamento mais robustos. A metodologia QLoRA, apresentou-se bastante eficiente, pois efetuou executou com sucesso o ajuste fino com tempo reduzido, corroborando outros trabalhos [Zhang et al. 2023b, Ni et al. 2024].

As recomendações para os próximos passos incluem o processamento da base de dados maior para a previsão do modelo, a realização de testes extensivos para avaliar a eficácia do chatbot em diferentes cenários de segurança da informação, e a utilização de um modelo base menor, com o objetivo de manter a acurácia enquanto se reduz a necessidade de processamento. O modelo e seu código encontram-se disponíveis no <https://github.com/MateusFernandes25/Sectrum> e <https://huggingface.co/MatNLP/Sectrum>.

Referências

- AlDaajeh, S., Saleous, H., Alrabaa, S., Barka, E., Breiting, F., and Raymond Choo, K.-K. (2022). The role of national cybersecurity strategies on the improvement of cybersecurity education. *Computers Security*, 119:102754.
- Corrêa, N. K., Falk, S., Fatimah, S., Sen, A., and De Oliveira, N. (2024). Teenytinyllama: Open-source tiny language models trained in brazilian portuguese. *Machine Learning with Applications*, 16:100558.
- Cui, J., Li, Z., Yan, Y., Chen, B., and Yuan, L. (2023). Chatlaw: Open-source legal large language model with integrated external knowledge bases. *arXiv preprint arXiv:2306.16092*.
- Dettmers, T., Pagnoni, A., Holtzman, A., and Zettlemoyer, L. (2023). Qlora: Efficient finetuning of quantized llms. In Oh, A., Naumann, T., Globerson, A., Saenko, K., Hardt, M., and Levine, S., editors, *Advances in Neural Information Processing Systems*, volume 36, pages 10088–10115. Curran Associates, Inc.
- Feng, S., Shi, W., Bai, Y., Balachandran, V., He, T., and Tsvetkov, Y. (2024). Knowledge card: Filling LLMs’ knowledge gaps with plug-in specialized language models. In *The Twelfth International Conference on Learning Representations*.
- Gao, L., Tow, J., Abbasi, B., Biderman, S., Black, S., DiPofi, A., Foster, C., Golding, L., Hsu, J., Le Noac’h, A., Li, H., McDonell, K., Muennighoff, N., Ociepa, C., Phang, J., Reynolds, L., Schoelkopf, H., Skowron, A., Sutawika, L., Tang, E., Thite, A., Wang, B., Wang, K., and Zou, A. (2023). A framework for few-shot language model evaluation.
- Garfinkel, S. L. (2012). The cybersecurity risk. *Communications of the ACM*, 55(6):29–32.
- Gökçearsan, S., Tosun, C., and Erdemir, Z. G. (2024). Benefits, challenges, and methods of artificial intelligence (ai) chatbots in education: A systematic literature review. *International Journal of Technology in Education*, 7(1):19–39.
- Gonzalez, J. J. and Sawicka, A. (2002). A framework for human factors in information security. In *Wseas international conference on information security, Rio de Janeiro*, pages 448–187.
- Gundu, T. (2023). Chatbots: A framework for improving information security behaviours using chatgpt. In Furnell, S. and Clarke, N., editors, *Human Aspects of Information Security and Assurance*, pages 418–431, Cham. Springer Nature Switzerland.
- Hu, E. J., Shen, Y., Wallis, P., Allen-Zhu, Z., Li, Y., Wang, S., Wang, L., and Chen, W. (2021). Lora: Low-rank adaptation of large language models.
- Hu, Z., Wang, L., Lan, Y., Xu, W., Lim, E.-P., Bing, L., Xu, X., Poria, S., and Lee, R. K.-W. (2023). Llm-adapters: An adapter family for parameter-efficient fine-tuning of large language models.
- Lai, V., Ngo, N. T., Veyseh, A. P. B., Dernoncourt, F., and Nguyen, T. H. (2023). Open multilingual llm evaluation leaderboard.
- Lee, D. D., Pham, P., Largman, Y., and Ng, A. (2009). Advances in neural information processing systems 22. *Tech Rep*.

- META (2023). Llama 2. Acessado: 16/05/2024.
- Mishra, A., Asai, A., Balachandran, V., Wang, Y., Neubig, G., Tsvetkov, Y., and Hajishirzi, H. (2024). Fine-grained hallucination detection and editing for language models.
- Ni, H., Meng, S., Chen, X., Zhao, Z., Chen, A., Li, P., Zhang, S., Yin, Q., Wang, Y., and Chan, Y. (2024). Harnessing earnings reports for stock predictions: A qlora-enhanced llm approach.
- Pires, R., Abonizio, H., Almeida, T. S., and Nogueira, R. (2023). *Sabiá: Portuguese Large Language Models*, page 226–240. Springer Nature Switzerland.
- Rabe, M. N. and Staats, C. (2021). Self-attention does not need $o(n^2)$ memory. *arXiv preprint arXiv:2112.05682*.
- Roberts, A., Raffel, C., and Shazeer, N. (2020). How much knowledge can you pack into the parameters of a language model?
- Schulman, J., Zoph, B., Kim, C., Hilton, J., Menick, J., Weng, J., Uribe, J. F. C., Fedus, L., Metz, L., Pokorny, M., et al. (2022). Chatgpt: Optimizing language models for dialogue. *OpenAI blog*, 2:4.
- Shazeer, N. (2020). Glu variants improve transformer.
- Su, J., Ahmed, M., Lu, Y., Pan, S., Bo, W., and Liu, Y. (2024). Roformer: Enhanced transformer with rotary position embedding. *Neurocomputing*, 568:127063.
- Touvron, H., Lavril, T., Izacard, G., Martinet, X., Lachaux, M.-A., Lacroix, T., Rozière, B., Goyal, N., Hambro, E., Azhar, F., Rodriguez, A., Joulin, A., Grave, E., and Lample, G. (2023). Llama: Open and efficient foundation language models.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I. (2023). Attention is all you need.
- Yang, H., Liu, X.-Y., and Wang, C. D. (2023). Fingpt: Open-source financial large language models. *arXiv preprint arXiv:2306.06031*.
- Yunxiang, L., Zihan, L., Kai, Z., Ruilong, D., and You, Z. (2023). Chatdoctor: A medical chat model fine-tuned on llama model using medical domain knowledge. *arXiv preprint arXiv:2303.14070*.
- Zhang, H., Chen, J., Jiang, F., Yu, F., Chen, Z., Li, J., Chen, G., Wu, X., Zhang, Z., Xiao, Q., et al. (2023a). Huatuoqpt, towards taming language model to be a doctor. *arXiv preprint arXiv:2305.15075*.
- Zhang, X., Rajabi, N., Duh, K., and Koehn, P. (2023b). Machine translation with large language models: Prompting, few-shot learning, and fine-tuning with QLoRA. In Koehn, P., Haddow, B., Kocmi, T., and Monz, C., editors, *Proceedings of the Eighth Conference on Machine Translation*, pages 468–481, Singapore. Association for Computational Linguistics.
- Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., Min, Y., Zhang, B., Zhang, J., Dong, Z., Du, Y., Yang, C., Chen, Y., Chen, Z., Jiang, J., Ren, R., Li, Y., Tang, X., Liu, Z., Liu, P., Nie, J.-Y., and Wen, J.-R. (2023). A survey of large language models.