

UTILIZANDO BERT PARA A TAREFA DE PERGUNTA-RESPOSTA EM LÍNGUA PORTUGUESA

GUILHERME RAMISON¹; LARISSA ASTROGILDO DE FREITAS²

¹Universidade Federal de Pelotas – gramison@inf.ufpel.edu.br

²Universidade Federal de Pelotas – larissa@inf.ufpel.edu.br

1. INTRODUÇÃO

Com o constante avanço da tecnologia e um mercado cada vez mais automatizado, soluções envolvendo o Processamento da Língua Natural (PLN), sejam elas chatbots, atendentes virtuais ou outros softwares, estão ficando cada vez mais evidentes no nosso dia-a-dia. Segundo Gattis (2020), o uso de tecnologias envolvendo PLN cresceu 100% em torno do globo, tendo em vista a atual situação de isolamento social causado pelo COVID-19.

Existem vários segmentos envolvendo PLN, o que iremos abordar neste trabalho é o de Pergunta-Resposta (*Question-Answer*). Dado um contexto, essa tarefa auxilia na localização de respostas de acordo com uma pergunta feita ao modelo. Sendo assim, utilizaremos a arquitetura *Transformers*, mais especificamente o modelo BERT, um modelo de Aprendizado de Máquina (AM) que se destacou em 2018 por obter o melhor score na tarefa de *Question-Answer* (Google AI Blog, 2018).

2. METODOLOGIA

O BERT faz uso do *Transformer*, um mecanismo de atenção que aprende relações contextuais entre palavras (ou subpalavras) em um texto. Em sua forma original, o *Transformer* inclui dois mecanismos separados - um codificador que lê a entrada de texto e um decodificador que produz uma previsão para a tarefa. Uma vez que o objetivo do BERT é gerar um modelo de linguagem, apenas o mecanismo do codificador é necessário (HOREV, 2018).

Ao contrário dos modelos direcionais, que lêem a entrada de texto sequencialmente (da esquerda para a direita ou da direita para a esquerda), o codificador *Transformer* lê toda a sequência de palavras de uma vez. Portanto, é considerado bidirecional, embora seja mais preciso dizer que é não direcional. Esta característica permite que o modelo aprenda o contexto de uma palavra com base em todos os seus arredores (esquerdo e direito da palavra) (HOREV, 2018).

Com o BERT, podemos pré-treinar um modelo, processo que requer muitos dados na linguagem alvo, como artigos, notícias, livros, etc.

Também temos a opção de usar um modelo pré-treinado e fazer um *fine-tuning* para uma tarefa específica, usando nosso próprio *dataset* no processo. O *fine-tuning* visa melhorar os resultados obtidos pelo modelo na tarefa de interesse, no nosso caso, *Question-Answer*.

A sequência de entrada do *fine-tuning* para tarefa de Pergunta-Resposta tem duas partes: a Pergunta (tokenizada), seguida por um token especial [SEP] e o Contexto (tokenizado) (Figura 1). Para mais informações sobre o funcionamento do processo, veja Google AI Language (2019).




Figura 1. Arquitetura do *fine-tuning* para *Question-Answer*

O Google disponibiliza vários modelos pré-treinados do BERT. Neste trabalho vamos utilizar o BERT Multilingual (Google Research, 2018), o qual suporta 104 linguagens, dentre elas o português (<https://github.com/google-research/bert>).

Porém, para fazer o *fine-tuning*, nós precisamos juntar dados para o input do modelo. O formato dos dados mais utilizado para realizar a tarefa de Pergunta-Resposta é do SQuAD (<https://rajpurkar.github.io/SQuAD-explorer/>), que consiste em dar um contexto, uma lista de perguntas relacionadas ao contexto e suas respectivas respostas. O SQuAD versão 1.1 contém um conjunto com mais de 100 mil Perguntas-Respostas em inglês.

Dentre os datasets de Perguntas-Respostas disponíveis em língua portuguesa podemos citar: uma versão do SQuAD versão 1.1 com 60 mil Perguntas-Respostas traduzidas pela API do Google Translate (<https://cloud.google.com/translate/?hl=pt-BR>), uma versão do SQuAD versão 1.1 traduzida e revisada pela AI Lab (UnB, 2020) e partes da coleção CHAVE com 172 novos pares de Perguntas-Respostas. O CHAVE consiste nas edições completas dos anos de 1994 e 1995 dos jornais PÚBLICO (www.publico.pt) e Folha de São Paulo (www.folha.com.br), que foi compilada pela Linguateca (www.linguateca.pt) no quadro do CLEF (www.clef-campaign.org).

Como o dataset do CHAVE estava fora do formato SQuAD e tinha algumas informações que não podiam ser transformadas para o padrão, rodamos um *script* Python para colocar os dados no formato SQuAD.

Com os datasets padronizados, começamos juntando a versão do SQuAD com 60 mil Perguntas-Respostas com o CHAVE, em seguida rodamos o *script* para fazer o *fine-tuning* em uma TPU por meio do Google Colab. A execução demorou por volta de 20 minutos, um tempo muito pequeno em comparação com o treinamento de um modelo que pode durar horas.

Com a versão traduzida completa do SQuAD, repetimos o processo de *fine-tuning* no Google Colab. Desta vez, o tempo de execução foi em torno de 30 minutos, aumento causado pela diferença do tamanho entre os *datasets*.

Em ambos os processos foi observado falta ou perda de *matches* por conta da caixa das letras, pois o BERT leva em consideração se a letra está maiúscula ou minúscula. Por conta disso, pretendemos repetir os processos com os *datasets* formatados em minúsculo para uma possível melhora nos resultados.

3. RESULTADOS E DISCUSSÃO

Para fins de avaliação dos modelos, utilizaremos as seguintes medidas: Exact Match (EM) e o F1. Para encontrarmos essas medidas, precisamos comparar as previsões feitas pelo modelo com um *dataset* de teste, onde se encontram perguntas, contextos e respostas diferentes do *dataset* usado para fazer o *fine-tuning*, e fazer uma matriz de confusão (Figura 2).

		Valor Preditivo	
		Sim	Não
Real	Sim	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Figura 2. Exemplo de matriz de confusão (Medium, 2019)

O F1 nos mostra o balanço entre a precisão e o *recall* do nosso modelo, calculado por $2 * (\text{precisão} * \text{recall}) / (\text{precisão} + \text{recall})$, sendo a precisão: TP / (TP + FP) e sendo o recall: TP / (TP + FN).

O EM representa a proporção de respostas que bateram exatamente entre o conjunto de teste e as previsões. Lembrando que um match pode variar entre 0 (*No Match*) e 1 (*Exact Match*).

Por meio do Google Colab, realizamos o *fine-tuning* com os dois *datasets* separadamente, obtendo os seguintes resultados:

Datasets	EM	F1
SQuADv1 60mil + CHAVE	50,73	68,98
SQuADv1 completo	57,58	74,16

Figura 3. Tabela dos resultados obtidos no *fine-tuning*

Como mencionado anteriormente, esperamos que se fizermos o *fine-tuning* com os contextos, perguntas e respostas formatados com as letras minúsculas, os resultados possam melhorar por causa da maior quantidade de matches entre a predição e o *dataset* de teste.

Comparando os resultados com modelos treinados em inglês, temos uma diferença considerável: a F1 do modelo *BERT Inglês base* (Google Research, 2018) é de 88,4. Já em modelos ajustados (*BERT Multilingual*) para outras línguas, como a Russa, a F1 é 83,09 e a Chinesa, a F1 é 85,00 (DeepPavlov, 2019).

4. CONCLUSÕES

A arquitetura BERT é consideravelmente fácil de usar, sendo bem documentada e tendo vários exemplos de uso na internet, deixando ainda mais acessível à comunidade de interesse.

A próxima etapa deste trabalho é utilizar o modelo pré-treinado para o português do BERT, BERTimbau (NeuralMind, 2020). Utilizando esse modelo, esperamos ter uma melhora nos resultados obtidos na tarefa de Pergunta-Resposta, por conta do modelo ser pré-treinado especialmente para o português.

5. REFERÊNCIAS BIBLIOGRÁFICAS

GATTIS, N. **Olhar Digital**. Acessado em 23 set. 2020. Disponível em:
<https://olhardigital.com.br/coronavirus/noticia/coronavirus-atendimentos-via-chatbots-aumentam-100-no-mundo/98554>

Medium. **Métricas de Avaliação: acurácia, precisão, recall... quais as diferenças?**. Acessado em 27 set. 2020. Disponível em:
<https://medium.com/@vitorborbarodrigues/m%C3%A9tricas-de-avalia%C3%A7%C3%A3o-acur%C3%A1cia-precis%C3%A3o-recall-quais-as-diferen%C3%A7%C3%A3as-c8f05e0a513c>

Google Research. **BERT**. Acessado em 24 set. 2020. Disponível em:
<https://github.com/google-research/bert>

HOREV, R. **BERT Explained: State of the art language model for NLP**. Acessado em 23 set. 2020. Disponível em:
<https://towardsdatascience.com/bert-explained-state-of-the-art-language-model-for-nlp-f8b21a9b6270>

NeuralMind. **BERTimbau**. Acessado em 25 set. 2020. Disponível em:
<https://github.com/neuralmind-ai/portuguese-bert>

Google AI Language. **BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding**. Acessado em 25 set. 2020. Disponível em:
<https://arxiv.org/pdf/1810.04805.pdf>

UnB. **Datasets em Português**. Acessado em 23 set. 2020. Disponível em:
<https://forum.ailab.unb.br/t/datasets-em-portugues/251>