

Beijing Forest Studio  
北京理工大学信息系统及安全对抗实验中心



# 层次多标签文本分类方法

层次多标签文本分类方法

吴杭颐 硕士研究生

2022年06月05日



- 背景简介
- 基本概念
- 算法原理
  - HiMatch
  - HGCLR
- 应用总结
- 参考文献



- 预期收获

- 1. 了解层次多标签基本概念
- 2. 了解层次多标签分类的常用方法
- 3. 掌握层次感知方法的算法原理
- 4. 了解领域实际应用和发展方向



背景简介



# 背景简介



- 多分类 (Multi-Class)

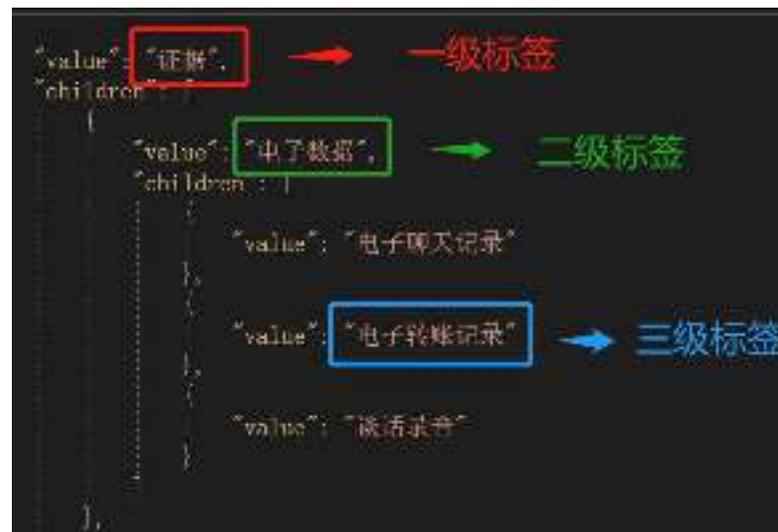
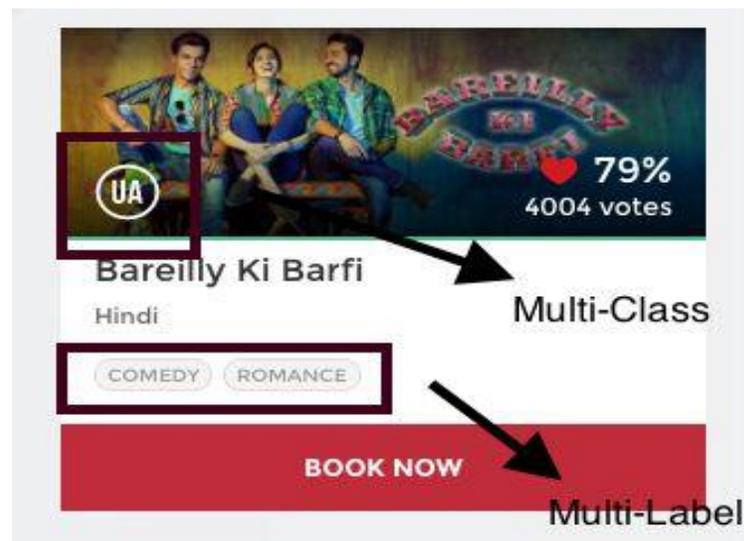
- 也称多元分类，指在分类任务中有2个以上类别
- 各标签互斥，每个样本有且仅有一个标签

- 多标签分类 (Multi-Label)

- 给每个样本一系列的目标标签，各标签不互斥
- 如一部电影可同时被打上动作片和犯罪片标签

- 层次多标签分类 (Hierarchical Multi-Label)

- 多标签分类下的子任务，标签类别被组织成层次结构
- 如一篇裁判文书可被打上证据/电子证据/电子转账记录标签





## 层次多标签分类方法：





# 基本概念



- 层次多标签分类中的标签粒度定义

- 细粒度标签

- 是用于描述输入样本的最合适的标签
    - 通常是最底层的**叶子标签**

- 粗粒度标签

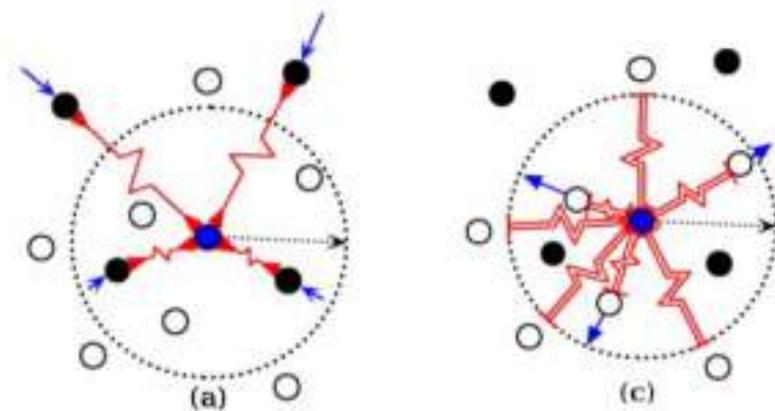
- 通常是粗粒度标签或细粒度标签的父节点
    - 通常是除叶子标签外的**其它层标签**





- 对比学习

- 思想：将样本和与它语义相似的例子（正样本）以及与它语义不相似的例子（负样本）进行**对比**
- 目标：使得正样本对在表征空间中**接近**，负样本对在表征空间中**远离**
- 难点：正负样本的构造和对比损失的设计





## 算法原理



T	预测样本 $x_i$ 在给定标签层次结构中的多个所属标签
I	文本 $x_i$ 、先验标签集合 $L=\{l_1, l_2, \dots, l_N\}$
P	1.对文本进行编码，得到文本表征向量 $S_t$ 2.对先验标签体系进行编码，得到标签表征向量 $S_l$ 3.将 $S_t$ 和 $S_l$ 映射到同一表征空间 4.根据损失函数进行多任务优化
O	文本 $x_i$ 对应的所有标签

P	对层级性的标签体系进行编码
C	数据集中的标签空间本身带有层次结构
D	如何利用先验层级知识引导和约束网络学习
L	ACL 2021

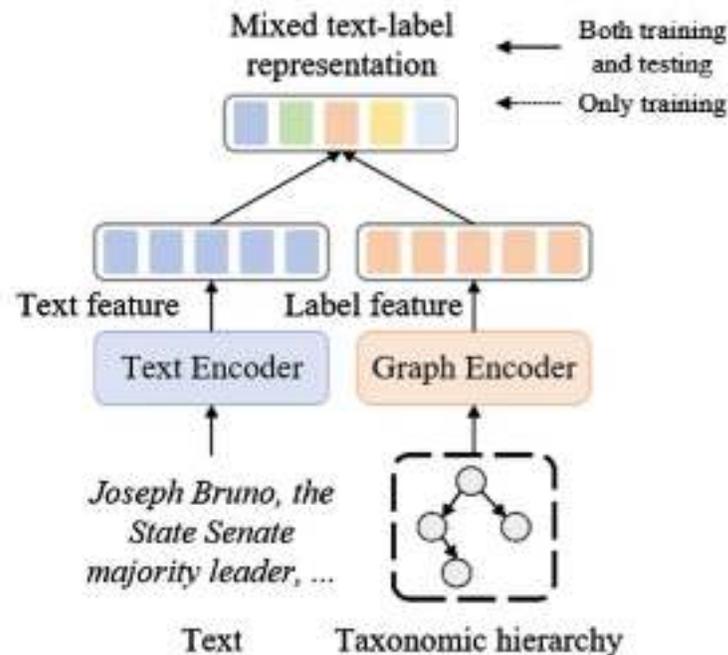


- 核心思想

- 将文本和标签**分别**进行表征学习，根据两表征向量定义不同的**优化目标**，从而提升层次多标签文本分类效果

- 逻辑框架

- 1. 文本编码
- 2. 先验标签体系编码
- 3. 优化目标

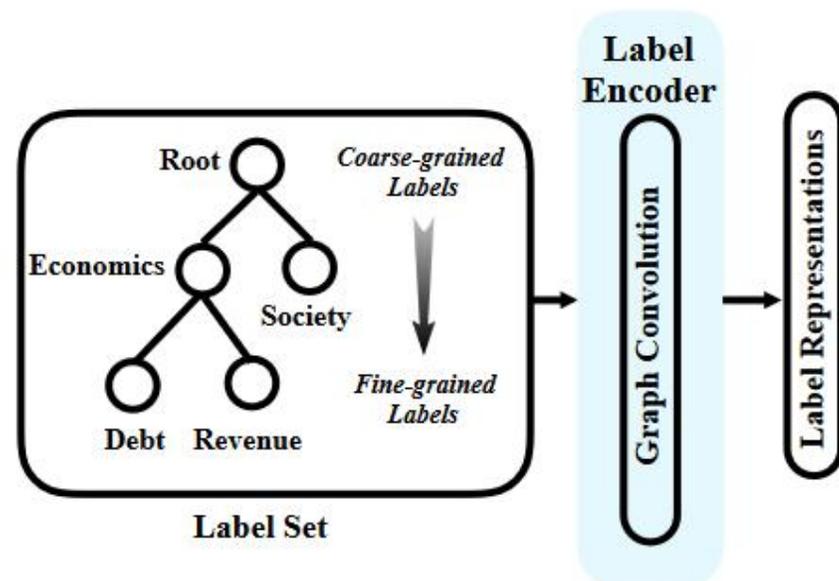




- 标签表征

- 利用先验知识将标签体系定义为图  $G = (V_l, \vec{E}, \overleftarrow{E})$ ,  
 $V_l$  是标签表征向量,  $\vec{E}$  表示父节点到子节点的路径,  
 $\overleftarrow{E}$  表示子节点到父节点的路径, 路径上的值是根据数据集统计而来的先验概率
- 使用GCN网络进行表征学习

$$S_l = \sigma(\overleftarrow{E} \cdot V_l \cdot W_{g3} + \vec{E} \cdot V_l \cdot W_{g4})$$





- 优化目标:

- 将文本表征 $S_t$ 和先验标签表征 $S_l$ 映射到**同一表征空间**

$$\Phi_t = FFN_t(S_t) \quad , \quad \Phi_l = FFN_l(S_l)$$

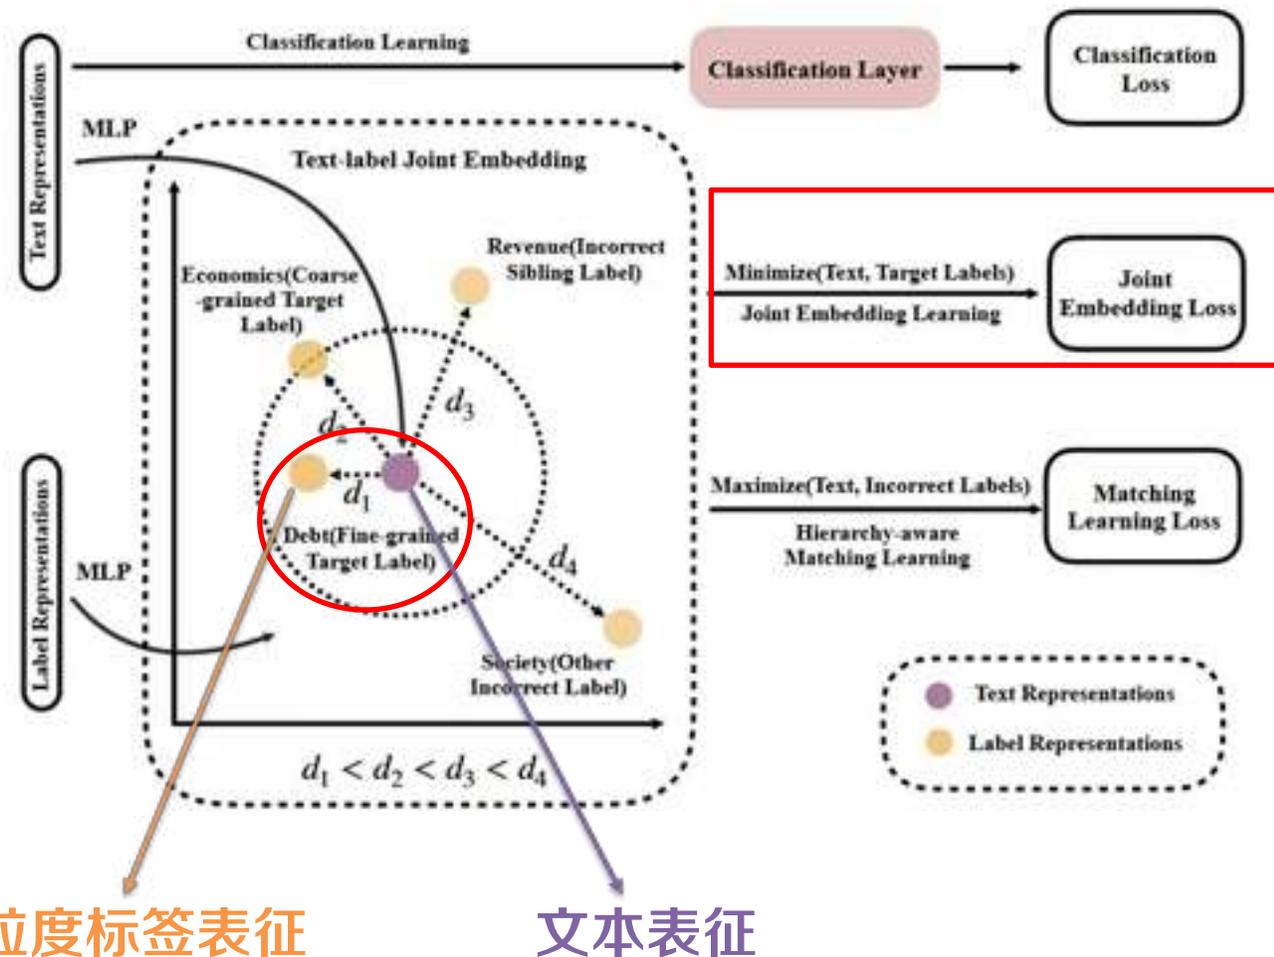
- 多任务损失:

- 联合嵌入损失

- 目标: 希望表征的文本语义向量与它对应的真实标签表征的语义向量**越近越好**

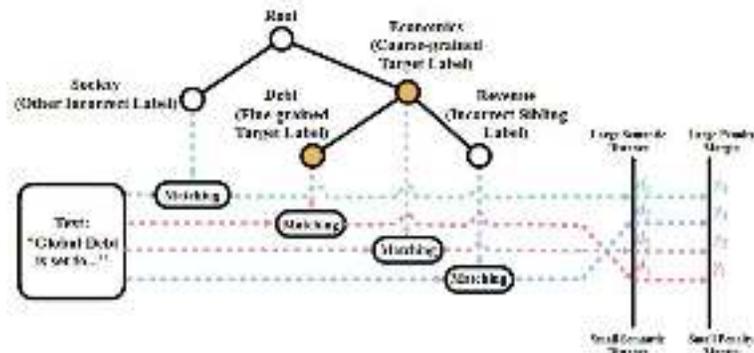
- $\mathcal{L}_{joint} = \sum_{p \in P(y)} \|\Phi_t - \Phi_l^p\|_2^2$

- $P(y)$ 是目标标签集





- 多任务损失：
  - 层次感知匹配损失—层次感知抽样
    - 由于HMTC任务的大量标签集，为每个标签计算匹配损失尤为耗时，故为每个细粒度标签  $y$  抽样其所有粗粒度标签、一个兄弟标签和一个不相关标签作为  $y$  的负标签集  $n \in N(y)$
    - 文本语义应该与细粒度标签最匹配，拥有最短的文本-标签距离  $d_1$ ，文本-粗粒度标签的语义匹配距离  $d_2$  稍大，文本-兄弟标签的语义匹配距离  $d_3$  更大，文本-不相关标签的语义匹配距离  $d_4$  最大
    - 引入层次感知的匹配惩罚边际  $\gamma_1$ 、 $\gamma_2$ 、 $\gamma_3$ 、 $\gamma_4$  建模上述可比关系，若希望语义匹配距离更小，则对应更小的匹配惩罚边际  $\gamma_2 = \alpha\gamma$ ；  $\gamma_3 = \beta\gamma$ ；  $\gamma_4 = \gamma$  ( $0 < \alpha < \beta < 1$ )
    - 由于文本语义和细粒度标签的匹配关系已在联合嵌入学习中被考虑，故忽略  $\gamma_1$



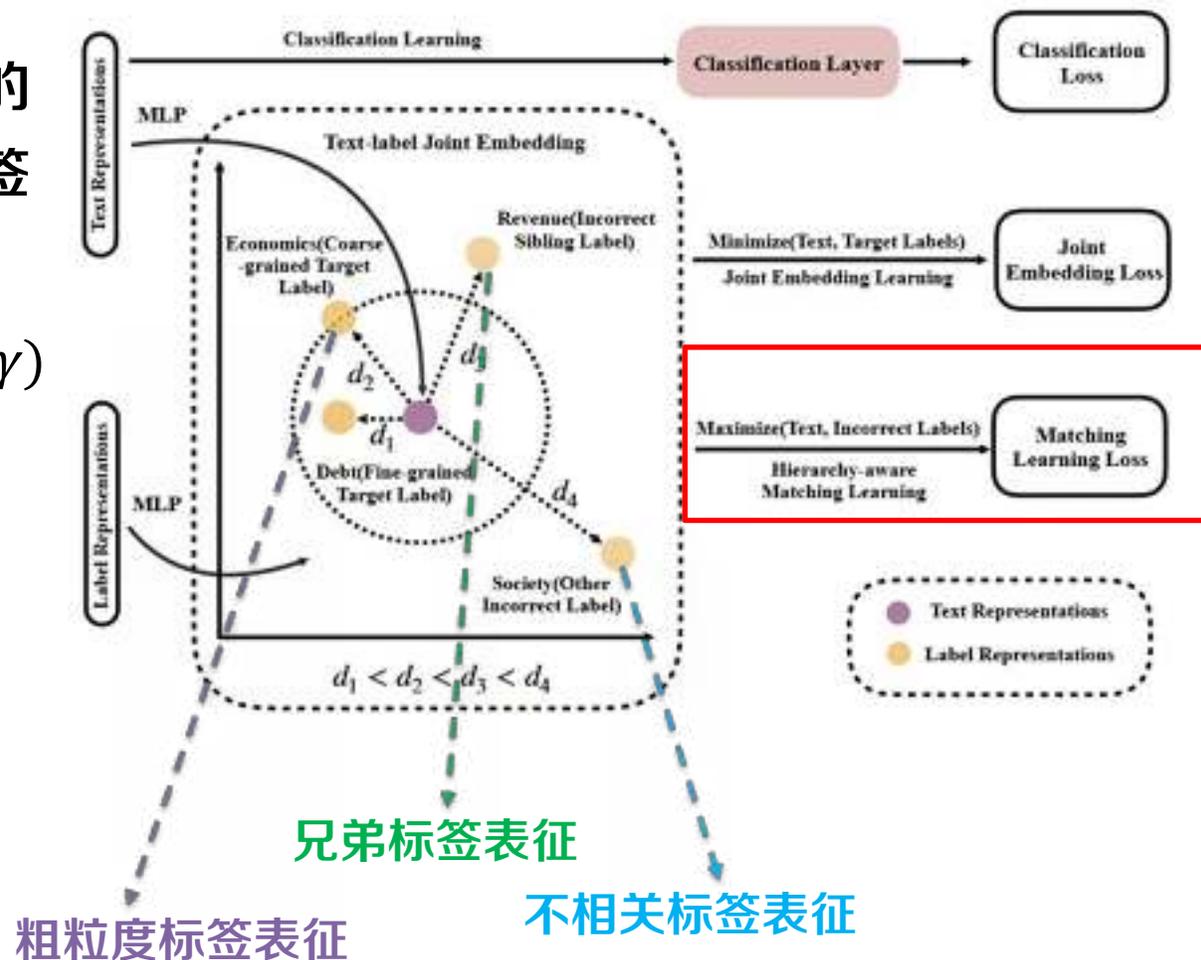
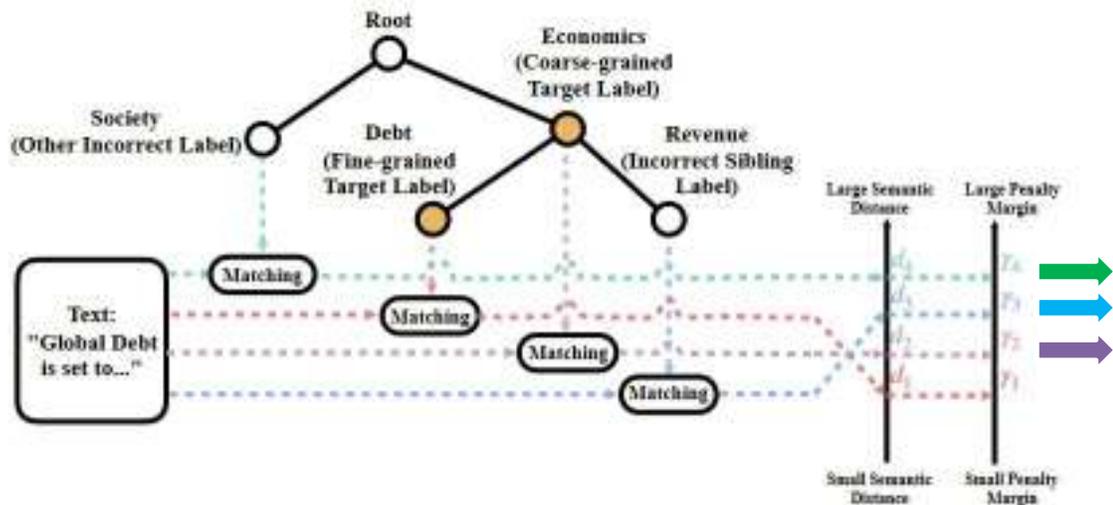


## 多任务损失:

### 层次感知匹配损失

- 目标: 希望表征的文本向量不仅要与对应的真实标签向量越近越好, 还要与非真实标签向量越远越好

- $\mathcal{L}_{match} = \max(0, D(\Phi_t, \Phi_l^p) - D(\Phi_t, \Phi_l^n) + \gamma)$
- $\Phi_l^p$  表示目标标签语义
- $n$  是非真实标签, 对应为负标签集合





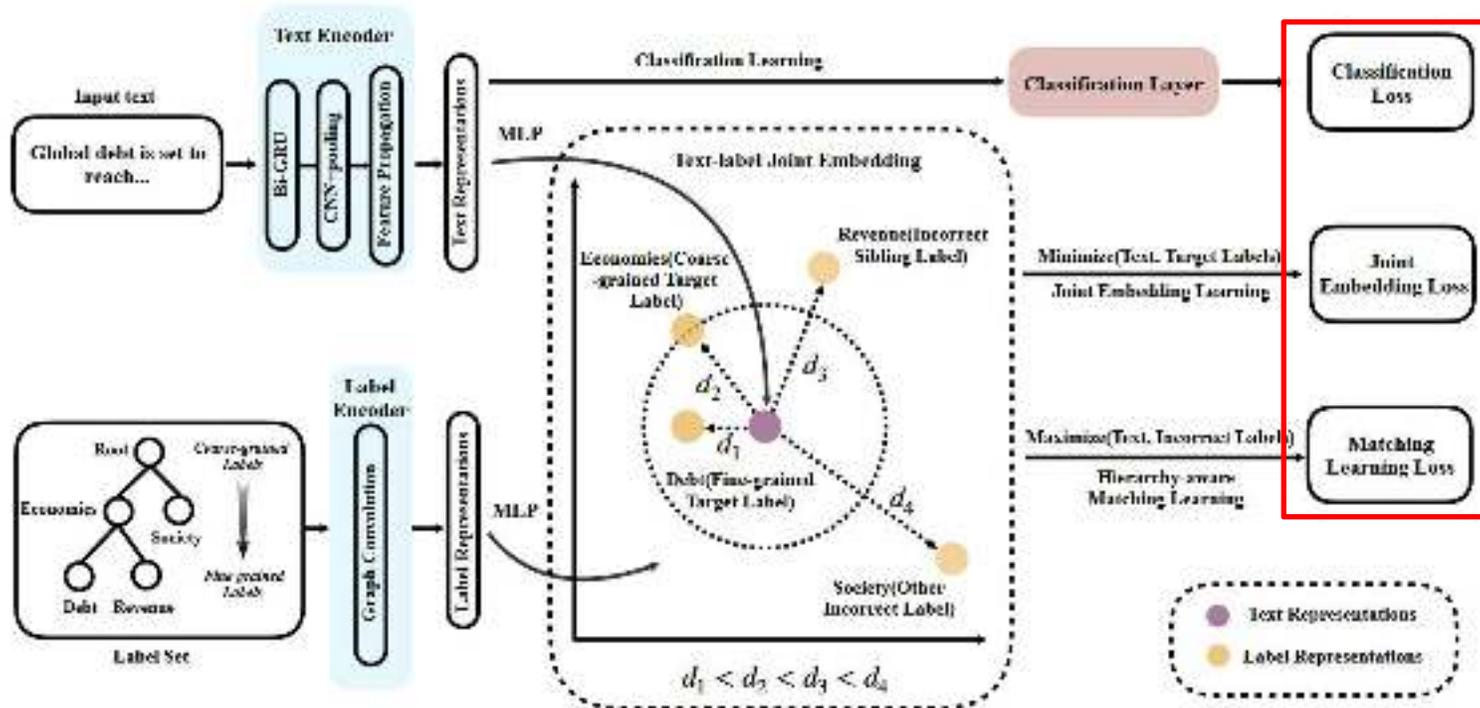
- 多任务损失:

- 分类损失

- 目标: 使用交叉熵损失, 用于衡量模型分类的预测值与真实值之间的不一致程度

- 总优化目标

- $$\mathcal{L} = \mathcal{L}_{cls}(y, \hat{y}) + \lambda_1 \mathcal{L}_{joint} + \lambda_2 \mathcal{L}_{match}$$





- 数据集

- WOS

- web of science中的论文数据集，包含出版论文的摘要和与之相关的主题，采用2级标签结构、标签总数达到141的标签体系

- RCV1-V2

- 新闻语料库数据集，包含大量路透社新闻故事，采用4级标签结构、标签总数达到103的标签体系

- 评价指标

- Macro-F1

- $F1 = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}$
    - $Macro-F1 = \frac{1}{N} \sum_{i=1}^N F1_{ci}$

- Micro-F1

- $Precision_{micro} = \frac{\sum_{i=1}^n TP_i}{\sum_{i=1}^n TP_i + \sum_{i=1}^n FP_i}$
    - $Recall_{micro} = \frac{\sum_{i=1}^n TP_i}{\sum_{i=1}^n TP_i + \sum_{i=1}^n FN_i}$
    - $Micro-F1 = 2 \cdot \frac{Precision_{micro} \cdot Recall_{micro}}{Precision_{micro} + Recall_{micro}}$



## • 对比实验

Models	Micro	Macro
<b>Baselines</b>		
TextRCNN (Zhou et al., 2020)	81.57	59.25
TextRCNN-LA (Zhou et al., 2020)	81.88	59.85
SGM (Zhou et al., 2020)	77.30	47.49
<b>Hierarchy-Aware Models</b>		
HE-AGCRCNN (Peng et al., 2019)	77.80	51.30
HMCN (Mao et al., 2019)	80.80	54.60
Htrans (Banerjee et al., 2019)	80.51	58.49
HiLAP-RL (Mao et al., 2019)	83.30	60.10
HiAGM (Zhou et al., 2020)	83.96	63.35
<b>HiMatch</b>	<b>84.73</b>	<b>64.11</b>
<b>Pretrained Language Models</b>		
BERT (Devlin et al., 2018)	86.26	67.35
<b>BERT+HiMatch</b>	<b>86.33</b>	<b>68.66</b>

RCV1-V2实验结果

## • 实验结果分析

- 以前的方法都忽略文本和标签的语义关系
- HiMatch通过以层次感知的方法捕获文本-标签之间的匹配关系，达到了最好的结果

Models	Micro	Macro
<b>Baselines</b>		
TextRNN (Zhou et al., 2020)	77.94	69.65
TextCNN (Zhou et al., 2020)	82.00	76.18
TextRCNN (Zhou et al., 2020)	83.55	76.99
<b>Hierarchy-Aware Models</b>		
HiAGM (Zhou et al., 2020)	85.82	80.28
<b>HiMatch</b>	<b>86.20</b>	<b>80.53</b>
<b>Pretrained Language Models</b>		
BERT (Devlin et al., 2018)	86.26	80.58
<b>BERT+HiMatch</b>	<b>86.70</b>	<b>81.06</b>

WOS实验结果

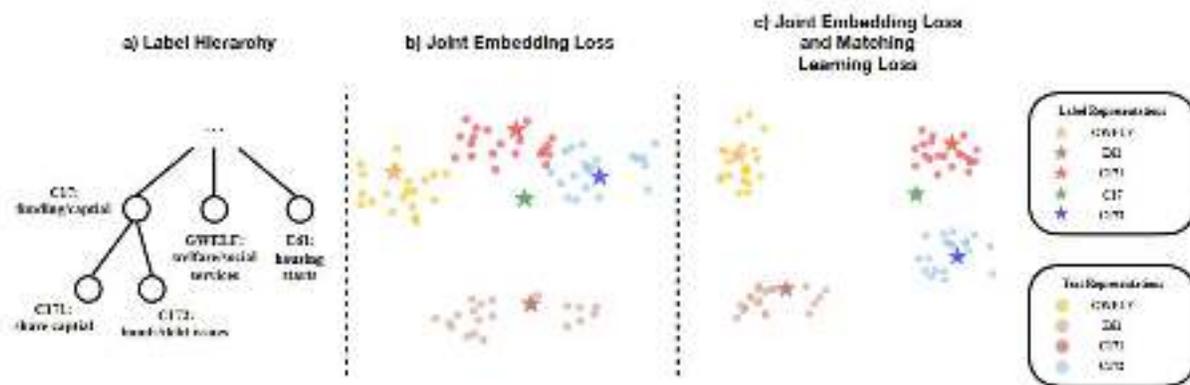


## 消融实验

Ablation Models	Micro	Macro
TextRCNN	81.57	59.25
HiMatch	<b>84.73</b>	<b>64.11</b>
- w/o Joint Embedding Loss	84.49	62.57
- w/o Matching Learning Loss	84.46	63.58
- w/o Hierarchy-aware Sampling	84.67	63.45

## 实验结果分析

- 只引入Joint Embedding Loss，文本表征**接近**于相应的标签表征。但忽略了标签间的匹配关系，不同标签的文本表征可能会**重叠**
- 再引入Matching Learning Loss，不同标签的文本表征更**分离**
- HiMatch能捕获文本与不同粒度标签之间的语义关系





## 超参数实验

No.	$\gamma$	$\alpha$	$\beta$	Micro	Macro
HiMatch					
①	0.2	0.01	0.5	84.73	64.11
Fine-tuning $\gamma$					
②	0.02	0.01	0.5	84.51	63.26
③	2	0.01	0.5	84.69	63.55
Fine-tuning $\alpha, \beta$					
④	0.2	0.5	0.01	84.52	63.35
⑤	0.2	1	1	84.37	63.45
⑥	0.2	0.01	0.01	84.49	63.20
⑦	0.2	0.5	0.5	84.47	64.02

匹配惩罚边缘  $\gamma_2 = \alpha\gamma$ ;  $\gamma_3 = \beta\gamma$ ;  $\gamma_4 = \gamma$  ( $0 < \alpha < \beta < 1$ )

## 实验结果分析

- 实验②③微调 $\gamma$ ，得到最佳 $\gamma$ 为0.2
- 实验④⑤⑥⑦微调 $\alpha$ 、 $\beta$ 
  - ④违反了层次结构，性能降低
  - ⑤忽略了层次结构，性能降低
  - ⑥⑦忽略了粗粒度标签和兄弟标签的关系，性能降低
- 为粗粒度标签设置一个小的匹配惩罚边缘，为不相关标签设置一个大的匹配惩罚边缘是**必要**的



- 横向对比
  - 通过**多任务优化**提升F1值
  - 单独建模文本和先验标签，在模型测试阶段仍需编码先验标签
- 纵向对比
  - 提出了层次感知的语义匹配网络，充分考虑了文本与粗/细粒度标签关系
  - 首次将HMTC任务视为**语义匹配任务**



## 算法原理



T	预测样本 $x_i$ 在 <b>给定标签层次结构</b> 中的多个所属标签
I	文本 $x_i$ 、先验标签集合 $L=\{l_1, l_2, \dots, l_N\}$
P	1.对文本和先验标签体系进行编码 2.构造正样本 3.对比学习模块 4.分类和损失计算
O	文本 $x_i$ 对应的所有标签

P	在层次标签的指导下构造正样本
C	数据集中的标签空间本身带有层次结构
D	如何利用先验层级知识引导和约束网络学习
L	ACL 2022

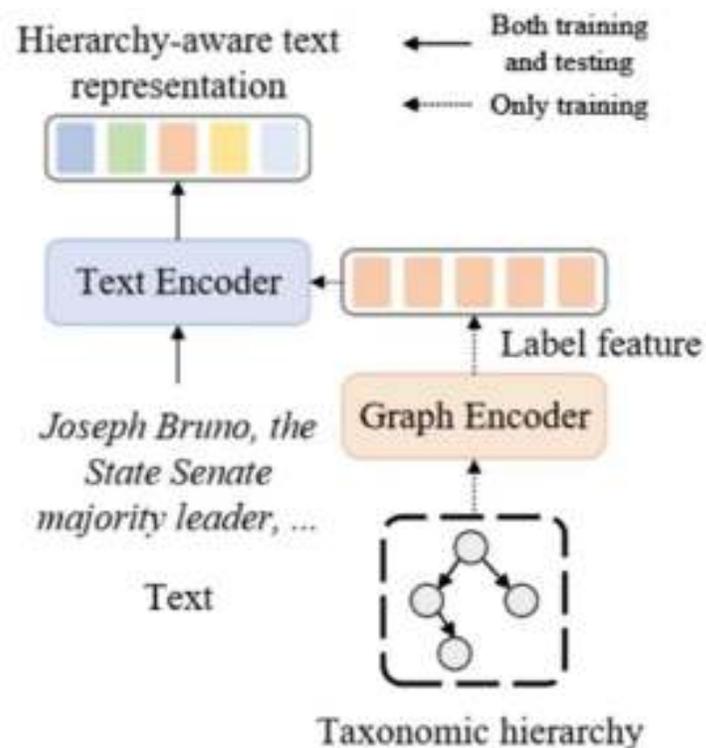


- 核心思想

- 将层次嵌入到文本编码器中，在训练时HGCLR在标签层次结构的指导下，为输入文本构建正样本。通过将输入文本和它的正样本放在一起，文本编码器学习到独立地生成支持层次结构的文本表示

- 逻辑框架

- 1. 文本编码
- 2. 先验标签体系编码
- 3. 正样本生成
- 4. 对比学习模块
- 5. 分类和目标函数





## – 文本编码

- $\{e_1, e_2, \dots, e_n\} = BERT(x)$
- $e_i$  为每个样本词嵌入

## – 先验标签编码

- 利用图编码，得到  $l_j$  作为每个标签嵌入

## – 正样本生成

- 目标：在保留样本部分词的同时保留样本标签

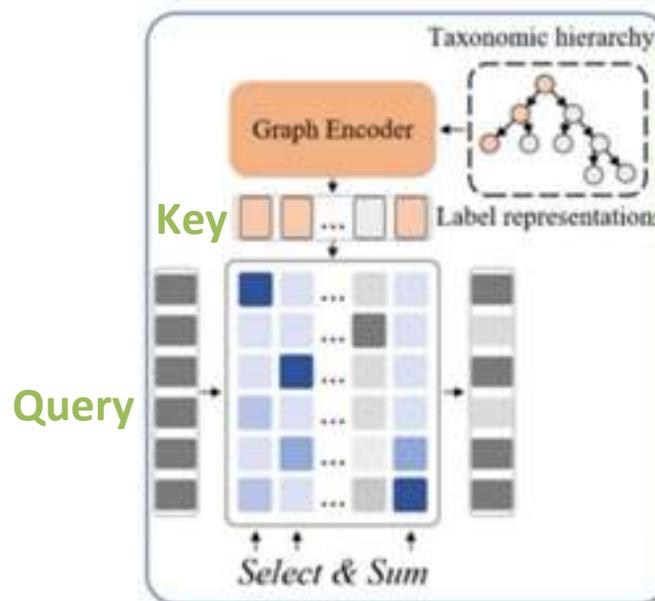
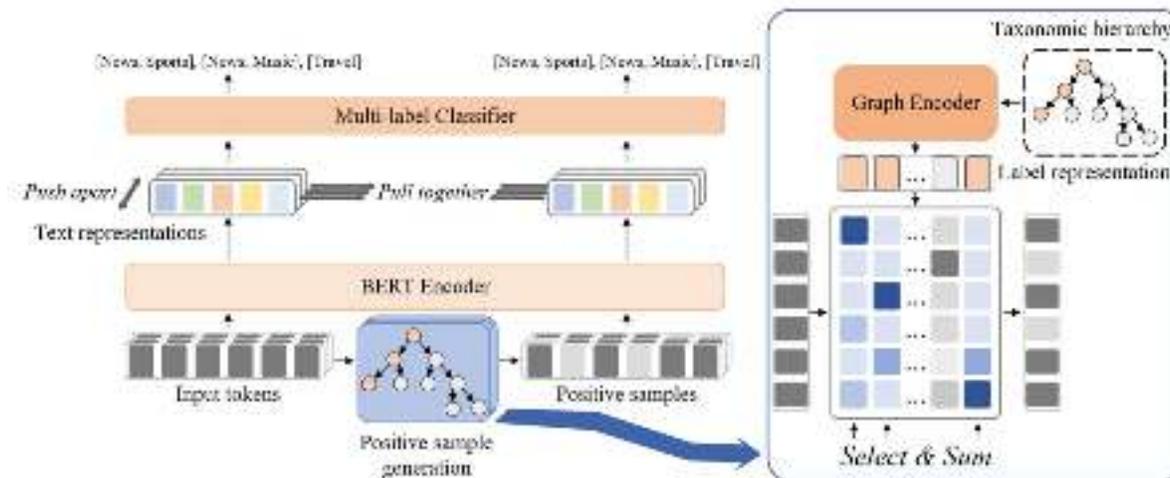
$$- q_i = e_i W_Q, \quad k_j = l_j W_K, \quad A_{ij} = \frac{q_i k_j^T}{\sqrt{d_h}}$$

$$- P_i = \sum_{j \in y} P_{ij}$$

$$- \hat{x} = \{x_i \text{ if } P_i > \gamma \text{ else } 0\}$$

$$- \hat{H} = BERT(\hat{x})$$

- Query: 样本词嵌入; Key: 标签嵌入



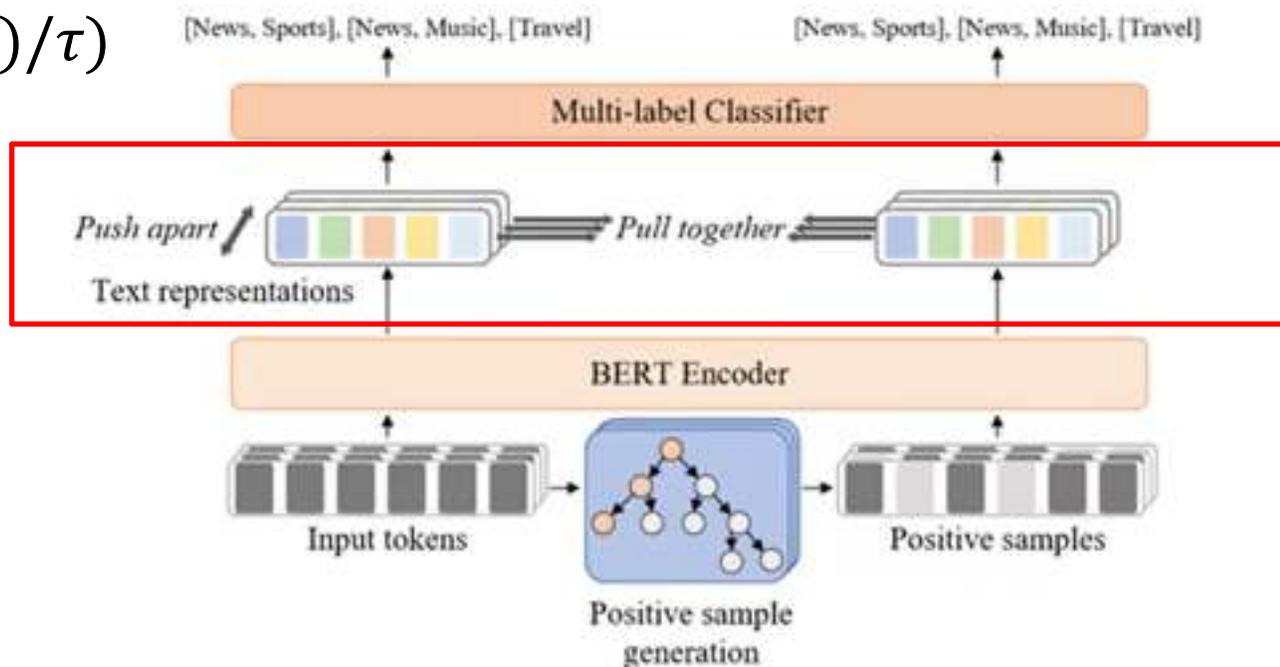


- 对比学习模块:

$$\mathcal{L}_m^{con} = -\log \frac{\exp(\text{sim}(z_m, \mu(z_m))/\tau)}{\sum_{i=1, i \neq m}^{2N} \exp(\text{sim}(z_m, z_i)/\tau)}$$

$$\mu(z_m) = \begin{cases} c_i, & \text{if } z_m = \hat{c}_i \\ \hat{c}_i, & \text{if } z_m = c_i \end{cases}$$

$$\mathcal{L}^{con} = \frac{1}{2N} \sum_{m=1}^{2N} \mathcal{L}_m^{con}$$





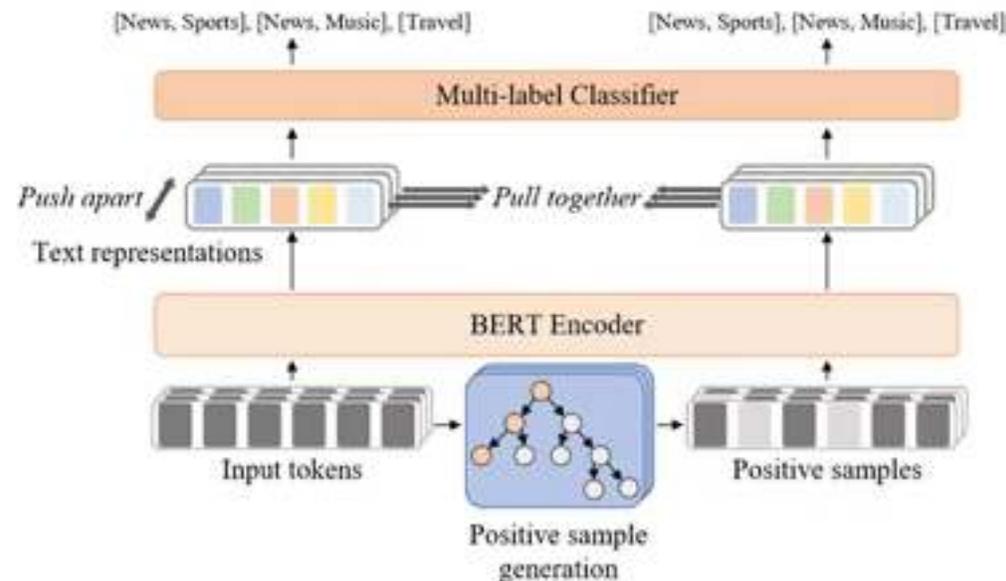
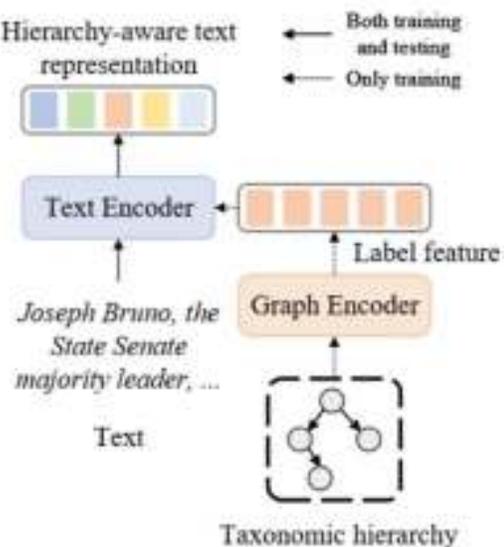
- 分类和目标函数:

$$L^C$$

$$= - \sum_{i=1}^N \sum_{j=1}^k [y_{ij} \log(p_{ij}) + (1 - y_{ij}) \log(1 - p_{ij})]$$

$$\mathcal{L} = \mathcal{L}^C + \widehat{\mathcal{L}}^C + \lambda \mathcal{L}^{con}$$

- 在模型测试阶段，仅用文本编码器进行分类，模型退化为 Bert 模型





- 数据集：
  - WOS
    - web of science中的论文数据集，包含出版论文的摘要和与之相关的主题，采用2级标签结构、标签总数达到141的标签体系
  - RCV1-V2
    - 新闻语料库数据集，包含大量路透社新闻故事，采用4级标签结构、标签总数达到103的标签体系
  - NYT
    - 纽约时报数据集，包含大量纽约时报新闻故事，采用8级标签结构、标签总数达到166的标签体系
- 评价指标
  - Macro-F1
  - Micro-F1



- 对比实验结果

Model	WOS		NYT		RCV1-V2	
	Micro-F1	Macro-F1	Micro-F1	Macro-F1	Micro-F1	Macro-F1
<b>Hierarchy-Aware Models</b>						
TextRCNN (Zhou et al., 2020)	83.55	76.99	70.83	56.18	81.57	59.25
HiAGM (Zhou et al., 2020)	85.82	80.28	74.97	60.83	83.96	63.35
HTCInfoMax (Deng et al., 2021)	85.58	80.05	-	-	83.51	62.71
HiMatch (Chen et al., 2021)	86.20	80.53	-	-	84.73	64.11
<b>Pretrained Language Models</b>						
BERT (Our implement)	85.63	79.07	78.24	65.62	85.65	67.02
BERT (Chen et al., 2021)	86.26	80.58	-	-	86.26	67.35
BERT+HiAGM (Our implement)	86.04	80.19	78.64	66.76	85.58	67.93
BERT+HTCInfoMax (Our implement)	86.30	79.97	78.75	67.31	85.53	67.09
BERT+HiMatch (Chen et al., 2021)	86.70	81.06	-	-	86.33	<b>68.66</b>
HGCLR	<b>87.11</b>	<b>81.20</b>	<b>78.86</b>	<b>67.96</b>	<b>86.49</b>	68.31



- 消融实验结果

Ablation Models	Micro-F1	Macro-F1
BERT	85.75	79.36
<b>HGCLR</b>	<b>87.46</b>	<b>81.52</b>
<i>-r.p.</i> GCN	87.06	80.63
<i>-r.p.</i> GAT	87.18	81.45
<i>-r.m.</i> graph encoder	86.67	80.11
<i>-r.m.</i> contrastive loss	86.72	80.97

Generation Strategy	Micro-F1	Macro-F1
<b>Hierarchy-guided</b>	<b>87.46</b>	<b>81.52</b>
Dropout	86.94	79.91
Random masking	87.19	81.16
Adversarial attack	86.67	80.24

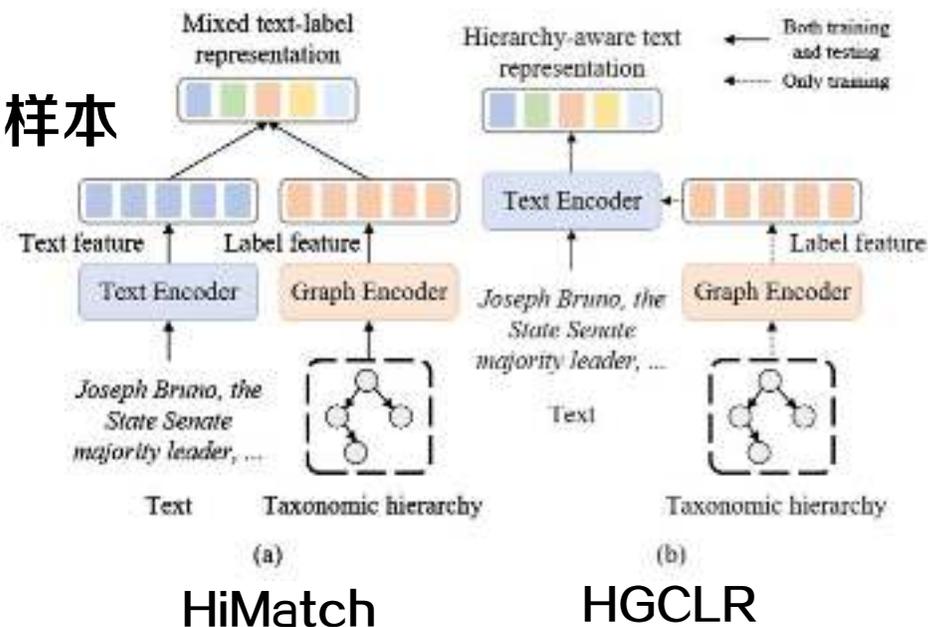


- 横向对比

- 在训练阶段将先验标签注入到文本编码器中，使得文本编码器学习到**独立**地生成支持层次结构的文本表示，在测试阶段无需编码先验标签

- 纵向对比

- 首次将**对比学习**引入HMTC任务
- 考虑了任务独有性，在标签层次的指导下构造正样本





应用总结

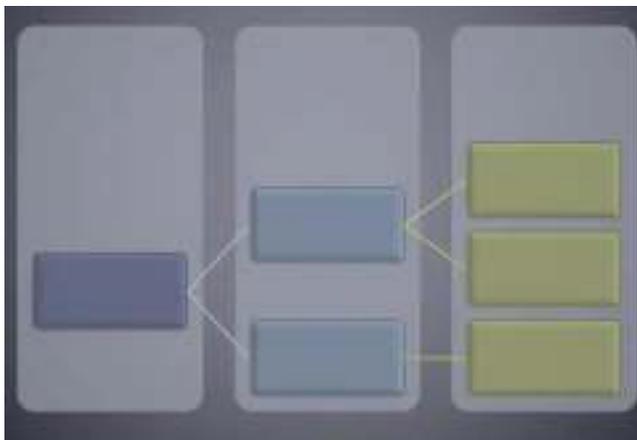


**应用总结**



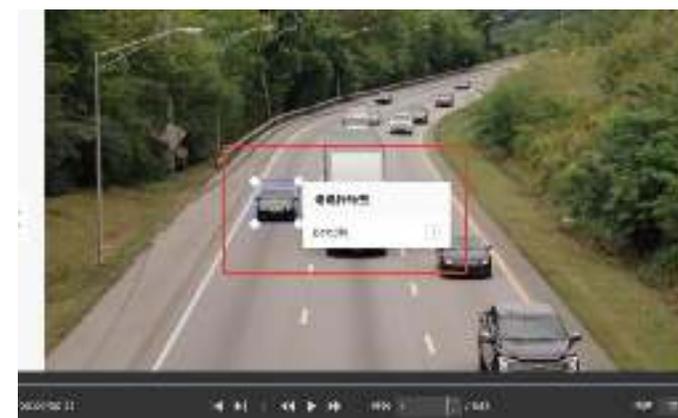
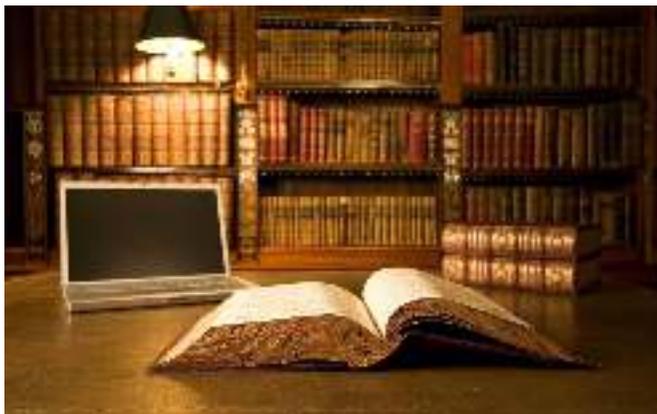
## 应用领域

- 文献组织
- 图像识别
- 视频注释
- 基因功能预测



## 未来的发展

- 时间和空间效率的提升
- 极端层次多标签的处理





- [1] Haibin Chen, Qianli Ma, Zhenxi Lin and Jiangyue Yan. Annual Hierarchy-aware Label Semantics Matching Network for Hierarchical Text Classification. Meeting of the Association for Computational Linguistics, 2021.
- [2] Zihan Wang, Peiyi Wang, et al. Incorporating Hierarchy into Text Encoder: a Contrastive Learning Approach for Hierarchical Text Classification. Meeting of the Association for Computational Linguistics, 2022.
- [3] Jie Zhou, Chunping Ma, Dingkun Long, , et al. Hierarchy-aware global model for hierarchical text classification. Meeting of the Association for Computational Linguistics, 2020.



上善若水。水善利万物而不争，处众人之所恶，故几於道。居善地，心善渊与善仁，言善信，正善治，事善能，动善时。夫唯不争，故无尤。

# 谢谢！

