中国科学院高能物理研究所
Institute of High Energy Physics Chinese Academy of Sciences

AI platform for HEP

(Zhengde Zhang)张正德

Feb. 2023

Main goal

The main goals of Hakutaku AI (HAI) platform are:

Provide **general technical support** for particle physics, astrophysics, synchrotron radiation and neutron science to **accelerate** AI enabling scientific research, solve specific scientific problems, assist scientific exploration and new discoveries, and promote the transformation of scientific research model.

key words:
Software and hardware platform
Content and Datum
Address application requirements
Promote cross frontier

HAI architecture

Common technologies:

Full stack tool chain:

- data annotation,
- data processing,
- algorithm research,
- model training,
- model evaluation and
- cloud edge deployment

Functions:

- AI software framework,
- algorithm library interface
- dataset interface,
- cutting-edge neural network construction scheme,
- heterogeneous resource scheduling
- intelligent and efficient development environment,
- code hosting

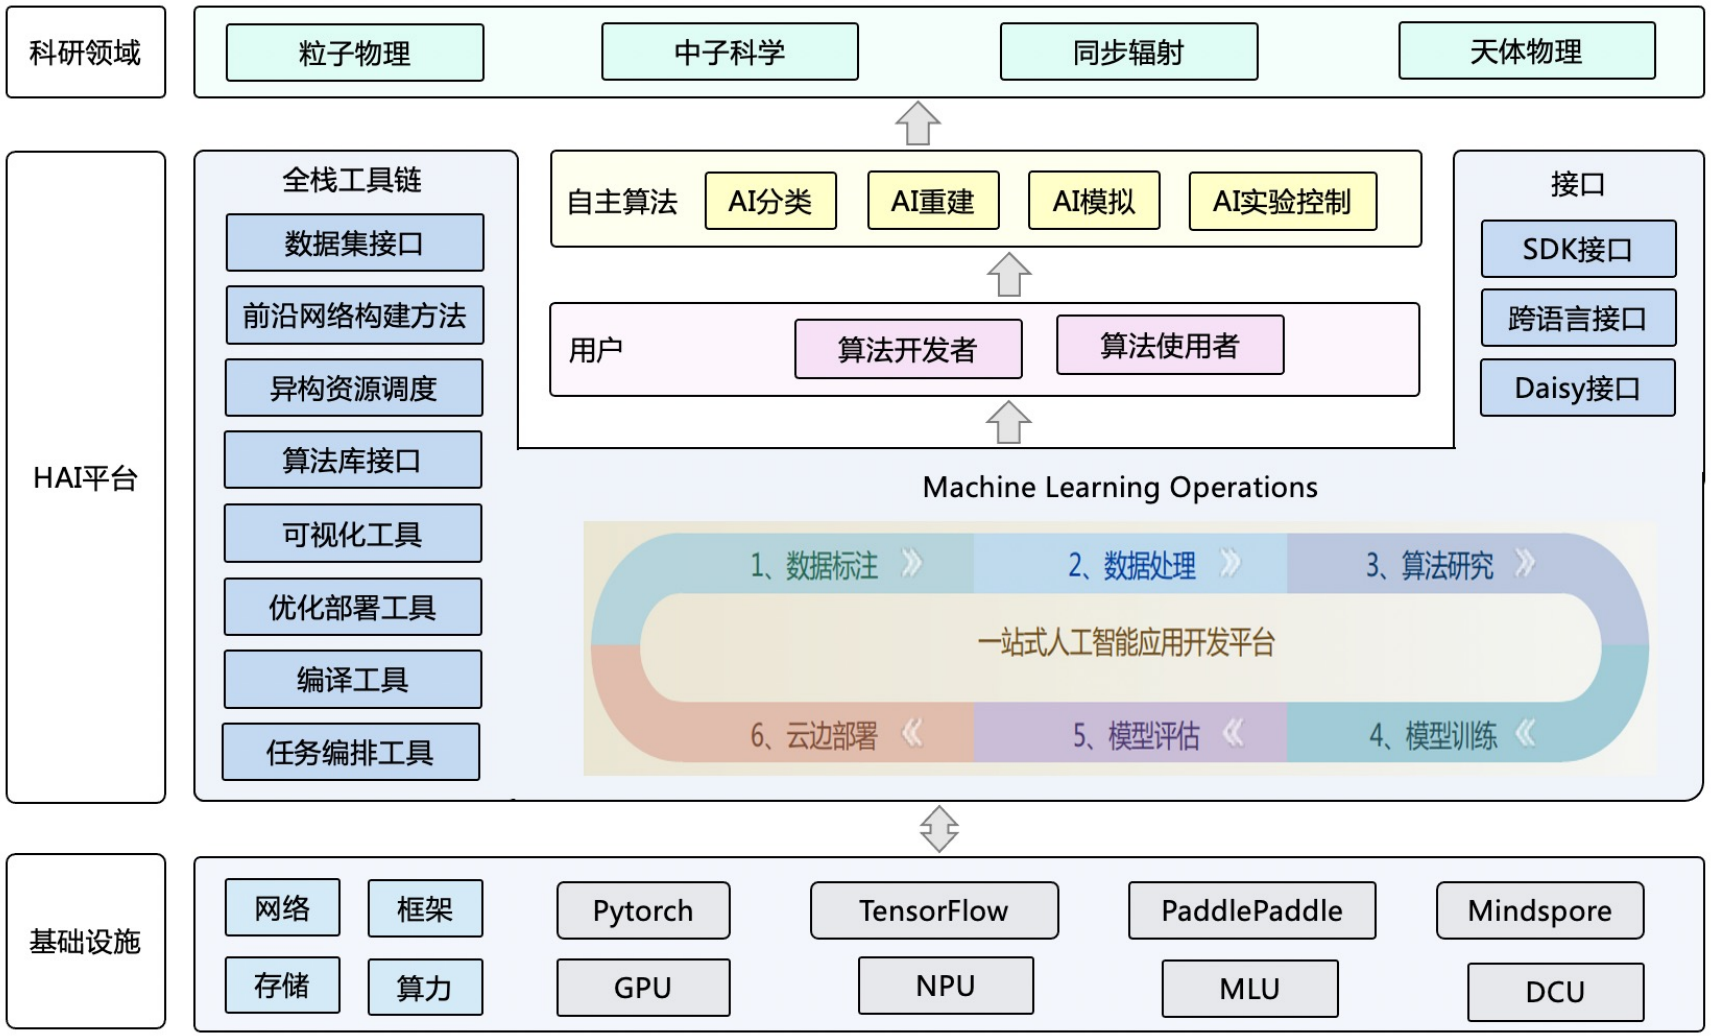

Features

Scientific datasets

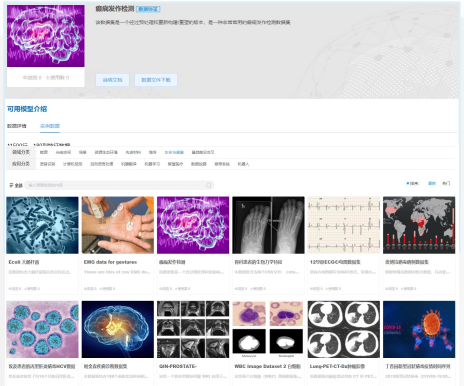

Efficient development environment

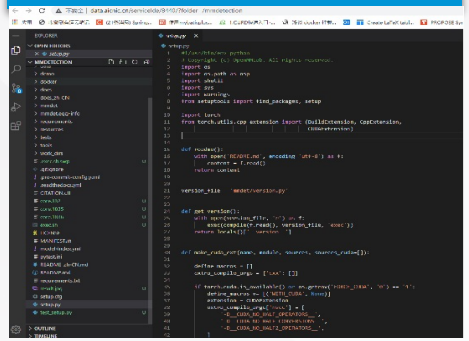

Automatic completion of code AI

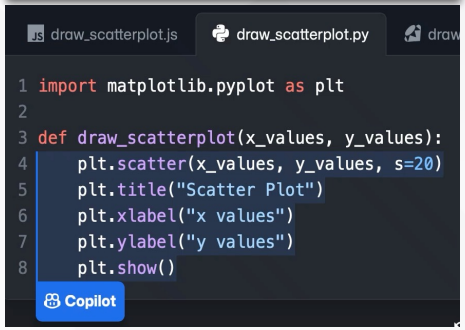

Code hosting platform

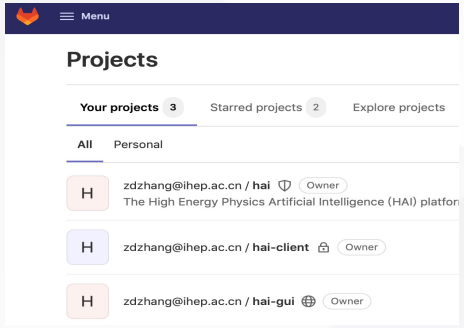

Elastic computing resources

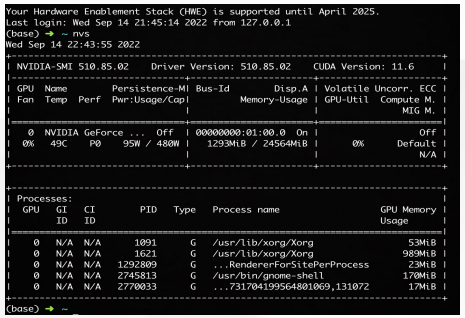

AI annotation tool

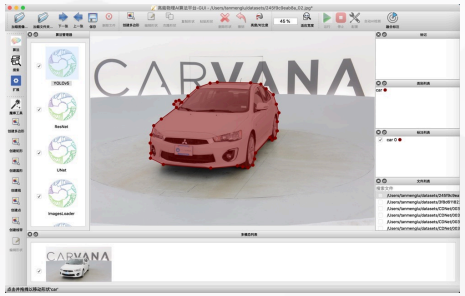

Data simulation software

Tomopy	XDS
UFO*	cpp4
HEPSCT*	autoProc
PyFai	dials
PDFgetX3	Phenix
	CONUSS
	PHOENIX

Tutorail website

Platform application scenario

快速复现论文

```python
import hai_client
import cv2
import numpy as np

ip = '127.0.0.1'
port = 9999
hai = hai_client.HAIClient(ip=ip, port=port)
modules = hai.hub.list(ret_fmt='json')  # 列出所有模型
print(f'Modules: \n{modules} {type(modules)}')

model_name = 'UNet'
weights = hai.hub.list_weights(name=model_name)  # 列出所有模型权重
model = hai.hub.load(model_name,   # 根据模型名称加载云模型
    weights=f'hai/unet/unet_v1.1.pth',  # 指定模型权重文件，可选
    )
docs = hai.hub.docs(model_name)  # 查看模型文档连接
config = model.config  # 获取模型配置
# config.weights = "hai/unet/unet_v1.1.pth"  # 方法2：指定模型权重文件，相同的方法可修改其他配置
config.source = '/Path/to/your/datasets' # 指定数据集路径
ret_url = model.train()  # 云端训练模型
print(f'ret_url: {ret_url}')  # 通过url查看训练过程和训练结果
```

获取源码、数据集

学习算法、编程、软件

学习前沿网络构建方法

- 空间注意力机制
- 通道注意力机制
- 跨阶段局部网络
- 空间金字塔
- 路径聚合网络
- 自注意力机制

AI辅助数据标注

使用开源算法训练自定义数据集

异构GPU资源调度训练

开源自研算法提升影响力

便捷地进行模型性能对比

神经网络剪枝优化压缩

模型硬件优化部署

算法国产化

Progress (2023.02)

- Overall progress 20%
  https://code.ihep.ac.cn/zdzhang/hai
- AI algorithm framework **HaiCore**, 70%
  - Integrated algorithm: 2 universal (YOLOv5 and ResNet) and 4 particle physics (ParNet, ParT, PCNN, PFN)
  - Integrated open source datasets: 3 (JetClass, TopLandscape, QuarkGluon)
- AI software interface framework **HaiGF**, core function 60%
- Infrastructure
  - 70k CPUs, 400 GPUs, high-performance network, National High Energy Physics Science Data Center ✅
  - Code hosting platform ✅
- Own computing power
  - Huawei Shengteng 910 * 8 card NPU server ✅

Construction progress

Develop AI algorithm framework HaiCore

- HaiCore provides the platform with core capabilities, including model training, evaluation, reasoning, deployment unified architecture, algorithm library unified interface, cross-language, cross-system scheduling scheme, etc. The core functions are completed by 70%+.

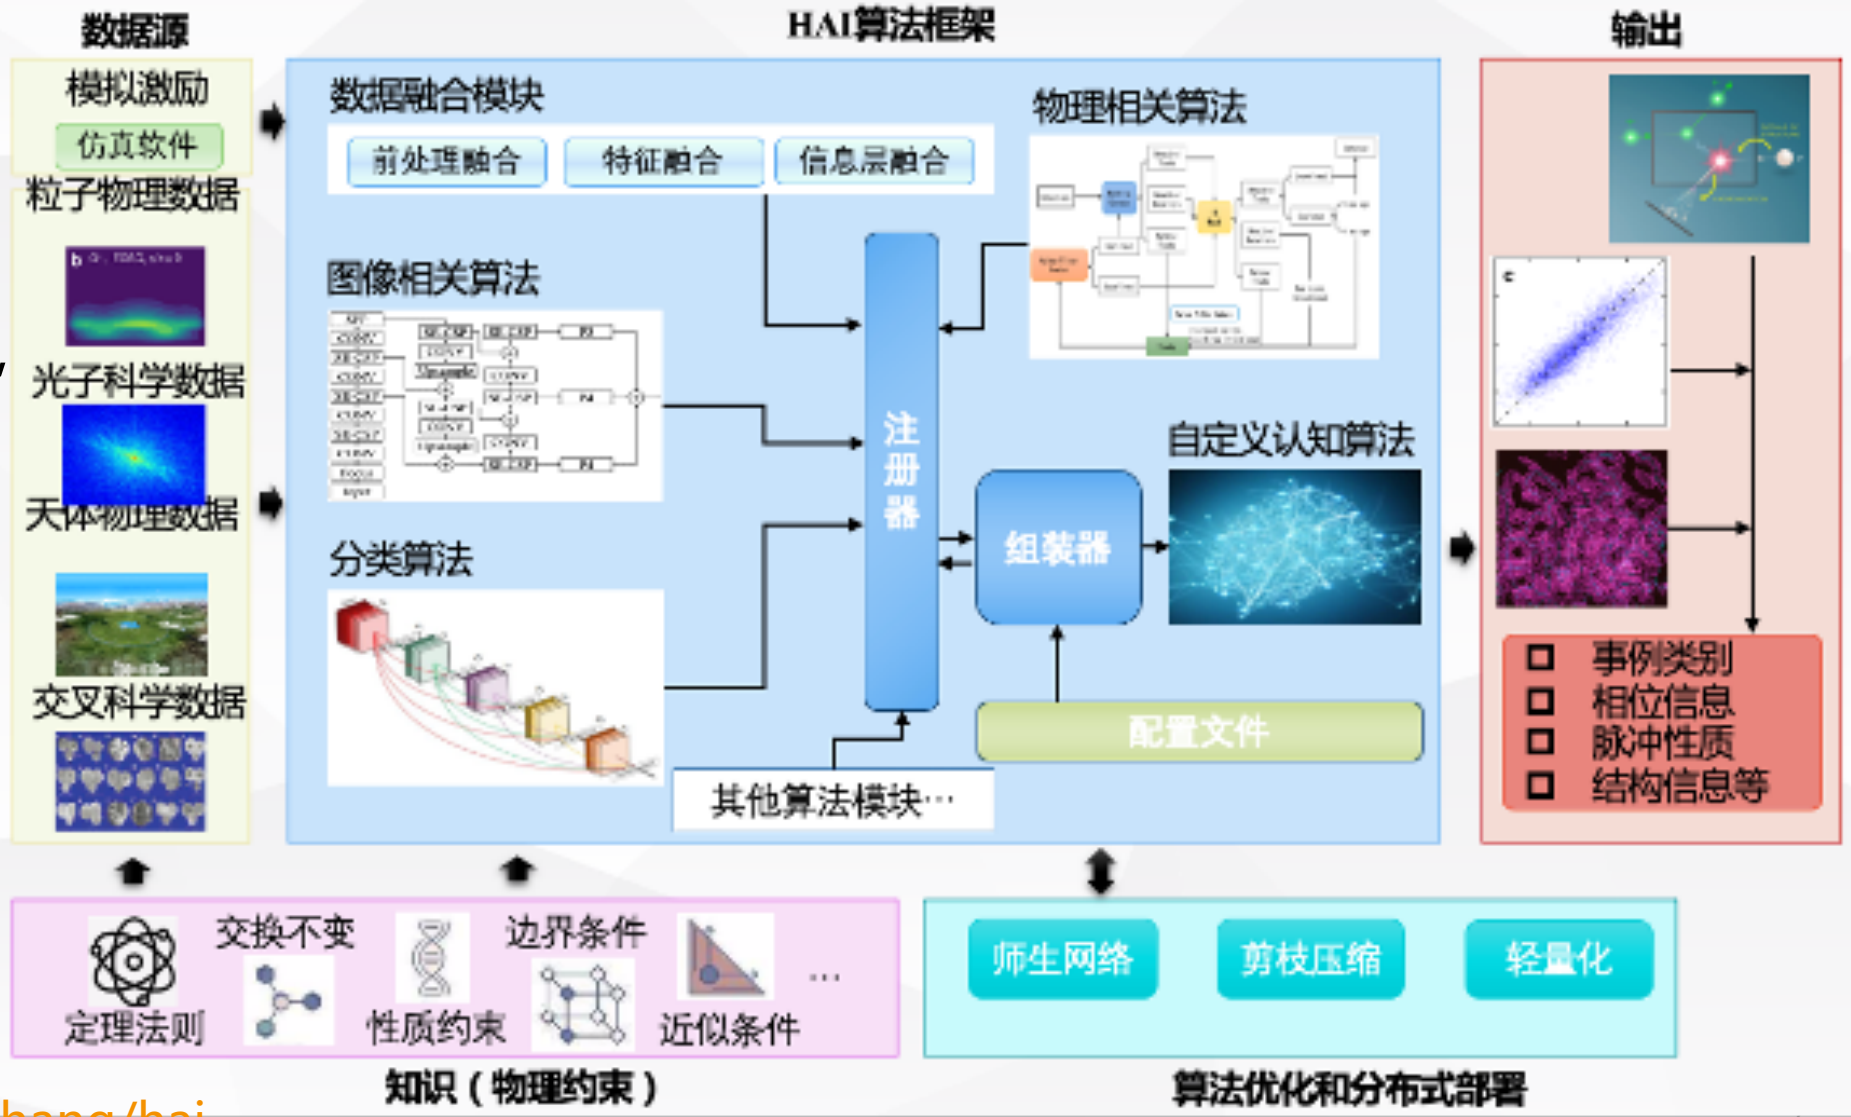

https://code.ihep.ac.cn/zdzhang/hai

HaiCore integrates open source algorithms and datasets

- ✓ Four deep learning algorithms (ParNet, ParT, PCNN, PFN) for Jet tagging are integrated,
- ✓ Integration of three open source data sets (JetClass, TopLandscape, QuarkGluon)
- ✓ Use PointNet to reconstruct and identify atmospheric neutrinos in JUNO experiment
- ■ TODO:
  - ■ Reconstruct the algorithm to separate the data loader, network architecture, parameter settings, etc.
  - ■ Compile documents for training customized data sets based on integrated algorithms

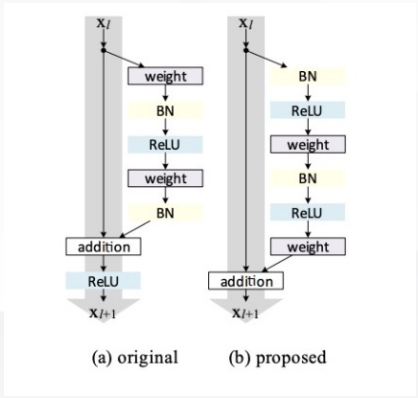

PCNN

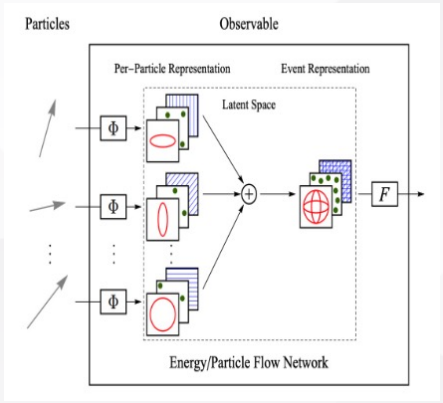

PFN

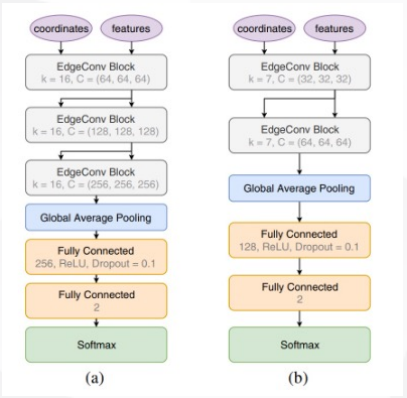

ParticleNet

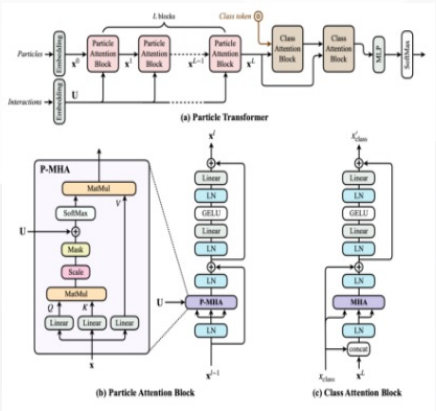

ParticleTransformer

HAI GUI Framework

New **extensible** and **lightweight** AI software interface framework **HaiGF**

① Core function bar
- Asset Browser
- Dimension tools
- AI tool (remote)
- More features

② Main sidebar
- Specific deployment of core functions

③ Central control
- Visualize data and interaction
- Scalable design based on tab+page
- Automatic screen splitting based on screen splitter

④ Auxiliary sidebar
- Detailed attributes, information, etc

⑤ Panel bar
- Multi-tab output panel

HAI GUI Framework

Develop AI software interface framework HaiGF

An extensible and lightweight framework for developing interface programs based on machine learning algorithms.
repo.: https://code.ihep.ac.cn/zdzhang/hai-gui-framework

- Split screen ✅, Multilingual translation ✅。
- Integrate the HAI algorithm library and the communication between client and server is completed.
- Develop algorithm workflow based on pyflow, complete the background interface of central control, algorithm node and pin display, node dragging, pin connection. Design py script node ✅ .
- Embed annotation tools. TODO: image display, algorithm and image linkage.
- Write documents: how to develop plug-ins, APIs of components, and how to generate APIs_ Doc, how to translate GUI interface
- Develop hai_ Tools plug-in to realize remote call of algorithms in the hai algorithm library
- Develop a workflow based on pyflow to realize drag and link of algorithm modules
- Integration of scientific research drawing case based on pyqtgraph

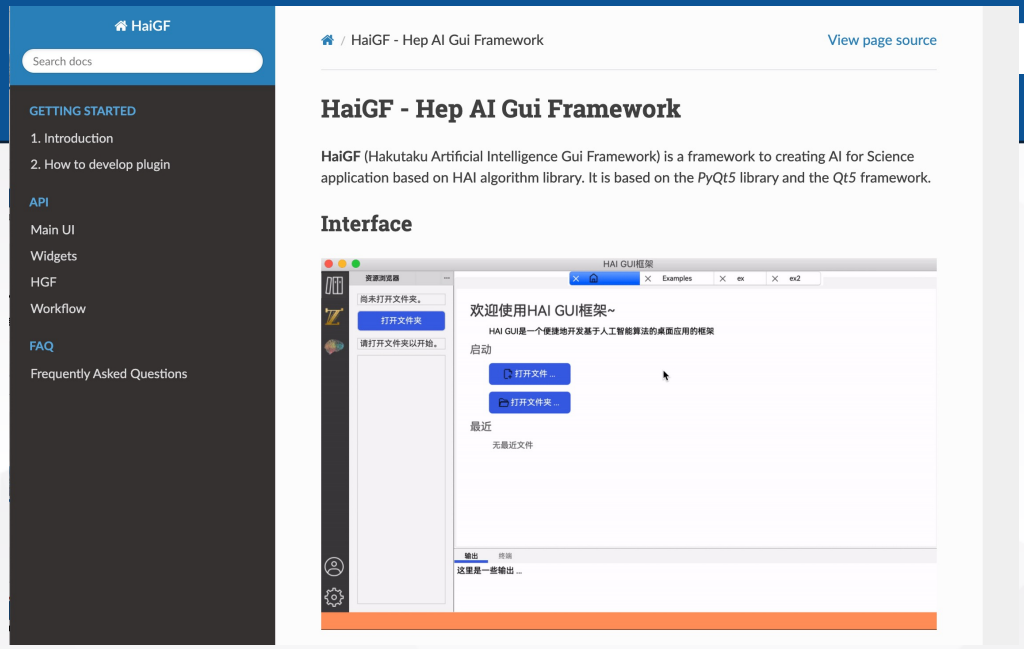

API doc：http://192.168.32.148:8000/

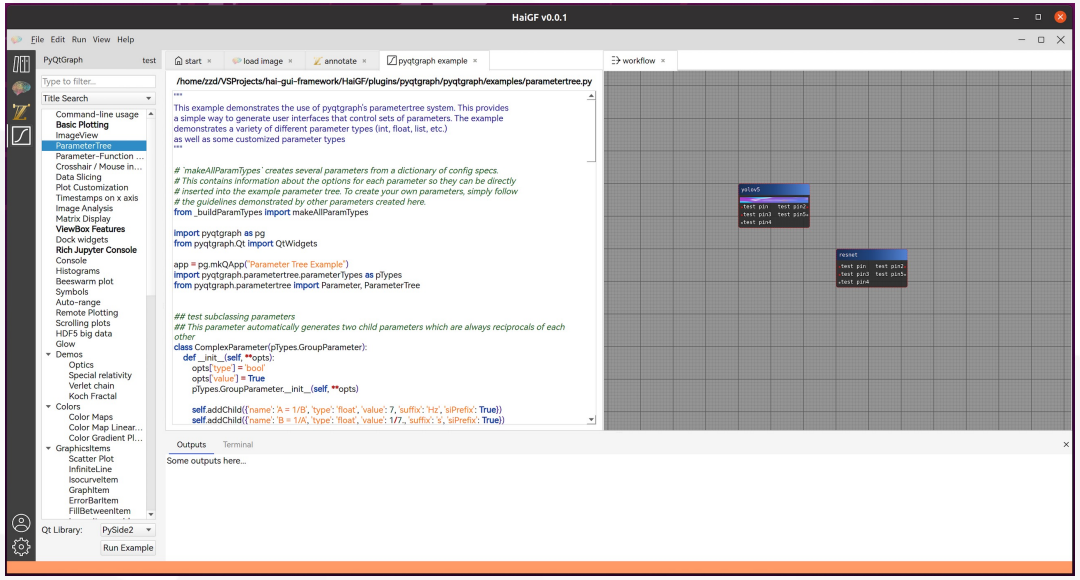

HaiGF

基础设施

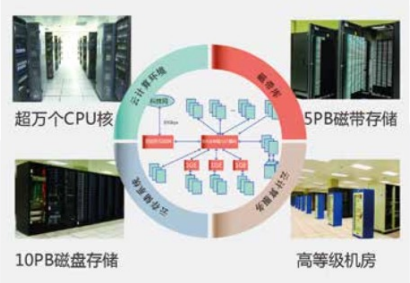

>大规模高性能计算集群

万核级别高吞吐量计算集群和混合异构高性能计算集群

>海量存储

建设了高等级的海量数据存储，磁盘70PB，聚合带宽40GB/s，磁带存储40PB

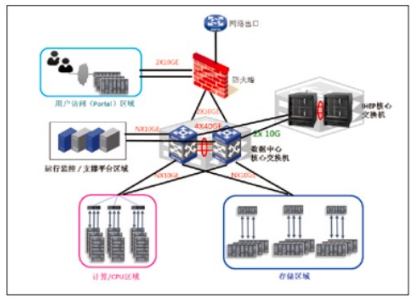

>高性能网络

提供高带宽、低延迟、稳定、安全的网络环境，骨干带宽160Gbps，4*10Gbps双栈互联网出口，到欧洲及北美的10Gbps级专用网络带宽

>分布式计算

为全球高能物理提供超过800万CPU小时的计算服务

为BESIII、JUNO、CEPC等实验提供全球分布式、异构计算的数据处理和分析统一平台

算力：北京 1821节点，7W核，GPU (V100+A100) 400块+

大数据基础设施

国家高能物理科学数据中心

国家高能物理科学数据中心
National HEP Data Center

分为北京数据中心和大湾区中心，实现数据资源、软件工具、数据分析等资源能力的汇交和共享。
目前40PB，数万CPU核计算能力，万兆国际网络链路，信息支撑系统。
5个领域的数据：

高能物理数据

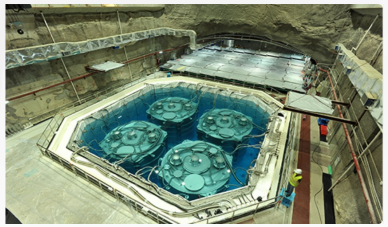

DYB 大亚湾
BESIII 北京谱仪
JUNO 江门
CMS ATLAS LHCb
强子对撞
L3c L3宇宙线

中子科学数据

CSNS
散裂中子源

天体物理数据

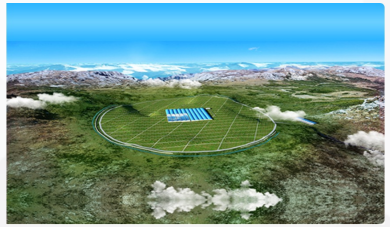

LHAASO 高海拔宇宙线
YBJ-Asγ 羊八井
ARGO-YBJ 羊八井
HXMT 硬X射线调制望远镜

光子科学数据

BSRF 北京同步辐射
HEPS 高能同步辐射

交叉学科数据

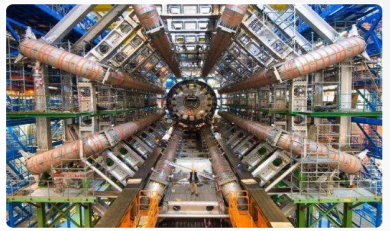

钢轨在线激光选区
硅雪崩光电探测
碳碳熔合截面测量
试能谱数据
原子核质量数据
双TOF测试数据等

代码托管平台

代码托管平台 https://code.ihep.ac.cn

NPU服务器

华为Atlas800-9000 NPU训练服务器上架

配置表：

类型	描述
机框基础配置	Atlas 800 (Model 9000)(3*2.5"NVME SSD 风冷机箱,4*Kunpeng 920,8*Ascend 910 B)
CPU	192核（Kunpeng 920 2.6GHz * 4）
内存	768G（32G 2933MHz * 24）
NPU卡	128G显存（Ascend 910 B * 8）
硬盘2	NVME 1.92TB SSD
网卡1	板载GE电口
网卡2	TM272板载灵活网卡-100GE-2端口-QSFP28
电源	8000W（服务器白金2000W * 4）

安装位置：多学科机房
IP：192.168.68.22
系统：Centos 8.2
软件：Pytorch 1.8.1+ascend

ChatGPT使用

方式一：

HaiChatGPT，基于OpenAI API的免费体验版（无需梯子）

Web界面

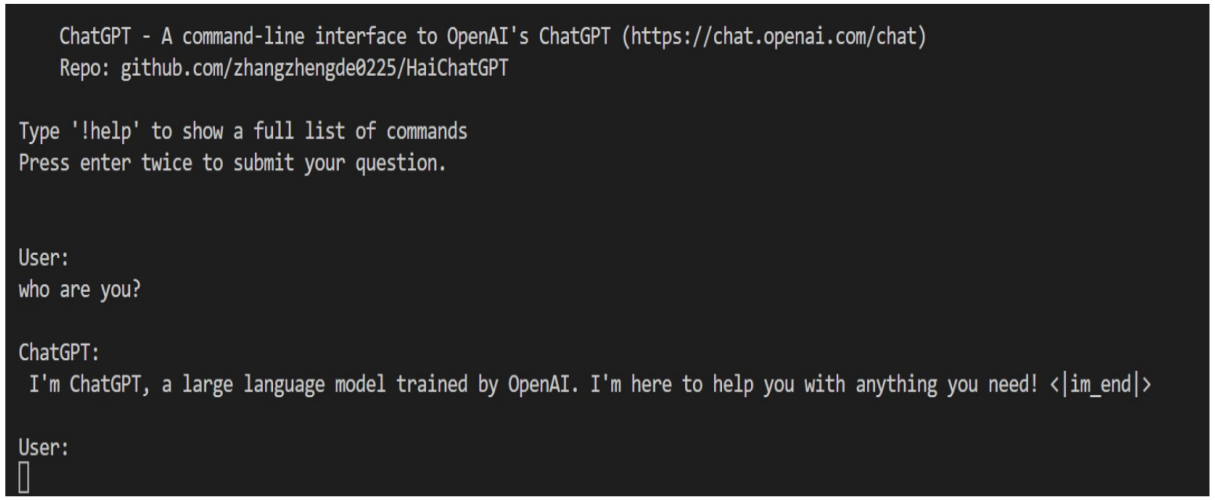

命令行界面

- 开源地址：https://github.com/zhangzhengde0225/HaiChatGPT
- 网页：ai.ihep.ac.cn(内网)，47.114.37.111(公网)

限制：

- 使用个人API_KEY，$18耗尽后无法调用
- 使用基于GPT3的text-davinci-003模型，性能上不如官网基于GPT3.5的版本

ChatGPT使用

方式二（推荐）：

ChatGPT官网：http://ai.com/

- 提供免费web访问，目前最强大的聊天机器人；
- 提供API调用接口，API每月$18免费额度，按TOKEN计费，约1000次调用
- 不提供模型、预训练权重。
- 限制：
  - 注册需要科学上网，同时，OpenAI对出口限制、高度出口限制国家（中国、俄罗斯等）、受美国制裁国家不提供服务。
  - 免费版服务器爆满
  - Plus会员每月$20，需国外信用卡和地址支付，Plus版与免费版性能一致，速度略有差别，Plus不排队

附：注册保姆级教程和临时科学上网梯子：
https://code.ihep.ac.cn/zdzhang/haichatgpt/-/blob/main/docs/reg_tutorial.md

- 科学上网卡密：
  - 服务器ip: 8.130.55.206
  - 端口号port: 429
  - 密码: bxx_ss_temp
  - 加密方式: aes-256-cfb
  - 服务器类型: ss
  - 名称: bxx_ss (自定义)
  - 带宽：1MBps
  - 到期时间：2023.03.16
  - 客户端：shadowsocks

注意事项：提供公共服务梯子不是政策支持的，请低调使用；梯子为临时的、免费的，带宽很小，大家共用，仅用于注册，请勿用于其他用途。

ChatGPT应用于科学研究的思考

直接应用

1. 写代码，代码纠错，通用知识问答。
2. 写综述、写摘要、翻译、词句润色、语法纠正…（注：已引起争议讨论）

潜在应用

1. 应用于大科学装置， 辅助装置操作，提升智能化水平。难点：需要复现大模型
2. 应用于探测科学的领域数据校验，采集到的无标注的数据，用预训练大模型的方式进行自监督学习，使模型逐步把握所有数据中的全局规律，以少量的异常样本为Prompt对模型进行提示，使模型能对原始数据进行质量判别，输出数据一致程度，发现异常数据(感兴趣数据)。
3. 引导ChatGPT使用科学工具：计算器、积分工具、科学领域分析工具等，使用工具的结果中用于自监督学习（有点不断自演进的感觉了）。
4. 检索知识密集型任务，存储在LLM中的知识可以显著提高知识密集型任务的性能，参考MMLU基准数据集，包括来自STEM、人文、社科等57个学科的选择题，用于测试 LLM 的世界知识和问题解答的能力。
5. 分布外(Out-of-Distribution, OOD)泛化，传统的微调可能会过拟合训练集并且有较差的分布外泛化能力；而少样本的上下文学习（in-context learning）能够有更好的分布外泛化性。

ChatGPT复现的难点

目前所有公开的对 GPT-3 的复现都失败了，包括且不限于：GPT-3, PaLM, BLOOM, OPT, FLAN-T5/PaLM, HELM 等。“失败”是指训练得出模型有接近 GPT-3 或者更大的参数量，但仍无法与 GPT-3 原始文献中报告的性能所匹配。

主要原因是**训练昂贵、预训练数据**和**训练策略**等问题。
训练昂贵：一次训练就将需要在约 1000 个 80G A100 GPU 上花费至少 2 个月的时间（数据来自于 OPT 的原始文献）。

预训练数据问题

GPT-3 在共计 300B 的 token 上进行训练，其中 60% 来自经过筛选的 Common Crawl，其它则来自：webtext2（用于训练 GPT-2 的语料库），Books1，Books2 、维基百科、Github Code。
每个部分的占比并不与与原始数据集的大小成比例，相反的，具有更高质量的数据集被更加频繁地采样。

- 第一点是一个具有良好性能的用于**筛选低质量数据**的分类器。
  - 一些文章表示一个用更少但质量更高的数据集训练的预训练模型，可以在性能上超过另一个用更多的混合质量数据集训练的模型。当然，数据的多样性仍然是十分重要的，应当非常小心地处理在数据多样性和质量之间的权衡。
- 第二点是**预训练数据集的去重。**
  - 去重有助于避免预训练模型多次面对相同的数据后记住它们或者在其上过拟合，因此有助于提高模型的泛化能力
- 第三点是**预训练数据集的多样性。**
  - 包括领域多样性、格式多样性（例如：文本、代码和表格）和语言多样性。

ChatGPT复现的难点

训练策略问题

包括训练框架、训练持续时间、模型架构 / 训练设置、训练过程中的修改。在训练非常大的模型时，它们被用于获得更好的稳定性和收敛性。一般来说，由于未知的原因，预训练过程中广泛观察到损失尖峰（loss spike）和无法收敛的情况。

- 训练框架
  - 数据并行(分布式优化器)和模型并行(包括张量并行（tensor parallel）、流水线并行（pipeline parallel），有时还包括序列并行（sequence parallel））
  - bfloat16和float16问题，bfloat16 可以表示更大范围的浮点数，能够处理在损失尖峰时出现的大数值。
- 训练过程中的修改
  - 训练中途调整，例如：中途调整并从最近的 checkpoint 重启训练，包括改变截断梯度范数 (clip gradient norm) 和学习率，切换到简单的 SGD 优化器然后回到 Adam，重置动态损失标量 (dynamic loss scalar)，切换到更新版本的 Megatron 等等。
- 训练架构/训练设置
  - 使用 Adafactor 的修改版本作为优化器，缩放在 softmax 之前的输出 logit，使用辅助损失来鼓励 softmax 归一化器接近 0，对词向量和其他层权重使用不同的初始化，在前馈层和层归一化中不使用偏差项，并且在预训练期间不使用 dropout。
- 训练过程：
  - 逐步增大的Batch Size
  - 激活函数的选择，ReLU、SwiGLU、GeLU等
  - 词向量建模方式，RoPR词向量、ALiBi词向量等

ChatGPT复现方案

低成本复现方案 Colossal-AI

Colossal-AI快速跟进，**首个开源低成本复现ChatGPT完整流程。**作为当下最火热的开源AI大模型解决方案，Colossal-AI已收获开源社区**GitHub Star近万颗**，此次开源亮点包括：

- **开源完整基于PyTorch的ChatGPT复现流程**，涵盖全部3个阶段，可实现从预训练模型到ChatGPT的蜕变；
- 体验最小demo训练流程最低**仅需1.62GB显存**，任意单张消费级GPU即可满足，单卡模型容量最多**提升10.3倍**；
- 相比原生PyTorch，最高可**提升单机训练速度7.73倍**，单卡推理速度1.42倍，**一行代码即可使用；**
- 对于微调任务，可最多**提升单卡的微调模型容量3.7倍，同时保持高速运行**，仅需一行代码；
- 提**供单卡、单机多卡、1750亿参数等多个版本**，支持从Hugging Face导入OPT，GPT-3，BLOOM等多种预训练大模型；
- 收敛验证正在进行中，该项目也在吸引合作者**共建生态。**

开源地址：
https://github.com/hpcaitech/ColossalAI

2月20日讲座中，作者表示LLM大语言模型175B没有完全跑通，后面的两个6B模型能跑通。

ChatGPT复现方案

特斯拉前AI总监发布NanoGPT，已基于OpenWebText重现 GPT-2 (124M)，在单个8XA100 40GB节点上，训练时间为38小时。
开源地址：https://github.com/karpathy/nanogpt

Jaymody发布picoGPT，60行numpy代码实现复现GPT2✅
开源地址：https://github.com/jaymody/picoGPT

OpenAI的GPT-2: https://github.com/openai/gpt-2

复旦版ChatGPT: https://txsun1997.github.io/blogs/moss.html

2023年2月21日发布，冲上热搜，服务器挤爆，引起了很多争议。
Q: 模型是什么？怎么训练的？数据怎么获取的？
A: 暂时不方便透露，我们尽快开源，尽量三月份开源。

资源包

OpenAI官网：https://openai.com/
ChatGPT官网：http://ai.com/

HaiChatGPT: https://github.com/zhangzhengde0225/HaiChatGPT
HaiChatGPT网页：ai.ihep.ac.cn(内网)，47.114.37.111(公网)
官网账号注册教程：https://code.ihep.ac.cn/zdzhang/haichatgpt/-/blob/main/docs/reg_tutorial.md

扩展资源：
1. 解读 ChatGPT 背后的技术重点：RLHF、IFT、CoT、红蓝对抗
2. ChatGPT发展历程、原理、技术架构详解和产业未来（收录于先进AI技术深度解读）
3. ChatGPT API（非官方）：https://github.com/acheong08/ChatGPT
4. HaiChatGPT： https://github.com/zhangzhengde0225/HaiChatGPT
5. ChatGPT中文调教指南： https://github.com/PlexPt/awesome-chatgpt-prompts-zh
6. 复旦版ChatGPT-MOSS: 体验链接： https://moss.fastnlp.top/
项目主页： https://txsun1997.github.io/blogs/moss.html
7.首个开源低成本复现方案： https://github.com/hpcaitech/ColossalAI
8.NanoGPT: https://github.com/karpathy/nanogpt
9.PicoGPT: https://github.com/jaymody/picoGPT
10.GPT-2: https://github.com/openai/gpt-2
11. MOSS: https://txsun1997.github.io/blogs/moss.html

总结

AI won't replace the scientist, but scientists who use AI will replace those who don't.

——Microsoft report "The Future Computed"

院里：发挥高能物理学科基础和优势，打造高水平的数据和AI驱动平台。

发展高能物理AI的优势：有海量数据、有高性能算力
劣势：刚刚起步，目前AI研究以课题组的形式进行，没有形成交叉合作模式

方案：多领域人才进行合作，实现AI4HEP的应用；探索共性技术，推动高能物理与人工智能交叉前沿，在知识-数据协同驱动的第三代人工智能弯道超车。

目标：实现高能物理领域研究和人工智能算法研究相互促进，进而推动社会、经济的发展。

目前任务：搭建高能物理AI平台，形成长效合作机制。

请批评指正！

Backup