



山东大学
SHANDONG UNIVERSITY



STCF基于RDataFrame并行 物理分析框架

杨莹 李腾 黄性涛

山东大学

STCF 2026

2026.7.2



目录

- 01 研究背景
- 02 物理需求和框架设计
- 03 应用与验证
- 04 性能检测





山东大学
SHANDONG UNIVERSITY

1


研究背景

STCF(Super Tau Charm Facility)

- **物理目标：**精确测量 τ 轻子、粲夸克相关物理过程。
- **核心参数：**能量范围覆盖 2 - 7 GeV，峰值亮度高达 $0.5 \times 10^{35} \text{ cm}^{-2} \text{ s}^{-1}$ 。
- **数据挑战：**海量数据实时产生，每年原始数据量达**数百PB级**。



OSCAR(Offline Software for Super Tau-Charm Facility)



OSCAR :

➢ 覆盖从探测器模拟、本底混合数字化到数据重建的完整离线处理链路。


核心挑战一：物理分析中海量数据的高效处理

➢ 传统串行模式失效，需构建高并发并行分析框架，突破I/O瓶颈与算力调度限制，保障物理分析数据处理时效性。

核心挑战二：高精度物理结果

➢ 顶点拟合等算法计算密集，需优化底层实现与资源分配，在有限算力下确保结果的精度与可靠性。

CME (GeV)	Lumi (ab ⁻¹)	Samples	σ (nb)	No. of Events	Remarks
3.097	1	J/ψ	3400	3.4×10^{12}	
3.670	1	$\tau^+ \tau^-$	2.4	2.4×10^9	
3.686	1	$\psi(3686)$	640	6.4×10^{11}	
		$\tau^+ \tau^-$	2.5	2.5×10^9	
		$\psi(3686) \rightarrow \tau^+ \tau^-$		2.0×10^9	
		$D^0 \bar{D}^0$	3.6	3.6×10^9	
3.770	1	$D^+ \bar{D}^-$	2.8	2.8×10^9	
		$D^0 \bar{D}^0$		7.9×10^8	
		$D^+ \bar{D}^-$		5.5×10^8	Single tag
		$\tau^+ \tau^-$	2.9	2.9×10^9	Single tag





山东大学
SHANDONG UNIVERSITY

2

物理需求和框架设计

需求分析

挑战与目标

挑战：海量数据

面对PB级实验数据，处理效率亟待提升

目标：高精度结果

确保物理分析的准确性与可重复性



存储兼容

无缝处理ROOT数据文件



硬件适配

多核CPU与GPU：充分利用并行算力



软件集成

分析工具复用：灵活接口



用户易用


极简交互：透明化处理

技术选型

ROOT::RDataFrame

CERN ROOT库中的模块

ROOT::RDataFrame:声明式编程




- **声明式编程模型**: 用户只需描述数据分析的目标（“做什么”），无需关心底层数据遍历、循环控制等具体实现（“怎么做”）。
- 传统函数编程

```
import ROOT
ROOT.gSystem.Load(path/to/myLibrary.so)
ROOT.gInterpreter.Declare('#include "myLibrary.h"')
df=ROOT.RDataFrame("myTree","myroot.root")
newdf=df.Define("p", "Complexcalculation(p_x,p_y,p_z)").Filter("p>10").Histo1D("p")
newdf.Draw()
```

```
import ROOT
df=ROOT.RDataFrame("myTree","myroot.root")
newdf=df.Define("p", "p_x*p_x+p_y*p_y+p_z*p_z").Filter("p>10").Histo1D("p")
newdf.Draw()
```

- ✓ 便捷访问 ROOT 数据
- ✓ 用户透明
- ✓ 便于集成





- **Intel TBB 内核调度：** 内部集成Intel TBB并行库，实现任务的动态拆分与智能调度。
- **多核自动并行化：** 任务自动分发至CPU多核心执行，充分利用硬件资源提升计算效率。 ✓多线程并行
- **零并行代码成本：** 用户无需掌握并行编程，现有代码自动获得并行加速能力。


```
ROOT::EnableImplicitMT(); // Enable ROOT's implicit multi-threading
```

RDFAnalysis (RDataFrame analysis framework)

- **双语言支持**: 同时提供高性能 C++ 底层接口与简洁易用的 Python 上层接口, 兼顾计算效率与开发灵活性。
- **核心物理工具集成**: 封装 Vertex Fit、Kinematic Fit、GlobalPID 核心高能物理分析工具。
- **混合编程范式兼容**: 完美融合传统函数式编程与现代声明式编程风格, 适配不同开发者场景需求。




RDFAnalysis 接口设计




- **TrackParamHelper**: 封装径迹数据结构，提供便捷的径迹参数访问，简化物理量调用流程。
- **VertexFitUtil**: 集成顶点拟合核心算法，提供用户接口。
- **KinematicFit**: 实现运动学约束拟合功能，提供用户接口。
- **GlobalPID**: 特征值提取，融合多种探测器信息，获得五粒子鉴别概率。

RDFAnalysis 接口设计: KinematicFit VertexFit

➤ OSCAR



➤ RDFAnalysis



RDFAnalysis 接口设计: GlobalPID


- 在探测器数据中，每条径迹都有一个唯一的 `TrackID`
- GlobalPID 通过 `TrackID` 将不同探测器的数据关联起来
- 获取每条Track对应的dEdX, BTOF, DTOF, MUD, ECAL, Track信息
- 提取特征值传入模型
- 得到PID鉴别结果：5粒子概率

用户使用示例

- 传入需要做PID鉴别的径迹
- 定义好径迹条件
- 应用条件到径迹中

```
df2= build_pid_chain("Tracks",df1)
```

```
GooTrk=df2.Define("GoodTrackCondition","pi_prob > k_prob && pi_prob > mu_prob")\
            .Define("GoodTrack","Tracks[GoodTrackCondition]")
```





山东大学
SHANDONG UNIVERSITY

3

应用举例与验证

分析算法示例: $J/\psi \rightarrow \rho\pi^0 \rightarrow \pi^-\pi^+\gamma\gamma$

核心代码片段

```
# 1. 环境配置与初始化
config = {"input_file": "...", "model_path": "...", "thread":4}
set_model_path(config["model_path"])
ROOT.EnableImplicitMT(config["thread"])
# 2. 数据读取 (RDataFrame)
df = ROOT.RDataFrame("events", config["input_file"])
# 3. 径迹选择 & PID分析
df1 = build_track_chain(df, 2)
df2 = build_pid_chain("TrackerRecTrackCol", df1)
# 4. 好径迹筛选 ( $\pi^+\pi^-$ )
df3 = df2.Define("GoodPimtrk", "...pi_prob > k_prob...")\
.Define("GoodPiptrk", "...pi_prob > k_prob...")\
.Define("Pip", "TrackerRecTrackCol[GoodPiptrk]")\
.Define("Pim", "TrackerRecTrackCol[GoodPimtrk]")\
.Filter("Pim.size() == 1 && Pip.size() == 1")
# 5. 顶点与运动学拟合
df4 = df3.Define("pimwtrk", get_wtrack("Pim[0]", 2))\
.Define("pipwtrk", get_wtrack("Pip[0]", 2))

df6 = df4.Define("vertexfit", get_vfit("pipwtrk", "pimwtrk"))\
.Filter("vertexfit.Fit(0)")
df7 = df6.Define("kfit", "KinematicFitObject(3.097, ...)")\
.Filter("kfit->Fit()")
# 6. 结果输出
df7.Snapshot("events", "output.root", ["m_mrho_afterfit", ...])
```


➤ Global PID

➤ 设置筛选径迹条件

➤ 应用筛选径迹条件


➤ 数据类型转换
WTrackParamter

物理分析流程图




$$J/\psi \rightarrow \rho\pi^0 \rightarrow \pi^-\pi^+\gamma\gamma$$

- 挑选的 π^- 粒子为 π 的概率值



- π^0 质量谱



$$J/\psi \rightarrow \Lambda \bar{\Lambda} \rightarrow p \pi^- \bar{p} \pi^+$$

核心代码片段

1. 数据读取与环境初始化

```
df = ROOT.RDataFrame("events", "input.root")
```

2. 径迹参数定义 (底层提取)

```
df = df.Define("trk_d0", "TrackParamHelper::getD0ForHypoPivotIP (...)")
      .Define("trk_z0", "TrackParamHelper::getZ0ForHypoPivotIP (...)")
      .Define("trk_mom", "TrackParamHelper::getMomForTrack (...)")
```

3. 粒子筛选与物理对象构建

```
df = df.Define("GoodPtrk", "trk_d0<3 && trk_z0<5&&trk_mom>0.5...")
      .Define("TrackPm", "TrackerRecTrackCol[GoodPtrk]")
```

4. 顶点拟合


```
df = df.Define("vfit", "VertexFitUtil::get_vfit(...)")
      .Filter("vfit.Fit(0)")
```

5. 运动学拟合

```
df = df.Define("kfit", "KalmanFitUtil::get_kfit(...)")
      .Define("mass_lam", "VertexFitUtil::get_massafterkfit(kfit,0,1)")
```

6. 结果输出

```
df.Snapshot("lambda_result.root", ["decayL", "mass_lam", ...])
```





物理分析流程图

$$J/\psi \rightarrow \Lambda \bar{\Lambda} \rightarrow p \pi^- \bar{p} \pi^+$$

10 million events

顶点拟合

运动学拟合






山东大学
SHANDONG UNIVERSITY

4

性能测试

性能分析

- 20万 events



- 4线程下，处理速度提升251%
- 受限于数据读取速度和任务调用等必须串行进行的任务，8线程下速度提升不明显

总结

- **框架成功构建**: 基于RDataFrame实现STCF并行物理分析框架, 集成**顶点拟合**、**运动学拟合**、**GlobalPID**工具
- **物理正确性验证**: $J/\psi \rightarrow \rho\pi^0$, $J/\psi \rightarrow \Lambda\bar{\Lambda}$ 分析结果与现有OSCAR软件一致, 确保了物理分析流程与结论的**准确性**
- **显著性能提升**: 在多线程环境下显著缩短数据分析耗时
- **用户友好的接口设计**: 支持声明式编程范式, 极大降低了物理学家的使用与开发门槛

展望

- **模型深度适配**: 深入对接物理分析专用数据模型, 优化数据读写与处理逻辑, 进一步释放框架性能潜力
- **工具生态扩展**: 持续集成D-tagging等关键物理分析工具, 完善框架功能矩阵, 覆盖更多研究场景



THANKS!

分析算法示例: $J/\psi \rightarrow \rho\pi^0 \rightarrow \pi^-\pi^+\gamma\gamma$

```
# 构建数据框
df = ROOT.RDataFrame("events", config["input_file"])

# 添加事件索引 (从0开始递增)
df_with_index = df.Define("event_index", "rdentry_")\
    .Define("n_reconstructed_particles", "ReconstructedParticleCol.size()")\
    .Define("n_tracks", "TrackerRecTrackCol.size()")

# 1. 径迹选择 (使用简化接口)
df1 = build_track_chain(df_with_index, config["hypo_index"])

# 2. PID 分析 (使用简化接口)
df2 = build_pid_chain("TrackerRecTrackCol", df1)

# 3. 好径迹筛选
df3 = df2.Define("GoodPimtrk",
    f"abs(trk_d0) <= {config['vrCut']} && "
    f"abs(trk_z0) <= {config['vzCut']} && "
    f"trk_charge <= 0 && pi_prob > k_prob && pi_prob > mu_prob")\
    .Define("GoodPiptrk",
    f"abs(trk_d0) <= {config['vrCut']} && "
    f"abs(trk_z0) <= {config['vzCut']} && "
    f"trk_charge > 0 && pi_prob > k_prob && pi_prob > mu_prob")\
    .Define("probpim_pi", "pi_prob[GoodPimtrk]")\
    .Define("probpim_k", "k_prob[GoodPimtrk]")\
    .Define("Pim", "TrackerRecTrackCol[GoodPimtrk]")\
    .Define("Pip", "TrackerRecTrackCol[GoodPiptrk]")\
    .Filter("Pim.size() == 1 && Pip.size() == 1", "goodtrk")\
    .Redefine("probpim_pi", "probpim_pi[0]")\
    .Redefine("probpim_k", "probpim_k[0]")

# 4. 获取 WTrackParameter
df4 = df3.Define("pimwtrk", get_wtrack("Pim[0]", config["hypo_index"]))\
    .Define("pipwtrk", get_wtrack("Pip[0]", config["hypo_index"]))

# 5. 中性径迹选择
df5 = df4.Define("nwtrk",
    f"VertexFitUtil::SelectUtil::select_Neutral_Tracks("
    f"RecECALShowerCol, RecExtTrackCol_4, RecExtTrackCol, 2, {config['dangCut']})")\
    .Filter(f"nwtrk.size() >= 2", "neutral tracks")
```

```
# 6. 顶点拟合 (使用简化接口)
df6 = df5.Define("vertexfit", get_vfit("pipwtrk", "pimwtrk"))\
    .Filter("vertexfit.Fit(0)", "vfitc")\
    .Define("chi2v", "vertexfit.chisq(0)")\
    .Redefine("vertexfit", "VertexFitUtil::update_vfitData(vertexfit)")\
    .Define("kwtrk", "VertexFitUtil::get_forkfit(vertexfit)")\
    .Define("goodnwtrk", "VertexFitUtil::SelectUtil::select_Neuwtrk_forkfit(nwtrk, kwtrk[0], kwtrk[1])")\
    .Filter("goodnwtrk.size() == 2", "gn")

# 7. 运动学拟合
df7 = df6.Define("kfit",
    "KinematicFitObject(3.097, kwtrk, goodnwtrk)(2, 2)")\
    .Filter("kfit->Fit()", "kfit")\
    .Define("m_mrho_beforefit", "VertexFitUtil::get_massbeforekfit(kfit, 0, 1)")\
    .Define("m_mrho_afterfit", "VertexFitUtil::get_massafterkfit(kfit, 0, 1)")\
    .Define("m_mpi0_beforefit", "VertexFitUtil::get_massbeforekfit(kfit, 2, 3)")\
    .Define("m_mpi0_afterfit", "VertexFitUtil::get_massafterkfit(kfit, 2, 3)")

# 输出结果 (包含事件索引)
df7.Snapshot("events", config["output_file"], [
    "event_index",
    "n_reconstructed_particles",
    "n_tracks",
    "pi_prob",
    "k_prob",
    "mu_prob",
    "trk_d0",
    "trk_z0",
    "trk_pt",
    "m_mpi0_afterfit",
    "m_mrho_afterfit",
    "chi2v",
    "probpim_pi",
    "probpim_k"
])
```

Analysis Codes and Python scripts for $J/\psi \rightarrow \Lambda \bar{\Lambda} \rightarrow p \pi^- \bar{p} \pi^+$

```
df1 = df.Define("event_index", "rdfentry_")\
    .Define("trk_d0", "TrackParamHelper::getD0ForHypoPivotIP(TrackerRecTrackCol, TrackerHypoTrackCol, 2)")\
    .Define("trk_z0", "TrackParamHelper::getZ0ForHypoPivotIP(TrackerRecTrackCol, TrackerHypoTrackCol, 2)")\
    .Define("trk_theta", "TrackParamHelper::getThetaForTrack(TrackerRecTrackCol, TrackerRecTrackCol_1, 2)")\
    .Define("trk_mom", "TrackParamHelper::getMomForTrack(TrackerRecTrackCol, TrackerRecTrackCol_1, 2)")\
    .Define("GoodPtrk", f"abs(trk_d0)<10&&abs(trk_z0)<30&&abs(cos(trk_theta))<0.93 &&abs(trk_mom)>0.5")\
    .Define("GoodPitrk", f"abs(trk_d0)<10&&abs(trk_z0)<30&&abs(cos(trk_theta))<0.93 &&abs(trk_mom)<0.5")\
    .Define("TrackerP", "TrackerRecTrackCol[GoodPtrk]")\
    .Define("TrackerPi", "TrackerRecTrackCol[GoodPitrk]")\
    .Filter(f"TrackerP.size() >= 2 && TrackerPi.size() >= 2", "goodtrk")\
    .Define("Pcharge", "TrackParamHelper::getCharge(TrackerP)")\
    .Define("Picharge", "TrackParamHelper::getCharge(TrackerPi)")\
    .Define("TrackPm", "TrackerP[Pcharge<0]")\
    .Define("TrackPp", "TrackerP[Pcharge>0]")\
    .Define("TrackPip", "TrackerPi[Picharge>0]")\
    .Define("TrackPim", "TrackerPi[Picharge<0]")\
    .Filter("TrackPm.size()>=1 &&TrackPp.size()>=1&&TrackPip.size()>=1&&TrackPim.size()>=1", "track")


df_wtrk=df1.Define("wtrks", "VertexFitUtil::SelectUtil::select_WTP(TrackPp,TrackPim,TrackerHypoTrackCol,4,2,5,2,8,true)")\
    .Filter("wtrks[0].size()==1&&wtrks[1].size()==1")\
    .Define("Pp", "wtrks[0][0]")\
    .Define("Pim", "wtrks[1][0]")\
    .Define("Pmpipwtrks", "VertexFitUtil::SelectUtil::select_WTP(TrackPm,TrackPip,TrackerHypoTrackCol,4,2,5,2,8,true)")\
    .Filter("Pmpipwtrks[0].size()==1&&Pmpipwtrks[1].size()==1")\
    .Define("Pm", "Pmpipwtrks[0][0]")\
    .Define("Pip", "Pmpipwtrks[1][0]")
```

```
df2=df_wtrk.Define("Vertexfit_p_pi", "VertexFitUtil::get_vfitObject(Pp,Pim)")\
    .Filter("Vertexfit_p_pi.Fit(0)", "lamdvfit")\
    .Redefine("Vertexfit_p_pi", "VertexFitUtil::update_vfitData(Vertexfit_p_pi)")\
    .Define("wtrkpipi", "VertexFitUtil::get_forkfit(Vertexfit_p_pi)")\
    .Define("RDFAm_lambeforefit", "VertexFitUtil::getvfit_Massbefore(Vertexfit_p_pi)")\
    .Define("RDFAm_lamaftervfit", "VertexFitUtil::getvfit_Massafter(Vertexfit_p_pi)")\
    .Define("secondvfit", "VertexFitUtil::get_svfitObject(Vertexfit_p_pi, 5, 2, 8)")\
    .Filter("secondvfit.Fit()", "lamdvfit")\
    .Define("RDFAlam_decaylength", "VertexFitUtil::getsvfit_Decaylength(secondvfit)")\
    .Define("lam_svchi2", "secondvfit.chisq()")
```


```
#vertex fit for anti-Lambda
df3=df2.Define("Vertexfit_pbar_pip",
    "VertexFitUtil::get_vfitObject(Pm, Pip)")\
    .Filter("Vertexfit_pbar_pip.Fit(0)", "antilamd-vfit")\
    .Redefine("Vertexfit_pbar_pip", "VertexFitUtil::update_vfitData(Vertexfit_pbar_pip)")\
    .Define("wtrkpbarpip",
        "VertexFitUtil::get_forkfit(Vertexfit_pbar_pip)")\
    .Define("RDFAm_antilambeforefit",
        "VertexFitUtil::getvfit_Massbefore(Vertexfit_pbar_pip)")\
    .Define("RDFAm_antilamaftervfit",
        "VertexFitUtil::getvfit_Massafter(Vertexfit_pbar_pip)")\
    .Define("secondvfit0",
        "VertexFitUtil::get_svfitObject(Vertexfit_pbar_pip,5, 2, 8)")\
    .Filter("secondvfit0.Fit()", "antilamd-svfit")\
    .Define("RDFAantilam_decaylength",
        "VertexFitUtil::getsvfit_Decaylength(secondvfit0)")\
    .Define("antilam_svchi2", "secondvfit0.chisq()")

#kinematic fit
df4=df3.Define("kfit", f"KalmanKinematicFitObject(3.097,wtrkpipi,wtrkpbarpip)(4,0)")\
    .Filter("kfit->Fit()", "kfit")\
    .Define("RDFAm_lamafterkfit", "VertexFitUtil::get_massafterkfit(kfit,0,1)")\
    .Define("RDFAm_antilamafterkfit", "VertexFitUtil::get_massafterkfit(kfit,2,3)")\
    .Define("chi2", "VertexFitUtil::get_Chi2afterkfit(kfit)")
df4.Snapshot("events", f"2thread/RDFA_{i}.root", ["lam_svchi2", "antilam_svchi2", "event_index", "RDFAm_lamaftervfit"])
```

需求分析



Pref CPU Flame Graph (8 threads)



proportion:34.3% 323e9