

# Tucano em Question Answering: Exploração das capacidades do modelo no dataset FairytaleQA

Allan D. Ehlert<sup>1</sup>, Larissa A. de Freitas<sup>1</sup>, Ulisses B. Corrêa<sup>1</sup>

<sup>1</sup>Centro de Desenvolvimento Tecnológico – Universidade Federal de Pelotas (UFPel)  
96010-610 - Pelotas - RS - Brazil

{adehlert, larissa, ulisses}@inf.ufpel.br

**Abstract.** *Large Language Models (LLMs) have demonstrated remarkable capabilities in addressing various Natural Language Processing (NLP) tasks, including Question Answering (QA). To help bridge the gap between high-resource and low-resource languages, Tucano, a series of decoder-transformer models trained in Portuguese was developed. This study evaluates the performance of these models on the FairytaleQA-Translated dataset and compares results with previously tested datasets. Our findings highlight the potential of smaller, more efficient models for QA in portuguese and contribute to advancing research in low-resource languages.*

**Resumo.** *Modelos de Linguagem de Grande Escala (LLMs) têm demonstrado capacidades notáveis em diversas tarefas de Processamento de Linguagem Natural (PLN), incluindo a Geração Automática de Respostas (QA). Para ajudar a reduzir a lacuna entre idiomas de alto e baixo recurso, foi desenvolvida a série Tucano, composta por modelos decoder-transformers treinados em português. Este estudo avalia o desempenho desses modelos no dataset FairytaleQA-Translated e compara os resultados com datasets previamente testados. Nossos achados destacam o potencial de modelos menores e mais eficientes para QA em português e contribuem para o avanço da pesquisa em idiomas de baixo recurso.*

## 1. Introdução

As LLMs têm se destacado pela capacidade de lidar com múltiplos desafios em Processamento da Linguagem Natural (PLN), incluindo a Geração Automática de Perguntas e Respostas (QA – do Inglês Question Answering) [Wei et al. 2022]. Apesar dos avanços, ainda existe uma lacuna significativa entre os idiomas com muitos recursos e aqueles com poucos, como o português. Com o objetivo de reduzir essa desigualdade, foi desenvolvida a série Tucano [Corrêa et al. 2025], composta por modelos decoder-transformers treinados nativamente em português, variando de 160 milhões a 2,4 bilhões de parâmetros.

Este trabalho avalia o desempenho desses modelos na tarefa de QA utilizando o dataset FairytaleQA-Translated [Leite et al. 2024], assim como realiza comparações com outros *datasets* e modelos anteriormente testados, a fim de contribuir para o avanço da pesquisa em idiomas de poucos recursos e mostrando o potencial de modelos menores e mais eficientes no contexto do português.

A estrutura do trabalho está organizada da seguinte maneira: a seção de **Referencial Teórico** define conceitos essenciais para a compreensão do artigo; a seção **Trabalhos**

**Relacionados** apresenta a literatura relevante já publicada; a seção **Metodologia** descreve os procedimentos adotados para os experimentos; a seção **Resultados e Discussão** apresenta os resultados com as métricas utilizadas. Por fim, a seção **Conclusões** sintetiza os resultados alcançados e discute possíveis direções para estudos futuros.

## 2. Referencial Teórico

Modelos de Linguagem de Grande Escala (LLMs - do inglês *Large Language Models*) são tipos de modelos de linguagem desenvolvidos para produzir texto de maneira eficiente em diversas aplicações, utilizando grandes quantidades de dados durante o treinamento. Estes modelos se destacam por sua capacidade de aprender representações linguísticas a partir de imensas quantidades de dados textuais, permitindo uma alta adaptabilidade para vários tipos de tarefas, o que as tornam ferramentas poderosas para várias aplicações [Chang et al. 2023].

QA é uma tarefa de PLN, cujo objetivo é responder a perguntas formuladas em linguagem natural a partir de um texto ou base de conhecimento. Com a criação do SQuAD (*Stanford Question Answering Dataset*) [Rajpurkar et al. 2016], a tarefa de QA se consolidou como um *benchmark* imprescindível para avaliação de modelos, com uso de métricas como *Exact Match* (EM) e *F1-score*.

*Few-shot learning* é um método de treinamento onde um modelo é ajustado para executar uma tarefa com poucos exemplos de treinamento. Essa estratégia se posiciona entre o *fine-tuning* completo e o *zero-shot*, equilibrando desempenho e custo computacional.

Grande parte da pesquisa em torno de QA é voltada para línguas de alto recurso, como o inglês. Em contrapartida, línguas de baixo recurso possuem menos suporte e dados disponíveis, gerando uma lacuna significativa na área. Embora trabalhos recentes, como [da Rocha Junqueira et al. 2024], explorem técnicas para mitigar essa escassez, ainda há desafios relacionados à diversidade linguística do português brasileiro.

## 3. Trabalhos Relacionados

[Rodrigues et al. 2023] apresentaram o Albertina PT-\*, um modelo de linguagem desenvolvido especialmente para aprimorar o processamento neural tanto para o português europeu quanto para o português brasileiro. O modelo utiliza como base a arquitetura DeBERTa e foi pré-treinado em um conjunto de corpora em língua portuguesa.

O trabalho de [Pires et al. 2023] propôs o modelo Sabiá, baseado em dados derivados do corpus ClueWeb2022 [Overwijk et al. 2022]. Os modelos Sabiá foram treinados em um *dataset* português usando os *frameworks* T5X e SeqIO, contabilizando 10,4 bilhões de *tokens*. A avaliação foi conduzida com o *benchmark* Poeta [Pires et al. 2023], voltado a tarefas em português, com a abordagem *few-shot*. Os exemplos foram selecionados manualmente e inseridos dentro do limite de 2.048 *tokens* por contexto. Posteriormente, o estudo de [Da Rocha Junqueira et al. 2024] analisa o modelo Sabiá-7B em várias tarefas de PLN, incluindo QA. O estudo utilizou similarmente a abordagem *few-shot*, utilizando o *dataset* SQuAD v1.1-PT para a tarefa de QA. Nestes experimentos, o modelo obteve 0,54 na métrica *F1-score* e alcançou 39% na métrica EM.

Mais recentemente, [Corrêa et al. 2025] apresentaram o Tucano, que inclui a

criação de um novo corpora para o português, o GigaVerbo, além de treinamento de modelos do tipo *decoder-transformer*. Os modelos demonstraram desempenho equivalente ou superior aos modelos existentes em múltiplos *benchmarks*.

## 4. Metodologia

Neste trabalho, realizamos o pré-processamento das amostras *few-shot* do *dataset* FairytaleQA-Translated, selecionando e organizando exemplos dentro das limitações de contexto do modelo. Foi montado um conjunto de treinamento adequado para QA, maximizando o número de exemplos que coubessem junto à instância de teste dentro da janela de contexto, garantindo uma representação equilibrada. Os exemplos foram então utilizados como *prompts* durante a inferência nos modelos Tucano, incluindo o componente instrucional. Após a execução, foi realizada uma análise detalhada da saída do modelo, avaliando métricas de desempenho e comparando os resultados com experimentos anteriores. O objetivo final desta análise é investigar a eficácia da abordagem *few-shot* e identificar diferenças entre *datasets*, bem como limitações e pontos fortes dos modelos.

Para avaliar o desempenho dos modelos, utilizamos duas métricas: *Exact Match* (EM) e *F1-score*. Essas métricas fornecem medidas de precisão e qualidade das respostas geradas pelos modelos. A EM é uma métrica que avalia se a resposta gerada pelo modelo corresponde exatamente à resposta correta correspondente no *dataset*, enquanto a *F1-score* é uma métrica de precisão ponderada, que combina precisão e *recall* em uma única medida, possibilitando assim melhor captação de respostas parcialmente corretas.

## 5. Resultados e Discussão

Foram realizados experimentos com três modelos da família Tucano, avaliados em dois conjuntos de dados de QA: SQuAD v1.1-PT e FairytaleQA. No *dataset* SQuAD v1.1-PT, observa-se que o modelo Tucano-2b4-Instruct apresentou os maiores valores, com *F1-score* de 0,15 e EM de 7,03%, enquanto as variantes menores atingem valores mais baixos. De forma semelhante, no FairytaleQA-Translated, o modelo maior se destaca, alcançando um *F1-score* de 0,21 e EM de 3,60%, com a mesma tendência de valores baixos nos modelos menores.

Para fins de comparação, dados reportados na literatura de modelos amplamente utilizados no português também foram considerados. O Albertina Base obteve *F1-score* de 0,57 e EM de 45,12%, enquanto o Albertina Large, apesar de um *F1-score* mais baixo de 0,32, alcançou 47,30% em EM. Por fim, o Sabiá-7B obteve 0,54 em *F1-score* e 39,17% em EM.

**Tabela 1. Resultados dos modelos Tucano na tarefa de QA**

<b>Dataset</b>	<b>Modelo</b>	<b>F1-score</b>	<b>Exact Match (%)</b>
SQuAD v1.1-PT	Tucano-160m	0,05	1,07
	Tucano-630m	0,04	0,73
	Tucano-2b4-Instruct	0,15	<b>7,03</b>
FairytaleQA-Translated	Tucano-160m	0,07	0,10
	Tucano-630m	0,10	0,33
	Tucano-2b4-Instruct	<b>0,21</b>	3,60

## 6. Conclusões

Os experimentos demonstraram que o desempenho dos modelos Tucano na tarefa de QA ainda é limitado no contexto de *few-shot learning*. Embora o Tucano-2b4-Instruct, o maior modelo da série, apresente ganhos consistentes em relação às suas versões menores, seus resultados permanecem inferiores aos de outros modelos, como o Sabiá-7B. Além disso, a diferença notada entre *datasets* mostra que o FairytaleQA é ainda mais desafiador para os modelos Tucano, reforçando que a adaptação de modelos de linguagem para QA em português demanda outras estratégias, como *fine-tuning* e melhor processamento dos dados de treinamento. Com isso, conclui-se que a família Tucano tem potencial promissor para aplicações em português, mas ainda enfrenta alguns obstáculos em tarefas de QA, sendo de grande importância a investigação futura dos modelos com técnicas de *fine-tuning* e métodos de *prompting* mais robustos.

## Referências

- Chang, Y., Wang, X., Wang, J., Wu, Y., Yang, L., Zhu, K., Chen, H., Yi, X., Wang, C., Wang, Y., Ye, W., Zhang, Y., Chang, Y., Yu, P. S., Yang, Q., and Xie, X. (2023). A survey on evaluation of large language models.
- Corrêa, N. K., Sen, A., Falk, S., and Fatimah, S. (2025). Tucano: Advancing neural text generation for portuguese. *Patterns*, page 101325.
- da Rocha Junqueira, J., Freitas, L., and Corrêa, U. B. (2024). Transformer models for brazilian portuguese question generation: An experimental study. *The International FLAIRS Conference Proceedings*, 37.
- Da Rocha Junqueira, J., Lopes, P., Da S. M., C. L., Silva, F. L. V., Carvalho, E. A., Freitas, L., and Brisolara, U. (2024). Sabiá in action: An investigation of its abilities in aspect-based sentiment analysis, hate speech detection, irony detection, and question-answering. In *2024 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8.
- Leite, B., Osório, T. F., and Cardoso, H. L. (2024). Fairytaleqa translated: Enabling educational question and answer generation in less-resourced languages.
- Overwijk, A., Xiong, C., Liu, X., VandenBerg, C., and Callan, J. (2022). Clueweb22: 10 billion web documents with visual and semantic information.
- Pires, R., Abonizio, H., Almeida, T. S., and Nogueira, R. (2023). [inline-graphic not available: see fulltext] sabiá: Portuguese large language models. In *Intelligent Systems: 12th Brazilian Conference, BRACIS 2023, Belo Horizonte, Brazil, September 25–29, 2023, Proceedings, Part III*, page 226–240, Berlin, Heidelberg. Springer-Verlag.
- Rajpurkar, P., Zhang, J., Lopyrev, K., and Liang, P. (2016). Squad: 100,000+ questions for machine comprehension of text.
- Rodrigues, J., Gomes, L., Silva, J., Branco, A., Santos, R., Cardoso, H. L., and Osório, T. (2023). *Advancing Neural Encoding of Portuguese with Transformer Albertina PT-\**, page 441–453. Springer Nature Switzerland.
- Wei, J., Tay, Y., Bommasani, R., Raffel, C., Zoph, B., Borgeaud, S., Yogatama, D., Bosma, M., Zhou, D., Metzler, D., Chi, E. H., Hashimoto, T., Vinyals, O., Liang, P., Dean, J., and Fedus, W. (2022). Emergent abilities of large language models.