

修 士 学 位 論 文

高輝度 LHC-ATLAS 実験に向けた  
機械学習を用いた  
陽子対衝突点の高速再構成手法の開発

令和 8 年 2 月 6 日

専 攻 名 物理学専攻

学籍番号 244S106S

氏 名 笹田 真宏

神戸大学大学院理学研究科博士課程前期課程



# 概要

LHC-ATLAS 実験は、欧州合同原子核研究機構（CERN）で行われている陽子衝突型加速器 LHC を用いた実験プロジェクトである。LHC は標準模型の精密測定や新物理の発見を目標とし、高輝度化アップグレードを予定している。2030 年の運転開始に向けて、現在準備が進められている。

LHC では、陽子をバンチと呼ばれる塊にまとめて加速させ、バンチ同士を 25ns ごとに衝突させることで、衝突時に生成した粒子を観測する。高輝度化に伴い、1 バンチ交差あたりに衝突する陽子数であるパイルアップも平均 50–65 から、最大 200 に増加する。この環境下において多数の衝突の中から関心のある横運動量の大きな衝突（硬散乱事象）を取り出すには、硬散乱衝突の起きた位置を同定することが有用である。多数の重なる衝突のなかから最も横運動量の高い衝突の位置（Primary Vertex, PV）を再構成できれば、粒子の運動学的変数の再構成の精度を向上できる。このような精度の高い運動学的変数をオンライン事象選別であるトリガーで用いれば、早い段階での事象選別を行うことで、高輝度化で予想されるトリガーにおける計算機資源の大幅な増加を抑制できる。

本研究では、HL-LHC のトリガーシステムに向けて、機械学習を用いた PV 再構成アルゴリズムを開発した。まず、荷電粒子の飛跡のビーム軸方向に対応する座標を横運動量で重み付けしてヒストグラム化し、最大値をとる位置を PV とするシンプルな手法（ヒストグラム法）を開発した。しかし、ヒストグラム法はトラックフィットの品質を考慮しないなど理由から、物理事象によっては十分な再構成性能が得られなかった。そこで、多層パーセプトロン（MLP）を用いて各トラックの重みを学習する手法を開発した。本手法では、トラックの運動学的情報、幾何学的情報、再構成品質を表す 7 つのパラメータを入力として使用し、硬散乱由来のトラックを効果的に選別するように重みを求めた。

本論文では、高輝度化を想定したシミュレーションにおいて PV 再構成アルゴリズムの性能を評価した。本手法は位置分解能がオフラインアルゴリズムに比べて低くなったが、既存のオフラインアルゴリズムを上回る PV 位置の再構成効率を達成した。また、学習に用いていない物理事象に対しても機械学習によって高い性能を示す場合があることを示した。さらに、再構成した PV を用いて光子の横運動量を補正することで、2 光子不変質量の分解能が向上することを確認した。以上の結果から、本手法は HL-LHC のトリガーレベルでの応用に有望であることが示された。

# 目次

第 1 章	序論	1
1.1	素粒子標準模型	1
1.2	LHC 加速器	2
1.3	高輝度化アップグレード	2
1.4	高輝度 LHC で目指す物理	3
第 2 章	高輝度 LHC における ATLAS 実験と飛跡再構成	10
2.1	ATLAS 検出器	10
2.1.1	ITk	11
2.1.2	カロリメータ	13
2.1.3	ミュオンスペクトロメータ	13
2.2	トリガーシステム	14
2.3	飛跡再構成	15
2.4	陽子対衝突点	17
2.4.1	陽子対衝突点の再構成	17
2.4.2	オフラインにおける再構成手法	18
第 3 章	シンプルな PV 再構成手法	24
3.1	ヒストグラム法	24
3.2	データセット	24
3.3	性能評価	26
3.3.1	残差分布	27
3.3.2	Efficiency	27
3.3.3	Purity	27
3.4	結果	28
3.4.1	残差分布	28
3.4.2	Efficiency と Purity の関係	28
3.5	ヒストグラム法の問題点	30
第 4 章	機械学習を用いた陽子対衝突点の再構成	33

4.1	機械学習 . . . . .	33
4.1.1	ニューラルネットワーク . . . . .	33
4.2	機械学習を用いた再構成手法 . . . . .	37
4.2.1	学習モデル . . . . .	37
4.2.2	データセット . . . . .	38
4.2.3	損失関数 . . . . .	38
4.2.4	学習の詳細 . . . . .	39
第 5 章	機械学習手法の性能評価 . . . . .	41
5.1	$t\bar{t}, Z \rightarrow \mu\mu$ 事象における性能評価 . . . . .	41
5.1.1	学習過程 . . . . .	41
5.1.2	残差分布 . . . . .	41
5.1.3	Efficiency と Purity . . . . .	45
5.1.4	特徴量分布 . . . . .	45
5.2	混合学習による性能評価 . . . . .	48
5.2.1	学習過程 . . . . .	48
5.2.2	Efficiency と Purity . . . . .	48
5.3	$HH \rightarrow b\bar{b}\gamma\gamma$ 事象における性能評価 . . . . .	48
5.4	Run 3 における性能評価 . . . . .	50
5.4.1	学習過程 . . . . .	50
5.4.2	$t\bar{t}$ 事象における性能評価 . . . . .	50
5.4.3	$HH \rightarrow b\bar{b}\gamma\gamma$ 事象における性能評価 . . . . .	51
5.5	各条件での Efficiency のまとめ . . . . .	51
5.6	PV による運動学的変数の補正 . . . . .	51
第 6 章	まとめと展望 . . . . .	57
6.1	まとめ . . . . .	57
6.2	展望 . . . . .	58
付録 A	トラックのパラメータ分布 . . . . .	59
	謝辞 . . . . .	60
	参考文献 . . . . .	62

# 第 1 章

## 序論

### 1.1 素粒子標準模型

素粒子標準模型 (Standard Model) は、宇宙を構成する素粒子と素粒子間の相互作用を記述し、現時点で、これまでの実験結果を最も正確に記述する理論体系である。

標準模型で扱う素粒子は図 1.1 に示されるように、12 種類のフェルミオンと 4 種類のゲージボソン、ヒッグス粒子の合計 17 種類の粒子で構成される。標準模型は基本的な 4 つの相互作用のうち、重力相互作用を除く、強い相互作用、電磁相互作用、弱い相互作用の 3 つの相互作用を記述する。




図 1.1: 標準模型を構成する素粒子 [1]

素粒子標準模型は様々な実験により、その正当性が検証されている。しかし、標準模型では説明できない事象も存在する。例えば、宇宙の約 27% を占めるとされるが未だに発見できていないダークマターの存在 [2] や、物質と反物質の非対称性 [3] が挙げられる。現在、そのような未解決問題を解決するため、様々なアプローチから素粒子実験が行われている。LHC で行われている実験もその 1 つである。

## 1.2 LHC 加速器

LHC(Large Hadron Collider) は、スイスのジュネーブ郊外に位置する欧州原子核研究機構(CERN)の地下100mに建設された、周長約27kmの世界最大の円形加速器である。LHCで陽子を加速させ、重心エネルギー13.6TeV、1バンチあたり25nsの間隔で衝突させることが可能である。LHCの陽子衝突点は4箇所存在し、ATLAS実験、CMS実験は汎用大型検出器を衝突点に設置し、標準模型の精密測定や新物理の探索など幅広い物理を対象とした研究を行っている。LHCbは陽子衝突点の前方を集中的にカバーし、bクォークを含むビーム軸方向に多く生成される粒子の測定をターゲットにしている。ALICE実験は重イオンを加速、衝突させ、ビッグバン直後の宇宙初期に存在していたとされる物質相「クォーク・グルーオンプラズマ(QGP)」の性質の解明を主目的としている[4]。図1.2に、LHCの加速器システムの全容を示す。陽子は前段加速器で加速したのちにLHCに供給される。

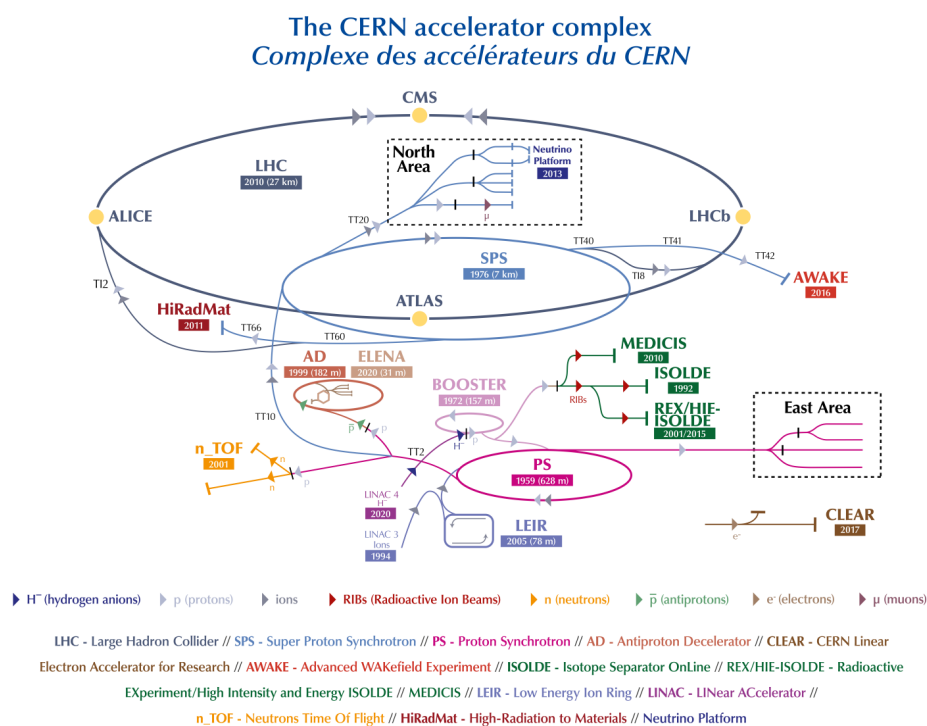


図 1.2: LHC の加速器システム [5]

## 1.3 高輝度化アップグレード

LHCではヒッグス粒子のより精密な測定、また新物理の発見に向けて、高輝度化アップグレード(HL-LHC: High-Luminosity LHC)の準備が現在進められている。LHCでは陽子の塊である1

バンチを交差させることで多数の陽子を衝突させている。高輝度化アップグレードでは1バンチあたりの陽子数を増加させること、またビームを絞ることで、瞬間ルミノシティを  $2 \times 10^{34} \text{cm}^{-2}\text{s}^{-1}$  から  $5 - 7.5 \times 10^{34} \text{cm}^{-2}\text{s}^{-1}$  まで増加させる予定になっている。これに伴い、1バンチ交差あたりに衝突する陽子数であるパイルアップも平均 50–65 から、150–200 に増加する。こういった高輝度化アップグレードによって新物理探索の感度が大幅に上がることが予想される。アップグレード計画のスケジュールを図 1.3 に示す。2030 年の運転開始にむけて、2026 年から 2030 年にかけて検出器等の設置期間が設けられている。

現在の ATLAS 検出器では高輝度化に対応できないため、大規模なアップグレードが必要である。また、電子回路やトリガーシステムも全面的に刷新され、大幅に増加するデータから興味のある物理を選定するトリガーシステムの改良が行われる。これらについては次章で述べる。



図 1.3: 高輝度化アップグレード計画のスケジュール [6]。2030 年の運転開始にむけて、2026 年から 2030 年にかけて検出器等の設置期間を設ける。

## 1.4 高輝度 LHC で目指す物理

LHC は、高エネルギーの陽子ビームを用いた、ヒッグス粒子を含めた標準模型の精密測定と、標準模型を超える新物理 (BSM) の探索を目的としている。LHC では、標準模型で予想されていて最後まで未発見であったヒッグス粒子が 2012 年に約  $5\sigma$  の確度を持って発見された。しかし、標準模型で予言されるヒッグスポテンシャルの検証など、取り組むべき重要な課題が残されている。高輝度化によって得られる大統計量を活用することで、BSM を含む生成断面積が小さい物理過程の観測を目指す。例として、ヒッグス粒子の概要とヒッグス粒子の対生成について説明する。



## ヒッグス粒子

標準模型では、複素スカラー二重項であるヒッグス場が真空期待値を持つことで電弱対称性が自発的に破れ、全ての質量を持つ素粒子に質量を与える。このヒッグス場の量子励起として現れる物理的なスカラー粒子がヒッグスボソンである。ヒッグスボソンは 1960 年代に Brout、Englert、Higgs らによって理論的に予言され、2012 年に ATLAS と CMS によって発見された粒子である。ヒッグスボソンは宇宙全体に存在するヒッグス場の媒介粒子であり、粒子がヒッグス場と相互作用する。つまりヒッグス場と結合定数が大きくなると、その質量は大きくなる [1]。図 1.4 にヒッグスポテンシャルの形状を示す。ヒッグスポテンシャルは以下のように記述される。

$$V(\phi) = -\mu^2|\phi|^2 + \lambda|\phi|^4, \quad (1.1)$$

ここで  $\phi$  は (複素) スカラー場であり、 $\mu^2 > 0$ 、 $\lambda > 0$  である。




図 1.4: ヒッグスポテンシャルの形状 [1]

### ■生成過程

ヒッグス粒子の主な生成過程は以下の通りである。

- gluon-gluon Fusion production  
グルーオンがトップクォークなどの重いクォークのループを介してヒッグス粒子を生成する過程。LHC ではもっとも断面積が大きい。
- VBF production  
クォークから出た W や Z などのベクトルボソンからヒッグス粒子が生成される過程。2 番目に断面積が大きい。
- VH production  
クォークの対消滅でできたベクトルボソンからヒッグス粒子が生成される過程。

- $q\bar{q}H$  production

グルーオンから対生成したトップクォークによってヒッグス粒子が生成される過程。

ヒッグス粒子の生成過程と生成断面積を、図 1.5 と図 1.6 に示す。

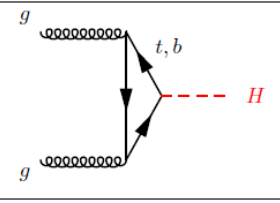
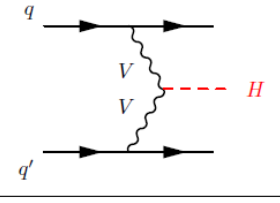
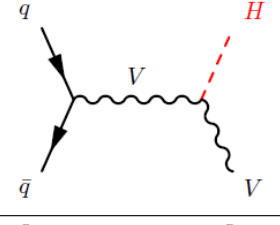
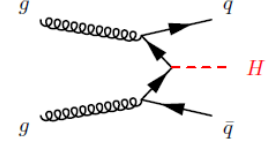
Production mode	LO diagram
ggF production	
VBF production	
VH production	
$q\bar{q}H$ production	

図 1.5: ヒッグス粒子の生成過程 [1]




図 1.6: 重心エネルギーに対するヒッグス粒子の生成断面積 [1]。量子色力学 (QCD) と電弱 (EW) モデルが生成断面積の予測に使われる。

### ■崩壊過程

標準模型によると、ヒッグス粒子はフェルミオンもしくはボソンのペアに崩壊する。崩壊チャンネルと分岐比を表 1.1 に示す。もっとも支配的なのは  $b\bar{b}$  への崩壊である。 $b$  クォークはハドロン化して  $B$  ハドロンを生成し、 $B$  ハドロンは比較的長い寿命を持つため、衝突点から数 mm 離れた位置で崩壊する。この崩壊点や、そこから生じる粒子の飛跡の衝突点からのずれなどの特徴を利用して、 $b$  クォーク由来のジェット ( $b$  ジェット) を他のジェットから識別する手法を  $b$  タギングと呼ぶ。しかし、QCD マルチジェット生成などのバックグラウンドの生成断面積がヒッグス粒子の生成断面積と比較して非常に大きく、 $b$  タギングを用いても十分なバックグラウンド抑制が難しいため、 $H \rightarrow b\bar{b}$  チャンネルでの信号の抽出は困難である。 $H \rightarrow W^+W^-$  や  $H \rightarrow ZZ$  のレプトニック崩壊のうち大部分はニュートリノ対への崩壊である。ニュートリノは物質とほとんど相互作用しないため検出が困難であり、横運動量の欠損として間接的に測定される。ヒッグスが 2 つの光子に

崩壊する過程は分岐比は小さいものの、光子のエネルギーの測定精度が良く、不変質量を組むことでヒッグスの質量付近で鋭いピークが見え、効率的な事象選別が可能である。

表 1.1: ヒッグス粒子の主な崩壊チャンネルと、その分岐比および不確かさ [1]

Decay channel	Branching ratio	Rel. uncertainty
$H \rightarrow \gamma\gamma$	$2.28 \times 10^{-3}$	+5.0% -4.9%
$H \rightarrow ZZ$	$2.64 \times 10^{-2}$	+4.3% -4.1%
$H \rightarrow W^+W^-$	$2.15 \times 10^{-1}$	+4.3% -4.2%
$H \rightarrow \tau^+\tau^-$	$6.32 \times 10^{-2}$	+5.7% -5.7%
$H \rightarrow b\bar{b}$	$5.77 \times 10^{-1}$	+3.2% -3.3%
$H \rightarrow Z\gamma$	$1.54 \times 10^{-3}$	+9.0% -8.9%
$H \rightarrow \mu^+\mu^-$	$2.19 \times 10^{-4}$	+6.0% -5.9%

## ヒッグス対生成

ヒッグス対生成は、1回の陽子衝突において2つのヒッグス粒子が同時に生成される過程である。この事象の生成断面積の測定は、ヒッグスポテンシャルに含まれる三重ヒッグス結合に感度を持つ数少ない手段であり、標準模型における電弱対称性の自発的破れ機構を検証する上で重要である。

式 (1.1) で示したヒッグスポテンシャルにおいて、電弱対称性の自発的破れ後の物理ヒッグス場  $H$  のポテンシャルは

$$V(H) = \frac{1}{2}m_H^2 H^2 + \lambda_3 v H^3 + \frac{1}{4}\lambda_4 H^4 \quad (1.2)$$

と表される。標準模型では、三重および四重ヒッグス結合は同一の自己結合定数によって決まり、

$$\lambda_3 = \lambda_4 = \lambda_{\text{SM}} = \frac{m_H^2}{2v^2} \quad (1.3)$$

である [7]。

後述するように、ヒッグス対生成の生成断面積は三重ヒッグス結合  $\lambda_3$  に依存するため、この過程の観測を通じてヒッグスポテンシャルの形状を実験的に検証することができる。

## ■生成過程

ヒッグス対生成の断面積は、単一ヒッグス生成に比べて約 1000 分の 1 と非常に小さく、その測定は実験的に困難である。ヒッグス対生成の主な生成過程を図 1.7 に示す。ここで三重ヒッグス自己結合の結合修正因子  $\kappa_\lambda$  は、測定される三重ヒッグス自己結合  $\lambda_{3,\text{meas}}$  を標準模型の値  $\lambda_{\text{SM}}$  で規格化した無次元量として

$$\kappa_\lambda = \frac{\lambda_{3,\text{meas}}}{\lambda_{\text{SM}}} \quad (1.4)$$

と定義される。

表 1.2 に、gluon–gluon fusion (ggF) 過程および vector boson fusion (VBF) 過程における  $\sqrt{s} = 14$  TeV での生成断面積を示す。支配的なのは ggF 過程であり、トップクォークループを介した box diagram と triangle diagram の 2 つの寄与が存在する。Triangle diagram には三重ヒッグス自己結合が含まれる一方、box diagram にはヒッグス自己結合は含まれない。ヒッグス対生成では、これら二つの寄与が振幅レベルで重ね合わされ、断面積（振幅の二乗）において破壊的干渉を生じる。 $\kappa_\lambda$  のわずかな変化が干渉パターンを変化させ、全生成断面積および微分分布に影響を与える [8]。表 1.3 に  $\kappa_\lambda$  による生成断面積の変化を示す。したがって、ヒッグス対生成過程の観測を通じて、三重ヒッグス自己結合に感度を持つ測定が可能となる。

一方、VBF 過程は、ggF に比べて生成断面積は小さいものの、ggF に次ぐ主要なヒッグス対生成過程である。VBF 過程では、前方に 2 本のタグジェットが生成される特徴的なトポロジーを持ち、ジェット対の大きな擬ラピディティ分離や不変質量を要求する運動学的カットをかけることで背景事象の大きな抑制が可能である。さらに、VBF 過程は三重ヒッグス自己結合の結合修正因子  $\kappa_\lambda$  に対する感度が高く、加えて  $hhVV$  四重結合の測定においても将来有望なチャンネルである [9]。




図 1.7: ヒッグス粒子対生成の最低次ファインマン図。(a,b) は支配的な ggF 過程、(c-e) は VBF 過程を示す。(a,c) は三重ヒッグス結合  $\kappa_\lambda$  を含み、(b,d) は 2 つの独立した単一ヒッグス頂点を持ち、(e) は  $VVHH$  頂点を含む。 $ttH$ 、 $VVH$ 、 $VVHH$  結合の結合修正因子はそれぞれ  $\kappa_t$ 、 $\kappa_V$ 、 $\kappa_{2V}$  で表される [7]。

表 1.2:  $\sqrt{s} = 14$  TeV における NLO 計算でのヒッグス対生成過程の生成断面積 [10]。

生成過程	$\sigma$ [fb]
ggF	33.89
VBF	2.01

表 1.3:  $\sqrt{s} = 14$  TeV における NLO 計算でのヒッグス対生成過程の全生成断面積  $\sigma(pp \rightarrow HH)$  の  $\kappa_\lambda$  依存性 [8]。

$\kappa_\lambda$	$\sigma_{\text{NLO}}$ [fb]
-1	$136.91^{+16.4\%}_{-13.9\%}$
0	$73.64^{+15.4\%}_{-13.4\%}$
1	$32.88^{+13.5\%}_{-12.5\%}$
2	$14.75^{+12.0\%}_{-11.8\%}$
2.4	$13.79^{+13.5\%}_{-12.5\%}$
3	$19.07^{+17.1\%}_{-14.1\%}$
5	$95.22^{+19.7\%}_{-11.5\%}$

### ■崩壊過程と $b\bar{b}\gamma\gamma$ チャンネル

ヒッグス粒子対は、それぞれが独立に崩壊するため、様々な終状態が考えられる。主な崩壊チャンネルを図 1.8 に示す。各崩壊チャンネルの特徴を以下に述べる。

最も分岐比が大きいのは  $b\bar{b}b\bar{b}$  チャンネル (約 34%) であるが、4つの  $b$  クォークを生成する標準模型過程が多数存在するため、バックグラウンドとの識別が困難である。 $b\bar{b}\tau^+\tau^-$  チャンネルは中程度のバックグラウンドを持つが、分岐比は  $b\bar{b}b\bar{b}$  の約 5 分の 1 であり、終状態にニュートリノを含むため完全な運動学的再構成が困難である。 $b\bar{b}l\bar{l} + E_{\text{T}}^{\text{miss}}$  チャンネルは、2つの  $b$  クォーク、2つのレプトン、ニュートリノを含む終状態であり、マルチレプトン終状態とともに探索に用いられている。

本研究で着目する  $b\bar{b}\gamma\gamma$  チャンネルは、一方のヒッグスが  $b\bar{b}$  に、もう一方が  $\gamma\gamma$  に崩壊する過程である。このチャンネルの分岐比は約 0.26% と小さいが、光子の優れたエネルギー分解能により  $\gamma\gamma$  不変質量からヒッグス粒子の質量を精度よく再構成でき、連続的なバックグラウンド事象との分離が容易である。加えて、2光子終状態は純粋な QCD 由来のバックグラウンドが比較的小さいことから、 $b\bar{b}\gamma\gamma$  チャンネルはヒッグス対生成探索において最も感度の高いチャンネルの一つである。

ATLAS では、これらの崩壊チャンネルを統計的に組み合わせることで、ヒッグス対生成およびヒッグス自己結合に対する感度を向上させている。図 1.9 に、Run 2 データを用いた各崩壊チャンネルおよび組み合わせ解析におけるシグナル強度  $\mu_{HH}$  の 95% 信頼水準での上限を示す。単一チャンネルとしては  $b\bar{b}\tau^+\tau^-$  が期待上限 3.3 と最も高い感度を持つ。 $b\bar{b}\gamma\gamma$  チャンネルは期待上限 5.0 であるが、観測上限は 4.0 と単一チャンネルで最も低い値を示している。全チャンネルの組み合わせにより、観測上限 2.9 (期待上限 2.4) が得られている [11]。

	bb	WW	$\tau\tau$	ZZ	$\Upsilon\Upsilon$
bb	34%				
WW	25%	4.6%			
$\tau\tau$	7.3%	2.7%	0.39%		
ZZ	3.1%	1.1%	0.33%	0.069%	
$\Upsilon\Upsilon$	0.26%	0.10%	0.028%	0.012%	0.0005%

図 1.8: ヒッグス対生成における主な崩壊チャンネルとその分岐比 [12]




図 1.9: ggF および VBF 過程を含むヒッグス対生成におけるシグナル強度  $\mu_{HH}$  の 95% 信頼水準での上限 [11]。各崩壊チャンネル ( $b\bar{b}\tau^+\tau^-$ 、 $b\bar{b}\gamma\gamma$ 、 $b\bar{b}b\bar{b}$ 、マルチレプトン、 $b\bar{b}l\bar{l} + E_T^{\text{miss}}$ ) および統計的組み合わせの結果を示す。黒点は観測上限、点線は期待上限を表し、青と黄のバンドはそれぞれ  $\pm 1\sigma$  および  $\pm 2\sigma$  の期待範囲を示す。

## 第 2 章

# 高輝度 LHC における ATLAS 実験と飛跡再構成

本章では、高輝度 LHC-ATLAS 実験で使用される汎用検出器である ATLAS 検出器の概要と、膨大なデータを処理するトリガーシステムについて述べる。

### 2.1 ATLAS 検出器

ATLAS 検出器は、LHC の衝突点の 1 つに設置された直径 25m、全長 46m、重量 7000 トンの大型検出器であり、ヒッグス粒子を発見した 2 台の検出器のひとつである。ATLAS 検出器の全体図を図 2.1 に示す。陽子対衝突点を中心として、内部飛跡検出器、電磁カロリメータ、ハドロンカロリメータ、ミュオンスペクトロメータで構成され、それぞれが粒子の運動量またはエネルギーを測定する。内部飛跡検出器とカロリメータの間には超伝導ソレノイド磁石が設置されており、内部飛跡検出器で荷電粒子の曲率を測定することで運動量を決定する。カロリメータの外側にはトロイド磁石が設置されており、ミュオンスペクトロメータでミュオンの曲率を測定し運動量を決定する。これらの組み合わせによって、衝突により生成された粒子のエネルギーを測定する。

ATLAS 実験では、衝突点を原点とした右手系の直交座標系を採用している。ビーム軸に沿って  $z$  軸を取り、LHC の中心方向を正の  $x$  軸とする。また、 $x-y$  平面における動径方向の距離を  $R = \sqrt{x^2 + y^2}$ 、ビーム軸周りの方位角を  $\phi$  と定義する。さらに、ビーム軸からの天頂角  $\theta$  を用いて、ラピディティ  $y$  および擬ラピディティ  $\eta$  を以下のように定義する。ラピディティは

$$y = \frac{1}{2} \ln \left( \frac{E + p_z}{E - p_z} \right) \quad (2.1)$$

と定義され、ビーム軸方向のローレンツ変換の下で

$$y \longrightarrow y + \text{const.} \quad (2.2)$$

と平行移動するため、加法性を持つ。一方、擬ラピディティは

$$\eta = -\ln \left( \tan \frac{\theta}{2} \right) \quad (2.3)$$

と角度のみで定義される。高エネルギー極限では  $E \simeq p$  となり、 $p_z = p \cos \theta$  を用いると  $y \simeq \eta$  が成り立つ。擬ラピディティは検出器の幾何配置と直接対応するため、ハドロン衝突実験において広く用いられている。ATLAS 検出器では、バレル形状の領域が  $|\eta| < 1.05$ 、エンドキャップ形状が  $|\eta| > 1.05$  の領域におおむね対応している。また、 $z > 0$  の領域を A-side、 $z < 0$  の領域を C-side と呼んでいる。





図 2.1: ATLAS 検出器 [13]

### 2.1.1 ITk

ITk (Inner Tracker) は、ATLAS 検出器の最内層に位置し、陽子対衝突により生成した荷電粒子の飛跡を詳細に検出する役割を担っている。高輝度 LHC-ATLAS 実験に対応するため、これまで使用していた Pixel, SCT, TRT からなる内部飛跡検出器を総入れ替えし、ITk を設置予定である。ITk は  $|\eta| < 4$  をカバーするピクセル検出器と  $|\eta| < 2.7$  をカバーするストリップ検出器で構成されるシリコン検出器である。ピクセルには  $13\text{m}^2$ 、ストリップには  $168\text{m}^2$  の薄板シリコンを用いる。

ピクセル検出器は、中心領域に配置された 5 層のバレル層に加え、前方領域を覆う傾斜あるいは垂直配置の複数のリング層から構成されており、 $z$  方向にも多数の検出面が配置されている。一方、ストリップ検出器は、バレル領域の 4 層のストリップモジュール層と、エンドキャップに配置された 6 枚のディスクから構成される。この組み合わせは、 $|\eta| < 4$  の範囲で検出器を通過する  $p_T > 1 \text{ GeV}$  の任意の荷電粒子に対して、幅 50 mm のガウス形状と仮定した予想されるビームスポットサイズの全幅に対して、トラックあたり少なくとも 9 回の精密測定を行うように設計されている。ITk レイアウトの全体像と、ピクセル検出器の拡大図を図 2.2 に示す。





(a)

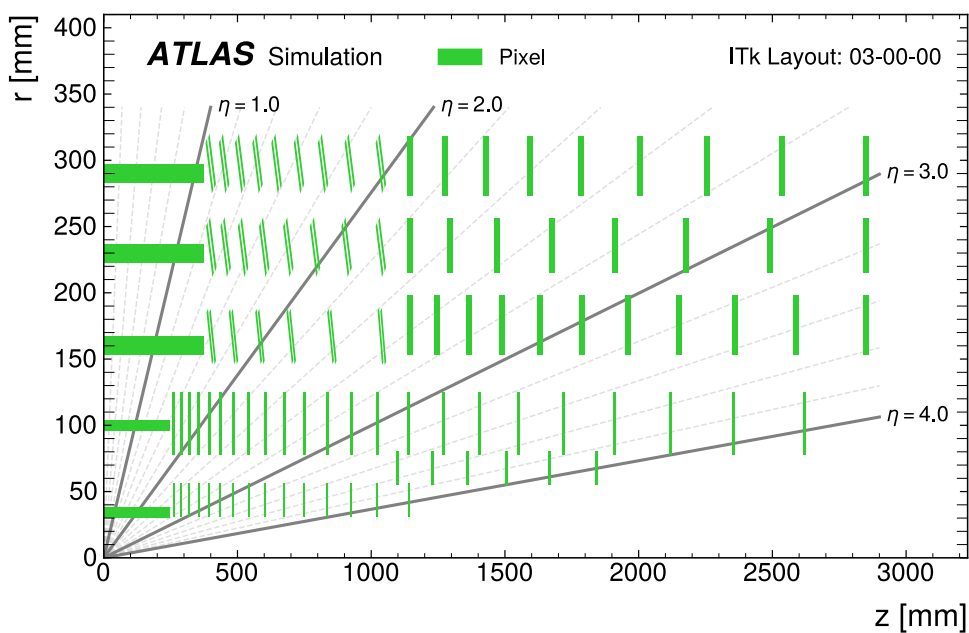


図 2.2: 上図: ITk レイアウトの全体図。下: ピクセル検出器の拡大図。それぞれ、全体の 4 分の 1 の象限とアクティブな検出器素子のみを示す。ストリップ検出器のアクティブな素子は青で、ピクセル検出器のアクティブな素子は緑で示される。横軸はビーム軸で、衝突点を 0 としている。縦軸は衝突点からの半径を示す [14]

。

## 2.1.2 カロリメータ

ATLAS 検出器のカロリメータは、図 2.3 に示すように、バレル部およびエンドキャップ部に配置された液体アルゴン (LAr) 電磁カロリメータ、ハドロンカロリメータ (バレル部のタイルカロリメータおよびエンドキャップ部の LAr ハドロンカロリメータ)、さらに前方領域をカバーする FCal(Forward Calorimeter) から構成されている。いずれもサンプリング型カロリメータを採用し、吸収体と検出媒体を交互に配置することで、粒子が吸収体中で形成するシャワーの一部を検出媒体でサンプリングし、そのエネルギーを測定する。

電磁カロリメータは主に電子や光子のエネルギー測定を担い、鉛を吸収体、液体アルゴンを検出媒体として用い、電磁シャワーにより生じた電離電荷を読み出すことでエネルギーを測定する。ハドロンカロリメータは主にハドロン (陽子、中性子、パイ中間子など) のエネルギー測定を担い、バレル領域では鉄とシンチレータからなるタイルカロリメータ、エンドキャップ領域では銅と液体アルゴンからなる LAr ハドロンカロリメータが用いられる。ハドロンは電磁カロリメータでも電磁シャワーを引き起こすため、そのエネルギーの一部は電磁カロリメータで測定され、残りのエネルギーがハドロンカロリメータで測定される。




図 2.3: カロリメータの全体像 [15]

## 2.1.3 ミューオンスペクトロメータ

ミューオンスペクトロメータは ATLAS 検出器の最外層に位置し、カロリメータを通過した荷電粒子の検出に用いられる。ミューオンスペクトロメータは、位置分解能が高く精密測定用として用

いられる Monitored Drift Tube(MDT) 検出器と、位置分解能は高くないが応答を早くして主にトリガー用に用いられる Resistive Plate Chamber(RPC) と Thin Gap Chamber(TGC) 検出器に分けられる。また、エンドキャップ領域の磁場領域より内側に New Small Wheel(NSW) が設置されている。図 2.4 にミュオンスペクトロメータの全体像を示す。




図 2.4: ミュオンスペクトロメータの全体像 [16]

## 2.2 トリガーシステム

ATLAS 実験では、衝突におけるデータ量が膨大なため、全てのデータを保存することはできない。そのため、トリガーシステムを用いて、ターゲットとなる物理事象に関連するデータのみを選定し、保存する。トリガーシステムはハードウェアベースの大まかな判定を行う初段トリガーと、ソフトウェアベースのより詳細な判定を行う後段トリガーに分けられる。

高輝度 LHC-ATLAS 実験におけるトリガーシステムの全体のアーキテクチャを図 2.5 に示す。L0 が初段トリガー、Event Filter が後段トリガーである。40MHz の衝突データを、L0 で 1MHz 程度まで落とす。その後、Event Filter を通すことで 10kHz 程度の興味のあるデータを永続化する。Event Filter では後述する荷電粒子の飛跡再構成が行われ、より詳細に物理事象の選別を行う。

高輝度化に伴い、処理時間の問題がある。図 2.6 に示すように、パイルアップが増加するに伴い、処理にかかる時間も大幅に増加する見込みである。これは、パイルアップが増加することによって再構成のパターン認識など、組み合わせが増加することにより計算が指数関数的に増加するため

ある。これに対応するために、トリガーアルゴリズムの更なる効率化、高速化が重要な課題となっている。

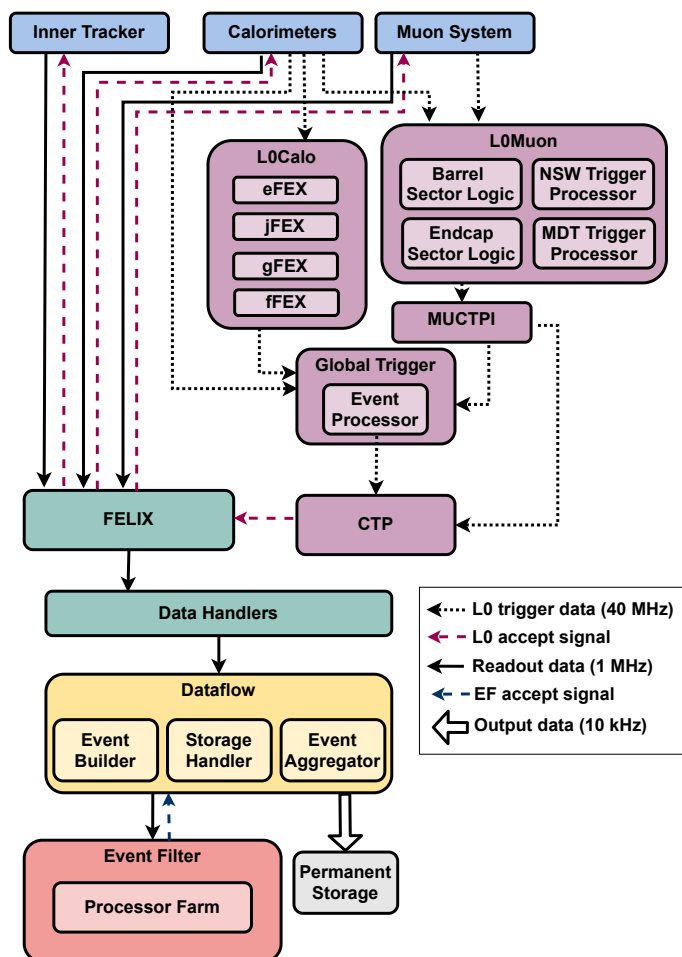


図 2.5: TDAQ Phase-II のアーキテクチャ [17]

## 2.3 飛跡再構成

ATLAS 検出器の内部飛跡検出器では  $z$  軸にほぼ平行に磁場がかかっており、陽子の衝突によって生じた荷電粒子は  $z$  方向を軸とする螺旋運動を描く。荷電粒子が内部飛跡検出器の各層を通過した際に測定された空間的な測定点（ヒット）を元に、荷電粒子の飛跡の再構成が行われる。再構成された飛跡は 5 つのパラメータで特徴付けられ、これらのパラメータは測定点に対するフィッティングによって決定される。フィッティングで求められる  $\chi^2$  値は飛跡の品質を評価する指標として用いられる。

図 2.7 に螺旋運動として再構成された荷電粒子のパラメータを示す。5 つのパラメータは以下のように定義される。




図 2.6: トリガーシステムにおけるパイラップに対する処理時間の関係 [18]。パイラップが増加するに伴い、処理時間も大幅に増加する。

- $d_0$ : 横方向インパクトパラメータ。ビーム軸に対する荷電粒子の飛跡の最近接点の横方向 ( $x$ - $y$  平面内) の距離を表す。
- $z_0$ : 縦方向インパクトパラメータ。ビーム軸に対する荷電粒子の飛跡の最近接点における  $z$  座標を表す。
- $\phi$ : 方位角。ビーム軸に対する荷電粒子の飛跡の最近接点における  $x - y$  平面での粒子の運動量方向を表す角度。
- $\theta$ : 極角。ビーム軸に対する荷電粒子の飛跡の最近接点におけるビーム軸 ( $z$  軸) からの粒子の運動量方向の角度。
- $\frac{q}{p}$ : 電荷と運動量の比。  $q$  は粒子の電荷、  $p$  は運動量の大きさであり、磁場中での粒子の曲率を表す。

これらのパラメータにより、荷電粒子の飛跡が記述される。

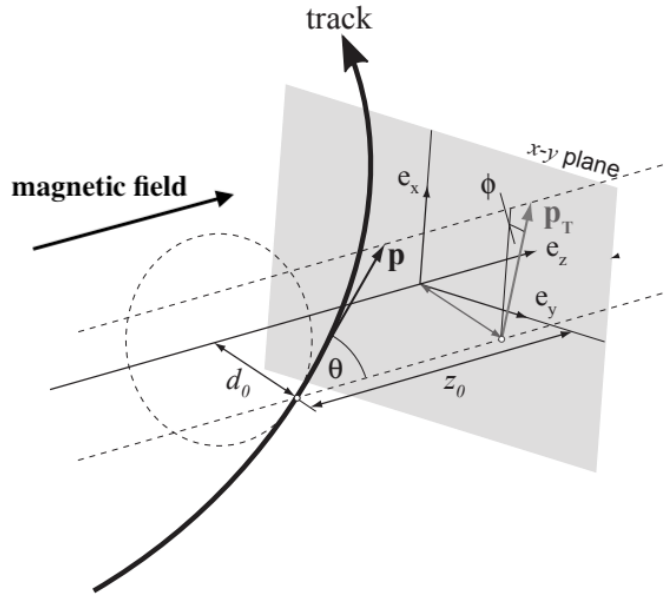


図 2.7: 再構成された荷電粒子のパラメータ [19]。5つのパラメータで表され、 $d_0$  と  $z_0$  はインパクトパラメータ、 $\frac{q}{p}$  は曲率を表す。

## 2.4 陽子対衝突点

### 2.4.1 陽子対衝突点の再構成

#### Primary Vertex

高エネルギーの陽子対が衝突すると、衝突点からは一般に複数の粒子が発生する。これらの粒子の軌跡の交点を vertex(頂点)と呼ぶ。図 2.8 に陽子対衝突の概略図を示す。一次衝突点を Primary Vertex(PV), PV で生成した b クォークなどの長寿命粒子が崩壊する点を Secondary Vertex(SV)と呼ぶ。生成する粒子から複数の荷電粒子を再構成できれば、vertex も再構成できる。PV を再構成することで陽子対の衝突点を決定することが可能である。散乱に大きな横運動量移行が伴い、陽子内部のパートン同士が相互作用をしているとみなせるような散乱を硬散乱 (hard scatter) とよび、このような過程では複数の高い横運動量  $p_T$  を持つ荷電粒子が生成される。一方、小さな運動量移行の軟散乱 (soft scatter) では、主に 1GeV 未満の低  $p_T$  の粒子が生成される。

本研究では、トリガーシステム上で PV を再構成するアルゴリズムを開発することを目指す。トリガーで PV を再構成することには、以下のような利点がある。

- 運動量・飛跡の基準点：PV を生成点として粒子の運動学的変数を正確に再構成できる。
- SV 再構成の起点：PV は SV 再構成の起点となる。SV を利用した b/c クォーク由来のジェットを同定するフレーバータギングは、ヒッグス粒子など標準模型の精密測定において重要である。




図 2.8: 陽子対衝突の概略図

### LHC における Primary Vertex

LHC では陽子の塊であるバンチを 25ns ごとに交差させており、1 度の交差で多数の陽子が衝突する。1 度のバンチ交差あたりの陽子の衝突数をパイルアップと呼び、高輝度 LHC-ATLAS 実験ではパイルアップは最大 200 に及ぶことが予定されている。本研究では、1 バンチ交差によって生じた vertex の中で、対応する荷電粒子トラックの  $\Sigma p_T^2$  が最も大きい vertex を Primary Vertex (PV) と以下呼ぶこととする。これは、最も大きな運動量移行を伴った硬散乱に対応する。PV を再構成することで、パイルアップ由来の粒子を除外し、興味のある硬散乱事象の選別精度を向上させることが可能となる。

本研究では、高輝度 LHC-ATLAS 実験を想定したモンテカルロシミュレーションで生成されたデータを用いる。このデータは、注目する硬散乱事象（例えば  $t\bar{t}$  事象）のシミュレーションに対して、平均 200 回の軟散乱のシミュレーションを重ね合わせたものである。以降、このようなサンプルをパイルアップ 200 の  $t\bar{t}$  事象のように表記する。パイルアップ 200 の  $t\bar{t}$  事象における PV の  $z$  座標分布を図 2.10 に示す。PV の  $z$  座標は原点を中心に、 $-200\text{mm}$  から  $200\text{mm}$  の範囲に分布している。

### 2.4.2 オフラインにおける再構成手法

Run3 において、オフラインにおける PV は Gaussian Track Density Seed Finder と Adaptive Multi-Vortex Reconstruction という 2 つの手法により再構成される。

#### Gaussian Track Density Seed Finder

Gaussian Track Density Seed Finder は、vertex 再構成の最初のステップであり、vertex のシード (候補点) を探索する手法である。シード探索から漏れた PV はこの時点で失われるため、高効率であることが求められる。

Run2 から Run3 へアップグレードされる際に、高輝度環境での性能向上を目指して、医療画像




図 2.9: バンチ交差によって起こる陽子対衝突の概略図。1 バンチ交差で複数の陽子が衝突し、Primary Vertex からは横運動量の大きい荷電粒子のトラックが派生する。

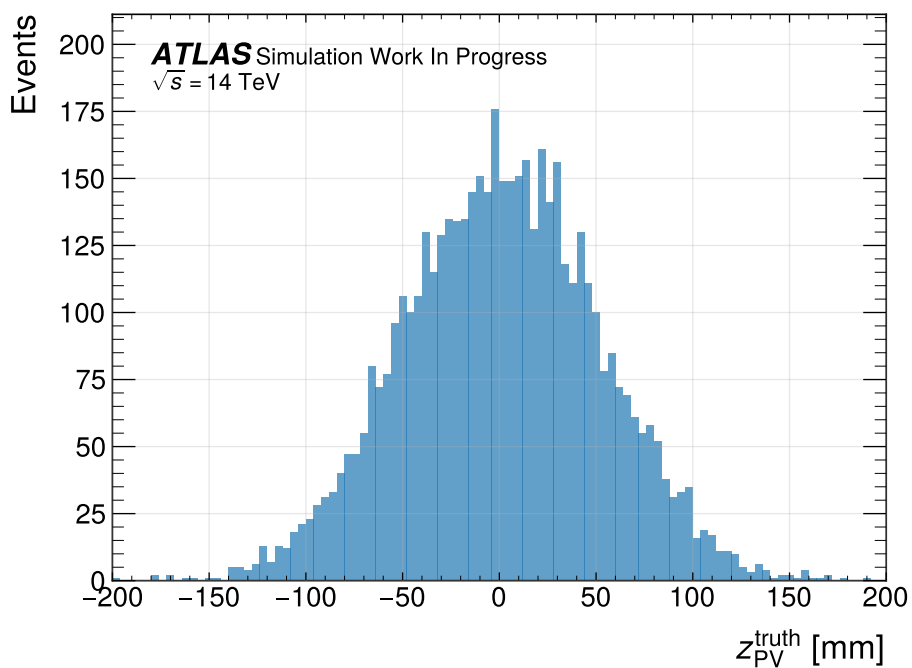


図 2.10: パイルアップ 200 の  $t\bar{t}$  事象における PV の  $z$  座標分布

処理に基づく手法 (Medical Imaging) が研究された。この手法では、空間中のトラック軌跡の 3 次元ヒストグラムを構築し、フーリエ変換で平滑化することでシード位置を抽出していた。しかし、この手法には以下のような欠点があった。

- 本質的に 1 次元の問題に対する 3 次元的な解法である



- 個々のトラックの測定誤差を組み込む明確な方法がない
- 計算コストが高く、非線形であり、トラックが vertex に割り当てられて除去される際に完全に再計算が必要

実際には、フーリエフィルタリングされた 3 次元トラック画像をビーム軸上に投影し、得られた 1 次元トラック密度ヒストグラム of 局所極大値をシード位置として抽出していた。図 2.11 では、Run1 と Run2 で使用していた FSMW Mode Finder、Medical Imaging に加え、以下で説明する Gaussian 手法 (GS) の 3 つのトラック密度推定量を比較している。これらの研究から、より単純で透明性の高い方法で、同様に平滑化された 1 次元トラック密度推定量を直接生成することの利点が見出され、Gaussian 手法が開発された。

GS では、ビーム軸に沿ったトラックの密度を使用して vertex の位置を推定する。各トラックは、 $(d_0, z_0)$  を中心とし、1 に正規化された相関のある横方向および縦方向のガウス確率分布  $P(r, z)$  としてモデル化される。この形状は、対応するヘリカルパラメータの共分散行列  $\Sigma$  によって特徴づけられる：

$$\Sigma = \begin{pmatrix} \sigma^2(d_0) & \sigma(d_0, z_0) \\ \sigma(d_0, z_0) & \sigma^2(z_0) \end{pmatrix} \quad (2.4)$$

トラックのシード探索密度  $\rho(z)$  は、ビーム軸上の任意の縦方向位置  $z$  で評価され、 $\rho(z) = P(0, z)$  として定義される。ここで、 $P(r, z)$  は以下のように表される。

$$P(r, z) = \frac{1}{2\pi\sqrt{|\Sigma|}} e^{-\frac{1}{2}((r-d_0), (z-z_0))^T \Sigma^{-1} ((r-d_0), (z-z_0))} \quad (2.5)$$

全体の密度関数  $W(z)$  は、 $z$  の関数として近傍の全てのトラックの和として表される。

$$W(z) = \sum_{i \in \text{tracks}} P_i(0, z) \quad (2.6)$$

この密度の極大値を探索することで、パイラップ密度の高い領域でも計算効率良く vertex のシードを特定する [20]。図 2.11 に、モンテカルロシミュレーション事象におけるこのガウス平滑化されたトラック密度関数の例を示す。他の手法と比べて、GS では各 vertex に対応するピークが明瞭に分離されており、シード位置の特定に適した密度分布が得られていることがわかる。

### Adaptive Multi-Vertex Finder

Adaptive Multi-Vertex Finder (AMVF) は、GS で見つけたシード位置を起点として、トラックを各 vertex に割り当てて vertex 位置を精密にフィッティングする手法である [20]。

図 2.12 に AMVF のアルゴリズムのフローチャートを示す。AMVF は以下のステップを繰り返し実行する。

1. **Seed pool** : 選択されたトラックをシードプールに格納する。
2. **New vertex seed** : シードプールから GS を用いて新たな vertex シード位置を探索する。

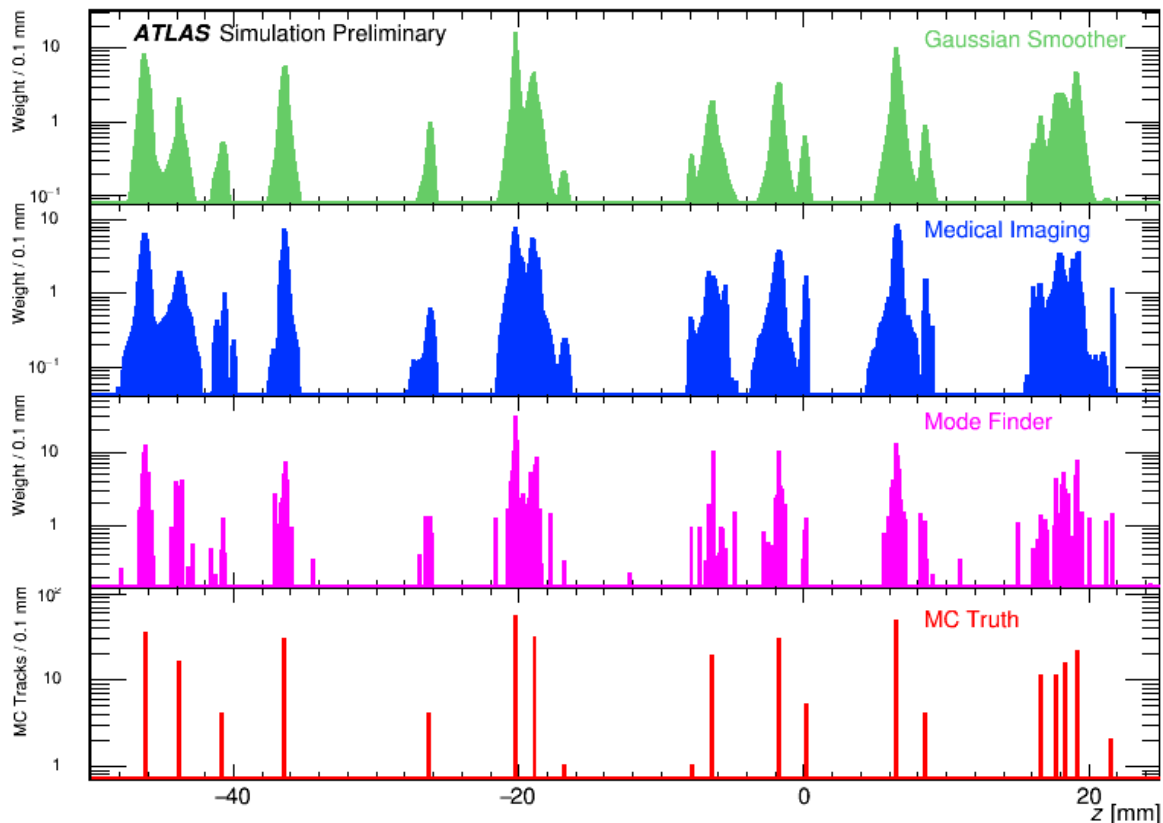


図 2.11: 3つの異なる PV シード探索手法の比較。下段のプロットは、ビームライン上に沿った pp 衝突のシミュレーション位置と、関連するトラック数を示す。上段の3つのプロットは、異なる手法によって計算されたトラック密度推定量を比較している。高い密度は、可能性のある vertex シード位置に対応する。ATLAS は Run1 と Run2 で FSMW Mode Finder を使用していた。Medical Imaging と Gaussian 手法は、どちらも高輝度環境での性能向上のために研究された [20]

3. **Add tracks to fit** : シード位置から、ある  $z$  範囲内で有意性に基づいてトラックを vertex に割り当てる候補として追加する。既に他の vertex に割り当てられたトラックも対象となる。
4. **Fit new vertex candidate** : 追加されたトラックを用いて新しい vertex 候補をフィットする。アニーリングプロセス<sup>\*1</sup>を通じて各トラックの重みを調整することで、最適な vertex とトラックの対応関係を決定する。このとき、以前にフィットされた関連する vertex も同時に再フィットされる。
5. **Remove outliers, compare** : アウトライヤーを除去し、以前にフィットされた vertex

<sup>\*1</sup> トラックと各頂点の整合度に基づく重みを反復的に更新することで、初めは複数頂点への曖昧な割当から始め、最終的に一意な対応関係へ収束させる手法である。4.2.4 節で述べる Softmax の温度アニーリングと同様に、平滑な割当から鋭い割当へ段階的に移行する

と比較する。基準を満たす場合、vertex として受理され、その vertex から出ているとみなされたトラックがシードプールから除去される。一方、基準を満たさず棄却された場合は、同一のシードが繰り返し探索されるのを防ぐため、その候補の核となった最も互換性の高いトラックのみをプールから除去する。

このサイクルは、シードプールに残るトラックが2つ未満になるか、シードが見つからなくなるまで繰り返される。

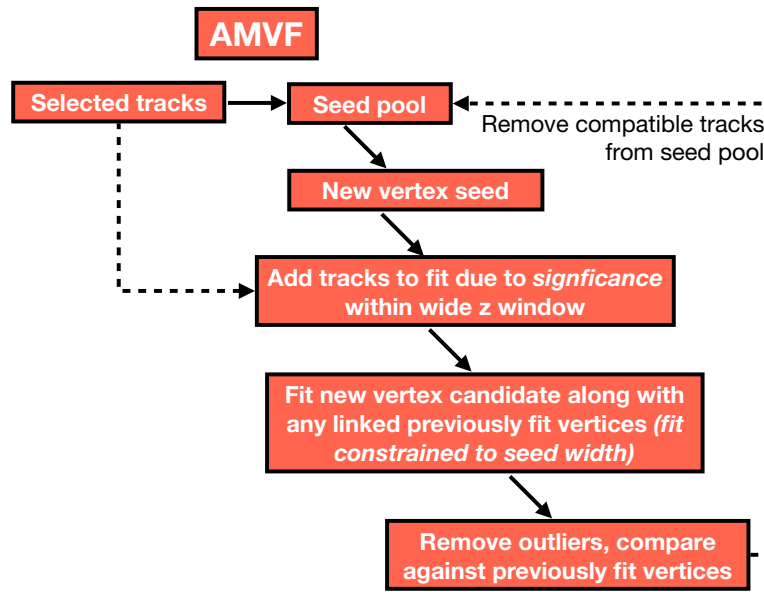


図 2.12: Adaptive Multi-Vertex Finder のアルゴリズムのフローチャート [20]。

### 残差分布

パイラアップ 200 の  $t\bar{t}$  事象においてオフラインアルゴリズムによって再構成された PV の  $z$  座標  $z_{\text{PV}}^{\text{reco}}$  と、真の PV の  $z$  座標  $z_{\text{PV}}^{\text{truth}}$  の残差の分布を図 2.13 に示す。残差分布のフィットには、両側 Crystal Ball 関数 (Double-Sided Crystal Ball function, DSCB) を用いた。DSCB 関数は、中心部をガウス関数で記述し、両側の裾を冪関数で接続した関数であり、以下のように定義される。

$$f(t; \alpha_L, n_L, \alpha_R, n_R) = \begin{cases} A_L \cdot (B_L - t)^{-n_L}, & t < -\alpha_L \\ \exp\left(-\frac{t^2}{2}\right), & -\alpha_L \leq t \leq \alpha_R \\ A_R \cdot (B_R + t)^{-n_R}, & t > \alpha_R \end{cases} \quad (2.7)$$

ここで  $t = (x - \mu)/\sigma$  であり、各パラメータは

$$A_{L,R} = \left(\frac{n_{L,R}}{|\alpha_{L,R}|}\right)^{n_{L,R}} \exp\left(-\frac{|\alpha_{L,R}|^2}{2}\right), \quad B_{L,R} = \frac{n_{L,R}}{|\alpha_{L,R}|} - |\alpha_{L,R}| \quad (2.8)$$

で与えられる。 $\alpha_{L,R}$  はガウス部分から冪関数へ遷移する位置を標準偏差の単位で表したパラメータ、 $n_{L,R}$  は冪関数の指数である。残差分布はガウス関数に比べて裾が広いため、DSCB 関数を用いることで裾部分も含めたフィットが可能となる。

フィットの結果、標準偏差  $\sigma = 6.7 \mu\text{m}$  が得られた。この標準偏差は PV の  $z$  座標の位置分解能に対応し、パイラップ 200 の  $t\bar{t}$  事象における本研究の条件下では、オフライン再構成により約  $7 \mu\text{m}$  の分解能が得られている。

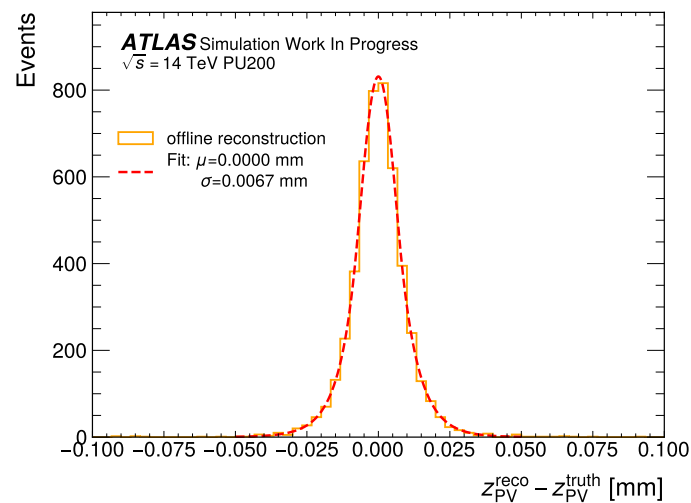


図 2.13: パイラップ 200 の  $t\bar{t}$  事象において、オフラインアルゴリズムで再構成された PV の  $z$  座標残差分布。赤線は DSCB 関数によるフィット結果を示す。

オフライン再構成は高い位置分解能を達成しているが、反復的なフィッティングを要するため計算コストが大きく、高速な処理が求められるトリガー上での適用には検討の余地がある。そこで本研究では、トリガーでの実装を見据えた高速な PV 再構成手法の開発を目指す。次章でまずシンプルなヒストグラムに基づく手法を検討し、その問題点を踏まえて第 4 章で機械学習を用いた改良手法を提案する。

## 第 3 章

# シンプルな PV 再構成手法

本章では、本研究で開発したシンプルな PV 再構成アルゴリズムとその問題点について述べる。

### 3.1 ヒストグラム法

前章で述べたように、トリガーでの実装を見据えた高速な PV 再構成手法として、まずシンプルなヒストグラム法を検討する。以降、単にヒストグラム法と表記する。

ヒストグラム法は、トラックの  $z_0$  座標をもとにヒストグラムを作成する。これは、オフラインアルゴリズムの第一段階である seed finding に対応する操作である。ヒストグラム法では、作成したヒストグラムの最も高い bin を出力するという単純な操作のみで構成される。オフラインの手法が反復計算や複雑な最適化を必要とするのに対し、ヒストグラム法は 1 回の走査で完了するため、計算時間を大幅に削減できる。

本研究では、モンテカルロシミュレーションで生成されたデータを元に再構成されたトラックを用いる。ここで、使用するトラックはオフラインによる飛跡再構成アルゴリズムで再構成されたものである。ヒストグラム法の手法は以下の通りである。

- ヒストグラムの bin 幅  $w_{\text{bin}}$  を設定する
- 横軸を  $z_0$ 、トラックの  $p_T$  をヒストグラムに詰める
- 最も高い bin の中点を PV の  $z$  座標とする

設定するヒストグラムは  $z_0$  を  $-200\text{mm}$  から  $200\text{mm}$  の範囲に設定し、bin 数は表 3.1 に示す 5 通りとする。トリガーでの計算を想定しているため、前章で述べたオフライン再構成の位置分解能 (約  $7\ \mu\text{m}$ ) の約 3 倍にあたる  $0.024\ \text{mm}$  を最も細かい  $w_{\text{bin}}$  とした。

### 3.2 データセット

本研究では、モンテカルロシミュレーションによって生成されたデータを用いて学習および評価を行った。使用したサンプルは、高輝度 LHC 環境を想定したパイルアップ 200 の条件で生成され

表 3.1: ヒストグラムの bin 数と  $w_{\text{bin}}$  の設定

bin 数	$w_{\text{bin}}$ [mm]
1024	0.391
2048	0.195
4096	0.098
8192	0.049
16384	0.024

た  $t\bar{t} \rightarrow \text{all hadron}$  事象、 $Z \rightarrow \mu\mu$  事象である。図 3.1 に、ファインマンダイアグラムを示す。各サンプルについて 5,000 イベントを使用した。以降、 $t\bar{t} \rightarrow \text{all hadron}$  事象を単に  $t\bar{t}$  と表記する。

各サンプルにおける 1 イベントあたりの PV 由来のオフライントラック数の平均値を表 3.2 に、各イベント中の PV 由来のトラック数、 $p_T$  分布を図 3.2 に示す。 $t\bar{t}$  事象では PV 由来のトラック数の平均は 78 本、 $Z \rightarrow \mu\mu$  事象では 35 本と、 $t\bar{t}$  事象の方が多い。 $t\bar{t}$  事象では、生成されたトップクォークが崩壊して複数のジェットを形成し、多くの荷電ハドロンに由来するトラックが PV から生成される。それに対して  $Z \rightarrow \mu\mu$  事象では、生成される荷電粒子が主に 2 本のミュオンと非弾性散乱に付随して生成したハドロンが主であり、PV 由来トラック数が相対的に少ないためである。




図 3.1:  $t\bar{t} \rightarrow \text{all hadron}$  事象 (左)、 $Z \rightarrow \mu\mu$  事象 (右) のファインマンダイアグラム。左図では、t クォークは b クォークと W ボソンに崩壊し、W ボソンが 2 つのクォークに崩壊する。右図では、Z ボソンが 2 つのミュオンに崩壊する。

ある 1 イベントで再構成した例を図 3.3 に示す。この図では可視化のため、bin 数を 256 に設定している。 $p_T$  のヒストグラムにおいて、 $z_0$  のピーク位置が真の PV の  $z$  座標に対応していることがわかる。

表 3.2: 各サンプルにおける 1 イベントあたりの PV 由来トラック数の平均値

サンプル名	PV 由来トラック数の平均値
$t\bar{t}$	79
$Z \rightarrow \mu\mu$	35

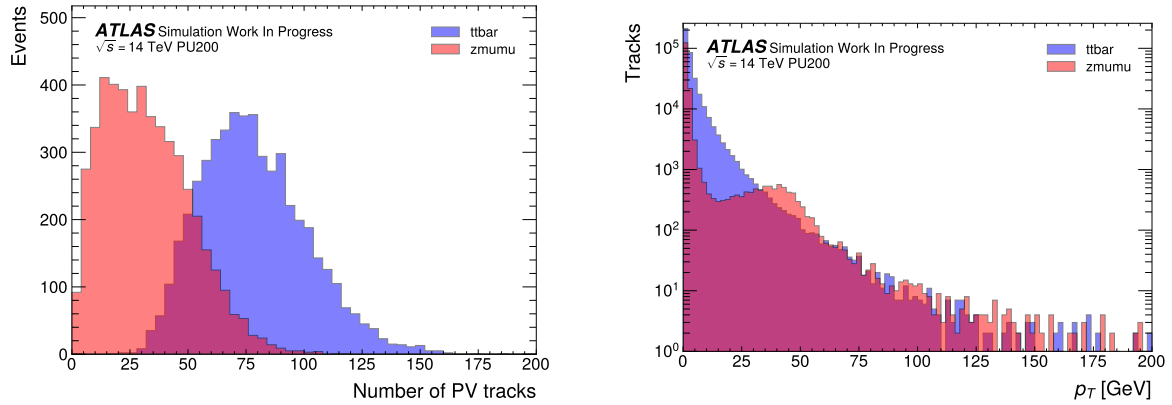


図 3.2:  $t\bar{t} \rightarrow \text{all hadron}$  事象、 $Z \rightarrow \mu\mu$  事象の PV 由来のトラック分布。左はトラック数、右は  $p_T$  分布を示す。45GeV 付近にミューオンのピークが見える。

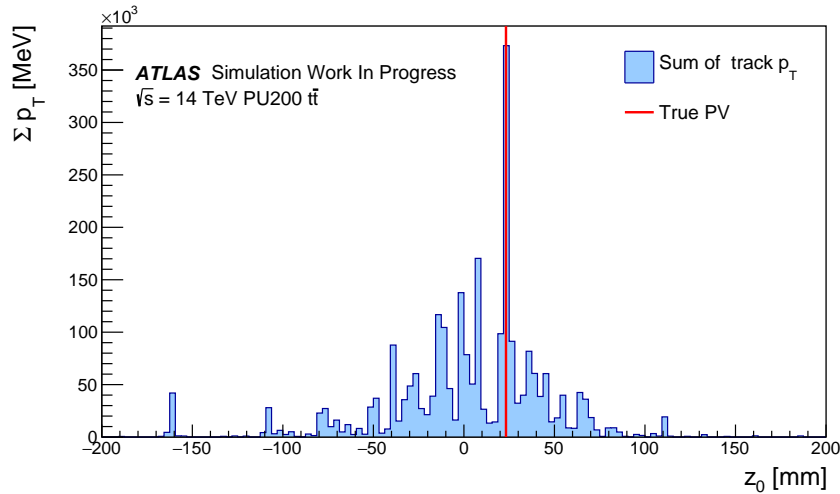


図 3.3: ヒストグラム法による再構成の例。bin 数は 256 であり、赤線が真の PV の  $z$  座標を示す。

### 3.3 性能評価

PV 再構成の性能評価として、残差分布、Efficiency、Purity を用いて評価を行う。

### 3.3.1 残差分布

残差は、再構成された PV の  $z$  座標と真の PV の  $z$  座標との差である。

$$\text{residual} = z_{\text{PV}}^{\text{reco}} - z_{\text{PV}}^{\text{truth}} \quad (3.1)$$

### 3.3.2 Efficiency

Efficiency は、真の PV 位置  $z_{\text{PV}}^{\text{truth}}$  に対して、再構成された PV 位置  $z_{\text{PV}}^{\text{reco}}$  がどの程度正確であるかを示す指標である。具体的には、再構成された PV 位置が真の PV 位置から一定の許容範囲内に収まっているイベントの割合として定義される。

$$\text{Efficiency} = \frac{N(|z_{\text{PV}}^{\text{reco}} - z_{\text{PV}}^{\text{truth}}| \leq w_{\text{bin}})}{N_{\text{total}}} \quad (3.2)$$

ここで、 $N_{\text{total}}$  は全イベント数、 $N(|z_{\text{PV}}^{\text{reco}} - z_{\text{PV}}^{\text{truth}}| \leq w_{\text{bin}})$  は真の PV の  $z$  座標から  $w_{\text{bin}}$  の範囲内に PV の  $z$  座標が再構成されたイベント数である。本研究では、許容範囲をヒストグラムの  $w_{\text{bin}}$  として設定した。再構成された PV 位置はヒストグラムの中点であるため、真の PV 位置が、最大となる bin の隣接する bin の幅の半分までにあることを許容範囲として設定した。これは、トラックの誤差を考慮しているためである。この許容範囲を超えた場合は、再構成が失敗したとみなす。

### 3.3.3 Purity

Purity は、PV 再構成に成功したイベントにおいて、再構成された PV 位置から許容範囲内 ( $\pm w_{\text{bin}}$ ) に存在するトラックのうち、真の PV に由来するトラックの割合を示す指標である。これにより、PV 再構成がどの程度クリーンであるか、すなわちパイルアップ由来のトラックをどの程度排除できているかを評価できる。

$$\text{Purity} = \frac{N_{\text{PV tracks within bin width}}}{N_{\text{all tracks within bin width}}} \quad (3.3)$$

ここで、 $N_{\text{PV tracks within bin width}}$  は再構成された PV 位置から許容範囲内に存在する真の PV 由来のトラック数、 $N_{\text{all tracks within bin width}}$  は同じ許容範囲内に存在する全トラック数である。Purity が高いほど、再構成された PV の近傍 (許容範囲内) が PV 由来のトラックで支配されていることを意味し、フレーバータギングなどの PV に依存する物理量の識別性能の向上につながる。



## 3.4 結果

### 3.4.1 残差分布

bin 数が 1024 の場合における  $t\bar{t}$  事象の残差分布を 図 3.4 に示す。大部分のイベントは、bin 幅に対応する 0.391 mm の範囲内に収まっており、本手法が高い位置分解能で PV を再構成できていることが分かる。この範囲を超えるイベントは、PV の再構成に失敗した事象に対応する。さらに、表示範囲を  $-200$  mm から  $200$  mm に拡張した場合の  $t\bar{t}$ 、 $Z \rightarrow \mu\mu$  事象の残差分布を 図 3.5 に示す。 $t\bar{t}$  事象では残差分布のテールが最も抑制されており、大きな残差を持つイベントの寄与が小さい。一方、 $Z \rightarrow \mu\mu$  事象ではテールが最も大きく、分布が広がっている。

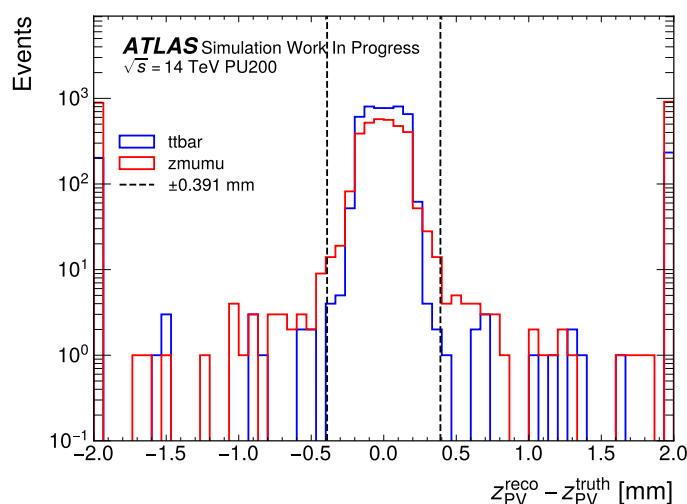


図 3.4: bin 数が 1024 の場合の  $t\bar{t}$  事象と  $Z \rightarrow \mu\mu$  事象における残差分布。点線は  $\pm w_{\text{bin}}$  を示し、左右の最も端の bin は、overflow と underflow を示す。

### 3.4.2 Efficiency と Purity の関係

#### サンプル依存性

$t\bar{t}$  事象、 $Z \rightarrow \mu\mu$  事象におけるヒストグラム法の性能評価結果を 図 3.6 に示す。Efficiency と Purity がともに高い、すなわち図の右上に位置するほど再構成性能が良いことを意味する。ただし、トリガー上ではまず PV を確実に捉えることが優先される場合もあり、Purity を多少犠牲にしてでも高い Efficiency を確保する運用も考えられる。どのサンプルでも、 $w_{\text{bin}}$  を広げるにつれて Efficiency が上昇し、Purity が低下する。これは、 $w_{\text{bin}}$  を広げることで真の PV との差の許容範囲が広がるため再構成の成功率が向上する一方で、許容範囲内により多くのパイルアップ由来のトラックが含まれるからである。




図 3.5: bin 数が 1024 の場合の  $t\bar{t}$  事象、 $Z \rightarrow \mu\mu$  事象の表示範囲を  $-200$  mm から  $200$  mm とした場合の残差分布の比較。

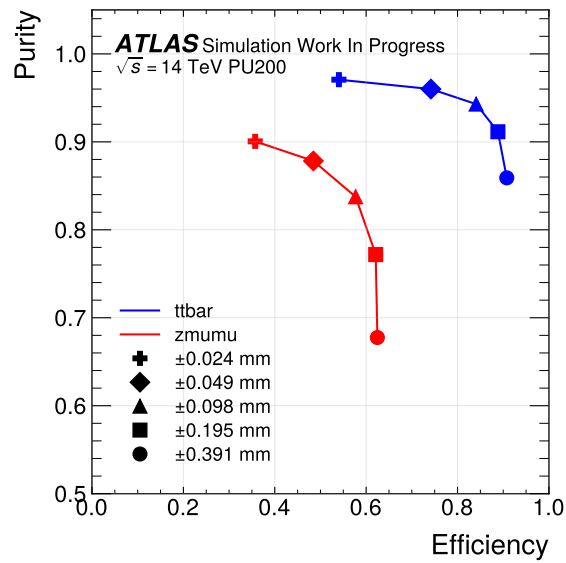


図 3.6: ヒストグラム法における、 $w_{\text{bin}}$  に対する Efficiency と Purity の分布

### オフラインアルゴリズムとの比較

ヒストグラム法とオフラインアルゴリズムとの比較結果を図 3.7 に示す。 $t\bar{t}$  事象、 $Z \rightarrow \mu\mu$  事象ともに、同じ  $w_{\text{bin}}$  では Purity は同程度である。一方で、全ての  $w_{\text{bin}}$  の設定値においてオフラインアルゴリズムに対しては Efficiency が低い。次章で、ヒストグラム法の問題点について述べる。

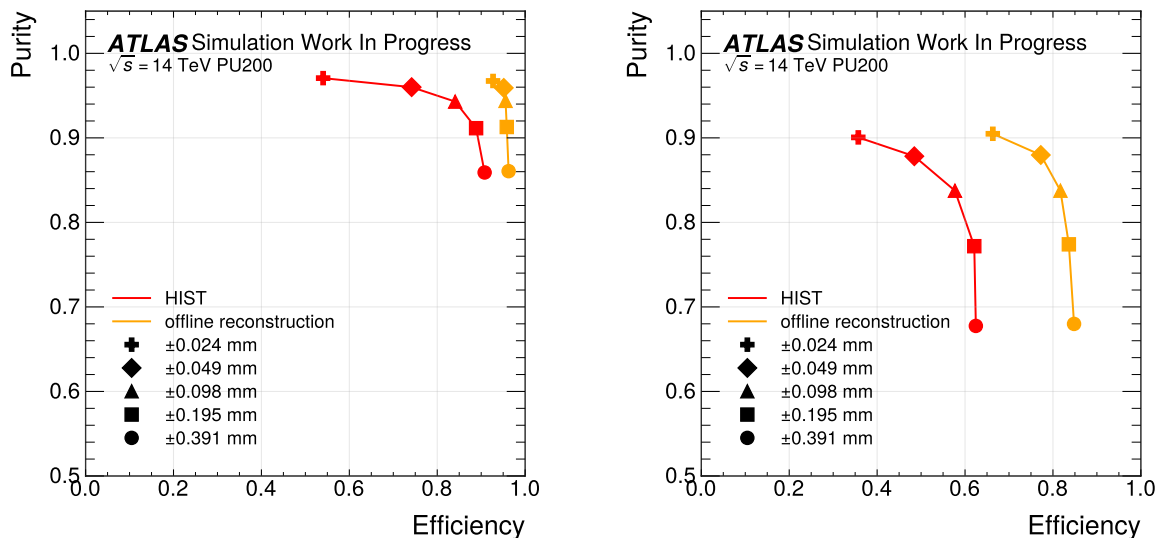


図 3.7:  $t\bar{t} \rightarrow \text{all hadron}$  事象、 $Z \rightarrow \mu\mu$  事象における、ヒストグラム法とオフラインの Efficiency と Purity の分布比較。

### 3.5 ヒストグラム法の問題点

ヒストグラム法の再構成失敗の原因を調べるため、再構成成功時と失敗時において、最大の bin に入ったトラックの中で最も高い  $p_T$  トラックの特性を比較した。図 3.8 に  $Z \rightarrow \mu\mu$  事象、図 3.9 に  $t\bar{t}$  事象における bin 数 1024 ( $w_{\text{bin}} = 0.391 \text{ mm}$ ) と 8192 ( $w_{\text{bin}} = 0.049 \text{ mm}$ ) の場合の  $\chi^2/\text{ndf}$  分布および  $p_T$  分布を示す。 $t\bar{t}$  事象は失敗イベントが少ないため対数で表示している。

$\chi^2/\text{ndf}$  分布を見ると、両事象ともに再構成成功時は 1 付近に集中しており、トラックフィットの品質が高いことを示している。一方、再構成失敗時は成功時に比べて  $\chi^2/\text{ndf}$  の値が大きく、フィット品質の低いトラックが多く含まれている。これは、bin 内で最も高い  $p_T$  を持つトラックの信頼性が低い場合、PV 再構成が失敗しやすいことを示唆している。

$p_T$  分布については、 $Z \rightarrow \mu\mu$  事象の再構成成功時は両方の  $w_{\text{bin}}$  で 45 GeV 付近にピークが見られる。これは、真の PV 由来のミュオンが適切に寄与していることを示す。一方、 $Z \rightarrow \mu\mu$  事象の再構成失敗時の  $p_T$  分布は  $w_{\text{bin}}$  に依存した特徴を示す。 $w_{\text{bin}}$  が広い場合 (bin 数 1024)、低  $p_T$  のトラックが多く含まれる。これは、広い  $w_{\text{bin}}$  により多数の低  $p_T$  トラックが集積し、パイルアップ由来のトラックが支配的になるためである。 $w_{\text{bin}}$  が狭い場合 (bin 数 8192)、45 GeV を超える高  $p_T$  トラックが多く見られる。これは、飛跡再構成アルゴリズムにおいて誤った  $p_T$  値に再構成されたトラックが、狭い bin 内で支配的になるためと推測される。

$t\bar{t}$  事象では、再構成失敗時に  $\chi^2/\text{ndf}$  が大きく、かつ高い  $p_T$  を持つトラックの分布が見られる。これは  $Z \rightarrow \mu\mu$  事象と同様にフィット品質の低いトラックが再構成に影響を与えていることを示す。また、 $Z \rightarrow \mu\mu$  事象で見られたような広い  $w_{\text{bin}}$  での低  $p_T$  トラックの集積が確認できる。

以上の結果から、ヒストグラム法では以下の問題点が明らかになった。

- トラックフィットの品質 ( $\chi^2$ ) を考慮していないため、フィット品質の低いトラックが再構成に寄与する
- $w_{\text{bin}}$  の設定により、パイルアップトラックの影響または飛跡再構成の不確かさの影響が顕著になる
- 単純な  $p_T$  の合計のみで判定するため、方向等の他のトラックパラメータを考慮できない
- $Z \rightarrow \mu\mu$  事象のように PV 由来のトラック数が少ない場合、パイルアップトラックとの弁別が困難になり、再構成性能が低下する

これらの問題を解決するため、次章では機械学習を用いてトラックの重みを考慮する手法を提案する。




図 3.8:  $Z \rightarrow \mu\mu$  事象における再構成成功時と失敗時の最大 bin に含まれる最高  $p_T$  トラックの特性分布。上段: bin 数 1024 ( $w_{\text{bin}} = 0.391$  mm)、下段: bin 数 8192 ( $w_{\text{bin}} = 0.049$  mm)。各図の左:  $\chi^2/\text{ndf}$  分布、右:  $p_T$  分布。再構成成功時はトラック品質が高く、ミュオンの 45 GeV 付近にピークが見られる。失敗時は低品質トラックが多く、 $w_{\text{bin}}$  により  $p_T$  分布の特徴が異なる。




図 3.9:  $t\bar{t}$  事象における再構成成功時と失敗時の最大 bin に含まれる最高  $p_T$  トラックの特性分布。上段: bin 数 1024 ( $w_{\text{bin}} = 0.391$  mm)、下段: bin 数 8192 ( $w_{\text{bin}} = 0.049$  mm)。各図の左:  $\chi^2/\text{ndf}$  分布、右:  $p_T$  分布。再構成失敗時に  $\chi^2/\text{ndf}$  が大きく、高い  $p_T$  を持つトラックの分布が見られる。

## 第 4 章

# 機械学習を用いた陽子対衝突点の再構成

本章では、本研究で使用する機械学習について説明した後に、メインテーマである陽子対衝突点の再構成アルゴリズムの機械学習による改良について述べる。

### 4.1 機械学習

機械学習とは、コンピュータに大量のデータを読み込ませ、データ内に潜むパターンを学習させることで、明示的にプログラムが命令せずとも予測や評価を行うことを可能にする技術である。機械学習は人工知能の一部に位置付けられている技術で、素粒子実験領域でも大量の実験データを扱うところから親和性があり活用が進んでいる。例えば、CMS 実験ではカロリメータ情報に対して機械学習に基づく補正を適用することで、 $Z \rightarrow e^+e^-$  崩壊における質量ピークの再構成精度が従来手法に比べて改善されることが示されている [21]。

#### 4.1.1 ニューラルネットワーク

機械学習には数多くの手法が存在するが、本節では本研究で用いたニューラルネットワークについて述べる。ニューラルネットワークは、人間の脳における神経回路（ニューロン）の構造を模倣した計算モデルで、機械学習の中核を成す技術の一つである。一般に、ニューラルネットワークは入力層、1 層以上の隠れ層、および出力層から構成される。

##### 単層パーセプトロン

パーセプトロンは、ニューラルネットワークの最も基本的な構成要素である。入力ベクトル  $x = (x_1, x_2, \dots, x_n)$  に対し、各入力には重み  $w = (w_1, w_2, \dots, w_n)$  が割り当てられ、加重和にバイアス  $b$  を加えた値が計算される。これに活性化関数  $f(\cdot)$  を適用することで、出力  $y$  が得られる。図 4.1 に、パーセプトロンの概略図を示す。

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (4.1)$$




図 4.1: 単層パーセプトロンの概略図

単層パーセプトロンでは隠れ層を持たず、入力の重み付き和に対して 1 回の変換しか行われないため、複雑な非線形な関係を表現することができない。

### 多層パーセプトロン

パーセプトロンを複数層に積み重ねたものを多層パーセプトロン (Multi-Layer Perceptron: MLP) と呼ぶ。図 4.2 に出力が 1 つの多層パーセプトロンの概略図を示す。多層パーセプトロンでは、入力に対する非線形変換を段階的に組み合わせることができ、単層モデルでは表現不可能であった非線形関係を近似することが可能となる。

多層パーセプトロンの学習には誤差逆伝播法 (backpropagation) が用いられ、出力と教師データとの差に基づいて重みおよびバイアスが反復的に更新される。本研究で用いたモデルも、この多層パーセプトロンの枠組みに基づいて構築されている。

### 活性化関数

活性化関数は、各ニューロンの出力に非線形性を導入するための関数であり、ニューラルネットワークが複雑な非線形関係を表現する上で重要な役割を果たす。活性化関数が  $f(x) = ax + b$  のような線形関数である場合、複数の層を重ねても各層の線形変換は合成されて単一の線形変換に帰着される。そのため、多層構造であってもネットワーク全体としては線形モデルと等価となり、複雑な非線形関係を学習することができない。一方で、非線形な活性化関数を導入することで、多層パーセプトロンは単一の線形変換では記述できない複雑な入力-出力関係を学習・近似することが可能となる。

代表的な活性化関数として、シグモイド関数、双曲線正接関数、および ReLU (Rectified Linear Unit) 関数が挙げられる。ReLU 関数は正の入力に対して勾配が一定であり、シグモイド関数など




図 4.2: 出力が 1 つの多層パーセプトロンの概略図

に見られる飽和領域を持たない。そのため、誤差逆伝播時における勾配消失問題\*1を緩和できるほか、計算効率が高いという利点を持つ。本研究では、これらの利点から、隠れ層の活性化関数として ReLU 関数を用いた。ReLU 関数は次式で定義される。

$$f(x) = \max(0, x) \quad (4.2)$$

Softmax 関数は、主に分類問題において出力層の活性化関数として用いられる関数で、ネットワークの出力を確率として解釈可能な形に正規化する役割を持つ。 $K$  個のクラスのいずれかに分類する問題において、出力層の各ユニットの入力を  $z_i$  ( $i = 1, \dots, K$ ) とすると、Softmax 関数は次式で定義される。

$$\text{Softmax}(z_i) = \frac{\exp(z_i)}{\sum_{j=1}^K \exp(z_j)} \quad (4.3)$$

このとき、各出力は 0 から 1 の範囲に収まり、全クラスに対する出力の和は 1 となる。したがって、Softmax 関数の出力は各クラスに属する確率として解釈することができる。Softmax 関数は、出力間の相対的な大小関係を強調する性質を持ち、入力値の差が大きいほど、最大の値に対応するクラスの確率が高くなる。この性質により、分類問題において最も尤もらしいクラスを選択することが可能である。

本研究では、前章で述べたような、各トラックの  $z_0$  のヒストグラムの各 bin に対して Softmax

\*1 深い層を持つニューラルネットワークにおいて、誤差逆伝播時に勾配が層を遡るごとに減衰し、入力層に近い層では勾配がほぼゼロになってしまう問題。シグモイド関数などでは入力値が大きい領域で微分がゼロに近づくため、この問題が顕著になる。



による重み付けを行い、出力された各 bin の値の加重平均を取ることで、 $z_0$  のピークの位置を取得する。この操作を微分可能な形で実現することにより、誤差逆伝播による学習が可能となる。

また、Softmax 関数の鋭さを制御するため、温度パラメータ  $T$  を導入した。温度パラメータを用いた Softmax 関数は次式で表される。

$$\text{Softmax}(z_i/T) = \frac{\exp(z_i/T)}{\sum_{j=1}^K \exp(z_j/T)} \quad (4.4)$$

温度が高いと Softmax の出力が平滑化され、温度が低いと最大値により大きな重みが与えられる。この温度パラメータを学習過程で調整することで、探索と収束のバランスを取ることができる。

### 損失関数

損失関数は、ニューラルネットワークの出力と教師データとの不一致を定量的に評価するための関数であり、学習の目的関数として用いられる。学習過程では、この損失関数を最小化するようにネットワークのパラメータが更新される。

回帰問題において広く用いられる損失関数の一つに平均二乗誤差 (Mean Squared Error: MSE) がある。MSE は次式で定義される。

$$\mathcal{L} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4.5)$$

ここで  $y_i$  は教師データ、 $\hat{y}_i$  はモデルの出力、 $N$  はデータ数を表す。本研究では、予測値と真値との差を評価する目的から、この損失関数を用いた。

### 最適化手法

ニューラルネットワークの学習では、損失関数の勾配に基づいてパラメータを更新する勾配降下法が用いられ、誤差逆伝播法によって計算された勾配を用いて重みおよびバイアスが反復的に更新される。本研究では、学習率の自動調整機構を持ち、安定した収束が得られる最適化手法として Adam (Adaptive Moment Estimation) を採用した。Adam は、各パラメータに対する勾配の 1 次モーメント (平均) と 2 次モーメント (分散) を移動平均として推定し、それらに基づいて更新量を適応的に調整することで、学習の効率化と収束性の向上を実現している。

### 過学習と早期終了

ニューラルネットワークは表現能力が高い一方で、学習データに過度に適合し、未知のデータに対する性能が低下する過学習 (overfitting) が生じやすい。過学習の発生は、学習データに対する損失が減少し続ける一方で、検証用データに対する損失が増加に転じることで確認できる。

本研究では、過学習を抑制するために、学習とは独立な検証用データを用いてモデルの性能を監視し、検証損失がある基準を超えて改善しなくなった時点で学習を終了する早期終了 (early stopping) を採用した。この手法により、学習データへの過度な適合を防ぎ、汎化性能の高いモデルを得ることができる。

## 4.2 機械学習を用いた再構成手法

ヒストグラム法による再構成手法は、高速であるものの、使用するトラックの品質に依存してしまうため、誤って高い横運動量を持ったトラックの影響を大きく受ける可能性がある。そこで、本研究では機械学習を用いてトラックを重みづけし、再構成精度の低い飛跡の重みを小さくすることによりその影響を減らす再構成手法を開発した。

### 4.2.1 学習モデル

今回の学習モデルを図 4.3 に示す。1 イベント内の各トラックに対して、MLP による重み付けを行い、ヒストグラムを作成する。ヒストグラムの各 bin の値に対して、Softmax による重み付けを行い、その加重平均を取ることで、ピーク付近の位置を微分可能な形で取得する。

MLP の入力は、各トラックの再構成時に求められた以下の 7 個のパラメータである。

- $p_T$ : 横運動量
- $\eta$ : 擬ラピディティ
- $d_0$ : 飛跡のビーム軸に対する最近接点の R 座標方向の距離
- $\phi$ : 方位角
- $\chi^2/\text{ndf}$ : カイ二乗値を自由度で割った値
- $\sigma_{d_0}$ :  $d_0$  の誤差
- $\sigma_{z_0}$ :  $z_0$  の誤差

MLP は、トラックの運動学的な情報 ( $p_T$ ,  $\eta$ ,  $\phi$ )、幾何学的な情報 ( $d_0$ )、および再構成品質を表す情報 ( $\chi^2/\text{ndf}$ ,  $\sigma_{d_0}$ ,  $\sigma_{z_0}$ ) を総合的に学習し、各トラックが PV に由来する確からしさを表す重みを出力する。ヒストグラム法では横運動量のみを用いていたため、誤って高い  $p_T$  を持って再構成されたトラックの影響を大きく受けていた。本手法では、トラックの多次元な特徴を考慮することで、より信頼性の高いトラックを適切に重み付けし、高精度な PV の再構成を実現する。




図 4.3: 学習モデル

## 4.2.2 データセット

### 使用サンプル

本研究では、3.2節で述べた  $t\bar{t}$ 、 $Z \rightarrow \mu\mu$  サンプルで学習、性能評価を行った。また、モデルの汎化性能を評価するため、学習に使用していない  $HH \rightarrow b\bar{b}\gamma\gamma$  事象での再構成性能を評価した。これは、学習過程と異なる物理過程においても PV 再構成が適切に機能するかを検証するための評価である。トリガー上での性能を評価するため、Run 3 検出器条件でシミュレートされた  $t\bar{t}$  サンプルでも学習を行い、Run 3 条件下での  $t\bar{t}$  事象および  $HH \rightarrow b\bar{b}\gamma\gamma$  事象における性能評価も実施した。

### データ分割

各サンプルを学習用データ 70,000 イベント、検証用データ 15,000 イベントに分割した。データ分割には毎回同じランダムシードを用いて再現性を確保している。学習用データはモデルのパラメータ更新に使用し、検証用データは学習過程における過学習の監視と早期終了の判定に用いた。最終的な性能評価は、学習に使用していない 5,000 イベントに対して行った。 $t\bar{t}$ 、 $Z \rightarrow \mu\mu$  サンプルでは、3.2節と同じデータを用いた。

### 前処理

入力特徴量の前処理として、 $z_0$  以外の 7 つの特徴量 ( $\eta$ 、 $\phi$ 、 $p_T$ 、 $\chi^2/\text{ndf}$ 、 $d_0$ 、 $\sigma_{d_0}$ 、 $\sigma_{z_0}$ ) に対して StandardScaler による標準化を適用した。StandardScaler は平均 0、標準偏差 1 に特徴量を正規化する手法であり、学習用データで計算した平均と標準偏差を用いて検証用データおよび評価用データも同様に変換した。 $z_0$  については、ヒストグラム化の際に元のスケール (単位: mm) が必要であるため、標準化を行わずそのまま使用した。

さらに、学習時に勾配が過度に大きくなる勾配爆発 (gradient explosion) を防ぐため、勾配クリッピング (gradient clipping) を導入した。これは、勾配のノルムが一定値を超えた場合にスケールリングして制限する手法であり、学習の安定化に寄与する。

また、イベントごとにトラック数が異なるため、バッチ処理時には最大トラック数に合わせてパディングを行った。パディング値として  $z_0$  の範囲外の値 ( $10^9$  mm) を用い、ヒストグラム化の際にこれらのパディングトラックが寄与しないようにした。

## 4.2.3 損失関数

本研究では、予測された PV の  $z$  座標と真の PV の  $z$  座標との差を直接最小化するため、損失関数として平均二乗誤差 (MSE) を採用した。 $y_i$  を真の PV の  $z$  座標、 $\hat{y}_i$  をモデルによって予測された PV の  $z$  座標とすると、損失関数は式 (4.5) を用いて計算される。

## 4.2.4 学習の詳細

### ハイパーパラメータ

学習におけるハイパーパラメータは以下の通りである。エポック数は、学習データ全体を1回学習する単位、バッチサイズは学習時に一度に処理するデータ数、学習率はパラメータ更新時の勾配に対する係数を表す。

- 最大エポック数: 150
- バッチサイズ: 128
- 学習率: 0.0001
- ヒストグラムの bin 数: 1024, 2048, 4096, 8192, 16384 の 5 通り
- ヒストグラムの  $z_0$  範囲: -200 mm から 200 mm

### 温度パラメータのアニーリング

式 (4.4) で導入した温度パラメータ  $T$  を用いて、学習過程における探索と収束のバランスを制御した。本研究では Softmax を用いてヒストグラムのピーク位置を特定しているが、温度が低すぎると出力が過度に鋭敏になり、わずかなパラメータの変化で全く異なる bin を指してしまうため、学習が不安定になる。そのため、学習の初期段階では温度を高く設定し、Softmax の出力を平滑化することで安定した学習を実現する。学習が進むにつれて温度を下げることで、ピーク位置をより正確に特定できるようにした。

具体的には、Cosine Annealing を用いて初期温度 1.0 から最終温度 0.05 まで 30 エポックかけて減衰させた。Cosine Annealing は、温度を滑らかに減衰させる手法であり、次式で定義される。

$$T(t) = T_{\text{final}} + \frac{T_{\text{init}} - T_{\text{final}}}{2} \left( 1 + \cos \left( \frac{\pi t}{t_{\text{max}}} \right) \right) \quad (4.6)$$

ここで、 $t$  は現在のエポック数、 $t_{\text{max}}$  はアニーリング期間 (30 エポック)、 $T_{\text{init}} = 1.0$ 、 $T_{\text{final}} = 0.05$  である。 $t$  が 0 から  $t_{\text{max}}$  まで増加すると、 $\cos \left( \frac{\pi t}{t_{\text{max}}} \right)$  が 1 から -1 へ単調減少するため、温度は  $T_{\text{init}}$  から  $T_{\text{final}}$  へ滑らかに減衰する。30 エポック以降は、次式に従い温度を周期的に変動させることで、過度な鋭敏化を避けた。

$$T(t) = T_{\text{final}} + 0.02 \left( 1 + \cos \left( \frac{\pi(t - t_{\text{max}})}{10} \right) \right) \quad (4.7)$$

これにより温度は  $T_{\text{final}} = 0.05$  から 0.09 の範囲を周期 20 エポックで振動する。

### 早期終了

過学習を防ぐため、前節で述べた早期終了を用いた。検証用データに対する損失が 30 エポック連続で改善しない場合に学習を終了する設定とした。ただし、学習の初期段階での打ち切りを避けるため、最低 25 エポックは必ず学習を継続するようにした。改善の判定には、損失の変化が  $10^{-4}$

以上であることを基準とした。最終的なモデルとして、検証用データに対する損失が最小となったエポックのモデルパラメータおよび温度パラメータを保存し、評価に使用した。

## 第 5 章

# 機械学習手法の性能評価

本章では、機械学習による再構成手法の性能評価を行う。まず、評価対象と同じ種類の物理サンプルで学習したモデルによる性能を評価し、ヒストグラム法およびオフラインアルゴリズムとの比較を行う。次に、複数の物理サンプルを混合して学習した場合や、学習に用いていない物理サンプルに適用した場合の汎化性能を検証する。

### 5.1 $t\bar{t}$ , $Z \rightarrow \mu\mu$ 事象における性能評価

#### 5.1.1 学習過程

本節では、 $t\bar{t}$  事象および  $Z \rightarrow \mu\mu$  事象それぞれについて、同じ種類の物理サンプルで学習したモデルを用いて性能評価を行う。学習は表 3.1 に示す bin 数ごとに独立に行った。パイルアップ 200 における  $t\bar{t}$  事象の学習過程での損失関数の推移を図 5.1 に、 $Z \rightarrow \mu\mu$  事象の推移を図 5.2 に示す。

$t\bar{t}$  事象では、学習損失と検証損失がともに安定して減少し、過学習を起こすことなく収束している。一方、 $Z \rightarrow \mu\mu$  事象では、学習損失は順調に減少するものの、検証損失が大きく振動している。

この振動は、 $Z \rightarrow \mu\mu$  事象の特性に起因すると考えられる。 $Z \rightarrow \mu\mu$  事象では、 $Z$  ボソンから崩壊した 2 つのミュオントラックに高い重みを付与し、パイルアップ由来の多数のトラックの重みを抑制する必要がある。しかし、PV に由来する信号トラック数が  $t\bar{t}$  事象に比べて少ないため、学習過程においてモデルパラメータのわずかな変化が個々のトラックの重みを大きく変動させやすいと推測される。その結果、Softmax によるピーク位置の選択がヒストグラム上の異なる bin に切り替わる事象が多く発生し、損失の不連続な変化が生じていると考えられる。

本研究では、温度パラメータのアニーリング完了後の 20 エポック以降で検証損失が最小となったモデルを採用し、性能評価に用いている。

#### 5.1.2 残差分布

3.4.1 節で評価したヒストグラム法の性能と比較する。ここでは、 $w_{\text{bin}}$  が広い場合の例として bin 数 1024,  $w_{\text{bin}}$  が狭い場合の例として bin 数 8192 を取り上げる。

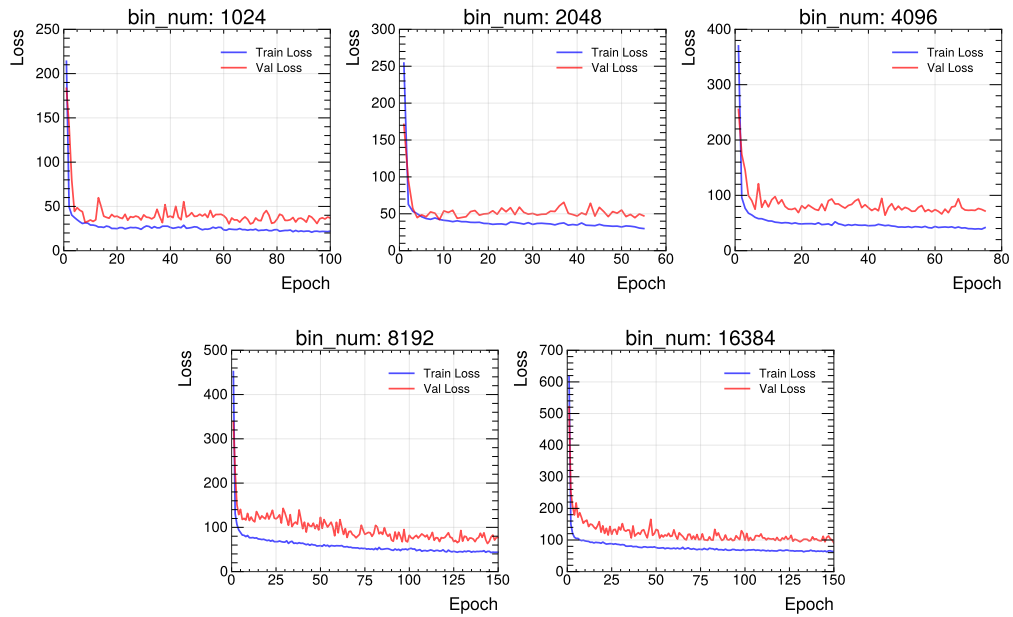


図 5.1: パイルアップ 200、 $t\bar{t}$  事象における損失関数の推移

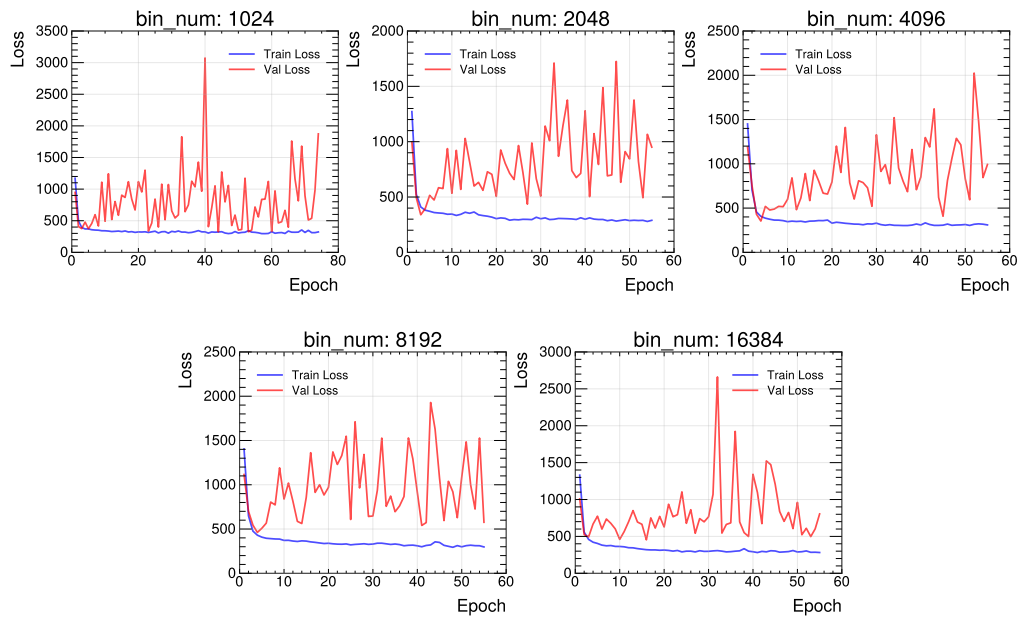



図 5.2: パイルアップ 200、 $Z \rightarrow \mu\mu$  事象における損失関数の推移


### bin 数 1024 の場合

bin 数 1024 の場合の結果を図 5.3 に示す。各図の (a) と (c) は 3.4.1 節と同じ  $-2$  mm から  $2$  mm の範囲、(b) と (d) は  $-200$  mm から  $200$  mm の範囲を示している。(a) と (c) を見ると、機械学習を用いることでヒストグラム法に比べて残差の中心ピークが高くなっており、 $w_{\text{bin}} = 0.391$


mm 内に収まるイベント数が増加している。ただし、オフラインアルゴリズムと比較すると、分布が細く、分解能はオフラインより劣る。一方、(b) と (d) の全範囲を見ると、機械学習手法は残差のテールを大きく抑制しており、大きな残差を持つイベントがヒストグラム法やオフラインアルゴリズムに比べて顕著に減少している。




(a)  $t\bar{t}$  (-2 mm から 2 mm)



(b)  $t\bar{t}$  (-200 mm から 200 mm)



(c)  $Z \rightarrow \mu\mu$  (-2 mm から 2 mm)



(d)  $Z \rightarrow \mu\mu$  (-200 mm から 200 mm)


図 5.3: bin 数が 1024 の場合の残差分布。ヒストグラム法、機械学習、オフラインの 3 つの手法を比較している。点線は  $w_{\text{bin}}$  を示し、左右の最も端の bin は、overflow と underflow を示す。上段は  $t\bar{t}$  事象、下段は  $Z \rightarrow \mu\mu$  事象。左列は -2 mm から 2 mm、右列は -200 mm から 200 mm の範囲。

#### bin 数 8192 の場合


bin 数 8192 の場合の結果を図 5.4 に示す。各図の (a) と (c) は  $w_{\text{bin}} = 0.049$  mm に合わせて -0.5 mm から 0.5 mm の範囲、(b) と (d) は -200 mm から 200 mm の範囲を示している。(a) と (c) を見ると、 $t\bar{t}$  事象と  $Z \rightarrow \mu\mu$  事象のどちらにおいても、 $w_{\text{bin}}$  が狭い場合でも機械学習手法




はヒストグラム法に比べて  $w_{\text{bin}}$  内に収まるイベント数が増加している。オフラインアルゴリズムと比較すると、オフラインが最もテールが小さく、0.5 mm の分解能ではオフラインアルゴリズムには再構成性能が及ばない結果となった。しかし、(b) と (d) の全範囲を見ると、機械学習手法は残差のテールをオフラインアルゴリズムよりも効果的に抑制しており、大きく PV の位置を誤るイベント数を大幅に削減できている。




(a)  $t\bar{t}$  (-0.5 mm から 0.5 mm)



(b)  $t\bar{t}$  (-200 mm から 200 mm)



(c)  $Z \rightarrow \mu\mu$  (-0.5 mm から 0.5 mm)



(d)  $Z \rightarrow \mu\mu$  (-200 mm から 200 mm)

図 5.4: bin 数が 8192 の場合の残差分布。ヒストグラム法、機械学習、オフラインの 3 つの手法を比較している。点線は  $w_{\text{bin}}$  を示し、左右の最も端の bin は、overflow と underflow を示す。上段は  $t\bar{t}$  事象、下段は  $Z \rightarrow \mu\mu$  事象。左列は -0.5 mm から 0.5 mm、右列は -200 mm から 200 mm の範囲。

### 5.1.3 Efficiency と Purity

Efficiency と Purity の分布を図 5.5 に示す。 $t\bar{t}$  事象と  $Z \rightarrow \mu\mu$  事象のどちらにおいても、ヒストグラム法に比べて Efficiency が上昇しており、機械学習によって適切にトラックに重み付けを行い、再構成ができています。オフラインアルゴリズムと比較すると、許容範囲が狭い場合はオフラインに比べて Efficiency が低いですが、許容範囲を広げることでオフラインに比べても高い Efficiency を示している。許容範囲  $\pm 0.391$  mm (bin 数 1024) における Efficiency は、 $t\bar{t}$  事象で機械学習が 0.993、オフラインが 0.962、 $Z \rightarrow \mu\mu$  事象で機械学習が 0.921、オフラインが 0.848 である。

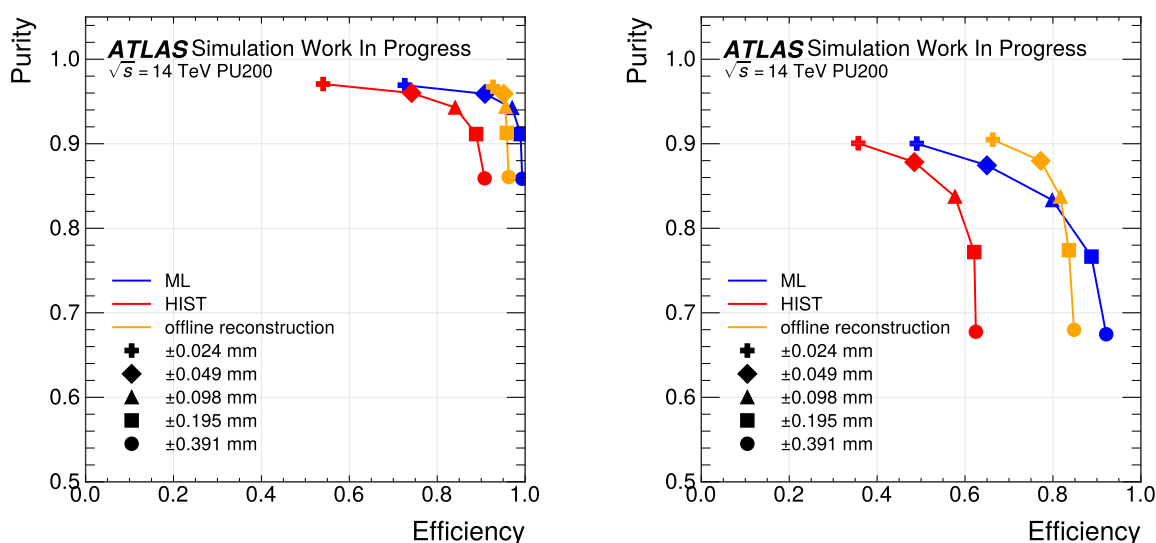


図 5.5:  $t\bar{t}$  事象、 $Z \rightarrow \mu\mu$  事象における、Efficiency と Purity の分布比較。

### 5.1.4 特徴量分布

機械学習モデルが各トラックに付与する重みと、入力特徴量との関係を調べる。図 5.6 および図 5.7 に、bin 数 1024 における 7 つの入力特徴量 ( $\eta$ ,  $\phi$ ,  $p_T$ ,  $\chi^2/\text{ndf}$ ,  $d_0$ ,  $\sigma(d_0)$ ,  $\sigma(z_0)$ ) に対するモデル出力の重み  $\langle w \rangle$  の平均値を示す。各特徴量の値域を等間隔に 40 分割し、各 bin に含まれるトラックの重みの平均値を算出している。帯は標準誤差を表す。青色は PV 由来のトラック、赤色はパイルアップ由来のトラックを示す。PV 由来のトラックはパイルアップ由来のトラックに比べて数が少ないため、標準誤差が大きい。

どちらの事象でも、PV 由来のトラックがパイルアップ由来のトラックより大きい重みを持つ。また、PV 由来のトラックであっても、 $\chi^2/\text{ndf}$ ,  $d_0$ ,  $\sigma(d_0)$ ,  $\sigma(z_0)$  が大きいトラックには小さい重みが付与されており、ヒストグラム法で課題であったトラックの品質を考慮した重み付けが実現できている。 $Z \rightarrow \mu\mu$  事象では、PV 由来とパイルアップ由来のトラックの重みの差が  $t\bar{t}$  事象より大

きいなど、学習する事象によって異なる傾向を示している。

また、図 5.8 および図 5.9 に、 $p_T$  と  $\chi^2/\text{ndf}$  の 2 次元平面上における重みの平均値を示す。 $p_T$  は 0–200 GeV、 $\chi^2/\text{ndf}$  は 0–10 の範囲をそれぞれ  $40 \times 40$  の bin に分割し、各 bin に含まれるトラックの重みの平均値をカラーマップで表示している。左から全トラック、PV 由来のトラック、パイルアップ由来のトラックの順に示している。 $p_T$  が大きいトラックであっても  $\chi^2/\text{ndf}$  が大きく品質の低いトラックには小さい重みが付与されており、トラックの品質を考慮した重み付けが確認できる。

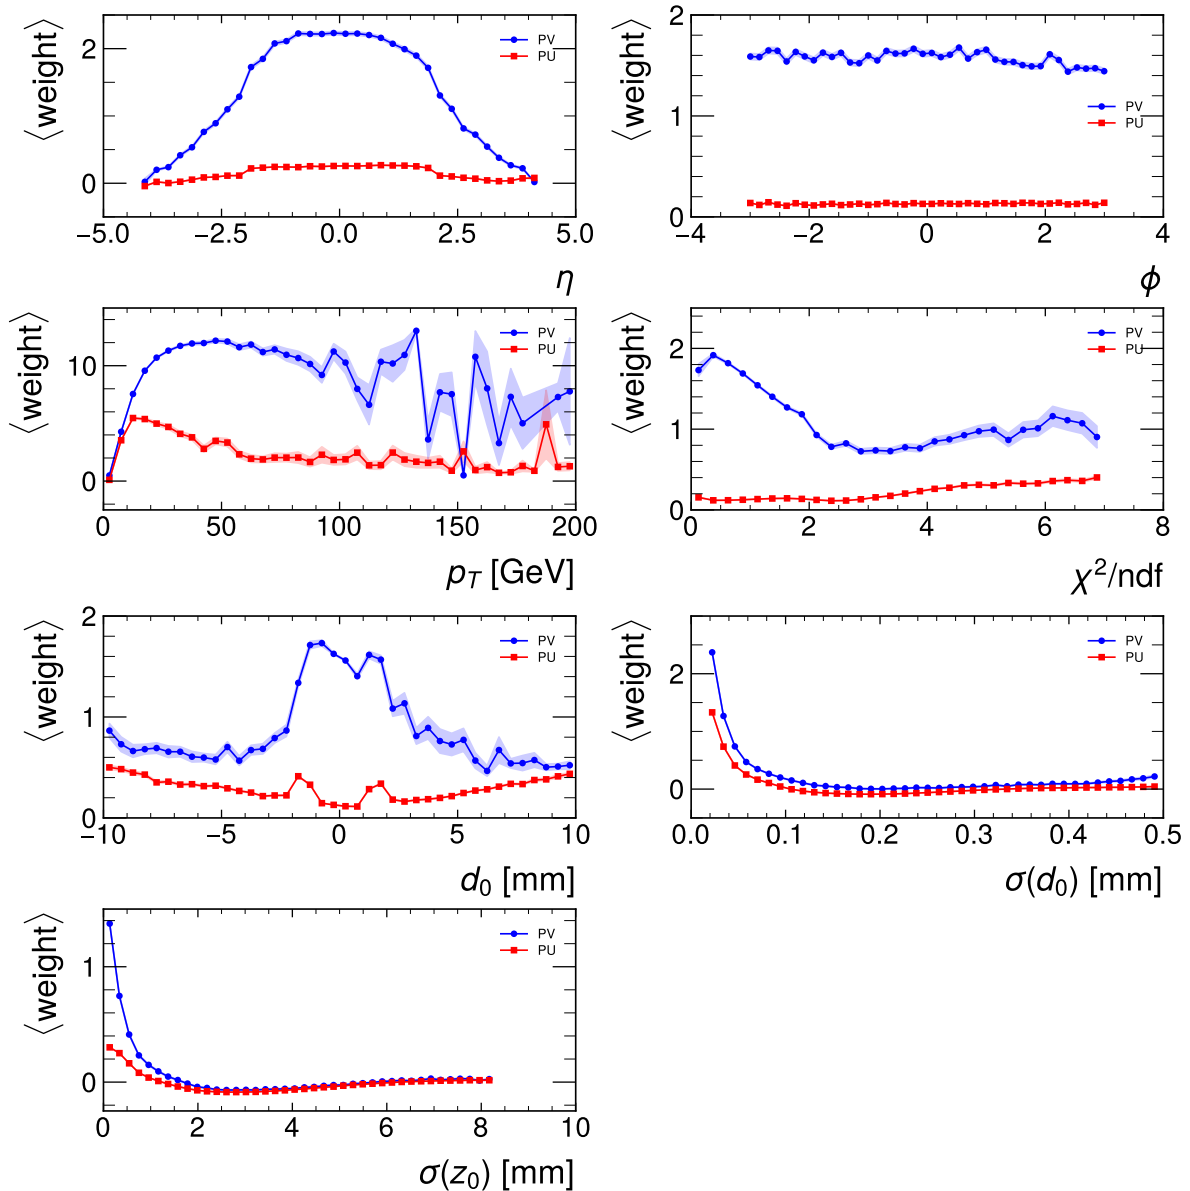


図 5.6:  $t\bar{t}$  事象 (bin 数 1024) における各入力特徴量に対する重みの平均値。青色が PV 由来のトラック、赤色がパイルアップ由来のトラック。帯は標準誤差を示す。

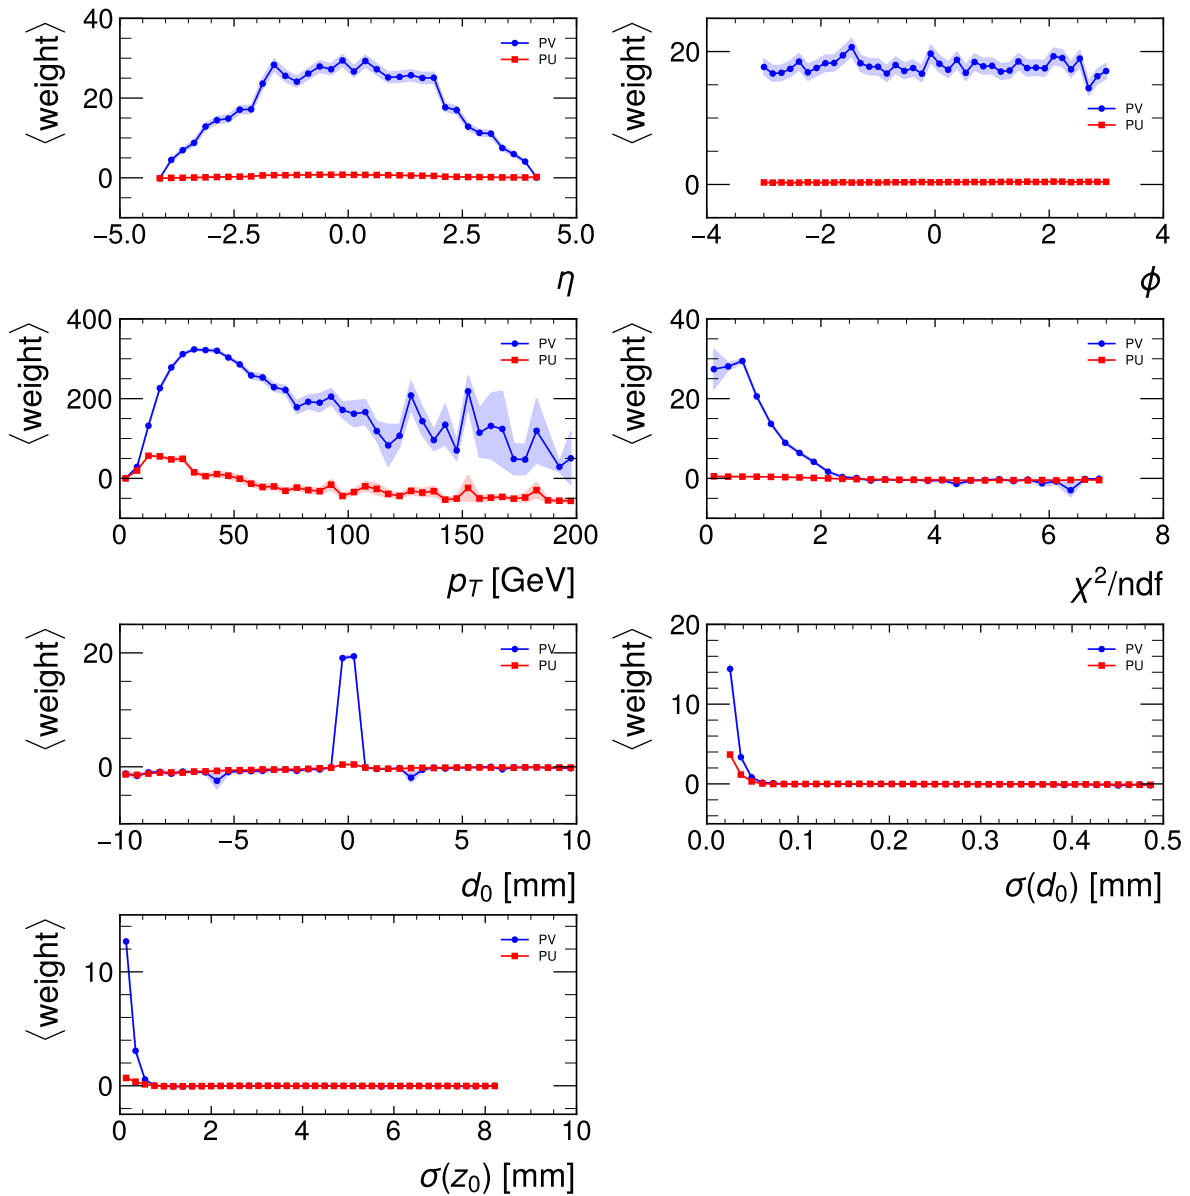


図 5.7:  $Z \rightarrow \mu\mu$  事象 (bin 数 1024) における各入力特徴量に対する重みの平均値。青色が PV 由来のトラック、赤色がパイルアップ由来のトラック。帯は標準誤差を示す。




図 5.8:  $t\bar{t}$  事象 (bin 数 1024) における  $p_T$ - $\chi^2/\text{ndf}$  平面上の重みの平均値。左から全トラック、PV 由来のトラック、パイルアップ由来のトラックを示す。




図 5.9:  $Z \rightarrow \mu\mu$  事象 (bin 数 1024) における  $p_T$ - $\chi^2/\text{ndf}$  平面上の重みの平均値。左から全トラック、PV 由来のトラック、パイルアップ由来のトラックを示す。

## 5.2 混合学習による性能評価

前節までは、 $t\bar{t}$  事象と  $Z \rightarrow \mu\mu$  事象をそれぞれ独立に学習していた。本節では、実際のアルゴリズムへの応用を見据えた汎化性能の検証のため、両事象を半分ずつ混合して学習を行い、性能評価を行う。学習に用いるデータ量の合計は前節までと同量とする。

### 5.2.1 学習過程

学習過程における損失関数の推移を図 5.10 に示す。 $t\bar{t}$  事象のみで学習した場合 (図 5.1) に比べて損失の値は大きい、 $Z \rightarrow \mu\mu$  事象のみで学習した場合 (図 5.2) に見られた検証損失の大きな振動は抑制されており、安定した学習が実現できている。

### 5.2.2 Efficiency と Purity

混合学習したモデルを  $t\bar{t}$  事象および  $Z \rightarrow \mu\mu$  事象の評価用データに適用した結果を図 5.11 に示す。前節で評価した、各事象を単独で学習したモデルとの比較も示している。 $t\bar{t}$  事象については、混合学習により単独学習モデルに比べて Efficiency が低下するものの、許容範囲を広げることで依然としてオフラインより高い Efficiency を示している。 $Z \rightarrow \mu\mu$  事象では、単独学習モデルに対する Efficiency の低下は  $t\bar{t}$  事象ほど顕著ではなく、同様に許容範囲を広げることでオフラインより高い Efficiency を達成している。許容範囲  $\pm 0.391$  mm (bin 数 1024) における Efficiency は、 $t\bar{t}$  事象で 0.983、 $Z \rightarrow \mu\mu$  事象で 0.917 である。

## 5.3 $HH \rightarrow b\bar{b}\gamma\gamma$ 事象における性能評価

更なる汎用化の検証のため、 $t\bar{t}$  事象で学習したモデルを  $HH \rightarrow b\bar{b}\gamma\gamma$  事象のシミュレーションデータに適用した性能評価を行う。オフラインアルゴリズムと比較した残差分布と Efficiency、

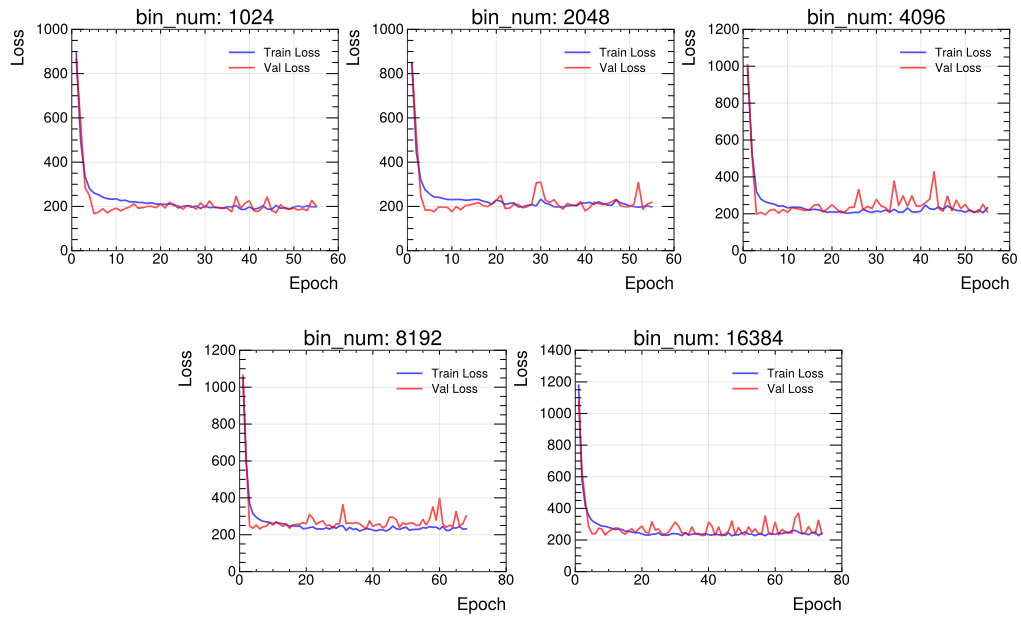


図 5.10: パイルアップ 200、 $t\bar{t}$  事象と  $Z \rightarrow \mu\mu$  事象の混合学習における損失関数の推移

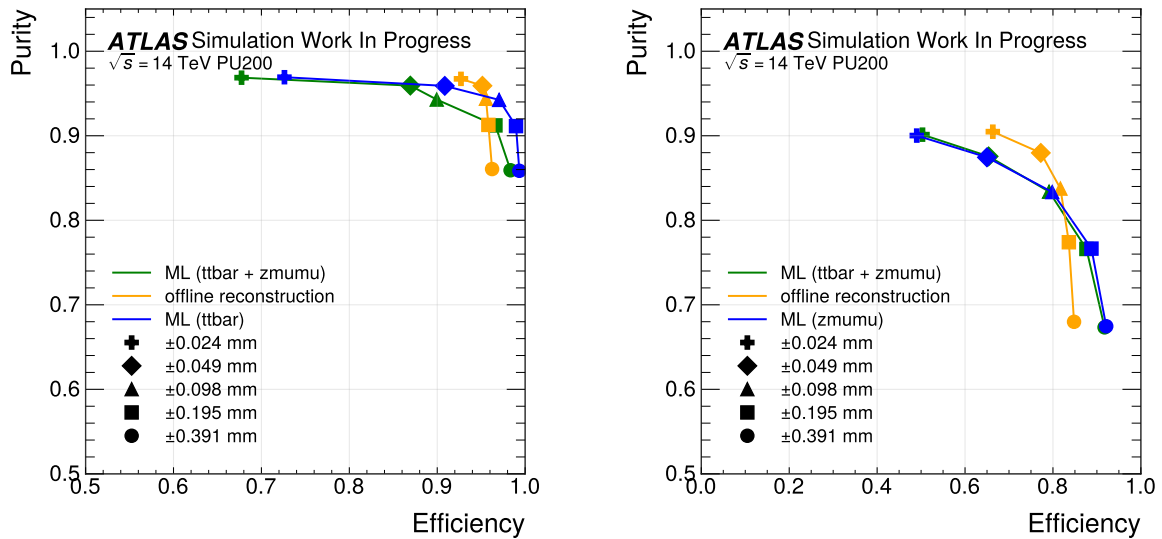


図 5.11: 混合学習モデルの性能評価。左図は  $t\bar{t}$  事象、右図は  $Z \rightarrow \mu\mu$  事象の評価用データに適用した結果。

Purity の分布を図 5.12 に示す。5.1 節と同じく、許容範囲が広い場合は機械学習を用いることでオフラインに対しても高い Efficiency を示しており、学習に用いていない物理過程においても本手法が有効な場合があることを示している。許容範囲  $\pm 0.391$  mm (bin 数 1024) における Efficiency は、機械学習が 0.967、オフラインが 0.836 である。




図 5.12:  $t\bar{t}$  事象で学習したモデルを  $HH \rightarrow b\bar{b}\gamma\gamma$  事象のデータに応用した場合の性能評価。左図は bin 数 1024 における残差分布、右図は Efficiency と Purity の分布比較。

## 5.4 Run 3 における性能評価

前節までは HL-LHC 条件（パイルアップ 200）で性能評価を行った。本節では Run 3 条件での性能評価を行う。Run 3 ではパイルアップが平均 50–65 であり、内部飛跡検出器は ITk ではなく現行の Pixel、SCT、TRT から構成される。パイルアップ 200 条件ではトリガーレベルで再構成されたデータがまだ利用できないため、後述するトリガーレベルでの応用（5.6 節）に向けて、Run 3 条件でシミュレートされた  $t\bar{t}$  事象で学習を行い、 $t\bar{t}$  事象および  $HH \rightarrow b\bar{b}\gamma\gamma$  事象での性能評価を行う。

### 5.4.1 学習過程

Run 3 の  $t\bar{t}$  事象における学習過程での損失関数の推移を図 5.13 に示す。パイルアップ 200 の結果（図 5.1）に比べて損失関数の値が小さく、安定した学習が実現できている。

### 5.4.2 $t\bar{t}$ 事象における性能評価

Run 3 の  $t\bar{t}$  事象における Efficiency と Purity の関係を図 5.14 に示す。Run 3 ではパイルアップが少なく Purity が高いため、 $y$  軸の表示範囲を拡大している。パイルアップ 200 の結果と同様に、許容範囲を広げることでオフラインアルゴリズムと同等の Efficiency を達成している。許容範囲  $\pm 0.391$  mm（bin 数 1024）における Efficiency は、機械学習が 0.993、オフラインが 0.995 である。

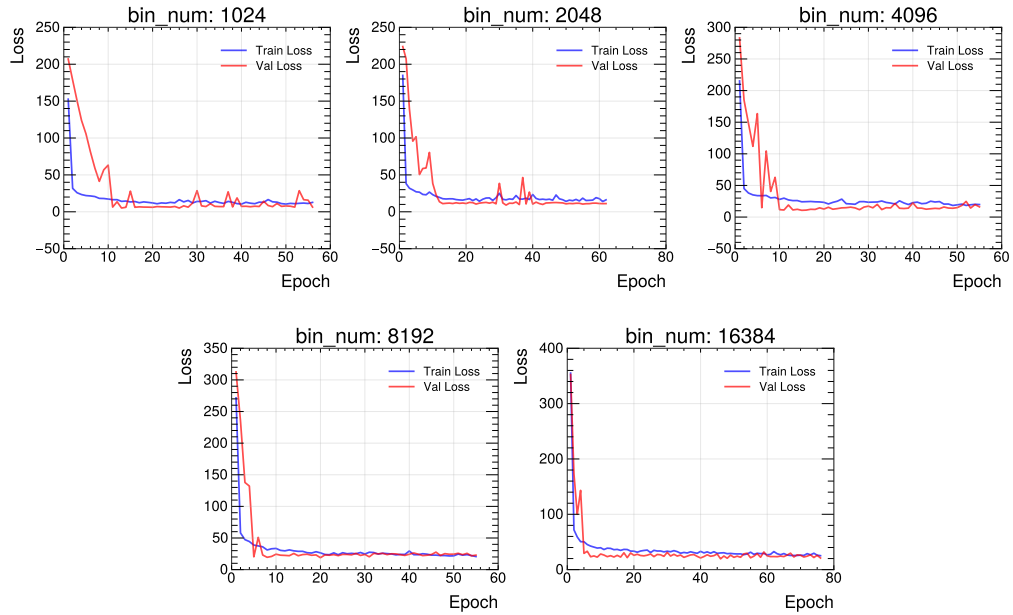


図 5.13: Run 3、 $t\bar{t}$  事象における損失関数の推移

### 5.4.3 $HH \rightarrow b\bar{b}\gamma\gamma$ 事象における性能評価

Run 3 の  $HH \rightarrow b\bar{b}\gamma\gamma$  事象における Efficiency と Purity の関係を図 5.15 に示す。許容範囲  $\pm 0.391$  mm 以上でオフラインアルゴリズムを上回る Efficiency を達成した。許容範囲  $\pm 0.391$  mm (bin 数 1024) における Efficiency は、機械学習が 0.916、オフラインが 0.896 である。

## 5.5 各条件での Efficiency のまとめ

表 5.1 に、許容範囲  $\pm 0.391$  mm (bin 数 1024) における各条件での Efficiency をまとめる。各サンプル、条件において、オフラインを上回る結果を達成した。

## 5.6 PV による運動学的変数の補正

5.4.3 で評価した Run 3 における  $HH \rightarrow b\bar{b}\gamma\gamma$  事象について、トリガーレベルで再構成された光子の横運動量  $p_T$  を許容範囲  $\pm 0.391$  mm で再構成した PV を基準として補正した結果を評価する。以降、トリガーレベルで再構成された光子を、オンライン光子と呼ぶ。

現行のトリガーアルゴリズムでは、オンライン光子の  $p_T$  は検出器の原点  $(0, 0, 0)$  を基準として計算されている。しかし、実際の衝突点である PV は  $z$  方向にばらつきを持つため、原点基準の  $p_T$  には系統的な誤差が含まれる。本研究では、PV の  $z$  座標を用いてオンライン光子の方向を補正し、より精度の高い  $p_T$  再構成を実現する。補正のイメージ図を図 5.16 に示す。






図 5.14: Run 3 における  $t\bar{t}$  事象の Efficiency, Purity の関係

表 5.1: 許容範囲  $\pm 0.391$  mm (bin 数 1024) における Efficiency のまとめ

条件	学習データ	評価データ	機械学習	オフライン
パイルアップ 200	$t\bar{t}$	$t\bar{t}$	0.993	0.962
パイルアップ 200	$Z \rightarrow \mu\mu$	$Z \rightarrow \mu\mu$	0.921	0.848
パイルアップ 200	$t\bar{t} + Z \rightarrow \mu\mu$	$t\bar{t}$	0.983	0.962
パイルアップ 200	$t\bar{t} + Z \rightarrow \mu\mu$	$Z \rightarrow \mu\mu$	0.917	0.848
パイルアップ 200	$t\bar{t}$	$HH \rightarrow b\bar{b}\gamma\gamma$	0.967	0.836
Run 3	$t\bar{t}$	$t\bar{t}$	0.993	0.995
Run 3	$t\bar{t}$	$HH \rightarrow b\bar{b}\gamma\gamma$	0.916	0.896

光子は中性粒子であるため飛跡を残さず、カロリメータでのエネルギー測定のみが利用可能である。カロリメータでは、入射した光子が電磁シャワーを形成し、複数のセルにエネルギーが蓄積される。これらの近接するセルをグループ化したものをクラスタと呼ぶ。カロリメータクラスタの位置を円筒座標系  $(r, \phi, z_{\text{calo}})$  で表す。ここで、 $r = \sqrt{x^2 + y^2}$  はビーム軸からの距離、 $z_{\text{calo}}$  はクラスタ重心の  $z$  座標である。PV を原点とした相対座標系で光子の方向を再計算するため、PV の  $z$  座標  $z_{\text{PV}}$  を用いて、PV からクラスタまでの相対  $z$  座標を

$$z_{\text{corr}} = z_{\text{calo}} - z_{\text{PV}} \quad (5.1)$$




図 5.15: Run 3 における  $HH \rightarrow b\bar{b}\gamma\gamma$  事象の Efficiency, Purity の関係

と定義する。 $\eta = -\ln(\tan(\theta/2))$  と幾何学的関係  $\cot \theta = z/r$  から  $\sinh \eta = z/r$  が導かれるため、PV を原点とした方向の擬ラピディティは

$$\eta_{\text{corr}} = \sinh^{-1} \left( \frac{z_{\text{corr}}}{r} \right) \quad (5.2)$$

と計算される。最後に、光子のエネルギー  $E$  と補正後の  $\eta_{\text{corr}}$  から、補正後の横運動量を

$$p_T^{\text{corr}} = \frac{E}{\cosh(\eta_{\text{corr}})} \quad (5.3)$$

として再構成する。

補正の効果を定量的に評価するため、イベント内で角度距離  $\Delta R = \sqrt{(\Delta\eta)^2 + (\Delta\phi)^2} \geq 0.2$  を満たす  $p_T$  が上位 2 つのオンライン光子と、真の  $HH \rightarrow b\bar{b}\gamma\gamma$  事象から生成された 2 つの光子との  $p_T$  の相対差を比較する。具体的には、最も  $p_T$  が高いオンライン光子 (leading photon) と真の事象で最も  $p_T$  が高い光子との相対差、および 2 番目に  $p_T$  が高いオンライン光子 (subleading photon) と真の事象で 2 番目に  $p_T$  が高い光子との相対差をそれぞれ評価する。シミュレーションデータにおいては、パイルアップ由来の光子を除けば、これらは多くの場合同一の光子の真の値と再構成した値との差を表すと考えられる。真の  $HH \rightarrow b\bar{b}\gamma\gamma$  事象から生成された 2 つの光子の  $p_T$  分布を図 5.17 に示す。Leading photon は約 100GeV 付近にピークを持ち、subleading photon は約 30GeV 付近にピークを持つ。

補正前後における  $p_T$  の相対差の分布を図 5.18 に示す。フィット関数は式 (2.7) の DSCB 関数を用いた。Leading photon では、フィットした際の標準偏差が補正前の 0.0157 から補正後の 0.0117




図 5.16: PV の  $z$  座標を基準にした光子の方向補正のイメージ図

に改善しており、PV 基準の補正によって  $p_T$  の再構成精度が向上している。一方、subleading photon では標準偏差が 0.0215 から 0.0190 となり、leading に比べて分布の形状に大きな変化は見られない。これは、subleading photon は  $p_T$  が低く、エネルギー測定の不確かさなど他の要因の寄与が相対的に大きいと考えられる。また、subleading photon では overflow、underflow のイベント数が leading photon に比べて多い。これは、subleading photon は  $p_T$  が低いため、パイラップ由来の光子との弁別が困難であり、異なる光子とマッチングされた事象が含まれるためと考えられる。

次に、 $HH \rightarrow b\bar{b}\gamma\gamma$  事象における 2 光子不変質量の再構成精度への影響を評価する。前述の leading photon および subleading photon に対して PV 補正を適用し、 $\eta_{\text{corr}}$  と  $p_T^{\text{corr}}$  を再計算する。エネルギー  $E$  は測定値をそのまま用いて、補正後の 4 元運動量を以下のように構築する。

$$p_x = p_T^{\text{corr}} \cos \phi, \quad (5.4)$$

$$p_y = p_T^{\text{corr}} \sin \phi, \quad (5.5)$$

$$p_z = p_T^{\text{corr}} \sinh(\eta_{\text{corr}}) \quad (5.6)$$

2 つの光子の 4 元運動量  $(E_i, p_{x,i}, p_{y,i}, p_{z,i})$  から、不変質量を

$$m_{\gamma\gamma} = \sqrt{\left(\sum_{i=1,2} E_i\right)^2 - \left(\sum_{i=1,2} p_{x,i}\right)^2 - \left(\sum_{i=1,2} p_{y,i}\right)^2 - \left(\sum_{i=1,2} p_{z,i}\right)^2} \quad (5.7)$$




図 5.17: 真の  $HH \rightarrow b\bar{b}\gamma\gamma$  事象から生成された 2 つの光子の  $p_T$  分布。Leading truth photon が最も  $p_T$  が高い光子、Subleading truth photon が 2 番目に  $p_T$  が高い光子を示す。




図 5.18: オンライン光子と真の  $HH \rightarrow b\bar{b}\gamma\gamma$  事象から生成された光子との  $p_T$  の相対差の分布のフィット結果。-0.05 から 0.05 までを DSCB 関数によりフィットしている。左図が最も  $p_T$  が高い光子 (leading photon)、右図が 2 番目に  $p_T$  が高い光子 (subleading photon) の結果を示す。赤が補正前、緑が補正後を示す。左右の最も端の bin は、overflow と underflow を示す。

として計算する。補正前後の分布を図 5.19 に示す。フィットの標準偏差は補正前の 2.38 GeV から補正後の 1.67 GeV に改善しており、補正によりヒッグスボソンの質量である 125 GeV 付近のピークがより鋭くなり、質量分解能が向上していることが確認できる。




図 5.19:  $p_T$  が上位 2 つのオンライン光子による 2 光子不変質量の分布のフィット結果。115GeV から 135GeV までを DSCB 関数によりフィットしている。赤が補正前、緑が補正後を示す。左右の最も端の bin は、overflow と underflow を示す。

## 第 6 章

# まとめと展望

### 6.1 まとめ

高輝度 LHC (HL-LHC) では、瞬間ルミノシティの増加に伴いパイルアップ数が最大 200 に達する。この高パイルアップ環境下において、トリガーレベルで 1 バンチ交差によって生じた vertex の中で、対応する荷電粒子トラックの  $\Sigma p_T^2$  が最も大きい vertex である、Primary Vertex (PV) を高い確率で正しく再構成することには重要な利点がある。PV を再構成することで、パイルアップ由来の粒子を除外して興味のある硬散乱事象の選別精度を向上させることが可能となる。また、PV を基準点として粒子の運動学的変数を正確に再構成できる。特に、光子などの中性粒子は飛跡検出器で飛跡を残さないため、PV の位置情報を用いた方向補正が重要である。

本研究では、トリガーレベルでの PV 再構成を目指し、まずヒストグラム法を開発した。ヒストグラム法は、各トラックのビーム軸上の最近接点の  $z$  座標  $z_0$  を横軸として横運動量  $p_T$  をヒストグラムに詰め、最大 bin の中心を PV 位置として出力するシンプルな手法である。しかし、この手法にはトラックフィットの品質 ( $\chi^2/\text{ndf}$ ) を考慮しないため品質の低いトラックが再構成に寄与すること、また単純な  $p_T$  の合計のみで判定するため他のトラック品質に関するパラメータを活用できないという問題点があることがわかった。

これを解決するため、機械学習を用いた手法を開発した。本手法では、多層パーセプトロン (MLP) を用いて各トラックに対する重みを学習する。入力として、トラックの運動学的情報 ( $p_T$ ,  $\eta$ ,  $\phi$ )、幾何学的情報 ( $d_0$ )、および再構成品質を表す情報 ( $\chi^2/\text{ndf}$ ,  $\sigma_{d_0}$ ,  $\sigma_{z_0}$ ) の 7 つのパラメータを使用することで、硬散乱由来のトラックを効果的に選別する。

機械学習によって、すべての bin 設定値でヒストグラム法に比べて高い Efficiency を示した。さらに許容範囲  $\pm 0.391$  mm (bin 数 1024) において、パイルアップ 200、Run3 条件の各事象でオフラインを上回る Efficiency を達成した。また、学習に使用していないサンプルに応用した場合でも、依然としてオフラインを上回る Efficiency を維持する場合があることを確認した。

さらに、再構成した PV を用いた光子の運動学的変数の補正についても検証を行った。 $HH \rightarrow b\bar{b}\gamma\gamma$  事象において、PV の  $z$  座標を基準として光子の擬ラピディティと横運動量を補正することで、leading photon の  $p_T$  再構成精度が向上し、2 光子不変質量分布においてヒッグスボソン質量

付近のピークがより鋭くなることを確認した。

以上の結果から、本研究で開発した機械学習ベースの PV 再構成手法は、許容範囲  $\pm 0.391$  mm の分解能で実行した場合、HL-LHC の高パイルアップ環境においてオフラインアルゴリズムと同等以上の性能を発揮し、トリガーレベルでの応用に有望であることが示された。

## 6.2 展望

今後の展望として、まず本研究で開発したアルゴリズムを実際のトリガーシステムに実装することが考えられる。本手法ではヒストグラムの bin 幅  $w_{\text{bin}}$  によって分解能と再構成性能のトレードオフが生じるため、トリガーシステムで要求される分解能を明確にし、最適な  $w_{\text{bin}}$  を決定する必要がある。例えば、5.6 節では  $w_{\text{bin}} = 0.391$  mm の場合でトリガーシステムに対して有用であることを評価した。また、トリガーシステムの厳しいレイテンシ要件を満たすため、アルゴリズムの実行時間についても評価が必要である。

次に、光子の conversion vertex の再構成への応用が考えられる。光子は検出器の物質中で電子-陽電子対に変換されることがあり、この現象を conversion と呼ぶ。本研究では PV を用いた光子の方向補正を行ったが、PV を起点として conversion vertex を再構成できれば、光子が conversion 由来であるかどうかを判定することが可能となる。conversion 由来の光子と非 conversion 光子ではカロリメータにおけるサンプリング係数が異なるため、この情報を活用することで光子のエネルギー再構成精度をさらに向上させることが期待される。

また、許容範囲を広げることでオフラインアルゴリズムよりも高い Efficiency を示したことから、本手法をオフラインアルゴリズム、つまり物理データ解析へ応用することも展望として考えられる。

## 付録 A

# トラックのパラメータ分布

本研究で使用したシミュレーションデータにおける、各トラックのパラメータの分布を掲載する。




図 A.1: パイルアップ 200、 $t\bar{t}$  事象におけるトラックのパラメータ分布



# 謝辞

本研究を行うにあたり、たくさんの方々にお世話になりました。研究生生活を支えてくださった全ての方々に心より感謝申し上げます。

指導教員である山崎祐司先生には、学部4年生の卒業研究から3年間指導していただき大変お世話になりました。質問に伺った際には、自分が苦手とする物理の理論的な背景はもちろん、山崎先生の専門外である機械学習の詳しい内容に至るまで、時には一緒に文献を読んでもらうなど、とても真摯に答えてくださりました。また、学会の発表の発表資料などの添削をお願いする際にも、お忙しい中オンラインやオフラインで何度も指導してくださりました。山崎先生のお優しいご指導のおかげで、楽しく研究を進めることができました。本当にありがとうございました。

神戸 ATLAS グループの前田順平先生、藏重久弥先生には毎週のミーティングにて助言をいただき、研究や発表準備を進めることができました。前田順平先生には、ご自身の指導学生が多くいるにも関わらず、研究の方針であったり、機械学習やソフトウェアなどの技術的な部分についても熱心にご指導くださいました、ありがとうございました。

粒子物理学研究室の、竹内康雄先生、身内賢太郎先生、鈴木州先生、東野聡先生、伊藤博士先生、越智敦彦先生、高橋真斗さんには、研究室のコロキウム等でご助言をいただきました。ありがとうございました。また、鈴木州先生、量子物性論の伏屋雄紀先生、副査をご担当いただきありがとうございました。

ATLAS Japan グループの皆様には大変お世話になりました。山口洋平先生、長野邦浩先生、清水志真先生、堀井泰之先生には、毎週のミーティングで助言をいただき、研究を進めることができました。堀井泰之先生には、イタリアでの ATLAS Week に参加した際に、海外での発表で緊張している中、気さくに話しかけていただき、とても心強かったです。CERN 出張中には、先生方、先輩方、同期の皆さんに大変お世話になりました。山口洋平先生には、CERN で直接ご指導していただき、研究を大きく前進させることができました。本当にありがとうございました。スイスでの生活は不安なことが多く、出張を敬遠していた時期もあったのですが、関わってくださったみなさんのおかげで本当に素敵な思い出になりました。ありがとうございました。

神戸 ATLAS グループの先輩である水引龍吾さん、張力さん、村田優衣さん、西将汰さん、樋口流雲さんには研究生生活に対する助言をいただき、モチベーションを保つことができました。ありがとうございました。

研究室同期の浅見優輝くん、佐倉慶汰くん、佐野友麻くん、田中亮祐くん、山口凜太郎くん、曾

根貴将くん、谷口紘大くん、鈴木啓司くん、和田伸一郎くん、研究生活は大変なことも多くありましたが、みなさんと話すことが毎日の楽しみでした。卒業後も仲良くしましょう。

神戸 ATLAS グループの後輩である神吉陽介くん、橋本真理子さん、あまり先輩らしいことは出来ませんでした。お二人の進捗報告を聞いて刺激をもらっていました。ありがとうございました。今後も頑張ってください。

最後に、ここまで長い学生生活を支えてくださった両親に心より感謝の気持ちを込めて、謝辞とさせていただきます。

## 参考文献

- [1] CERN, ATLAS Open Data: The Standard Model of Particle Physics and Beyond  
[https://opendata.atlas.cern/docs/documentation/introduction/SM\\_and\\_beyond](https://opendata.atlas.cern/docs/documentation/introduction/SM_and_beyond).  
Accessed: Oct. 26, 2025.
- [2] CERN, Dark Matter <https://home.cern/science/physics/dark-matter>. Accessed:  
Oct. 20, 2025.
- [3] CERN, The matter–antimatter asymmetry problem <https://home.web.cern.ch/science/physics/matter-antimatter-asymmetry-problem>.  
Accessed: Oct. 20, 2025.
- [4] LHC ALICE J-GROUP, ALICE 実験概要  
<http://alice-j.org/alice%E5%AE%9F%E9%A8%93/>. Accessed: Oct. 21, 2025.
- [5] CERN, CERN’ s accelerator complex  
<https://home.cern/science/accelerators/accelerator-complex>, 2025. Accessed:  
Oct. 20, 2025.
- [6] CERN, The HL-LHC project  
<https://hilumilhc.web.cern.ch/content/hl-lhc-project>. Accessed: Dec. 8, 2025.
- [7] ATLAS Collaboration, Study of Higgs boson pair production in the  $HH \rightarrow bb\gamma\gamma$  final state with  $308 \text{ fb}^{-1}$  of data collected at  $\sqrt{s} = 13$  and 13.6 TeV by the ATLAS experiment [arXiv:2507.03495](https://arxiv.org/abs/2507.03495) [hep-ex].
- [8] G. Heinrich, S. P. Jones, M. Kerner, G. Luisoni and L. Scyboz, Probing the trilinear Higgs boson coupling in di-Higgs production at NLO QCD including parton shower effects JHEP **06** (2019) 066, [arXiv:1903.08137](https://arxiv.org/abs/1903.08137) [hep-ph].
- [9] Dreyer, Frédéric A. and Karlberg, Alexander, Vector-boson fusion Higgs pair production at N<sup>3</sup>LO Phys. Rev. D **98** (2018) 114016, [arXiv:1811.07906](https://arxiv.org/abs/1811.07906) [hep-ph].
- [10] J. Baglio, A. Djouadi, R. Grober, M. M. Muhlleitner, J. Quevillon, M. Spira, The measurement of the Higgs self-coupling at the LHC: theoretical status JHEP (2013) 151, [arXiv:1212.5581](https://arxiv.org/abs/1212.5581) [hep-ph].
- [11] ATLAS Collaboration, Combination of searches for Higgs boson pair production in  $pp$  collisions at  $\sqrt{s} = 13$  TeV with the ATLAS detector Phys. Rev. Lett. **133** (2024)

- 101801, [arXiv:2408.09971](https://arxiv.org/abs/2408.09971) [[hep-ex](#)].
- [12] Jason Veatch, Searches for resonant scalar boson pair production using Run 2 LHC proton–proton collision data *Symmetry* **14** (2022) 260.
- [13] CERN, ATLAS experiment schematic or layout illustration  
<https://cds.cern.ch/record/2837191>, 2022. CERN Document Server, Date: Oct. 18, 2022.
- [14] ATLAS Collaboration, Expected tracking performance of the ATLAS Inner Tracker at the High-Luminosity LHC JINST **20** (2025) P02018, [arXiv:2412.15090](https://arxiv.org/abs/2412.15090) [[hep-ex](#)].
- [15] CERN, Computer Generated image of the ATLAS calorimeter  
<https://cds.cern.ch/record/1095927>, 2008. CERN Document Server, Date: Mar. 27 2008.
- [16] CERN, Computer generated image of the ATLAS Muons subsystem  
<https://cds.cern.ch/record/1095929>, 2008. CERN Document Server, Date: Mar. 27 2008.
- [17] ATLAS Collaboration, Technical Design Report for the Phase-II Upgrade of the ATLAS Trigger and Data Acquisition System – Event Filter Tracking Amendment 2022. CERN-LHCC-2022-004; ATLAS-TDR-029-ADD-1.
- [18] ATLAS Collaboration, ATLAS experiment – public results – Computing and Software  
<https://twiki.cern.ch/twiki/bin/view/AtlasPublic/ComputingandSoftwarePublicResults>. Accessed: Dec. 11, 2025.
- [19] ATLAS Tracking CP Group, ATLAS Track Reconstruction – General Overview  
<https://atlassoftwaredocs.web.cern.ch/internal-links/tracking-tutorial/idooverview/>. Accessed: Dec. 11, 2025.
- [20] ATLAS Collaboration, Development of ATLAS primary vertex reconstruction for LHC Run 3 <https://cds.cern.ch/record/2670380>, 2019. PROC-CTD19-035; ATL-PHYS-PROC-2019-048.
- [21] Radovic, Alexander and Williams, Mike and Rousseau, David and Kagan, Michael and Bonacorsi, Daniele and Himmel, Alexander and Aurisano, Adam and Terao, Kazuhiro and Wongjirad, Taritree, Machine learning at the energy and intensity frontiers of particle physics *Nature* **560** (2018) 41–48.