

# 多模态预训练模型调研记录

## 目录

视频和文本模态数据集 .....	2
1. 图像文本模态方法 .....	4
2. 视频文本模态方法 .....	5
2.1 TACo .....	5
2.2 CLIPBERT .....	6
2.3 CLIP4Clip .....	7
2.4 DRL .....	7
2.5 CLIP2Video .....	8
2.6 CLIP2TV .....	9
3. 多模态方法(至少三种模态) .....	10
3.1 VideoChat(image、video、text 三模态) .....	10
3.2 MERLOT Reserve (视频、文本、音频) .....	11
3.3 VATT (视频、文本、音频) .....	12
3.4 M2HF (视频、文本、音频) .....	13
3.5 ImageBind (图像、文本、音频、深度、热像和IMU 数据) .....	14
3.6 CoDi (视频、图像、文本、音频四模态到四模态生成模型) .....	15

## 视频和文本模态数据集

### 文本-视频常用数据集 (英文) :

**MSR-VTT**: 该数据集包含 10000 个视频片段 (video clip), 每个视频 10 s 到 32s, 被分为训练, 验证和测试集三部分。每个视频片段都被标注了大概 20 条英文句子。此外, MSR-VTT 还提供了每个视频类别信息 (共计 20 类), 这个类别信息算是先验的, 在测试集中也是已知的。同时, 视频都是包含音频信息的。该数据库共计使用了四种机器翻译的评价指标, 分别为: METEOR, BLEU@1-4, ROUGE-L, CIDEr。

数据集地址: <http://ms-multimedia-challenge.com/2017/dataset>

**MSVD**: 包含 1970 个视频, 每个视频剪辑包含 40 个句子, 每个视频 1s 到 62s, 平均时长为 9s, 视频包含不同的人, 动物, 动作, 场景等。每个视频由不同的人标注了多个句子, 大约 41 annotated sentences per clip, 共有 80839 个 sentences, 平均每个句子有 8 个 words, 这些所有的句子中共包含近 16000 个 unique words。caption 中包括多国的语言进行描述, 部分论文中采取只选用 language = english 的 caption 进行训练和测试。

数据集地址: <https://www.cs.utexas.edu/users/ml/clamp/videoDescription/>

**LSMDC**: 由 118081 个视频组成, 每个视频的长度从 2 秒到 30 秒不等。视频是从 202 部电影中提取的。验证集包含 7408 个视频, 测试集包含 1000 个电影视频

数据集地址: <https://sites.google.com/site/describingmovies/download>

**ActivityNet**: 是目前视频动作分析方向最大的数据集, 包含分类和检测两个任务。目前版本为 v1.3, 包括 20000 个 Youtube 视频 (训练集包含约 10000 个视频, 验证集和测试集各包含约 5000 个视频), 共计约 700 小时的视频, 平均每个视频上有 1.5 个动作标注 (action instance)。ActivityNet 涵盖了 200 种不同的日常活动, 例如: 'walking the dog', 'long jump', and 'vacuuming floor' 等。数据量分布: train (~50%), validation (~25%), test (~25%)。

数据集地址: <http://activity-net.org/download.html>

**DiDeMo**: 包含 10000 个视频和 40000 个句子。为了便于注释, 每个视频被分成 5 秒的时间块。第一个时间块对应视频中的 0-5 秒, 第二个时间块则对应 5-10 秒, 等等。

数据集地址: <https://github.com/LisaAnne/LocalizingMoments>

**VATEX**: 全称 Video And TEXT, 是一个大规模、多语言视频描述数据集, 该数据集包含超过 41250 个视频和 82.5 万中英文视频描述, 其中包括超过 20.6 万描述是中英平行翻译对。它包含 600 种人类活动和不同的视频内容。每个视频具备 10 个英文描述和 10 个中文描述, 分别来自 20 个人类标注者。

数据集地址: <https://eric-xw.github.io/vatex-website/download.html>

### **文本-视频常用数据集 (中文) :**

**Youku-mPLUG** : 含来自 45 个不同类别的 1000 万个中文视频-文本对。视频标题长度在 5 到 30 个字之间, 而且至少包含 5 个汉字, 长度在 10 到 120 秒之间。

数据集地址 : <https://modelscope.cn/datasets/modelscope/Youku-AliceMind/summary>

**Tencent-MVSE Dataset** : 中文视频多模态相似度数据集, 包含视频对, 和视频文本对, 每一个视频都提供了丰富的信息, 包括中文标题、ASR 文本(视频语音转化成文本)、视频 frame 特征、人工标注的 tag 以及视频所属的 category (垂类)。

数据集地址 : <https://tencent-mvse.github.io/>

### **其他训练可用数据集 (英文) :**

Howto100M 数据集 : <https://opendatalab.org.cn/HowTo100M/download> (质量比较差)

LAION-5B 数据集 : <https://laion.ai/blog/laion-5b/>

Web-Vid-10M 数据集 : <https://m-bain.github.io/webvid-dataset/>

HD-VILA-100M 数据集 : <https://github.com/microsoft/XPretrain/tree/main/hd-vila-100m>

UCF-101 数据集 : <https://www.crcv.ucf.edu/data/UCF101>

YT-Temporal-180M 数据集 : <https://opendatalab.com/YT-Temporal-180M>

### **图像-文本可用数据集 :**

LAION-400M 图文数据集 : <https://laion.ai/blog/laion-400-open-dataset/>

COYO-700M 图文数据集 : <https://github.com/kakaobrain/coyo-dataset>

MMC4-1000M 图文数据集 : <https://github.com/allenai/mmc4>

SBU-图文数据集 : [https://opendatalab.org.cn/SBU\\_Captions\\_Dataset/download](https://opendatalab.org.cn/SBU_Captions_Dataset/download)

Conceptual Captions-12M : [https://opendatalab.org.cn/Conceptual\\_Captions/download](https://opendatalab.org.cn/Conceptual_Captions/download)

COCO 数据集 : <http://images.cocodataset.org/>

GRIT- 20M 数据集 : <https://github.com/microsoft/unilm/tree/master/kosmos-2> (文本描述包含物体的位置坐标, 可以增强模型的位置感知能力, 参考论文 kosmos-2)

## 1. 图像文本模态方法

- (1) **CLIP** : Learning Transferable Visual Models From Natural Language Supervision  
Paper : <https://arxiv.org/pdf/2103.00020.pdf>
- (2) **FLIP** : Scaling Language-Image Pre-training via Masking  
Paper : <https://arxiv.org/pdf/2212.00794.pdf>  
亮点 : 通过随机 mask 掉图像的 patch,来极大的提高训练效率
- (3) **ViLT** : Vision-and-Language Transformer Without Convolution or Region Supervision  
Paper : <https://arxiv.org/pdf/2102.03334.pdf>  
亮点 : 直接把 text tokens 和 image patches 忍到一块过 Transformer, 大力出奇迹
- (4) **ALBEF** : Align before Fuse: Vision and Language Representation Learning with Momentum Distillation  
Paper : <https://arxiv.org/pdf/2107.07651.pdf>  
亮点 : 做 N 多个任务, 多个网络, 一次迭代要前传很多次
- (5) **BLIP** : BLIP: Bootstrapping Language-Image Pre-training for Unified Vision-Language Understanding and Generation  
Paper : <https://arxiv.org/pdf/2201.12086.pdf>  
亮点 : 利用训练好的 LM 生成伪标签、训练好的 ITM 清洗数据, 然后再训一轮
- (6) **BLIP2** : BLIP-2: Bootstrapping Language-Image Pre-training with Frozen Image Encoders and Large Language Models  
Paper : <https://arxiv.org/pdf/2301.12597.pdf>  
亮点 : 利用 Q-former 桥接视觉模型和语言模型 (LLM)
- (7) **CoCa** : Contrastive Captioners are Image-Text Foundation Models  
Paper : <https://arxiv.org/pdf/2205.01917.pdf>  
亮点 : 对比学习+captioning
- (7) **VLMO** : Unified Vision-Language Pre-Training with Mixture-of-Modality-Experts  
Paper : <https://arxiv.org/pdf/2111.02358.pdf>  
亮点 : 魔改 transformer layer, self-attention 部分不动 ; FFN 部分分成三 : V-FFN 处理视觉模态, L-FFN 处理文本模态, VL-FFN 处理多模态
- (7) **BEiT-V3** : Image as a Foreign Language: BEiT Pretraining for All Vision and Vision-Language Tasks  
Paper : <https://arxiv.org/pdf/2208.10442.pdf>  
亮点 : backbone 用 VLMO 里提出的 Multiway Transformer, 训练目标只有 Masked Data Modeling, 没有对比学习了
- (7) **Kosmos-1** : Language Is Not All You Need: Aligning Perception with Language Models  
Paper : <https://arxiv.org/pdf/2302.14045.pdf>  
亮点 : 一个多模态的 LLM, 把所有模态的输入都展平成序列按规则拼接到一起输入到 Transformer Decoder 中。
- (8) **Kosmos-2** : Grounding Multimodal Large Language Models to the World  
Paper : <https://komosarxiv.org/pdf/2306.14824.pdf>  
亮点 : 提出了一个 Large-Scale Training Corpus of Grounded Image-Text Pairs (GRIT) 数据集, 大模型模型具备了感知物体位置的能力。  
简要描述可参考 : [https://zhuanlan.zhihu.com/p/614964205?utm\\_id=0](https://zhuanlan.zhihu.com/p/614964205?utm_id=0)

## 2. 视频文本模态方法

目前已有的视频文本模态对齐方法有 CLIPBERT, CLIP4Clip, CLIP2Video, CLIPTV、TACo 等方法, 在这里我们将简单的对他们做一些总结性的介绍。

### 2.1 TACo

#### TACo: Token-aware Cascade Contrastive Learning for Video-Text Alignment

Jianwei Yang  
Microsoft Research  
jianwyan@microsoft.com

Yonatan Bisk  
Carnegie Mellon University  
ybisk@cs.cmu.edu

Jianfeng Gao  
Microsoft Research  
jfgao@microsoft.com

论文名: TACo: Token-aware Cascade Contrastive Learning for Video-Text Alignment

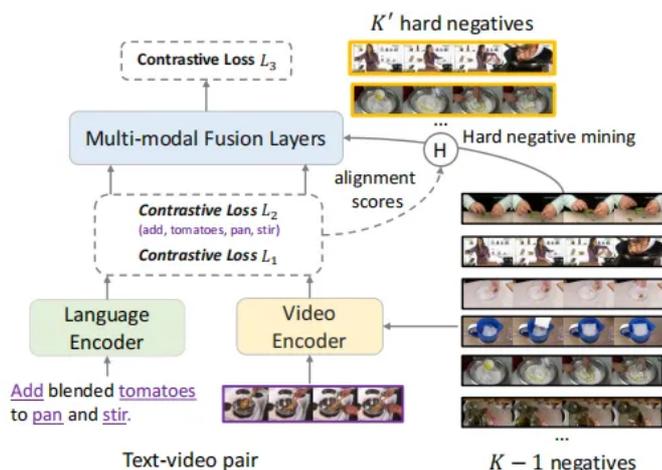
论文链接: <https://arxiv.org/abs/2108.09980>

代码链接: 无

论文机构: 微软

论文创新: 训练优化创新

本文提出了一种 token 感知级联对比学习(TACo) 算法, 该算法利用两种新技术改进了目前的对比学习。第一个是 token 感知的对比损失, 它是通过考虑单词的句法类来计算的。这是由于对于视频-文本对, 文本中的内容词, 如名词和动词, 比功能词更有可能与视频中的视觉内容对齐。第二是采用了级联采样方法生成一组少量 hard negative 样本, 以有效地估计多模态融合层的损失。



本文的方法主要有三个模块组成: Video encoding module、Language encoding module、Multi-modal fusion module

**[Video encoding module]** 视频编码模块由  $\theta$  参数化的自注意层实现。输入的视频特征使用一些预先训练的模型提取, 如 2D CNN 或 3D CNN。给定输入的视频嵌入, 视频编码器从一个线性层开始, 将它们投射到与自注意层相同的维度  $d$  上。作者用  $m$  个特征的序列来表示视频编码器的输出, 特征的数量  $m$  取决于采样帧率的选择和视频特征提取器的选择。

**[Language encoding module]** 作者分别使用预训练的 tokenizer 和 BERT 对输入文

本进行 tokenize 和提取文本特征。给定一个原始句子，分别在开头和结尾追加一个 “[CLS]” 和 “[SEP]”。在模型顶部，可以得到一个由  $n$  个文本特征组成的序列。这里保证了视频编码器的输出特征维数与语言编码器的特征相同。在训练过程中，更新语言编码器中的参数  $\theta$ ，以适应特定域的文本。

**【Multi-modal fusion module】** 多模态融合模块由具有可学习参数  $\theta$  的自注意层组成。它将两种独立模态的视频特征和文本特征作为输入，然后输出特征。

上述三个模块组成了本文的视频-文本对齐模型，然后对该模型使用所提出的 token 感知级联对比损失进行训练。

**sentence-level contrastive loss**：对整个视频帧编码后的特征求平均，对视频相应文本编码后的特征求平均，计算相似性损失

**token-level contrastive loss**：不求平均，计算损失，让文本特征和视频帧的特征对齐

**Token of interest loss**：挑选一些名词和动词的对应的 **Token** 出来计算损失，为了减少计算，只挑选  $k$  个最困难的负样本参与计算。

## 2.2 CLIPBERT

### Less is More: CLIPBERT for Video-and-Language Learning via Sparse Sampling

Jie Lei<sup>\*1</sup>, Linjie Li<sup>\*2</sup>, Luowei Zhou<sup>2</sup>, Zhe Gan<sup>2</sup>, Tamara L. Berg<sup>1</sup>, Mohit Bansal<sup>1</sup>, Jingjing Liu<sup>2</sup>

<sup>1</sup>UNC Chapel Hill <sup>2</sup>Microsoft Dynamics 365 AI Research

{jielei, tlberg, mbansal}@cs.unc.edu

{lindesy.li, luowei.zhou, zhe.gan, jingjl}@microsoft.com

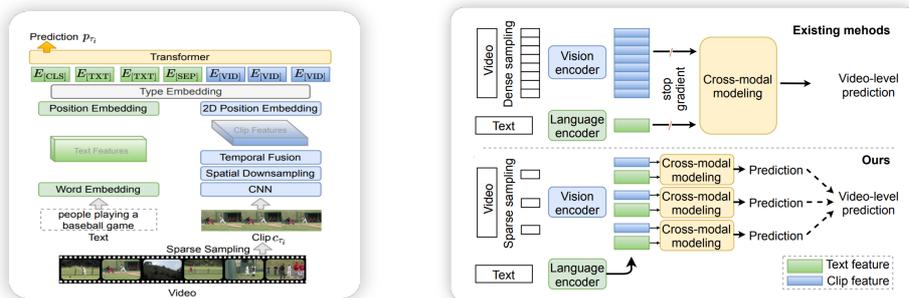
论文名：CLIP4Clip: An Empirical Study of CLIP for End to End Video Clip Retrieval

论文链接：<https://arxiv.org/pdf/2102.06183.pdf>

代码链接：<https://github.com/jayleicn/ClipBERT>

论文机构：微软

论文创新：结构小改



来自 CVPR2021。作者的 motivation 来自于，目前大部分预训练模型都使用提前提取好的特征提取器，然而 1) 固定的特征对于不同的下游任务来说不是最优的，且不同的模态的特征相互独立。2) 密集的视频特征的计算量要求较高，以原视频作为输入太慢了，因此特征提取器很难参与到微调中。

CLIPBERT，通过稀疏采样，即只使用一个或几个稀疏采样的视频短片来代替整个视频，以 less-is-more 的原则使模型可以负载端到端学习。如上图所示，该模型仅仅使用少量的短片即可，然后对多个短片的预测进行融合如平均池化，以得到最终在整个视频级上的预测。这种先稀疏训练后密集推理的策略可以大大减少内存需求和计算量。

## 2.3 CLIP4Clip

### CLIP4Clip: An Empirical Study of CLIP for End to End Video Clip Retrieval

Huaishao Luo<sup>1\*</sup>, Lei Ji<sup>2</sup>, Ming Zhong<sup>3</sup>, Yang Chen<sup>3</sup>, Wen Lei<sup>3</sup>, Nan Duan<sup>2</sup>, Tianrui Li<sup>1</sup>

<sup>1</sup>Southwest Jiaotong University, Chengdu, China

huaishao1uo@gmail.com, trli@swjtu.edu.cn

<sup>2</sup>Microsoft Research Asia, Beijing, China

<sup>3</sup>Microsoft STCA, Beijing, China

{lei.ji, minzhon, emchen, wen.lei, nanduan}@microsoft.com

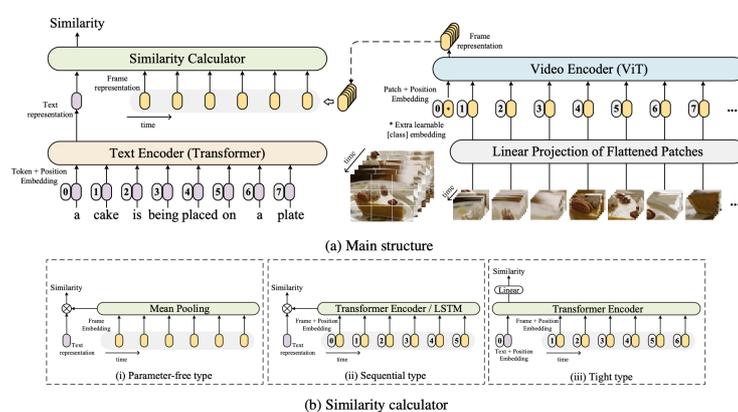
论文名：CLIP4Clip: An Empirical Study of CLIP for End to End Video Clip Retrieval

论文链接：<https://arxiv.org/pdf/2104.08860.pdf>

代码链接：<https://github.com/ArrowLuo/CLIP4Clip>

论文机构：微软

论文创新：增加了用于视频和文本的相似度计算模块



CLIP4Clip 基于预训练好的图文模型，引入 Similarity Calculator 来计算多帧特征和文本特征相似度，根据模块是否引入新参数进行学习，分为三类：无参数方法、序列型和紧凑型，结构分别如上图的下半部分。其中无参数方法直接使用平均池化直接融合视频表示。序列型的视频文本处理采用两个单独的分支。而紧凑型直接用 Transformer 学多模态交互。

## 2.4 DRL

### Disentangled Representation Learning for Text-Video Retrieval

Qiang Wang, Yanhao Zhang, Yun Zheng, Pan Pan, Xian-Sheng Hua

DAMO Academy, Alibaba Group

{qishi.wq, yanhao.zyh, zhengyun.zy, panpan.pp, xiansheng.hxs}@alibaba-inc.com

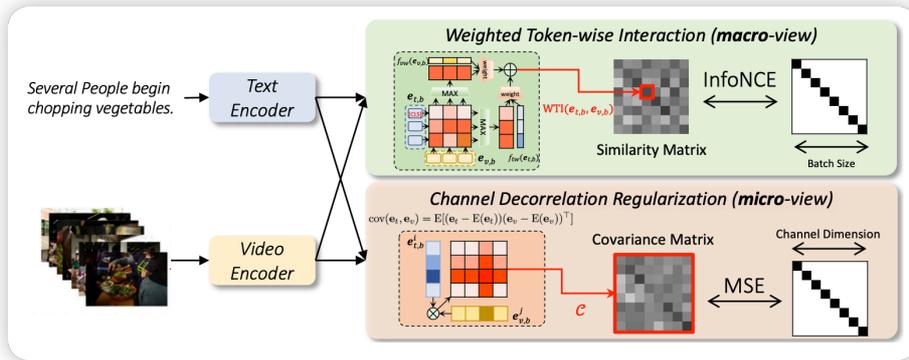
论文名：Disentangled Representation Learning for Text-Video Retrieval

论文链接：<https://arxiv.org/pdf/2203.07111.pdf>

代码链接：<https://towhee.io/video-text-embedding/drl>

论文机构：达摩院

论文创新：相似度计算改进



对 CLIP4Clip 的改进工作，之前的 CLIP4Clip 是对两个模态的总体表征计算相似度，缺少细粒度的交互，比如，描述可能只对应了视频的一部分帧，如果抽取整体特征可能其它帧的信息会占主导。DRL 使用提出两个重要改进，一个是 Weighted Token-wise Interaction，进行相似度的稠密预测，通过 max 操作找到潜在的激活的 token。另一个是 Channel Decorrelation Regularization，通道去相关正则可以减少通道间信息的冗余和竞争，使用协方差矩阵度量通道上的冗余。DRL 在大量视频检索数据集上取得了优于 CLIP4Clip 的效果。

## 2.5 CLIP2Video

**CLIP2Video: Mastering Video-Text Retrieval via Image CLIP**

Han Fang\* Pengfei Xiong\*\* Luhui Xu Yu Chen

PCG, Tencent

fanghan@bupt.edu.cn, xiongpengfei2019@gmail.com, {lukenxu, andyyuchen}@tencent.com

<https://github.com/CryhanFang/CLIP2Video>

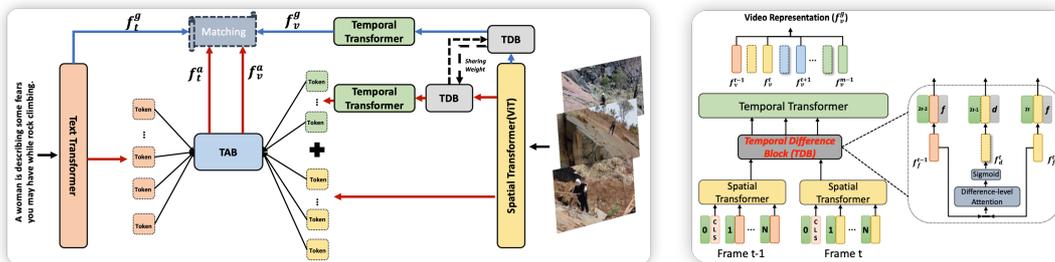
论文名：CLIP2Video: Mastering Video-Text Retrieval via Image CLIP

论文链接：https://arxiv.org/abs/2106.11097

代码链接: https://github.com/CryhanFang/CLIP2Video

论文机构：腾讯 PCG

论文创新：特征提取模块的改进



作者提出了两个模块：时间差分块（Temporal Difference Block, TDB）和时间对齐块（Temporal Alignment Block, TAB）。**时间差分块。**在序列中加入图像帧的差分来模拟运动变化。具体来说，以相邻时间戳之间帧嵌入的变换差来表示，即使用 sigmoid 和差异的注意力来表示，最后全局拼接得到视频表征。**时间对齐块。**利用文本上下文和关键帧内容之间的对齐，以增强视频片段和短语之间的相关性。具体实现是使用共享的聚类中心来联合对齐帧和单词嵌入，即计算不同模态特征和共享中心的相关度作为不同 cluster 中心的权重。

## 2.6 CLIP2TV

### CLIP2TV: Align, Match and Distill for Video-Text Retrieval

Zijian Gao<sup>1</sup>, Jingyu Liu<sup>1</sup>, Weiqi Sun<sup>1</sup>,  
Sheng Chen<sup>1</sup>, Dedan Chang<sup>1</sup>, and Lili Zhao<sup>1</sup>

OVB, PCG, Tencent  
gzjbupt2016@bupt.edu.cn, sunweiqi@buaa.edu.cn,  
{messijyliu, carlschen, dedanchang, lilillizhao}@tencent.com

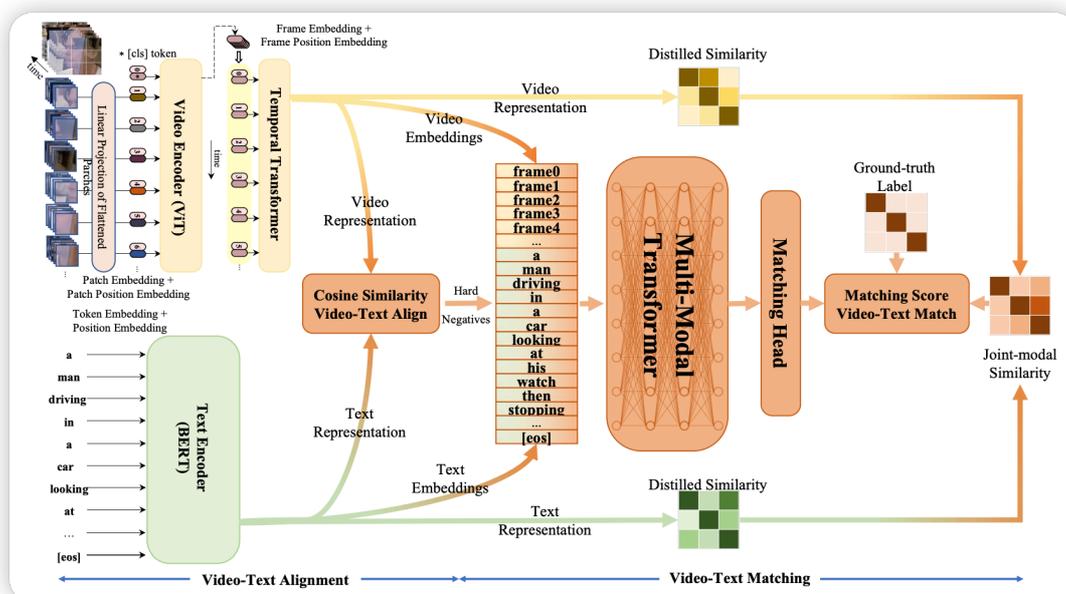
论文名：CLIP2TV: Align, Match and Distill for Video-Text Retrieval

论文链接：<https://arxiv.org/pdf/2111.05610.pdf>

代码链接：无

论文机构：腾讯 PCG

论文创新：特征提取模块的改进



结合 CLIP 和动量蒸馏来做视频文本检索。主要的贡献是在 CLIP4CLIP 的基础上，在推理阶段引入动量蒸馏。动量蒸馏的引入是为了解决图像文本的弱相关性，即标题不完全覆盖视频，视频片段又不包含文本描述。整体的结构如上图，主干部分和 CLIP4CLIP 一样，值得注意的点主要有：

**Contrastive learning**：由于帧特征和标题特征都被投影到了多模态共享空间中，作者试图结合余弦相似性和对比性损失，计算标准化帧表示和标准化标题表示之间的余弦相似度。

**Momentum Distillation**：动量蒸馏处理图像文本对之间的弱相关性。

### 3. 多模态方法(至少三种模态)

#### 3.1 VideoChat(image、video、text 三模态)



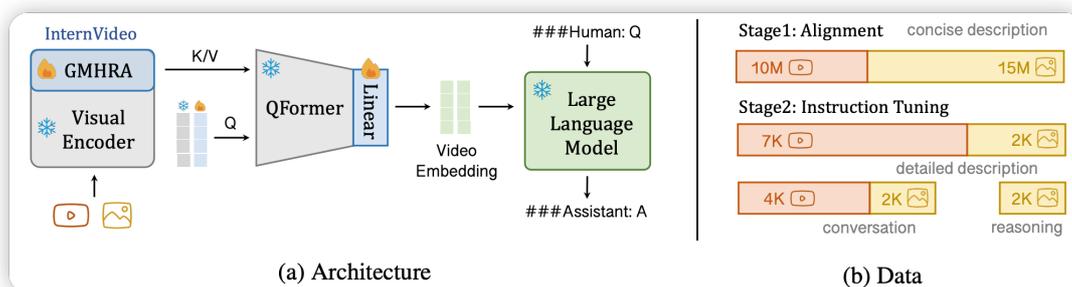
论文名：VideoChat : Chat-Centric Video Understanding

论文链接：https://arxiv.org/pdf/2305.06355.pdf

代码链接: https://github.com/OpenGVLab/Ask-Anything

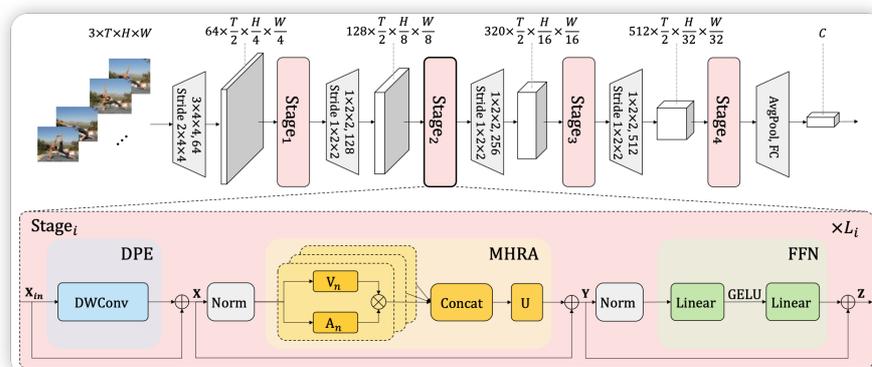
论文机构：上海人工智能实验室

支持模态：视频、图像、文本



VideoChat 通过 BLIP2 (BLIP+UniFormerV2)和 LLM (Vicuna)构建了一个支持图像和视频输入的多模态对话系统。作者以一种极其简洁的方式统一了视频和图像模态的特征提取，从而实现了 BLIP 对图像、视频、文本三模态的支持。

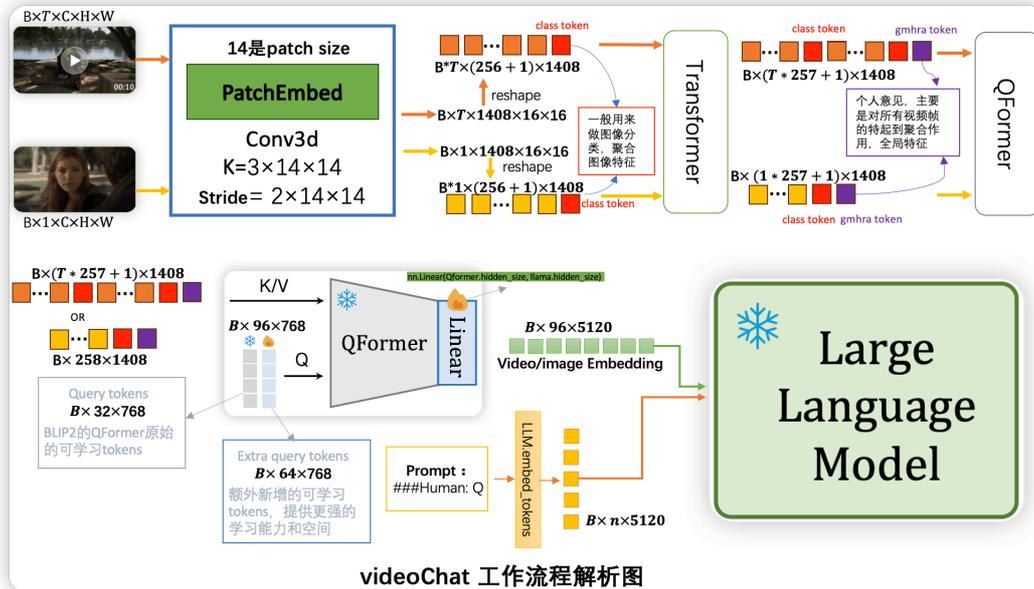
具体来说，作者通过将 BLIP 的特征提取网络（普通 VIT）替换成了兼容图像和视频特征提取的 VIT 神经网络 **UniFormer**，其结构如下：



UniFormer: Unified Transformer for Efficient Spatiotemporal Representation Learning

以下是 VideoChat 中图像和视频的处理流程：

- 1、对输入的图像和视频进行预处理，尺寸缩放到 224×224，颜色进行归一化处理。
- 2、利用 ViT-G (UniFormer) 网络进行图像和视频的特征提取，具体操作如下



- 3、将 QFormer 编码后的图像或者视频特征与文本经过编码的特征拼接到一起送入 LLM 中。通过以上流程，VideoChat 以一种优雅的方式统一了图像和视频模态，从而基于训练好的 BLIP2 和 LLM 权重构建了一个视频、图像和文本的三模态对话系统。

### 3.2 MERLOT Reserve (视频、文本、音频)

**MERLOT RESERVE:**  
**Neural Script Knowledge through Vision and Language and Sound**

Rowan Zellers<sup>✉</sup> Jiasen Lu<sup>\*</sup> Ximing Lu<sup>\*</sup> Youngjae Yu<sup>\*</sup> Yanpeng Zhao<sup>✉</sup>  
 Mohammadreza Salehi<sup>\*</sup> Aditya Kusupati<sup>\*</sup> Jack Hessel<sup>\*</sup> Ali Farhadi<sup>\*</sup> Yejin Choi<sup>\*</sup>

<sup>\*</sup>Paul G. Allen School of Computer Science & Engineering, University of Washington  
<sup>\*</sup>Allen Institute for Artificial Intelligence <sup>\*</sup>University of Edinburgh  
[rowanzellers.com/merlotreserve](http://rowanzellers.com/merlotreserve)

论文名：MERLOT Reserve: Neural Script Knowledge through Vision and Language and Sound

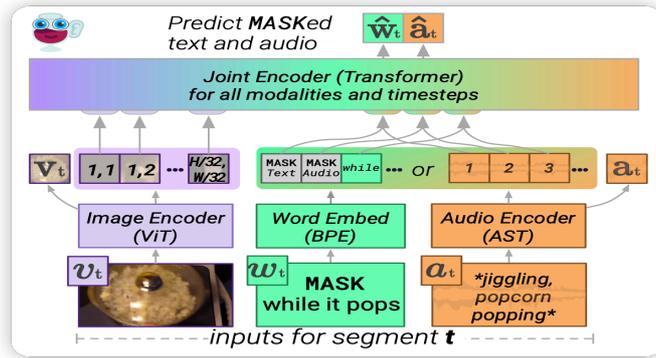
论文链接：<https://arxiv.org/pdf/2201.02639.pdf>

代码链接：<https://rowanzellers.com/merlotreserve/>

论文机构：华盛顿大学

支持模态：视频、图像(理论上支持)、文本、声音

创新类型：训练创新



作者使用了视频信息（帧）、文本信息（描述视频信息，即字幕）、语音信息（视频的音频部分），通过对模型的训练，能够实现给出视频的条件下，模型给出视频对应的文本以及语音信息的功能。将三种数据各自独立地编码后输入到联合编码器中，来将所有模态的数据融合在一起，并根据数据序列进行预测，恢复遮挡住的文本或者音频信息。

### 3.3 VATT（视频、文本、音频）



论文名：VATT: Transformers for Multimodal Self-Supervised Learning from Raw Video, Audio and Text

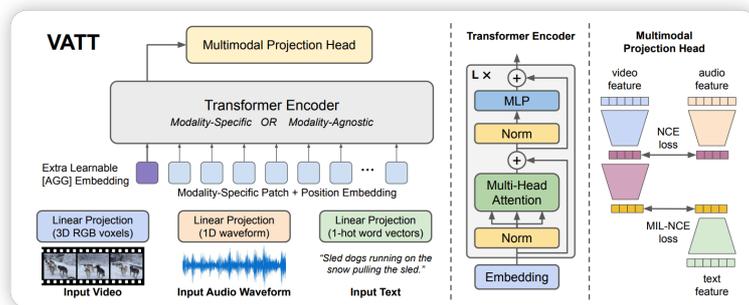
论文链接：<https://arxiv.org/abs/2104.11178>

代码链接：<https://github.com/google-research/google-research/tree/master/vatt>

论文机构：谷歌

支持模态：视频、文本、声音

创新类型：训练创新



VATT 直接对原始信号进行处理，视觉输入是 3 通道 RGB 像素视频帧，音频输入是初始波形，文本输入是单词序列。对于视频片段，方法是整个  $T \times H \times W$  的视频片段划分为  $[T/t] \times [H/h] \times [W/w]$  的小 Patch 序列，其中每个 patch 包含  $t \times h \times w \times 3$  个立体像素，然后对每个 patch 的所有像素应用一个线性投影，这个线性投影由一个可学习的权重执行。模型整体是通过 Transformer 提取不同模态的表示然后映射到公共空间，并通过对比损失来比较各个模态进行对齐。

### 3.4 M2HF (视频、文本、音频)

## M2HF: MULTI-LEVEL MULTI-MODAL HYBRID FUSION FOR TEXT-VIDEO RETRIEVAL

Shuo Liu<sup>\*1</sup>, Weize Quan<sup>1</sup>, Ming Zhou<sup>2</sup>, Sihong Chen<sup>†3</sup>, Jian Kang<sup>3</sup>, Zhe Zhao<sup>3</sup>, CHEN CHEN<sup>3</sup> and Dong-Ming Yan<sup>†1</sup>

<sup>1</sup>NLPR, Institute of Automation, Chinese Academy of Sciences, Beijing, China

<sup>2</sup>Donghua University, Shanghai, China

<sup>3</sup>Tencent TEG AI, Shenzhen, China

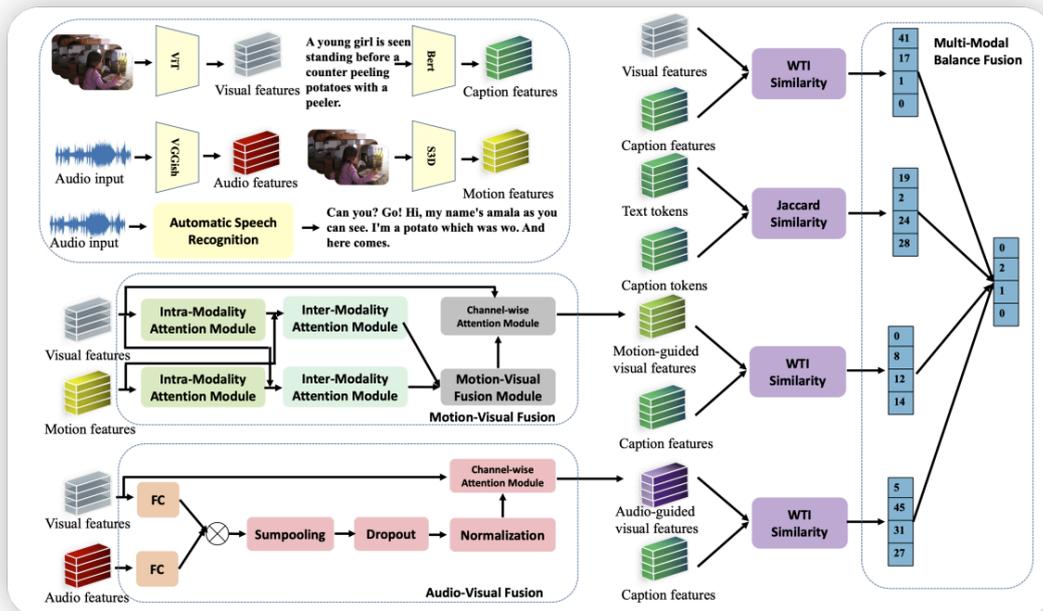
论文名：M2HF: Multi-level Multi-modal Hybrid Fusion for Text-Video Retrieval

论文链接：<https://arxiv.org/abs/2208.07664>

代码链接：暂无

论文机构：中科院

支持模态：视频、文本、声音



过建立语言对与从视频中提取的图像、音频、运动和文本之间的关系，设计了多层次的框架。除此之外，作者还设计了一种后期多模态平衡融合方法，通过在各层次中选择最优排序结果进行融合来得到最终的排序结果。

### 3.5 ImageBind (图像、文本、音频、深度、热像和 IMU 数据)

#### IMAGEBIND: One Embedding Space To Bind Them All

Rohit Girdhar\*    Alaaeldin El-Nouby\*    Zhuang Liu    Mannat Singh  
Kalyan Vasudev Alwala    Armand Joulin    Ishan Misra\*

FAIR, Meta AI

<https://facebookresearch.github.io/ImageBind>

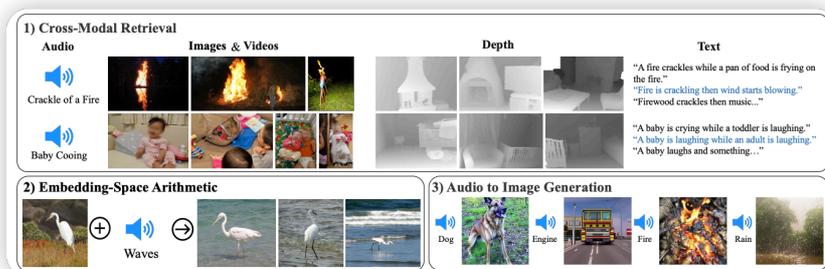
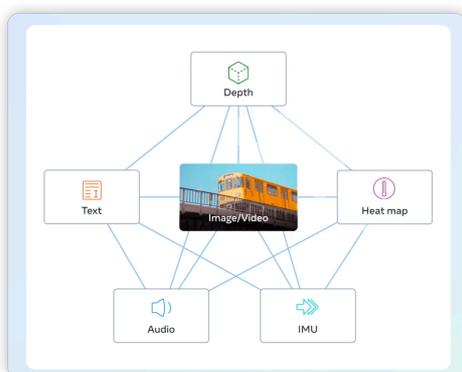
论文名：IMAGEBIND: One Embedding Space To Bind Them All

论文链接：<https://arxiv.org/pdf/2305.05665.pdf>

代码链接：<https://github.com/facebookresearch/ImageBind>

论文机构：facebook

支持模态：图像、文本、音频、深度、热像和 IMU 数据



Meta AI 提出了 ImageBind，它通过利用多种类型的图像配对数据来学习单个共享表示空间。该研究不需要所有模态相互同时出现的数据集，相反利用到了图像的绑定属性，只要将每个模态的嵌入与图像嵌入对齐，就会实现所有模态的迅速对齐。具体而言，ImageBind 利用网络规模（图像、文本）匹配数据，并将其与自然存在的配对数据（视频、音频、图像、深度）相结合，以学习单个联合嵌入空间。这样做使得 ImageBind 隐式地将文本嵌入与其他模态（如音频、深度等）对齐，从而在没有显式语义或文本配对的情况下，能在这些模态上实现零样本识别功能。通过将六种模态的嵌入对齐到一个公共空间，ImageBind 可以跨模态检索未同时观察到的不同类型的内容，添加不同模态的嵌入以自然地对其语义进行组合。将 ImageBind 与 LLM 结合就能很容易的构建一个多模态对话系统，目前已有开源的 ImageBind-LLM 系统 ([https://github.com/OpenGVLab/LLaMA-Adapter/tree/main/imagebind\\_LLM](https://github.com/OpenGVLab/LLaMA-Adapter/tree/main/imagebind_LLM))。

### 3.6 CoDi (视频、图像、文本、音频四模态到四模态生成模型)



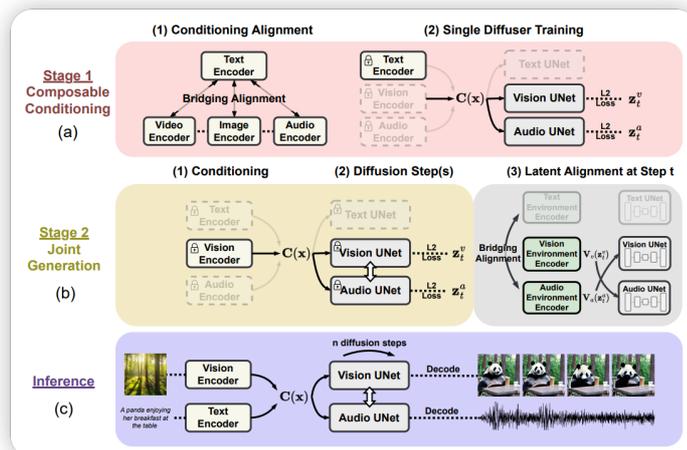
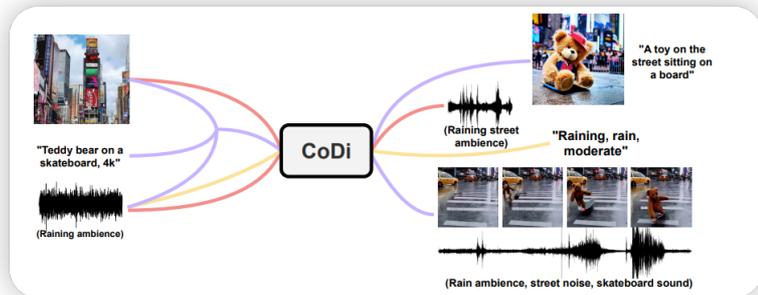
论文名：CoDi: Any-to-Any Generation via Composable Diffusion

论文链接：https://arxiv.org/abs/2305.11846

代码链接: https://github.com/microsoft/i-Code/tree/main/i-Code-V3

论文机构：微软

支持模态：图像、文本、音频到图像、文本、音频的生任务



这是一个多模态生成模型，输入视频，图片、语音、文本可以生成视频，图片、语音、文本。这个模型具有可以结合 LLM 构建一个强大的多模态对话系统的巨大潜力。