

三言語モデル寄れば文殊の知恵

稲葉 達郎¹, 藤井 巧朗², 小原 涼馬³, 柴田 幸輝⁴

¹京都大学, ²横浜国立大学, ³北海道大学, ⁴筑波大学



研究目的・概要

- 「三人寄れば文殊の知恵」を言語モデルで再現する
 - 性能向上・推論効率化
- 性質・特徴の違う言語モデルを作成し、アンサンブル学習により互いの能力を最大限補完し合うフレームワークを探す



背景

そもそも、文殊の知恵とは…?

- 「凡人でも三人集まって相談すれば、すばらしい知恵が出るものだ」ということ¹

これを言語モデルで再現するには…?

- 異なる知識・パラメータを持った言語モデルを複数作成し、それぞれの能力を最大限引き出すアンサンブル/マージを行えば良い
- 言語モデルの大規模化が進む今だからこそ、複数モデルに知識を分散させる方法を考えたい！！

どのように異なるモデルを作成する…?

- データセットが一つでメタデータがついていないものを今回は考える

関連研究

Mixture-of-Experts (MoE) [1]

- 複数のエキスパートモデルを作成し、親ゲートネットワークによりどのエキスパートモデルを使用するかを判別する

Branch-Train-Merge (BTM) [2]

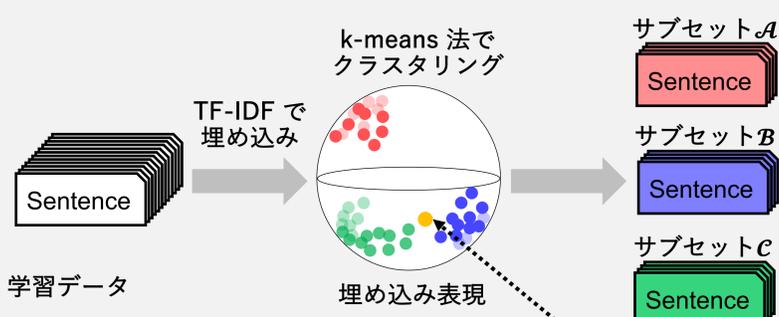
- k個のドメインコーパスでk個の Expert LM (ELM)を事前学習
- これらをマージしたものを初期値として再起的に学習

Cluster-BTM (c-BTM) [3]

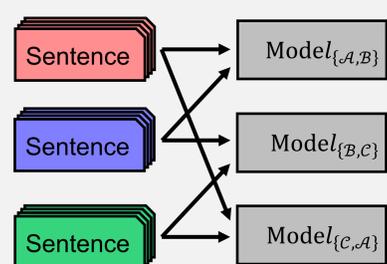
- コーパスを k-means 法でクラスタリング
- クラスタ毎にELMを事前学習 → 入力埋め込みと各クラスタ中心からの距離でlogitを重み付ける

手法

- CBTM の考え方をもとに、データセットをクラスタリングし、事前学習済みモデルの Fine-tuning に利用する

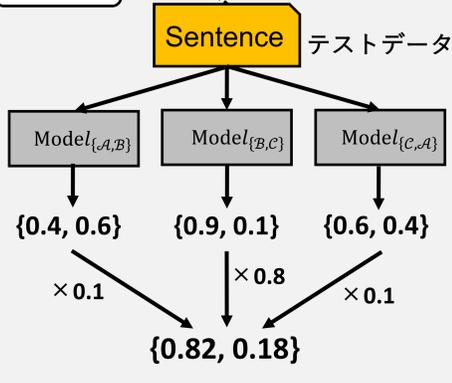


学習



- それぞれのモデルにサブセットを二種類学習させる → 境界部分の問題に対処
- テストデータも同様に埋め込み、得意なモデルの重みが大きくなるようにアンサンブル

推論



実験・結果

実験

- モデル: RoBERTa-base (125M)
- データセット: SST-2 (感情分析タスク)
- ベースライン
 - 全てのデータで Fine-tuning したモデルのアンサンブル²
- 文殊モデル
 - k = 3 でクラスタリング
 - 重みの計算は以下の式で行う

$$\alpha_{AB} = \frac{d_C}{d_A + d_B + d_C}, \alpha_{BC} = \frac{d_A}{d_A + d_B + d_C}, \alpha_{CA} = \frac{d_B}{d_A + d_B + d_C}$$

(α_{ij} は Model[ij] の重み, d_i はクラスタ i の中心からのユークリッド距離)

結果

Training Data	Acc. (%)	Ensemble	Acc. (%)
{A, B, C} _{seed=0}	93.23	Baseline	94.15
{A, B, C} _{seed=1}	93.69		
{A, B, C} _{seed=2}	93.35		
{A, B}	93.12	Monju	94.04
{B, C}	93.46		
{C, A}	92.66		

- 少ない学習量でベースライン相当の性能を達成
- アンサンブルした際の性能の上がり幅はベースラインより大きい

今後の展望

“三人寄れば…”の3人をどうやって作るか問題

- 1つのデータセットから複数のモデルを作成
 - それぞれ異なるデータの学習順序を用いる
 - 埋め込み手法に SentenceBERT 等のニューラルモデルを用いる
 - GMM 等のクラスタリング手法を用いる
 - 各モデルに異なるアーキテクチャを用いる
- 複数データセットから複数のモデルを作成
 - 転移学習を利用

他にも…

- デコーダモデルで文殊の知恵を創出
- アンサンブル以外にもマージ・蒸留等

[1] Robert A. Jacobs, Michael I. Jordan, Steven J. Nowlan, and Geoffrey E. Hinton. 1991. Adaptive mixtures of local experts. *Neural computation*, 3(1):79–87.
[2] Margaret LI, Suchin Gururangan, Tim Dettmers, Mike Lewis, Tim Althoff, Noah A. Smith, and Luke Zettlemoyer. Branch-train-merge: Embarrassingly parallel training of expert language models. In *First Workshop on Interpolation Regularizers and Beyond at NeurIPS 2022*.
[3] Suchin Gururangan, Margaret LI, Mike Lewis, Weijia Shi, Tim Althoff, Noah A. Smith, and Luke Zettlemoyer. Scaling expert language models with unsupervised domain discovery. *ArXiv*, 2023

¹ goo 辞書 “三人寄れば文殊の知恵 (さんにんよればもんじゅのちえ)” から引用
² シード値を変えることで3種類作成したモデルを同じ重み(1/3)でアンサンブルした