

# 強化学習に基づくデータ選別を通じた問題横断型小論文自動採点の精度向上

柴田拓海<sup>1</sup> 宇都雅輝<sup>1</sup>

<sup>1</sup> 電気通信大学大学院

{shibata,uto}@ai.lab.uec.ac.jp

## 概要

近年、小論文自動採点タスクの一つとして問題横断型自動採点が注目されている。しかし従来の問題横断型自動採点では様々な問題に対する採点済み小論文データを全て訓練に利用するため、目的の問題の自動採点に悪影響を与えうるデータまで訓練に利用される可能性がある。この問題を解決するために本研究では、訓練データの価値を評価し、モデル学習に悪影響を及ぼす可能性のあるデータを除外することでその採点精度を向上させる手法を提案する。

## 1 はじめに

近年、小論文試験の採点コストの削減や採点の一貫性を担保するアプローチの一つとして、小論文自動採点 (automated essay scoring : AES) が注目されている [1, 2]。小論文自動採点手法は問題固有型と問題横断型に大別できる。問題固有型自動採点手法は、目的の小論文問題に対する採点済み小論文データを用いて、その問題専用の自動採点モデルを構築する手法である。代表的な手法としては、小論文から文章長や文法誤り率などの特徴量を抽出し、これらの特徴量を用いて機械学習モデルを訓練する特徴量ベースの手法や、深層学習を用いて小論文の単語系列を入力として得点を予測する深層学習ベースの手法が知られている (e.g., [1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16])。近年では、BERT (bidirectional encoder representations from transformers) [17] や DeBERTa (decoding-enhanced BERT with disentangled attention) [18] などの Transformer エンコーダをベースにした事前学習済みの深層学習モデルを用いた自動採点モデルが高精度を達成している (e.g., [19, 20])。

問題固有型自動採点モデルは、訓練データと同一の問題に対しては高い性能を示すが、特定の問題に

対して構築されたモデルを他の問題の自動採点に直接流用しても高い性能が得られるとは限らない。そのため、一般に問題固有型自動採点で高精度を実現するためには、問題ごとに採点済み小論文データを収集してモデル訓練を行う必要がある。しかし、問題ごとに十分な数の採点済み小論文データを収集するには大きなコストを要する。このような問題ごとのモデル訓練のコストを軽減する方法として問題横断型自動採点手法が近年注目を集めている。問題横断型自動採点手法では採点したい問題に対する自動採点モデルを構築するために、その問題以外の多数の問題 (以下、元問題群と呼ぶ) に対応する採点済み小論文データも訓練データとして利用することで、自動採点の精度向上を目指す。このアプローチでは目的の問題に対応する採点済み小論文データがない、あるいは数が限られている場合に目的の問題に対する自動採点モデルの精度向上が期待できる。

従来の問題横断型自動採点手法は、元問題群の全ての小論文データを学習に利用する。しかし、元問題群に関するデータの中には、目的の問題に対する自動採点モデルの構築に悪影響を与えるデータが存在する可能性がある。そのため、そのようなデータを選択して除外することができれば、より高精度な問題横断型自動採点が可能になると期待される。

そこで本研究では、DVRL (data valuation using reinforcement learning) [21] と呼ばれる強化学習を用いたデータ価値推定手法を応用した問題横断型自動採点手法を提案する。DVRL は、目的のタスクの性能向上に対する各データの寄与の度合いをデータ価値として推定する手法である。本研究では DVRL を応用して、元問題群に関する採点済み小論文データのうち、目的の問題の自動採点の精度向上に寄与するデータに高いデータ価値を与え、精度に悪影響を与えるデータに低いデータ価値を与えるデータ価値推定器を構築する。提案手法では、これにより得ら

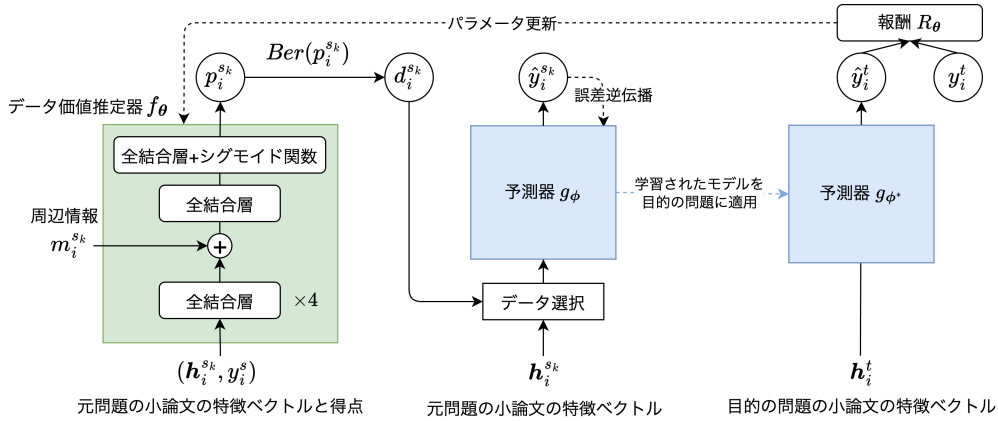


図1 DVRL の概念図

れたデータ価値推定器に基づいて元問題群に関する採点済み小論文データを取捨選択して自動採点モデルを訓練することで、目的の問題に対する採点精度の向上を目指す。本研究では小論文自動採点のベンチマークデータセットを用いて提案手法の有効性を評価する。

## 2 提案手法

本研究では、元問題群の各問題  $k$  ( $k = 1, 2, \dots, K$ ) に関する採点済み小論文データ  $\mathcal{D}^{sk} = \{(x_i^{sk}, y_i^{sk})\}_{i=1}^{N_{sk}}$  と、目的の問題に対する少量の採点済み小論文データ  $\mathcal{D}^t = \{(x_i^t, y_i^t)\}_{i=1}^{N_t}$  を利用する。ここで、 $K$  は元問題群の総数、 $x_i^{sk}$  と  $x_i^t$  はそれぞれ元問題群の問題  $k$  と目的の問題における  $i$  番目の小論文、 $y_i^{sk}$  と  $y_i^t$  はそれらに対応する得点、 $N_{sk}$  と  $N_t$  はそれぞれ元問題群の問題  $k$  と目的の問題の小論文の総数である。本研究の主たるアイデアは、元問題群の採点済み小論文データ  $\mathcal{D}^s = \bigcup_{k=1}^K \mathcal{D}^{sk}$  から有益な部分集合データを抽出し、目的の問題における未採点小論文データに対する得点を高精度に予測できる自動採点モデルを構築することにある。

提案手法では、これを実現するために、以下に示す二つの手順を実行する。1) DVRL を用いて元問題群の各小論文データに対してデータ価値を割り当てるデータ価値推定器を学習する。2) データ価値推定器によって高価値が割り当てられた元問題群の小論文のみを用いて目的の問題の自動採点モデルを学習する。以降の節で、各手順の詳細を説明する。

### 2.1 DVRL を用いたデータ価値推定

図1にDVRLを用いたデータ価値推定の概念図を示す。この手法は、元問題群の採点済み小論文データの価値を推定するデータ価値推定器  $f_\theta$  と、小論文

の予測得点を出力する予測器  $g_\phi$  の二つのモデルから構成される。ここで  $\theta$  と  $\phi$  はそれぞれデータ価値推定器と予測器のモデルパラメータを表す。なお、DVRL 全体の計算コストを抑えるため、これらのモデルには軽量なものが採用される。図中の  $h_i^{sk}$  と  $h_i^t$  は、それぞれ  $x_i^{sk}$  と  $x_i^t$  に対応する特徴ベクトルを表す。特徴ベクトルとしては、BERT や DeBERTa に基づく文章分散表現ベクトルや人手で設計された特徴ベクトル、それらの組み合わせなどが利用できる。

DVRL の学習過程は、次の最適化問題として定式化される [21]。

$$\begin{aligned} \max_{\theta} \quad & R_\theta(\phi^*, \mathcal{P}^t) \quad \text{s.t.} \\ \phi^* = \arg \min_{\phi} \quad & \mathbb{E}_{(h^s, y^s) \sim \mathcal{P}^s} [f_\theta(h^s, y^s) \mathcal{L}(g_\phi(h^s), y^s)] \end{aligned} \quad (1)$$

ここで、 $R_\theta(\cdot, \cdot)$  は報酬を表す。これは、元問題群の採点済み小論文データ  $\mathcal{D}^s$  を用いて学習した予測器  $g_\phi$  の、目的の問題の採点済み小論文データ  $\mathcal{D}^t$  に対する予測精度として与えられる。また、 $\mathcal{L}$  は予測器の訓練時の損失関数であり、 $\mathcal{P}^s$  と  $\mathcal{P}^t$  は、それぞれ元問題群の小論文データと目的の問題の小論文データの生成分布を表す。この最適化問題を解くことで、各小論文のデータ価値を推定するデータ価値推定器  $f_\theta$  が得られる。以降でこの最適化問題の具体的な計算手順を説明する。

DVRL ではまず、元問題群の小論文ベクトル  $h_i^{sk}$  と対応する得点  $y_i^{sk}$  を用いて、データ  $x_i^{sk}$  のデータ価値  $p_i^{sk} \in [0, 1]$  を  $p_i^{sk} = f_\theta(h_i^{sk}, y_i^{sk})$  として計算する。ここで、データ価値推定器  $f_\theta$  は六層の全結合層からなる深層ニューラルネットワークであり、出力層はシグモイド関数を活性化関数に持つ線形層である。なお、データ価値推定器の中間層には周辺情報  $m_i^{sk}$  が結合される。周辺情報  $m_i^{sk}$  とは、問題  $k$

の  $i$  番目の小論文のデータ価値と相関が期待される量であり,  $m_i^{sk} = |y_i^{sk} - g_\phi(\mathbf{h}_i^{sk})|$  と定義される. ここで  $g_\phi$  は  $\mathcal{D}^l$  を用いて事前に学習された予測器である. このようにして得られた採択確率  $p_i^{sk}$  を利用して  $x_i^{sk}$  の採択可否  $d_i^{sk} \in \{0, 1\}$  を確率  $p_i^{sk}$  のベルヌーイ分布からのサンプリングとして決定する. ここで  $d_i^{sk} = 1$  は問題  $k$  の  $i$  番目のデータが採択されたことを,  $d_i^{sk} = 0$  は採択されなかったことを意味する.

DVRL では次に, 採択された元問題群の小論文データを用いて予測器  $g_\phi$  を学習する. 予測器  $g_\phi$  はシグモイド関数を活性化関数とする線形出力層を持つ多層パーセプトロン (multi-layer perceptron : MLP) として構成される. 予測器の学習に用いる重み付き損失関数は,  $\mathcal{L}_{\text{pred}} = \frac{1}{|\mathcal{D}_{\text{selected}}^s|} \sum_{k=1}^K \sum_{i=1}^{N_{sk}} d_i^{sk} \cdot \mathcal{L}(\hat{y}_i^{sk}, y_i^{sk})$  で定義される. ここで,  $\mathcal{D}_{\text{selected}}^s = \{(x_i^{sk}, y_i^{sk}) \mid d_i^{sk} = 1\}$  は採択された元問題群データの集合,  $\hat{y}_i^{sk}$  は元問題群の問題  $k$  における  $i$  番目の小論文に対する予測器による予測得点である. 損失関数  $\mathcal{L}$  としては, 予測得点  $\hat{y}_i^{sk}$  と真の得点  $y_i^{sk}$  の平均二乗誤差を使用する. なお予測器  $g_\phi$  は出力層にシグモイド関数を用いているため, 予測得点は  $[0, 1]$  の範囲の値になる. そのため観測得点  $y_i^{sk}$  も  $[0, 1]$  の範囲に正規化する必要がある.

そして学習された予測器  $g_{\phi^*}$  の得点予測性能を目的の問題の小論文データ  $\mathcal{D}^l$  を利用して評価する. 予測性能の指標としては, 自動採点の研究で一般に利用される二次重み付きカップ係数 (quadratic weighted kappa : QWK) を用いる. この値を強化学習の報酬  $R_\theta = QWK(\{g_{\phi^*}(\mathbf{h}_i^l), y_i^l\}_{i=1}^{N_l})$  として採用し, データ価値推定器  $f_\theta$  のパラメータ  $\theta$  を更新する. パラメータの更新には, 強化学習アルゴリズムの一つである REINFORCE アルゴリズム [22] を用いる. REINFORCE アルゴリズムを適用するには, 報酬  $R_\theta$  の  $\theta$  による勾配が必要であるが, この勾配は  $\nabla_\theta R_\theta = R_\theta \cdot \nabla_\theta \log P(\{d_i^{sk}\} \mid \theta)$  で求められる [21]. ここで,  $P(\{d_i^{sk}\} \mid \theta)$  は, パラメータ  $\theta$  を所与とした採否結果データの同時確率であり,  $\prod_{k=1}^K \prod_{i=1}^{N_{sk}} (p_i^{sk})^{d_i^{sk}} (1 - p_i^{sk})^{1-d_i^{sk}} = \prod_{k=1}^K \prod_{i=1}^{N_{sk}} (f_\theta(\mathbf{h}_i^{sk}, y_i^{sk}))^{d_i^{sk}} (1 - f_\theta(\mathbf{h}_i^{sk}, y_i^{sk}))^{1-d_i^{sk}}$  で求められる. この勾配を用いて, パラメータ  $\theta$  を勾配上昇法により  $\theta \leftarrow \theta + \alpha \nabla_\theta R_\theta$  と更新する. ここで,  $\alpha$  は学習率を表し, 本研究では  $1 \times 10^{-3}$  に設定している. パラメータ更新の最適化手法としては, Adam [23] を用いる. 最後に, これまで説明したステップを繰り返すことで式 (1) に則したデータ価値

推定器  $f_\theta$  を学習する.

## 2.2 推定されたデータ価値に基づく任意の自動採点モデルの学習

本研究では, 前節の手続きで得られたデータ価値推定器  $f_\theta$  を用いて, 元問題群のデータの選別を行い, 選ばれたデータを用いて目的の問題に対する自動採点モデルを訓練する. しかし, この手続きでは, データ価値の推定値に基づいてどの程度の数のデータを選別すべきかが自明ではない. そこで本研究では, 先行研究 [21] と同様に以下の手順でデータ選別を行う. 1) 算出されたデータ価値に基づいて元問題群の小論文を降順に並び替える. 2) データ価値の上位 10% から 100% まで 10% 刻みでデータを採用し, それぞれのデータから自動採点モデルを構築する. 3) 構築された 10 パタンのモデルについて  $\mathcal{D}^l$  に対する性能を平均二乗誤差で評価する. 損失の値が最も低いモデルを最適なモデルとして選択し未採点の目的の問題の小論文に対して得点予測を行う.

## 3 実験

本研究では, 提案手法の有効性を評価するために, 実データを用いて評価実験を行った. 実データとしては Automated Student Assessment Prize (ASAP) と呼ばれるデータセットを使用した. ASAP は多くの自動採点研究においてベンチマークデータセットとして利用されており, 八種類の小論文問題に対する受検者の答案が合計 12,978 個と, その答案に対する得点が与えられている.

### 3.1 提案手法の性能評価

本研究では, 従来の問題横断型自動採点研究 [5, 8] と同様に問題単位の交差検証法を用いて提案手法の得点予測精度の評価実験を行った. 問題単位の交差検証法では, 一つの問題を目的の問題として設定し, 残りの全ての問題を学習用の元問題群として使用する. この手順を全ての問題について順に繰り返し, 性能評価を行った. また, 提案手法では目的の問題からサンプリングされた少数の採点済み小論文データ  $\mathcal{D}^l$  が必要となる. 本実験では,  $\mathcal{D}^l$  のデータ数を 30 と設定し, DeBERTa-v3-large [24] から得られた各小論文の分散表現ベクトルのユークリッド距離の和が最大となるようなデータ集合を選択した. 本実験では BERT, Llama-2-7B [25], PAES (prompt agnostic essay scorer) [5], PMAES (prompt-mapping contrastive learning for cross-prompt AES) [8] の四つ



表 1 得点予測精度の評価実験の結果

モデル	設定	問題 1	問題 2	問題 3	問題 4	問題 5	問題 6	問題 7	問題 8	平均
BERT	全データ利用	0.513	0.541	0.578	0.582	0.637	0.600	0.529	0.431	0.551
	提案	<b>0.640</b>	<b>0.581</b>	<b>0.684</b>	<b>0.631</b>	<b>0.683</b>	<b>0.636</b>	<b>0.597</b>	<b>0.628</b>	<b>0.635</b>
Llama-2-7B	全データ利用	0.481	<b>0.556</b>	0.545	<b>0.610</b>	0.690	<b>0.582</b>	0.583	0.424	0.559
	提案	<b>0.530</b>	0.522	<b>0.661</b>	0.589	<b>0.704</b>	0.574	<b>0.686</b>	<b>0.558</b>	<b>0.603</b>
PAES	全データ利用	0.654	0.583	<b>0.612</b>	<b>0.605</b>	0.730	0.565	0.706	0.542	0.625
	提案	<b>0.787</b>	<b>0.600</b>	0.588	0.588	<b>0.747</b>	<b>0.573</b>	<b>0.737</b>	<b>0.560</b>	<b>0.648</b>
PMAES	全データ利用	0.799	<b>0.634</b>	<b>0.591</b>	0.589	0.716	0.567	0.658	0.366	0.615
	提案	<b>0.800</b>	0.627	0.559	<b>0.606</b>	<b>0.749</b>	<b>0.613</b>	<b>0.664</b>	<b>0.523</b>	<b>0.643</b>

の代表的な自動採点モデルに対して、提案手法の有効性を評価した。DVRLにおけるデータ価値推定器と予測器の入力に使用する特徴量および予測器の構造は、モデルの種類によって変更した。BERTとLlama-2-7Bはセマンティックな特徴を考慮するモデルであるため、これらのモデルを利用する際には、DVRLの特徴量としてDeBERTa-v3-largeの分散表現ベクトルを用い、予測器としてMLPを使用した。他方で、PAESとPMAESは元々問題横断型として設計されたモデルであり、Ridleyら[5]が提案した問題非依存の特徴ベクトル $\mathbf{z}$ を入力に利用している。そこで、これらのモデルに対しては、DVRL内の特徴量も特徴ベクトル $\mathbf{z}$ を用い、予測器としてFeatures model (Ridleyら[5]が提案した特徴ベクトル $\mathbf{z}$ を入力とするロジスティック回帰モデル)を使用した。実験は「全データ利用」と「提案」の二つの設定で行った。まず、「全データ利用」は、自動採点モデルを全ての元問題群のデータを用いて学習する設定であり、提案手法において全ての小論文が採択された場合と等しい。「提案」は提案手法に従って自動採点モデルを学習する設定である。各設定における自動採点モデルの予測精度は、 $\mathcal{Q}$ として利用した30個のデータを除いた目的の問題の小論文データに対して得点予測を行い、QWKで評価した。

表1に実験結果を示す。表では各モデルに対し、問題ごとに精度が高い設定に対応する数値を太字で表現している。表から提案手法の平均予測精度は全てのモデルにおいて「全データ利用」の設定を上回っていることが読み取れる。この結果は、提案手法が自動採点モデルの予測精度を向上させるために有効であることを示しているといえる。

### 3.2 推定されたデータ価値の妥当性評価

本節では、提案手法により推定されたデータ価値が適切に機能しているかを評価する。評価のために、上位または下位  $n\%$  のデータ価値を持つ小論文




図 2 問題 1 における除外した小論文データの割合と QWK の関係

を除外した元問題群の小論文データを用いて学習した自動採点モデルの予測精度を算出した。ここで除外率  $n$  は 0% から 90% まで 10% 刻みで変更した。本実験では前節の実験で最も高い性能を示した PAES に対して実験を行った。

問題 1 に対する実験結果を図 2 に示した。横軸は除外された小論文の割合、縦軸は QWK を表す。青色のグラフはデータ価値の最も高い小論文から順に除外した場合の QWK の変化、橙色のグラフはデータ価値の最も低い小論文から順に除外した場合の QWK の変化を表している。図から、データ価値の低い小論文を除外すると QWK が増加する傾向があり、反対にデータ価値の高い小論文を除外すると QWK が減少する傾向が見られる。これらの結果から、提案手法は適切にデータ価値を推定していることが示唆される。

## 4 おわりに

本研究では、目的の問題に対する自動採点モデルの精度向上に効果的な元問題群の小論文データを選択するために、データ価値推定法を活用した問題横断型自動採点手法を提案した。実データを用いた実験により、従来の様々な自動採点モデルと比較して、目的の問題における採点性能が向上することを確認した。今後は提案手法により採択されるデータの傾向や特性に関する詳細な分析を行いたい。

## 謝辞

本研究は JSPS 科研費 23K17585, 23K20727, 24H00739 の助成を受けたものです。

## 参考文献

- [1] Masaki Uto. A review of deep-neural automated essay scoring models. **Behaviormetrika**, Vol. 48, No. 2, pp. 1–26, 2021.
- [2] Takumi Shibata and Masaki Uto. Analytic automated essay scoring based on deep neural networks integrating multidimensional item response theory. In **Proceedings of the 29th International Conference on Computational Linguistics**, pp. 2917–2926, 2022.
- [3] Yigal Attali and Jill Burstein. Automated essay scoring with e-rater® v.2. **The Journal of Technology, Learning and Assessment**, Vol. 4, No. 3, pp. 1–30, 2006.
- [4] Masaki Uto and Masashi Okano. Learning automated essay scoring models using item-response-theory-based scores to decrease effects of rater biases. **IEEE Transactions on Learning Technologies**, Vol. 14, No. 6, pp. 763–776, 2021.
- [5] Robert Ridley, Liang He, Xinyu Dai, Shujian Huang, and Jiajun Chen. Prompt agnostic essay scorer: A domain generalization approach to cross-prompt automated essay scoring. arXiv, 2020.
- [6] Fei Dong, Yue Zhang, and Jie Yang. Attention-based recurrent convolutional neural network for automatic essay scoring. In **Proceedings of the 21st Conference on Computational Natural Language Learning**, pp. 153–162, 2017.
- [7] Cancan Jin, Ben He, Kai Hui, and Le Sun. TDNN: A two-stage deep neural network for prompt-independent automated essay scoring. In **Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics**, pp. 1088–1097, 2018.
- [8] Yuan Chen and Xia Li. PMAES: Prompt-mapping contrastive learning for cross-prompt automated essay scoring. In **Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics**, pp. 1489–1503, 2023.
- [9] Xia Li, Mingping Chen, and Jian-Yun Nie. SEDNN: Shared and enhanced deep neural network model for cross-prompt automated essay scoring. **Knowledge-Based Systems**, Vol. 210, p. 106491, 2020.
- [10] Misato Yamaura, Itsuki Fukuda, and Masaki Uto. Neural automated essay scoring considering logical structure. In **Proceedings of the 24th Artificial Intelligence in Education**, pp. 267–278, 2023.
- [11] Pedro Uriá Rodríguez, Amir Jafari, and Christopher M. Ormerod. Language models and automated essay scoring. arXiv, 2019.
- [12] Masaki Uto and Yuto Takahashi. Neural automated essay scoring for improved confidence estimation and score prediction through integrated classification and regression. In **Proceedings of the 25th Artificial Intelligence in Education**, pp. 444–451, 2024.
- [13] Masaki Uto and Kota Aramaki. Linking essay-writing tests using many-facet models and neural automated essay scoring. **Behavior Research Methods**, Vol. 56, No. 8, pp. 8450–8479, 2024.
- [14] Kota Aramaki and Masaki Uto. Collaborative essay evaluation with human and neural graders using item response theory under a nonequivalent groups design. In **Proceedings of the 25th International Conference on Artificial Intelligence in Education**, pp. 79–87, 2024.
- [15] Masaki Uto, Itsuki Aomi, Emiko Tsutsumi, and Maomi Ueno. Integration of prediction scores from various automated essay scoring models using item response theory. **IEEE Transactions on Learning Technologies**, Vol. 16, No. 6, pp. 983–1000, 2023.
- [16] Takumi Shibata and Masaki Uto. Enhancing cross-prompt automated essay scoring by selecting training data based on reinforcement learning. In **Proceedings of the First Workshop on Automated Evaluation of Learning and Assessment Content, International Conference on Artificial Intelligence in Education**, 2024.
- [17] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. BERT: Pre-training of deep bidirectional transformers for language understanding. In **Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies**, pp. 4171–4186, 2019.
- [18] Pengcheng He, Xiaodong Liu, Jianfeng Gao, and Weizhu Chen. DeBERTa: Decoding-enhanced BERT with disentangled attention. arXiv, 2021.
- [19] Ruosong Yang, Jiannong Cao, Zhiyuan Wen, Youzheng Wu, and Xiaodong He. Enhancing automated essay scoring performance via fine-tuning pre-trained language models with combination of regression and ranking. In **Findings of the Association for Computational Linguistics**, pp. 1560–1569, 2020.
- [20] Yongjie Wang, Chuang Wang, Ruobing Li, and Hui Lin. On the use of Bert for automated essay scoring: Joint learning of multi-scale essay representation. In **Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies**, pp. 3416–3425, 2022.
- [21] Jinsung Yoon, Sercan Arik, and Tomas Pfister. Data valuation using reinforcement learning. In **Proceedings of the 37th International Conference on Machine Learning**, Vol. 119, pp. 10842–10851, 2020.
- [22] Ronald J Williams. Simple statistical gradient-following algorithms for connectionist reinforcement learning. **Machine learning**, Vol. 8, pp. 229–256, 1992.
- [23] Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization. arXiv, 2017.
- [24] Pengcheng He, Jianfeng Gao, and Weizhu Chen. DeBERTaV3: Improving DeBERTa using ELECTRA-style pre-training with gradient-disentangled embedding sharing. arXiv, 2021.
- [25] Hugo Touvron, Louis Martin, Kevin Stone, et al. Llama 2: Open foundation and fine-tuned chat models. arXiv, 2023.