

修　　士　　学　　位　　論　　文

高輝度 LHC-ATLAS 実験に向けた
新しい後段ミューオントリガー手法の開発

令和 7 年 2 月 7 日

専攻名 物理学専攻

学籍番号 230S123S

氏　　名 村田 優衣

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、欧州素粒子原子核研究機構 (CERN) で行われている素粒子国際共同実験である。陽子 – 陽子衝突型加速器である LHC を用い、重心系エネルギー 13 TeV で陽子同士を衝突させた際に生成した粒子を観測する。世界最高エネルギーでの大型実験であり、標準模型の精密検証や標準模型を超える物理の探索を目的としている。これまでにヒッグス粒子の発見や、標準模型の精密測定など多くの物理事象の観測を行なってきた。しかし、現在までに標準模型を超える物理を示唆する結果はほとんど得られていない。そこで、標準模型を超える新たな物理現象の発見を目指し、LHC を高輝度化することを予定している。高輝度化によりデータ収集量を一桁増やすことで、ヒッグス粒子のさらなる精密測定や、新物理探索感度の大幅な向上を目指す。

LHC を高輝度化した高輝度 LHC は、2030 年に運転開始予定である。LHC では、陽子をバンチと呼ばれる塊にまとめ、バンチ同士を 25 ns 間隔で衝突させている。高輝度化に伴いバンチの中の陽子数が増加するため、一度の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増加する。結果、1 事象あたりの飛跡数や背景事象数が大きく増加する。そのため、データの取得時に物理として興味のある事象のみを選別する「トリガー」において、現在のものよりも高精度なものが求められる。トリガーでは高速に事象選別を行うことが必要であるが、高輝度化によってデータの処理に必要となる計算時間が大きく増加することが見込まれている。現在の試算では、データ量の増加に対して計算資源の増設が追いつかない見積りとなっており、計算資源の要求を抑制する改良が喫緊の課題である。また、大量のデータ処理をおこなうための計算機資源の利用による消費電力量の増加も問題視されている。これらを踏まえ、高輝度化に向けて高精度かつ高速化するようなトリガーシステムの改良が必要である。

本研究では、新たな計算機資源とトリガーアルゴリズムという観点から、高輝度化に向けたトリガーシステムの改良に向けた研究を行った。計算資源については、並列計算により効率よくデータ処理を行うことができるアクセラレータに注目し、それらをトリガーシステムに導入するメリットや可能性について、処理速度・消費電力量の観点から評価を行った。また、アルゴリズムについてはトリガーシステムのうちソフトウェアを用いて行う後段ミューオントリガーにおいて、機械学習を新たに使用するアルゴリズムの開発と評価を行なった。新たなアルゴリズムでは、現在のアルゴリズムで CPU の消費量が多い過程を機械学習で置き換えた。さらに、これまでにはミューオン検出器と内部飛跡で独立して行っていたミューオン再構成について、内部飛跡の情報を利用してミューオン検出器内の再構成を行うことで、衝突点以外からのミューオンによる背景事象も早い段階から排除することを試みた。

本論文では、アクセラレータを使用した機械学習の推論速度や消費電力量の評価および、開発した新たなミューオントリガーアルゴリズムの詳細と性能について述べる。

目次

第 1 章	序論	3
1.1	素粒子標準模型	3
1.2	LHC-ATLAS 実験	4
1.2.1	LHC で目指す物理	4
1.2.2	LHC 加速器	8
1.2.3	ATLAS 検出器	9
1.3	Phase-II アップグレード	10
1.4	本研究の目的と本論文の構成	10
第 2 章	高輝度 LHC における ATLAS 検出器	12
2.1	ATLAS 座標系	12
2.2	ATLAS マグネットシステム	12
2.3	内部飛跡検出器	13
2.3.1	Run3 における内部飛跡検出器	13
2.3.2	内部飛跡検出器の高輝度化に向けたアップグレード	16
2.4	ミューオンスペクトロメータ	18
2.4.1	ミューオンスペクトロメータの高輝度化に向けたアップグレード	25
第 3 章	ミューオントリガーシステムと高輝度 LHC に向けたアップグレード	27
3.1	ATLAS トリガーシステム	27
3.2	Run 3 におけるミューオントリガーシステム	28
3.2.1	トリガーチェイン	29
3.2.2	初段ミューオントリガーシステム (L1 ミューオントリガー)	29
3.2.3	後段ミューオントリガーシステム	31
3.3	高輝度化に向けたトリガーシステムのアップグレード	39
3.3.1	初段ミューオントリガーシステムのアップグレード	40
3.3.2	後段ミューオントリガーシステムのアップグレード	43
第 4 章	機械学習を用いたヘテロジニアスコンピューティングの評価	45

4.1	機械学習	45
4.1.1	ニューラルネットワーク	47
4.2	ヘテロジニアスコンピューティング	51
4.2.1	アクセラレータ	52
4.2.2	高位合成	52
4.3	評価方法	53
4.3.1	使用したCPUとアクセラレータ	53
4.3.2	使用した機械学習モデル	54
4.3.3	各デバイスへの実装	55
4.3.4	消費電力測定方法	57
4.4	機械学習を用いたヘテロジニアスコンピューティングの評価	58
4.4.1	CPUのスレッド数を1で固定した場合	58
4.4.2	CPUのスレッド数を変化させた場合	61
第5章 高輝度化に向けた高速ミューオン再構成アルゴリズムの開発		63
5.1	本研究アルゴリズムの概要	63
5.1.1	現在のアルゴリズムの問題点	63
5.1.2	機械学習を用いたミューオン高速再構成	64
5.2	シミュレーションサンプルの作成	66
5.2.1	検出器シミュレーション	66
5.2.2	機械学習の学習に使用するデータセット	67
5.3	機械学習を用いたミューオンの高速再構成	69
5.3.1	内部飛跡の絞り込み	69
5.3.2	セグメントの選択	71
5.3.3	横運動量 p_T の分類	75
5.3.4	ミューオンの再構成	80
5.4	各変数の結果への寄与	81
5.5	本研究アルゴリズムの評価	83
5.5.1	$\langle\mu\rangle=200$ Phase-II シミュレーションサンプルを用いた評価	86
5.5.2	Run 3 データを用いた評価	89
5.6	性能評価のまとめとトリガー導入への課題	97
第6章 まとめと展望		99
謝辞		102
参考文献		104

第1章

序論

1.1 素粒子標準模型

素粒子とは、物質を構成する最小単位の粒子のことである。標準模型は、これまでに観測されているほぼ全ての素粒子現象を数式として定量的に記述できる理論であり、現在、素粒子とその相互作用を最も正確に記述する理論体系とされる。

物質を構成する粒子とそれらの間で働く力の種類を包括的に扱う標準模型は、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、ヒッグス粒子の計 17 種類の粒子で構成されている。これらは強い相互作用 (グルーオンとクォーク間の相互作用), 電磁相互作用 (光子による相互作用), 弱い相互作用 (W ボソンと Z ボソンによる相互作用) の 3 つの主要な相互作用を説明している。

これまで標準模型により数々の素粒子の存在が予言され、実験によってそれらの素粒子が発見されてきた。2012 年には標準模型が存在を予言する素粒子の中で唯一発見されていなかったヒッグス粒子も発見された。しかし、素粒子物理学には標準模型で記述される以外にも、電弱スケールがなぜ重力やプランクスケールと大きく異なるかを問う階層性問題や、宇宙の約 3 割を占めると言わされているが未だ発見されていないダークマター (暗黒物質) の存在など、未解決の問題が数多く残されている。

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。その一つである LHC-ATLAS 実験 [2] は、世界最高エネルギーを持つ大型ハドロン衝突型加速器 (LHC: Large Hadron Collider) を用いた実験である。高エネルギーの陽子 – 陽子衝突によって生成される粒子を用いて、未解決問題の検証から標準模型の精密測定まで、幅広く研究対象として実験が行われている。

今後、新物理の探索感度を向上させるため、LHC を高輝度化することが計画されている。ATLAS 実験では 40 MHz で陽子 – 陽子衝突を起こすため、その間に取得データを解析し、最終的にストレージに保存するデータを選別する必要がある。本論文は、そのシステムにおける高輝度化に向けた改良について説明する。

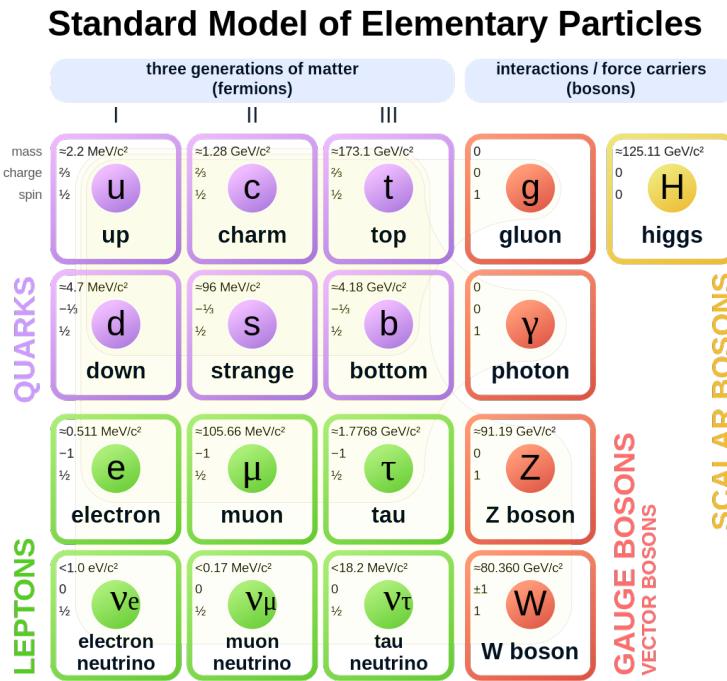


図 1.1: 標準模型を構成する素粒子 [1]

1.2 LHC-ATLAS 実験

ATLAS 実験は、スイス・ジュネーヴ郊外の CERN（欧州原子核研究機構）で行われている素粒子物理実験の 1 つである。1.2.2 節で述べる LHC 加速器を使用し、高エネルギーの陽子同士や重イオンを衝突させることで、素粒子の性質や新物理の研究を行う。

1.2.1 LHC で目指す物理

LHC で行われている実験は、唯一 TeV 領域にアクセスできる加速器を用いた高エネルギー実験において、様々なアプローチで物理の解明を目指している。以下では、ATLAS 実験と CMS 実験 [3] で対象としている物理のうち、ヒッグス粒子と超対称性粒子について述べる。

■ヒッグス粒子の精密測定

現在ヒッグス粒子を生成できる加速器は LHC のみであるため、ATLAS 実験においてヒッグス粒子の詳細な研究を行うことが重要な課題である。

ヒッグス粒子は、粒子の質量の起源を説明する理論であるヒッグス機構において存在が予想された素粒子であり、物質に質量を与えている。ATLAS 実験における主なヒッグス粒子の生成過程を図 1.2 に示す。ヒッグス粒子は質量の大きい粒子とより強く結合するため、重い粒子を介した生成

が主な過程となる。LHC のようなハドロンコライダーにおいては、陽子・陽子中に多く存在するグルーオンが相互作用し、 t クォークを介して、ヒッグス粒子が生成されるグルーオン融合（図 1.2 中 ggF oriduction）が主な過程となる。続いて、2 つのクォークがゲージボソンを放出し、それらが融合するベクトルボソン融合（図 1.2 中 VBF oriduction）も探索に有効な過程である。ベクトルボソンやトップクォークのペアに付随する生成にも大きな寄与がある。

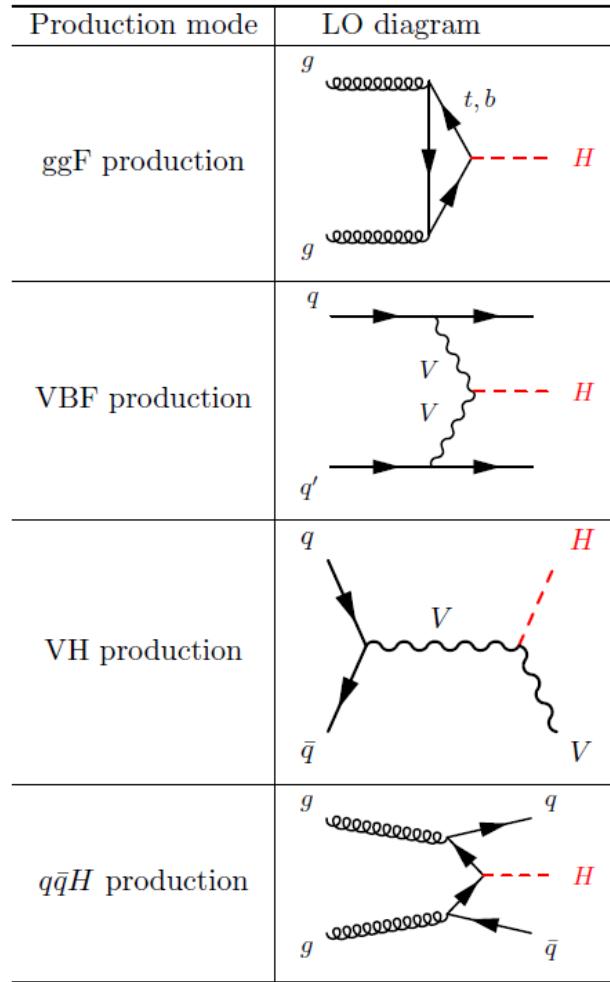


図 1.2: ATLAS 実験におけるヒッグス粒子の主な生成過程 [1]。最も生成断面積が大きいのは ggF production である。

標準模型でのラグランジアンは、式 (1.1) のように与えられる。ここで、 $\mathcal{L}_{\text{gauge}}$ は強い相互作用、弱い相互作用、電磁相互作用を記述するゲージ場、 $\mathcal{L}_{\text{fermion}}$ はフェルミオン運動項、 $\mathcal{L}_{\text{Higgs}}$ は物質に質量を与えるスカラー場であるヒッグス場、 $\mathcal{L}_{\text{Yukawa}}$ はヒッグス粒子とレプトンやクォークとの相互作用を記述する湯川相互作用を示す。

$$\mathcal{L} = \mathcal{L}_{\text{gauge}} + \mathcal{L}_{\text{fermion}} + \mathcal{L}_{\text{Higgs}} + \mathcal{L}_{\text{Yukawa}} \quad (1.1)$$

湯川相互作用において、ヒッグス場とフェルミオン場（クォークやレプトンなど）との間で起こる相互作用の強さを湯川結合と呼ぶ。湯川結合定数は標準模型において、 v をヒッグス場に関する定数、 m_f をフェルミオンの質量としたとき、 $G_{ff} = \frac{m_f}{v}$ と表され、フェルミオンの質量と比例関係にあるとされる。標準模型では、ヒッグス粒子はフェルミオンまたはボソンのペアに崩壊する。その生成断面積を測定することにより、結合定数を測定することができる。これまでに測定された湯川結合定数の結果は図 1.3 のようになっており、今のところ標準模型を外れていない測定結果となっているが、新物理の寄与によって比例関係でなくなる可能性がある [4]。また、第二世代のフェルミオンであるミューオンに関しては、ヒッグス粒子との結合定数が第三世代のフェルミオンに比べて小さいため、精密な測定を行うことが難しい。新物理の寄与を確認するためにはより多くの粒子に対してより精密な結合定数の測定を行うことが重要であり、今後高輝度 LHC にて統計量を増やした測定を行うことで検証を行う。

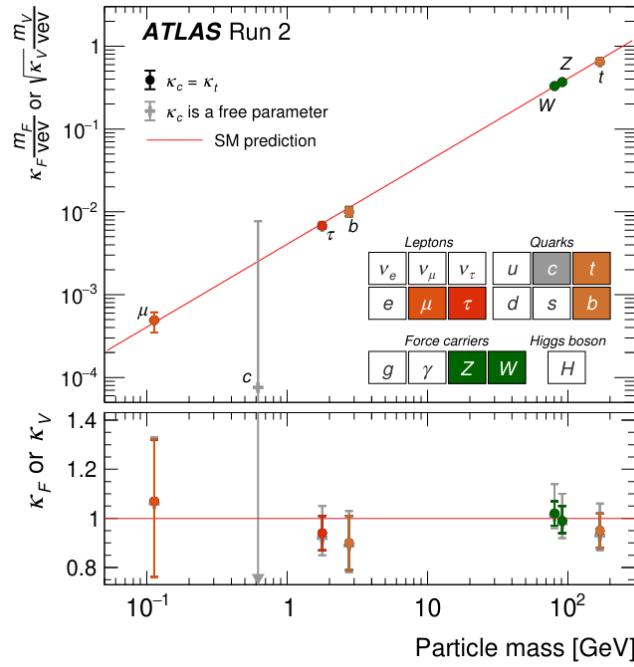


図 1.3: ATLAS 実験における各粒子とヒッグス粒子との結合定数測定結果 [5]。

また、 $\mathcal{L}_{\text{Higgs}}$ は、ヒッグス場を ϕ 、ゲージ相互作用を含むような偏微分を D_μ として $(D_\mu \phi)^+ (D_\mu \phi) - V(\phi)$ と書ける。このうちのヒッグスポテンシャル $V(\phi)$ は $V(\phi) = m_H^2 |\phi|^2 + \frac{\lambda}{2} |\phi|^4$ で表され、1 つ目がヒッグスの質量に関する項、2 つ目がヒッグスの自己結合に関する項で、 λ はヒッグスの自己結合である。ヒッグスポテンシャルの定数については分かっていないことが多く、ヒッグス粒子の精密測定によりポテンシャルがどのような形をしているか決定できる。また、ヒッ

ゲスの自己相互作用を調べることは現在ヒッグスボテンシャルを直接測定するための唯一の方法である。 λ の測定に感度がある重要な事象の一つに、図 1.4 に示すようなヒッグスの対生成がある。ヒッグスの対生成は稀な事象であることに加えて背景事象が多く解析が難しい [6]。統計量を大幅に増やすことができる高輝度 LHC で、今後ヒッグスボテンシャルの直接的検証を行うことを目指す。

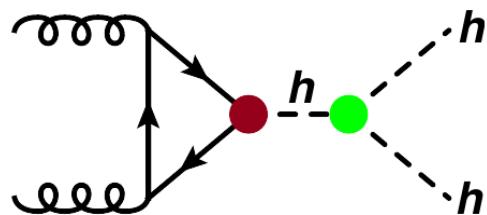


図 1.4: ヒッグス対生成の例 [6]。

■標準模型を超える物理の探索

LHC を使用した実験では、超対称性粒子 (SuperSymmetry, SUSY) や暗黒物質などの標準模型を超えた新粒子探索を TeV スケールまで行うことができる。

標準模型の粒子に対し、スピンが $1/2$ 異なるだけで電荷などが全て等値の素粒子を超対称性粒子と言う。図 1.5 に超対称性粒子の一覧を示す。全ての標準模型粒子は超対称性パートナーを持ち、スピンが $1/2$ ずれるため、既存のフェルミオンに対し未知のボソン、既存のボソンに対し未知のフェルミオンが対となる。

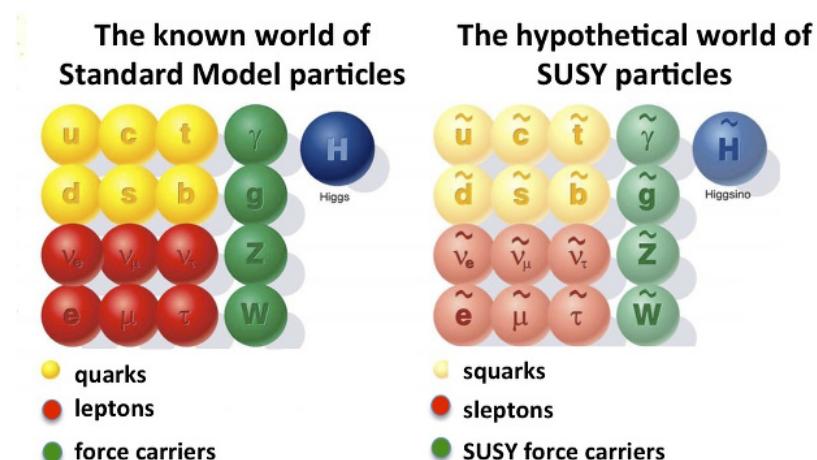


図 1.5: 超対称性粒子の一覧 [7]。右側に記されているのが超対称性粒子で、それぞれ標準模型の粒子のパートナーを持つ。

電弱相互作用、弱い力、強い力の結合定数が一致する理論のことを大統一理論と言い、素粒子の基本的な相互作用である電磁相互作用、弱い相互作用、強い相互作用を統一的に記述する理論である。宇宙の始まりに存在した1つの力がその後4つに分かれたという考え方から、4つの力を一つの形で表して統一しようとする考えに基づいている。現在、大統一スケールでの結合定数が一致していないため、超対称性粒子などの新物理が期待されている。しかし、これまでの探索結果から、低いエネルギーでの超対称性粒子は見つかっておらず、超対称性が破れていることが分かっている。もし超対称性が1 TeV付近で見つかった場合、そのエネルギースケールでの各結合定数の量子補正が変化する結果結合定数がちょうど大統一スケールで一致し、階層性問題も緩和できる。また、暗黒物質には「光らない・非相対論的・バリオンでない」などの条件があるが、最も軽く電気的に中性な超対称性粒子であるニュートラリーノが、電磁気的な相互作用をほとんど起こさない「冷たい暗黒物質」の候補の1つにもなっている[8]。

ATLAS 実験においてこれまで超対称粒子の兆候は見つかっていない。今後、高輝度 LHC 実験でのさらなる探索領域の拡大を目指す。

1.2.2 LHC 加速器

Large Hadron Collider (LHC) は、スイス・ジュネーヴ郊外に位置する欧州素粒子原子核研究機構 (CERN) の地下に建設された、周長約 27 km の円形加速器である。世界最大の重心エネルギー 14 TeV の陽子衝突を起こすことが可能であり、陽子だけでなく鉛などの重イオンも加速することができるため、幅広い素粒子実験で使用される。LHC の円周上には4つの衝突点があり、ATLAS 実験の他にも、同様に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ている CMS 実験、重イオン衝突を用いてクォーク・グルーオン・プラズマを対象としている ALICE 実験[9]、 b クォークの物理に特化した LHCb 実験[10]の4つの検出器がそれぞれの衝突点に設置されている。LHC は複数の前段加速器と共に運用されている。図 1.6 に、CERN の LHC 加速器システムの全体図を示す。陽子は、初めに線形加速器である Linear Accelerator2 (Linac2) で 50 MeV まで加速された後、Proton Synchrotron Booster (PSB) で 1.4 GeV まで加速される。さらに、Proton Synchrotron (PS) で 25 GeV、Super Proton Synchrotron (SPS) で 450 GeV まで加速された後、LHC に入射する。

LHC は 2010 年から運転を始め、2012 年までの Run 1 では重心系エネルギー 7-8 TeV、その後アップグレードを経て 2015 年から 2018 年までの Run 2 では重心系エネルギー 13 TeV で運転された。また、2022 年から 2025 年にかけての Run 3 では重心系エネルギー 13.6 TeV で運転が行われ、2030 年からはさらに 1.3 節で述べるアップグレードを経た高輝度 LHC にて重心系エネルギー 14 TeV での運転開始が予定されている。

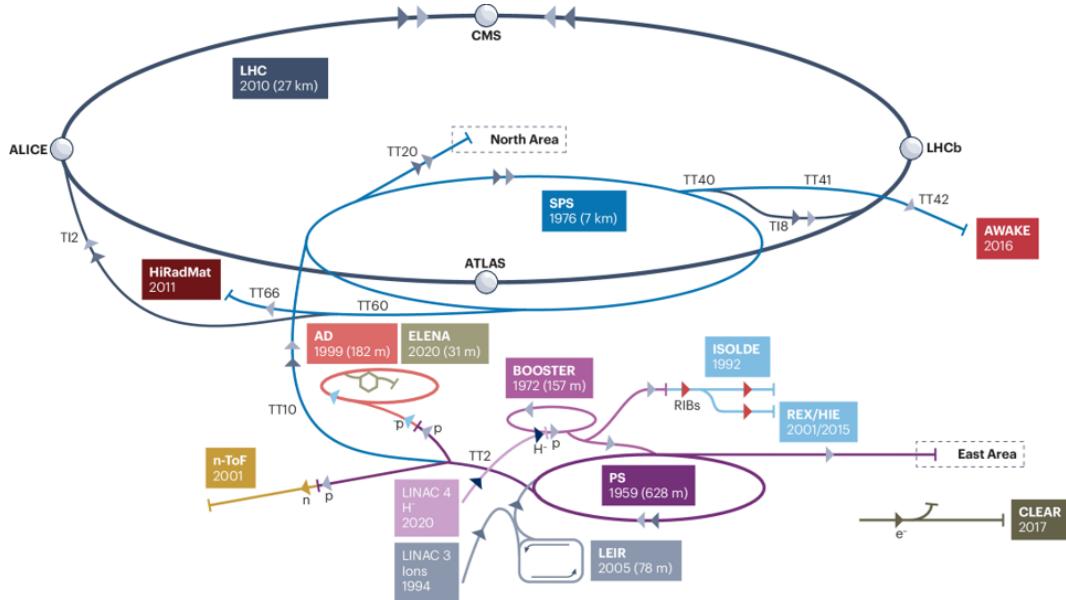


図 1.6: CERN に設置されている加速器群 [11]。最も直径が大きいリングが LHC で、その下に示されているのが前段加速器群である。

1.2.3 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 25 m、長さ 44 m の円筒形の大型汎用検出器である。この全体像を図 1.7 に示す。

ATLAS 検出器は複数の検出器システムを組み合わせて構成されている。陽子 – 陽子衝突点を中心として、内側から順に内部飛跡検出器、電磁/ハドロンカロリメータ、ミューオンスペクトロメータで構成されており、それぞれが粒子を検出および識別するための役割を担っている。また、粒子の運動量を測定することを目的として、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、カロリメータの外側にはトロイド磁石がそれぞれ設置されており、磁場によって曲げられた荷電粒子の曲率から粒子の運動量を求めることができる。これらを組み合わせることで、衝突によりどの粒子がどれくらいのエネルギーを持って生成したかを調べることができる。内部飛跡検出器は、衝突点で生じた荷電粒子を捉え、その情報をもとに飛跡再構成や運動量の測定が行われる。電磁カロリメータは電子と光子、ハドロンカロリメータはハドロンを検出し、エネルギーの測定を行う。また、ミューオンは透過率が高いため、ミューオンスペクトロメータは最外層に設置され、内側の検出器を通過したミューオンを捉える。実際にどの粒子が生成したかを確認するためには複数の検出器からの情報を組み合わせることが多く、例えば、内部飛跡の情報と電磁カロリメータの情報を組み合わせることで、電子と光子の識別が可能となる。

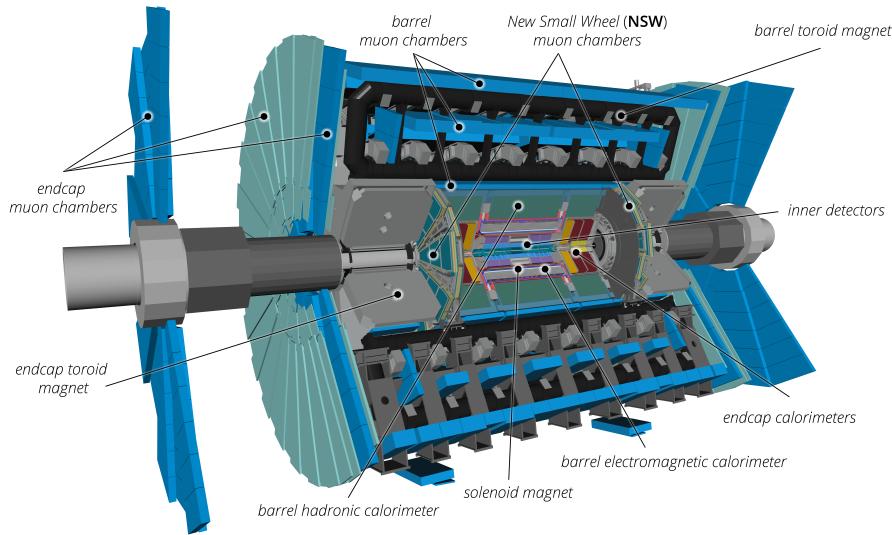


図 1.7: ATLAS 検出器 [12]。内側から内部飛跡検出器、カロリーメータ、ミューオンスペクトロメータで構成され、内部飛跡検出器とカロリーメータの間には超伝導ソレノイド磁石、カロリーメータの外側にはトロイド磁石がそれぞれ設置されている。

1.3 Phase-II アップグレード

現在、LHC-ATLAS 実験では標準模型を超える物理の兆候は得られておらず、新物理への感度向上を目指して高輝度 LHC-ATLAS 実験へのアップグレードが計画されている。図 1.8 に LHC の運転計画を示す。2026 年からの高輝度化によりデータ収集量を一気に増やすことで、新物理探索感度を大幅に向上させる。高輝度 LHC-ATLAS 実験では、陽子をまとめた塊である 1 バンチあたりの陽子数を増やすこと、またビームを絞ることで瞬間ルミノシティを Run 3 での $2 \times 10^{34} \text{ cm}^{-2} \text{s}^{-1}$ から $5 - 7.5 \times 10^{34} \text{ cm}^{-2} \text{s}^{-1}$ まで増加させ、10 年間で $3,000 \text{ fb}^{-1}$ の積分ルミノシティを達成する予定である。また、1 度のバンチ交差で衝突する陽子 – 陽子数であるパイルアップも Run 3 での平均 $50 - 65$ から、 $150 - 200$ へと大幅に増加する。それに伴い、物理的に重要なデータや背景事象の増加が予想され、より精度の高い測定や事象選別が必要となる。そこで、高輝度 LHC-ATLAS 実験に向けて ATLAS 検出器、第 3 章で述べるトリガー・データ収集システムが大幅に改良される。この一連の改良を Phase-II アップグレードと呼ぶ。

1.4 本研究の目的と本論文の構成

本研究は高輝度 LHC-ATLAS 実験に向けた新たなトリガーシステムの開発を目的とする。高輝度化に向けて、トリガーシステムにおいてより高速な事象選別が必要であるが、同時に精度も必要である。また ATLAS 実験では、高輝度 LHC-ATLAS 実験のトリガーシステムにおいて、どのよ



図 1.8: LHC アップグレード計画 [13]。2022 年から 2026 年まで Run 3 としてデータ取得が行われ、その後 2030 年までのアップグレード期間 (LS3) を経て、高輝度 LHC (HL-LHC) の運転が開始される予定である。

うなハードウェアアーキテクチャ (プロセッサなど) を使用するかの決定が 2025 年に行われる。そのため、トリガーシステムの改良に向けて、どのようなハードウェアアーキテクチャを使用するのが良いかの検討も重要である。本研究では、機械学習を使用したアルゴリズムと、GPU や FPGA といったアクセラレータに注目した。まず新たなハードウェアアーキテクチャとしてアクセラレータを使用する場合に、トリガーシステムにおいてどのようなメリットが得られるか、処理速度と消費電力量の観点から評価を行った。次に、その結果を基にアルゴリズムの開発を行い、トリガーシステムとしての性能の評価を行った。

本論文では、第 2 章で LHC-ATLAS 実験と高輝度 LHC-ATLAS 実験に向けた検出器について、第 3 章でトリガーシステムの概要と高輝度化に向けた改良について述べる。第 4 章ではアクセラレータを使用した場合の機械学習の推論速度、消費電力量の評価について、また第 5 章では新たなミューオントリガーシステムのアルゴリズムの詳細と性能について述べた後、第 6 章で本研究のまとめと今後の展望について述べる。

第 2 章

高輝度 LHC における ATLAS 検出器

LHC の高輝度化に伴うパイルアップの増加により、ATLAS 実験の背景事象や事象レートが増加する。そのため高輝度 LHC-ATLAS 実験では、分解能を上げる、背景事象を削減するなど、より高精度な粒子の測定が必要である。本章では、Run 3 で使用している ATLAS 検出器と高輝度 LHC-ATLAS 実験に向けたアップグレード計画について、特に本研究に関連する内部飛跡検出器、ミューオン検出器のアップグレードについて述べる。

2.1 ATLAS 座標系

ATLAS 実験で使用する座標系を図 2.1 に示す。ATLAS 実験では、衝突点を原点として、LHC の中心への方向を正とした x 軸、ビーム軸に沿った z 軸、また $x - z$ 平面に垂直上向きに取る y 軸からなる直交座標系(右手系)を採用している。 $x - y$ 平面において、 $R = \sqrt{x^2 + y^2}$ を動径方向にとり、ビーム軸周りの方位角を ϕ 、ビーム軸からの天頂角を θ と定義する。ATLAS 実験では、この θ を用いた変数とした擬ラピディティ

$$\eta = -\ln \left(\tan \frac{\theta}{2} \right) \quad (2.1)$$

が用いられる。また、 $|\eta| < 1.05$ の領域をバレル領域、 $|\eta| > 1.05$ の領域をエンドキャップ領域と呼び、さらに便宜上、 $z > 0$ の領域を A-side、 $z < 0$ の領域を C-side と呼んでいる。

2.2 ATLAS マグネットシステム

ATLAS 検出器には、粒子の運動量を測定することを目的として磁石が設置されている。ATLAS 検出器での磁石の配置を図 2.2(b) に示す。ATLAS マグネットシステムは、ビーム軸上のソレノイド磁石とバレルと 2 つのエンドキャップぞれぞれのトロイド磁石の 4 つの大型超伝導マグネットで構成されており、全体で 22 m、長さ 26 m で、蓄積エネルギー 1.6 GJ である [2]。磁石の配置図を図 2.2(a) に示す。ソレノイド磁石は内部飛跡検出器とカロリメータの間に設置されており、内部検出器に 2 T の軸方向磁場をかけている。この電磁石が作り出す磁場によって荷電粒子を曲げ、

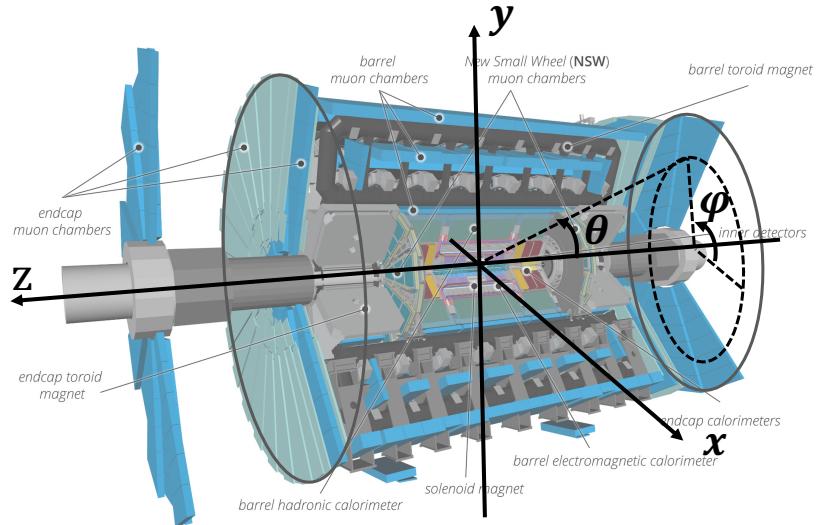


図 2.1: ATLAS 座標系。図に示すような円筒座標系を使用する。

内部飛跡検出器でその曲率を測定することによって衝突点付近で発生した荷電粒子の運動量測定が可能になる。また、トロイド磁石はバレル部、エンドキャップ部それぞれに ϕ 方向に 8 つずつ等間隔で配置され、バレル部には 0.5 T、エンドキャップ部には 1 T のトロイダル磁場を発生させている。その磁場により、ミューオンの運動量測定が可能となっている。

しかし、設置位置の影響でトロイド磁石による磁場は一定でなく、図 2.3 に示すような複雑な磁場構造になっている。 η 方向にも ϕ 方向にも磁場の不均一性があることが分かる。この複雑な磁場構造により、トロイド磁場領域での横運動量の推定や飛跡再構成で複雑な計算を行う必要がある。

2.3 内部飛跡検出器

2.3.1 Run3における内部飛跡検出器

内部飛跡検出器は、検出器の最も内側に位置し、衝突点からの荷電粒子の飛跡情報を取得する。内側から Pixel 検出器 (Pixel) と Insertable B-layer (IBL)、Semiconductor Tracker (SCT)、Transition Radiation Tracker (TRT) で構成されている。最も精密な飛跡を測定する検出器であり、内部飛跡検出器からの情報とカロリメータ、ミューオンスペクトロメータなどからの情報を組み合わせることで粒子の同定を行っている。内部飛跡検出器の全体像と断面図を図 2.4 に示す。

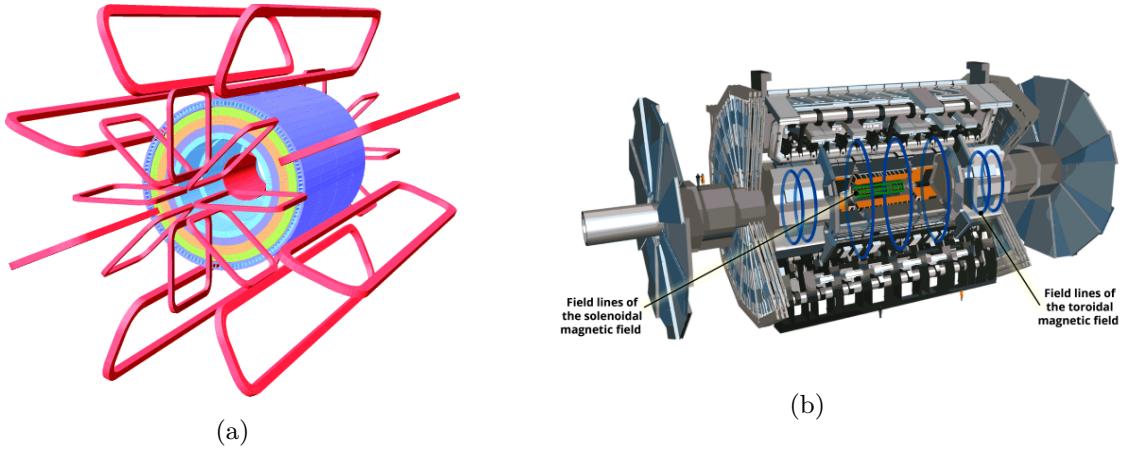


図2.2: (a): 磁石の巻き線とタイルカロリーメーター鋼の形状 [2]。エンドキャップコイルを挟み込んだ8つのバレルトロイドコイル(長方形)と、カロリメータの内側にあるソレノイド(中央の円筒)で構成される。(b): ATLAS検出器における磁場 [2]。

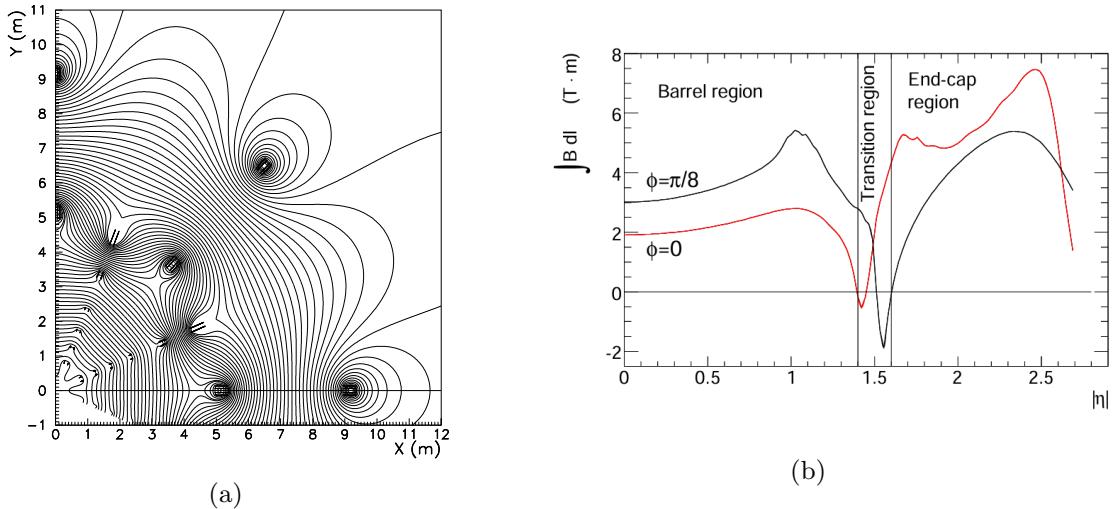
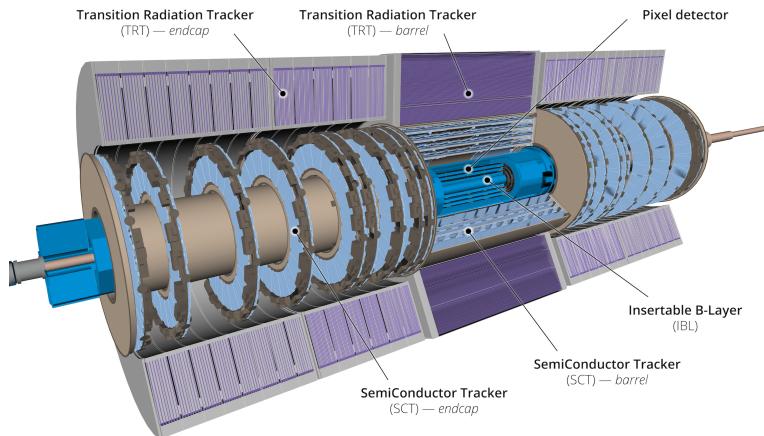


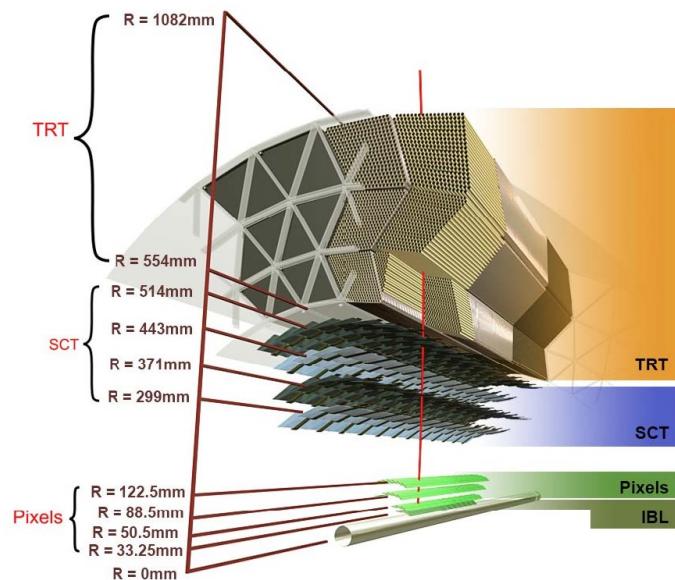
図2.3: (a): ϕ 方向($x-y$ 平面)の磁力線 [14]。(b): 積分磁場強度の依存性 [2]。

• Pixel

Pixel検出器は $|\eta| < 2.5$ の領域をカバーしているシリコン検出器である。バレル領域ではビーム軸を中心とした同心円上に、エンドキャップ領域ではビーム軸に垂直な方向でディスク状に配置されている。それぞれ3層で構成され、全体で約8,000万個の読み出しチャンネルを持っている。ピクセルのサイズは $50 \mu\text{m} \times 400 \mu\text{m}$ であり、位置分解能はバレル領域では $10 \mu\text{m}$ ($r-\phi$ 方向), $115 \mu\text{m}$ (z 方向)、エンドキャップ領域では $10 \mu\text{m}$ ($r-\phi$ 方向), $115 \mu\text{m}$ (z 方向) となっている。



(a) 内部飛跡検出器の全体像



(b) 内部飛跡検出器の断面図

図2.4: 内部飛跡検出器の全体像と断面図 [12]。

・ IBL

Run 2からは新たに追加された IBL は、pixel の内側にさらにもう一つ検出器を挟むことで衝突点から検出器までの距離を 5 cm から 3.3 cm に短縮し、頂点再構成やフレーバータギング性能を強化するために導入された。ピクセルのサイズは $50 \times 250 \mu\text{m}^2$ で、pixel 検出器のサイズの 60% の大きさである。また、総ピクセル数は約 1200 万ピクセルである。IBL を用いた Run 2 では、横運動量 p_T の低い領域での衝突パラメータ分解能が向上しており、1 GeV 以下の p_T では約 40 % 向上した [15]。

· SCT

SCT は pixel 検出器と同様 $|\eta| < 2.5$ の領域をカバーしているシリコン検出器であり、バレル部ではビームパイプを中心とした同軸円筒状、エンドキャップ部ではビームパイプに垂直なディスク状の検出器が設置されている。8つのストリップ層による4つの空間点で飛跡情報を取得する。バレル領域では、長さ 12.8 cm のストリップがビームパイプと平行に 80 μm 間隔で設置されており、40 mrad 傾けたステレオストリップを設置することにより、 $r - \phi$ 方向と z 方向の両方を測定する。エンドキャップ領域では、ストリップが放射状に 80 μm 間隔で設置されており、更にもう1層 40 mrad 傾けたストリップを設置することにより、 r 方向の測定も可能となっている。全体で SCT は約 630 万の読み出しチャンネルを持っている。位置分解能は、バレル領域では 17 μm ($r - \phi$ 方向), 580 μm (z 方向)、エンドキャップ領域では 17 μm ($r - \phi$ 方向), 580 μm (r 方向) となっている。

· TRT

TRT は内部飛跡検出器の最外層に位置し、 $|\eta| < 2$ の範囲をカバーする約 30 万本のドリフトチューブから構成されている検出器である。直径 4 mm のドリフトチューブ外壁には -1.5 kV の高電圧が印加されており、チューブの内部は $\text{Xe} : \text{CO}_2 : \text{O}_2 = 70 : 27 : 3$ の混合ガスで満たされている。チューブ中心の直径 30 μm のタングステンワイヤーから電荷の読み出しを行う。チューブ 1 本あたりの位置分解能は 120 μm 程度となっているが、複数のチューブからの情報を組み合わせることにより詳細な測定が可能である。また、ワイヤーからの高い読み出しレートにより、ナノ秒レベルでのタイミング情報を付加する事が可能となっている。

2.3.2 内部飛跡検出器の高輝度化に向けたアップグレード

高輝度 LHC-ATLAS 実験では、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、シリコン検出器のみで構成される予定である。ピクセル検出器とストリップ検出器で構成され、ピクセルには 13 m^2 、ストリップには 168 m^2 のシリコンが内蔵される。また、 η 方向のカバー領域も 2.4 から 4 まで増加する。現在 ATLAS 内部検出器 (ID) に設置されているピクセル検出器とストリップ検出器は、およそ 1 億チャンネルで構成されているが、高輝度 LHC-ATLAS 実験に設置予定の Inner Tracke r (ITk) では 50 億チャンネル以上で構成される。ITk レイアウトの 4 分の 1 の概略図を図 2.5 に示す。バレル領域では、ピクセルとストリップ検出器がそれぞれ 5 層と 4 層で構成される。エンドキャップ領域は、図 2.5 のように複数のピクセルリングと 6 つのストリッピングで構成されている。

また、ITk 検出器は図 2.6 に示すように、 $|\eta| = 4$ まで、バレル領域では 1 トラックあたり少なくとも 9 点、エンドキャップでは 13 点という、非常にきめ細かく粒度の高い測定を可能にし、パターン認識を向上させることができる。

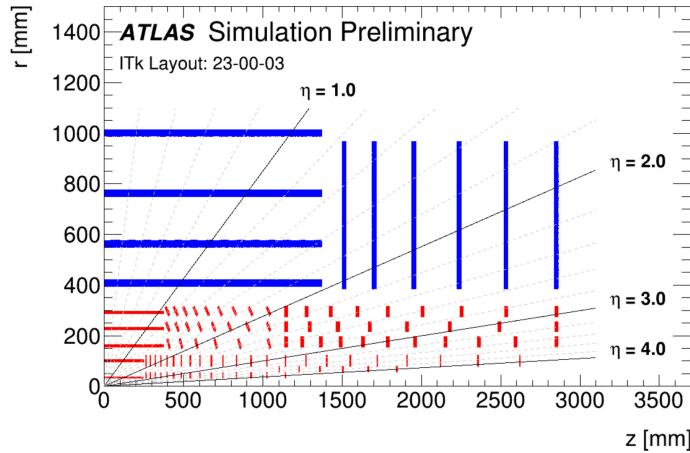


図 2.5: ITk レイアウトの 4 分の 1 の概略図 [16]。赤がピクセル検出器、青がストリップ検出器。検出器を横切る粒子が検出器内を通る距離を少なくするために、一部のピクセル検出器は傾斜して取り付けられている。

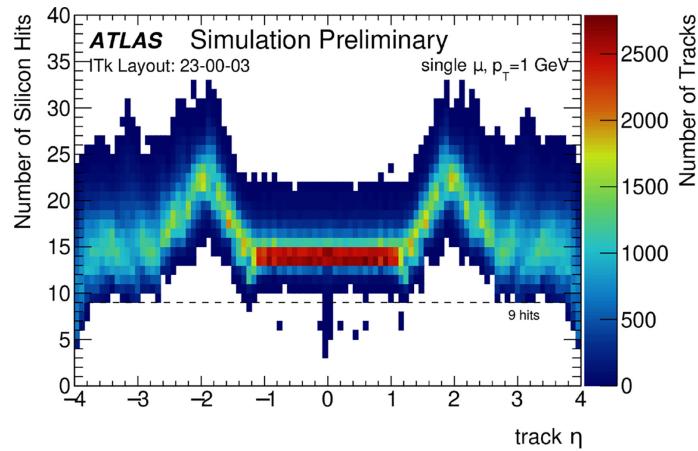


図 2.6: 1 GeV のミューオンの飛跡による ITk センサーの測定点数 [16]。 η の関数で表示した。 $|\eta| < 1.05$ のバレル領域ではほとんどの飛跡が 9–15 あたりのヒット点を持つことが分かる。同様に、 $|\eta| > 1.05$ のエンドキャップ領域ではほとんどの飛跡が 13–18 あたりのヒット点を持つことが分かる。

・ ITk ピクセル検出器

ITk ピクセル検出器にはセンサーサイズ $50 \times 50 \mu\text{m}^2$ と $25 \times 25 \mu\text{m}^2$ のシリコン・センサーが含まれ、インナーシステム、アウターバレル、アウターエンドキャップの 3 つのシステムで構成される。インナーシステムはビームパイプに最も近く、最内層はビームパイプから 34 mm の位置に配置されている。ピクセルの放射耐性は $1 \times 10^{16} \text{ neq}/\text{cm}^2$ の 3D センサーであり、放射線による検出器モジュールの性能劣化が予想される場合に交換できるように設計されている。また、アウ

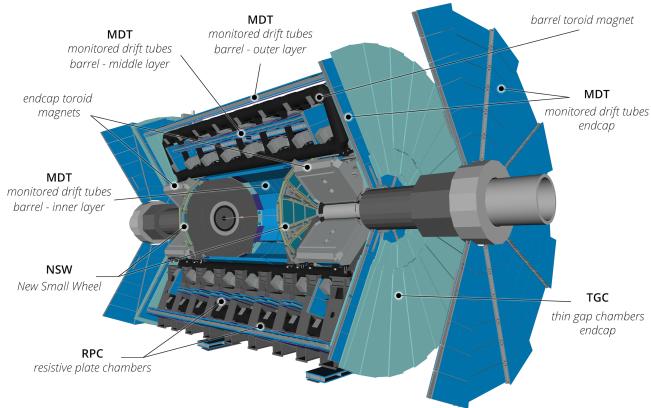


図2.7: ミューオンスペクトロメータの全体図 [12]。

ターバレルシステムは2Dセンサーで構成される。3層のモジュールと3組のリングで構成され、ピクセルに比べてより大きな半径で中央検出器領域をカバーしている。リングに関しては、検出器を横切る粒子が検出器内を通る距離を少なくするために、モジュールを傾斜して取り付けるように設計されている。3つ目のシステムであるアウターエンドキャップは、アウターバレルの両側に取り付けられた3組の両面リング(double-sided rings)で構成されている。

・ITkストリップ検出器

ITkストリップ検出器は、バレル領域と2つの同じエンドキャップ領域で構成されている。ストリップ幅は $\sim 75\ \mu\text{m}$ で、カバー領域は $|\eta| < 2.7$ である。センサーとASICの両方の製造は順調に進んでおり、その他はこれから製造が始まる予定である。

2.4 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粒子の検出に用いられる。 $|\eta| < 2.7$ の範囲で粒子の横運動量 p_T を測定するとともに、 $|\eta| < 2.4$ の範囲で粒子をトリガーする。図2.7にミューオンスペクトロメータの全体図を示す。3つの同心円状の円筒形のステーションからなるバレルと、エンドキャップホイールと呼ばれる3つのディスクからなる両側のステーションから構成される。

図2.8に示すように ϕ 方向に大きさの違う2つのセクターを持ち、それぞれスマールセクター、ラージセクターと呼んでいる。8つのスマールセクターがバレルトロイド磁石の8つのコイルと並んでおり、8つのラージセクターがコイルの間の領域をカバーしている構造になっている。また、RPCとMDTからなる3つのステーションで構成されており、それぞれ最も内側のステーションをインナーステーション、真ん中のステーションをミドルステーション、外側のステーションをアウターステーションと呼んでいる。各ステーションの配置を図2.9に示す。バレル領域においては3つの同心円状のほぼ円筒形のステーション(外側から Barrel Outer: BO, Barrel Middle: BM,

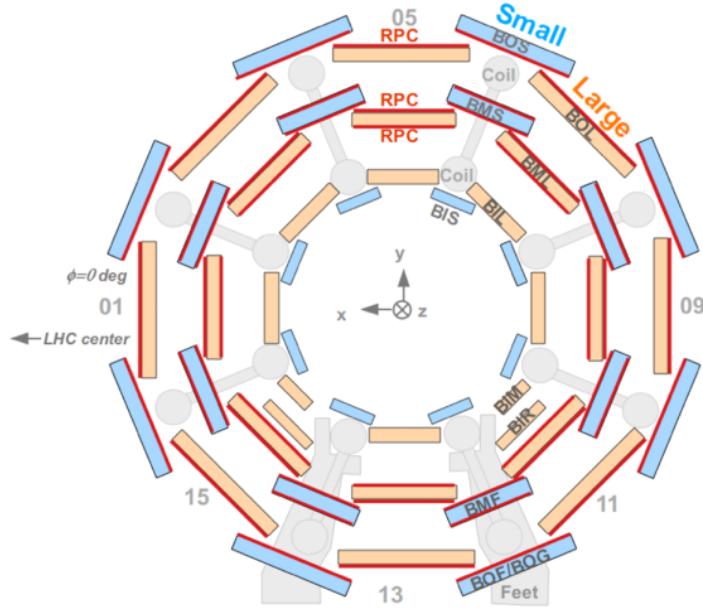
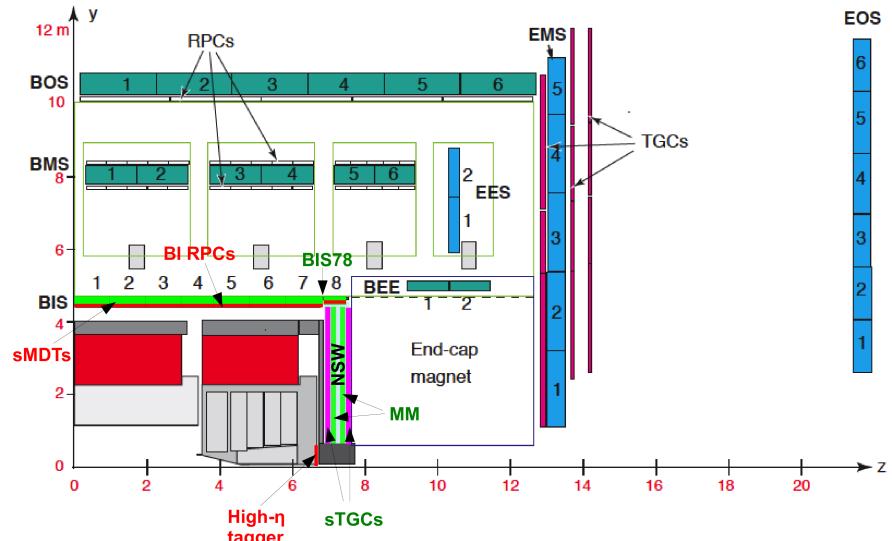


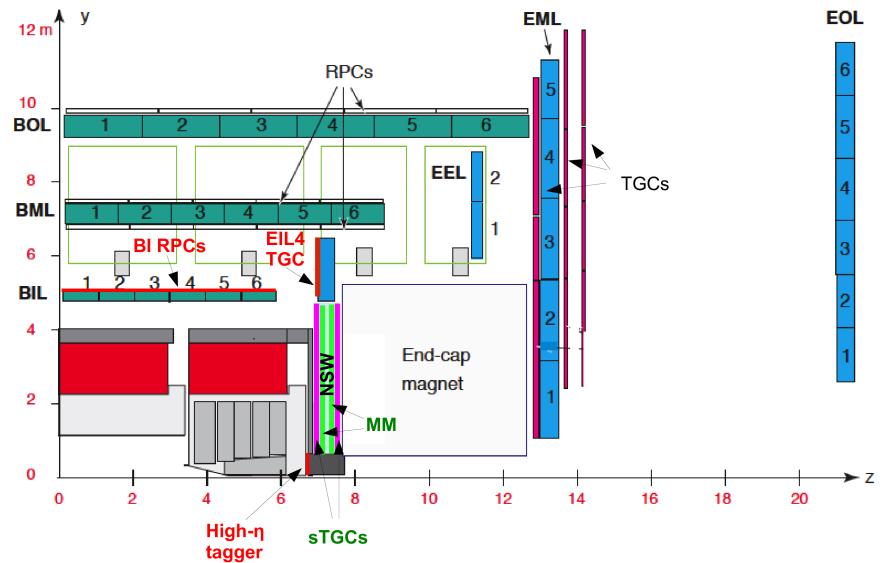
図2.8: ミューオン検出器のバレル領域の $r - \phi$ 平面断面図 [17]。

Barrel Inner: BI) と、2つのエンドキャップ領域それぞれの3つのディスク(外側から Endcap Outer: EO, Endcap Middle: EM, Endcap Inner: EI)、および各エンドキャップトロイドクライオスタットの半径の外側に配置された拡張エンドキャップリング(EE)で構成される。EI チェンバーはバレルトロイド内のカロリメータとエンドキャップトロイドクライオスタットの間に配置されている。EE リングは、EO ホイールでカバーされていない領域($1.05 < |\eta| < 1.3$)のために設置され、また EI 領域の最も外側のステーションは、 $1.0 < |\eta| < 1.25$ をカバーしている。図2.9から分かるように、内部検出器とカロリメータのメンテナンスのために確保されたスペースのため、 $\eta = 0$ に位置するエリアにはミューオンチェンバーがなく、高 p_T ミューオントリガーのアクセプタンスは制限されている。

バレル領域は、3つのステーション全てに位置分解能が良い精密測定用の Monitored Drift Tube (MDT) と、BO と BM に設置されたトリガー用およびトラックの方位座標 ϕ を測定するための Resistive Plate Chamber (RPC) で構成されている。エンドキャップ領域は、バレルと同様に MDT と、EI ホイールの最も内側の領域にある New Small Wheel (NSW)、トリガー用およびミューオンの方位座標 ϕ を測定するための Thin Gap Chambers (TGC) で構成されている。EI については、衝突点から発生するミューオントラックとの整合性を確認するために十分な角度の精度を持つポイントセグメントが必要であったため、Run 3 で NSW が新たに導入された。ミューオンの座標測定に関して、バレル領域では MDT によって η 方向、RPC によって ϕ 方向の位置情報が測定され、エンドキャップ領域では NSW と MDT によって η 方向、NSW と TGC によって ϕ 方向の位置情報が測定される。以下に各検出器の詳細を述べる。



(a)



(b)

図2.9: ミューオン検出器のSmall sector(上)とLarge sector(下)の $r-z$ 平面断面図 [12]。緑の文字で示すのがRun 3で新たに導入された検出器、赤色の文字で示すのがPhase-IIアップグレードで新たに導入予定の検出器である。

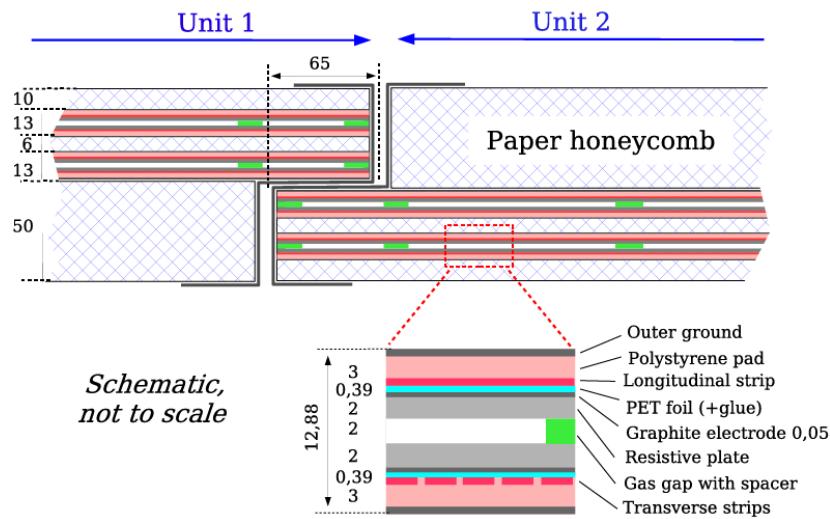


図2.10: RPCの構造 [12]。

· Resistive Plate Chamber (RPC)

バレル領域での測定に用いられ、 $|\eta| < 1.05$ の範囲をカバーしている。2つの独立した検出器層で構成され、半径約 7~10 m の3つの同心円筒状に配置されている。RPCの構造を図2.10に示す。メラミンフェノールでラミネートされた抵抗板が2 mmのガスギャップを挟んで平行に配置され、 $\text{C}_2\text{H}_2\text{F}_4$ (94.7 %), iso- C_4H_{10} (5.0 %), SF_6 (0.3 %) の割合でガスが充填されている。抵抗板間に約4.9 kV/mmの電場が印加されており、この電場によってアバランシェ増幅を起こるために荷電粒子が通過した際の信号を得ることができる。 η 方向、 ϕ 方向の位置を読み出すために、幅が約2.3~3.5 cmのストリップが η 方向と ϕ 方向に直交して配置されている。Large sectorとSmall sectorそれぞれに、MDTミドルステーションを挟み込むように2枚、MDTアウターステーションの外側に1枚の、計3枚のRPCが配置されている。

· Monitored Drift Tube(MDT)

MDT検出器は $|\eta| < 2.7$ の範囲をカバーしている精密用測定器である。直径約30 mm、約38万本のアノードワイヤー径50 μm のドリフトチューブを積層した構造となっており、ドリフトチューブは ϕ 方向に沿って並べられている。ドリフトチューブの構造を図2.11、MDTの構造を図2.12に示す。ドリフトチューブ内には3気圧のアルゴン・二酸化炭素混合ガス (Ar: 93 %, CO_2 : 7 %) が封入されており、アノードワイヤーはタンクステン-レニウム合金製である。アノードとカソードの間には高電圧が印加されており、荷電粒子がドリフトチューブ内のガスを電離して発生した電子がアノードへとドリフトする。このドリフト時間を測定することで、荷電粒子の通過位置を測定することができる。主にミューオンの精密測定用に用いられ、最大35 μm の位置分解能で測定可

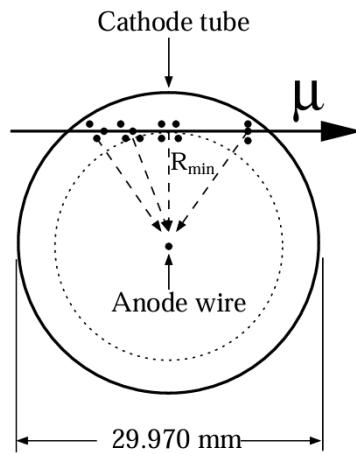


図2.11: MDTのドリフトチューブの構造 [2]。

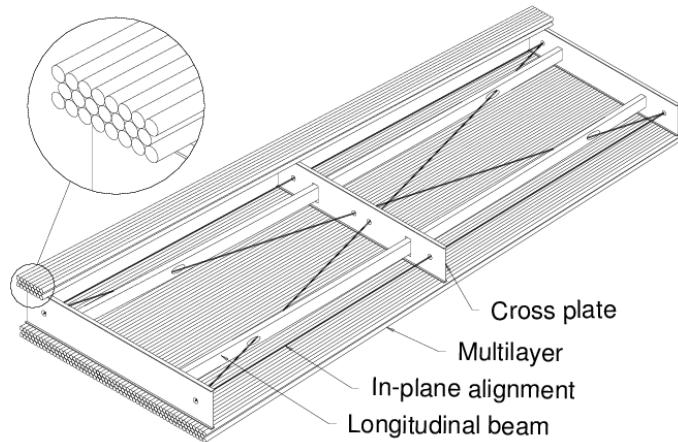


図2.12: MDTの構造 [2]。ドリフトチューブを積層した構造となっている。

能である。MDTでは ϕ 方向の測定ができないため、ミューオンの ϕ 方向の座標はRPCで測定されたものを用いる。

· Thin Gap Chambers (TGC)

エンドキャップ領域でのミューオントリガー判定に用いられる。 $1.05 < |\eta| < 2.4$ の範囲をカバーしており、 $r - \phi$ 平面での位置の読み出しを行う。TGCは multi-wire proportional chambers (MWPC) の1種である。各層は、ワイヤーとアノード層、ストリップ層から構成され、 η 方向をワイヤー、 ϕ 方向をストリップで測定している。TGC内の構造を図2.13に示す。幅2.8 mmのガスギャップ中に1.8 mm間隔で直径50 mmのアノードワイヤーが張られている。アノードワイヤーには2.9 kVの高電圧が印加されており、 CO_2 とn- C_5H_{12} の混合ガスの電離によって生じた電子をワイヤー電極及びストリップで読み出し、荷電粒子の η 方向の位置を測定して

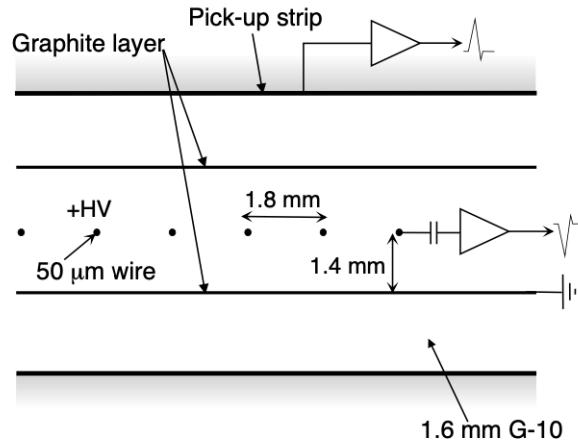
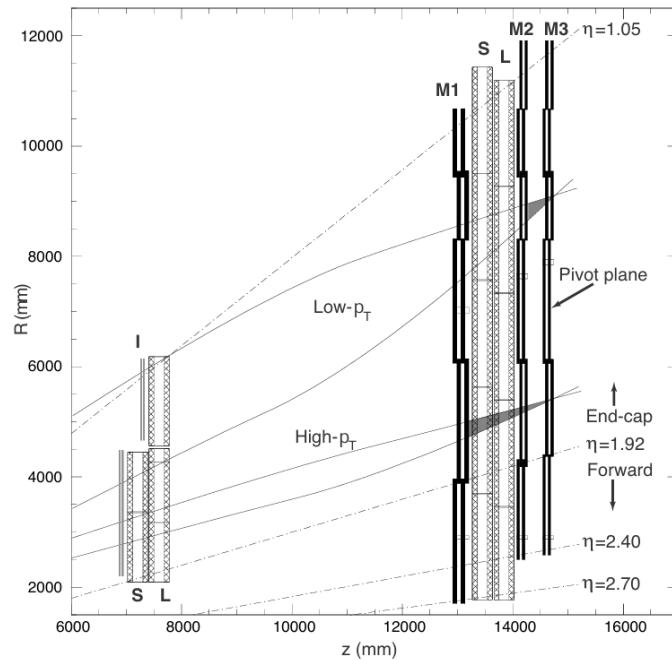


図2.13: TGCの構造 [2]。MWPCの構造をしている。

図2.14: TGCの $r - Z$ 平面から見た配置 [2]。インナーステーションに1枚、ミドルステーションに3枚配置されている。

いる。ガスゲインは約 3×10^5 となっている。また、TGC は図 2.14 のように配置されている。TGC は 2 層または 3 層の 1 組で構成されており、各層とのコインシデンスを取ることによってフェイク信号を削減している。ミドルステーションでは MDT を挟み込むように TGC が設置されており、バレル領域と同様に MDT では ϕ 方向の測定ができないので、TGC で測定した ϕ 方向の座標をミューオンの通過位置として用いる。

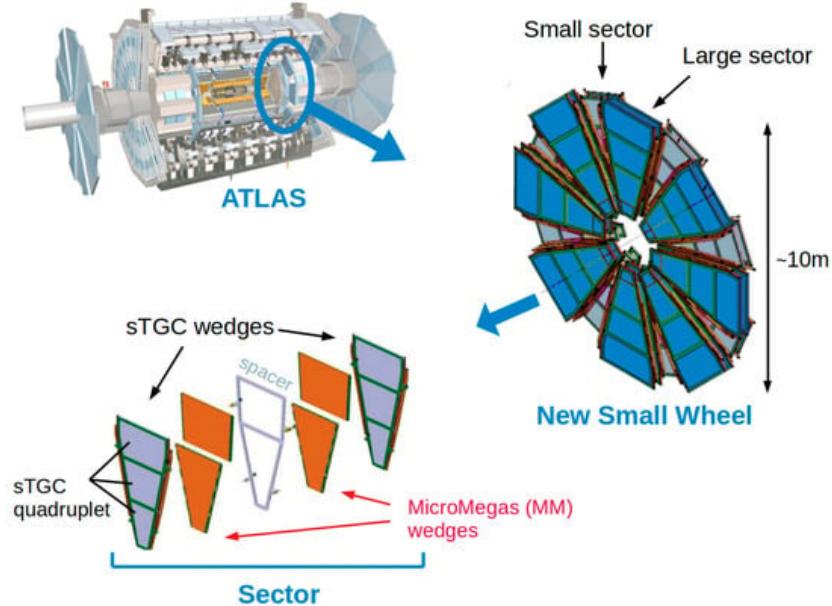


図2.15: NSWの構造 [18]。大小8つの台形セクタで構成されている。

・ New Small Wheel (NSW)

NSWはエンドキャップ領域での測定に用いられ、 $1.3 < |\eta| < 2.7$ の範囲をカバーしている。エンドキャップの最も内側に位置し、Micromegas (MM) と small-strip TGC (sTGC) の検2種類の出器を組み合わせて構成されている。直径10mのディスク型検出器を持つNSWは、図2.15に示すように大小8つのセクターから構成され、衝突点からsTGC4層、MM4層、MM4層、sTGC4層の順に、2つのMMが2つのsTGCで覆われる形で計16層取り付けられている。

sTGCは、TGCと同様に2.8mmのガスギャップを持つMWPCである。図2.16に、sTGCの構造を示す。sTGCでは、ワイヤーで ϕ 方向、ストリップで η 方向の位置測定を行う。ガスギャップの中心には18mm間隔で金メッキされたタンゲステンワイヤーが張られており、アノードワイヤーとして機能する。アノードワイヤーは1.4mmの距離にある2つのカソード平面に挟まれている。NSWの総面積は約2400m²である。ストリップの幅がATLASで用いられているTGCと比べてはるかに小さいため、位置分解能が高く、1TeVで15%の p_T 分解能、レイヤーあたり50μmの位置分解能を実現する。

MMは、ワイヤーを用いないガス検出器である。図2.17に、MMの構造及び動作原理を示す。MM検出器は、ドリフト電極、ドリフト領域として機能する厚さ5mmのガスギャップ、および増幅領域を形成する読み出し電極から約128μmの距離にある薄いステンレス製のメッシュで構成されている。検出器内はAr, CO₂, C₄H₁₀の混合ガスで満たされており、増幅領域で増幅された信号は400μm間隔で配置されたストリップから読み出される。荷電粒子がMMを通過することで生じた電子がドリフトし、メッシュを通過した後に雪崩増幅を起こす。増幅領域では電子と同時に

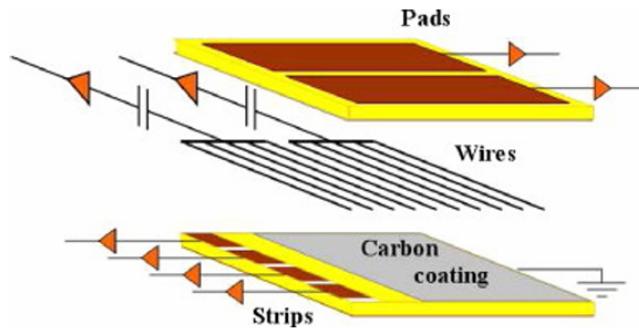


図2.16: sTGCの構造 [19]。

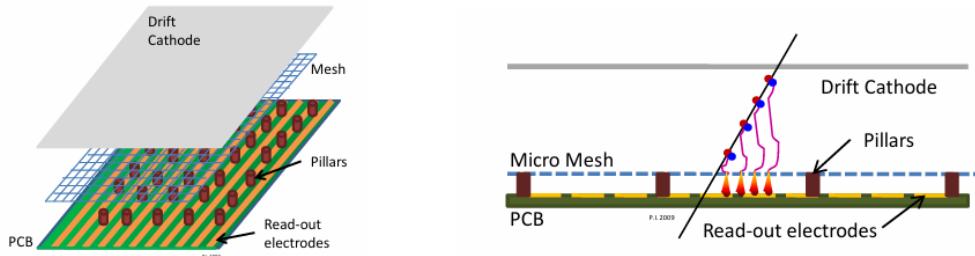


図2.17: MMの構造及び動作原理 [19]。

陽イオンも生成され、陽イオンは電子と反対方向に移動してメッシュに戻るが、MMの増幅領域は約 $128 \mu\text{m}$ と薄いためメッシュに到達するまでの時間が短くなる。そのため、高レートで粒子が飛来する環境下に適した検出器であり、比較的高いレート耐性を持っている。

2.4.1 ミューオンスペクトロメータの高輝度化に向けたアップグレード

高輝度LHC-ATLAS実験に向けたミューオンシステムのアップグレードは、検出器の厚さを減らすことによって、同じ領域に新たにチャンバーを追加するか、チャンバーあたりの層を2層から3層に増やすことによって、特にトランジション領域における飛跡のヒット数を改善することを目的としている。同時に、新しい検出器は、性能の向上、動作電圧の低下、環境負荷の低減を特徴とすることが期待される。エレクトロニクスの大部分は、すべてのサブシステムで刷新される。図2.9内に赤色の文字で示しているのが、Phase-IIアップグレードで新たに導入される予定のミューオン検出器である。バレル部について、現在RPCはBM, BOステーションのみに設置されているが、アクセプタンス向上のため、新たにBIステーションにもRPCが導入される。RPC BIは3層のガスギャップから構成されており、それぞれ独立に読み出しが行われる。また、BIにRPCが導入されることにより、スペースの問題からBIのMDTの代わりにsMDTが導入される。sMDTは従来のMDTよりもドリフトチューブが小さく、より高い分解能で位置の測定を行うことができ

る。また、High- η tagger は、文字通り大きな η の領域でミューオンを取得するために設置するものである。ID が ITk に置き換わることにより、トラッキングのためのカバレッジが $\eta = 4.0$ まで拡張される。そのため、 $\eta = 4.0$ までの範囲でミューオンを捉えることを目的としているものであるが、高輝度 LHC-ATLAS 実験開始直後の Run 4 では設置が予定されていない。

また、放射線耐性を上げるために、従来のチェンバーを低電圧で運転できるよう、新しいトリガーチェンバーの使用の検討が行われている。ガスギャップの厚みを減らした新しい RPC の機械設計が検証され、この新しいチェンバーでは、従来の RPC の 9600 V から大幅に減らした 5900 V でも一様に 98% のプラトー効率を示している [20]。

第3章

ミューオントリガーシステムと高輝度 LHC に向けたアップグレード

ATLAS 実験では、LHC 加速器を用いて 40 MHz の陽子バンチ衝突を起こし、その衝突により生成した粒子を検出する。全ての事象を保存すると 1 秒間で 100 TB もの膨大なデータ量になることに加え、観測データのうち新物理の発見などに関わり解析対象となるデータはごく一部である。そのため、重要な事象のみを効率よく選別するためのトリガーシステムが必要不可欠である。本章では、ATLAS 実験のトリガーシステムと高輝度 LHC-ATLAS 実験に向けたアップデートについて、特に本研究が関連しているミューオントリガーシステムについて述べる。

3.1 ATLAS トリガーシステム

ATLAS 実験において、オンライントリガーシステムは、ハードウェアによる高速で大まかな判定を行う初段トリガーと、ソフトウェアによるオンライン事象再構成にもとづいた精密な判定を行う後段トリガーの二段階に大別される。トリガーシステムには測定したい物理に応じてミューオン、電子、光子、タウ、ジェットなどのそれぞれのオブジェクトに対しての再構成アルゴリズムが用意されている。事象選別では、横運動量 p_T やエネルギーに対して閾値を設けることで、単位時間当たりに処理するイベントの数 (トリガーレート) が、処理能力や記憶装置の容量の上限を超えないようにしている。

LHC-ATLAS 実験 Run 3 におけるトリガーシステムの概略を図 3.1 に示す。初段トリガー (L1) は主にカロリメータからの情報を用いる L1Calo, ミューオン検出器からの情報を用いる L1Muon の 2 つの独立したシステムに基づいている。また L1 トポロジカル・プロセッサ (L1Topo) システムは、L1Calo および L1Muon システムで再構成されたオブジェクトからの情報を組み合わせた事象選別を行う。L1 トリガーの決定は、L1Calo トリガーシステム、L1Muon トリガーシステム、L1Topo システム、および他のいくつかのサブシステムから受信した入力を組み合わせて、Central Trigger Processor (CTP) によって行われる。Run 3 では、3.2 節で述べるオブジェクトタイプ、閾値、トリガメニュー要件を満たすイベントを、 $2.5 \mu\text{s}$ 以下の固定レイテンシー、最大検出器読み

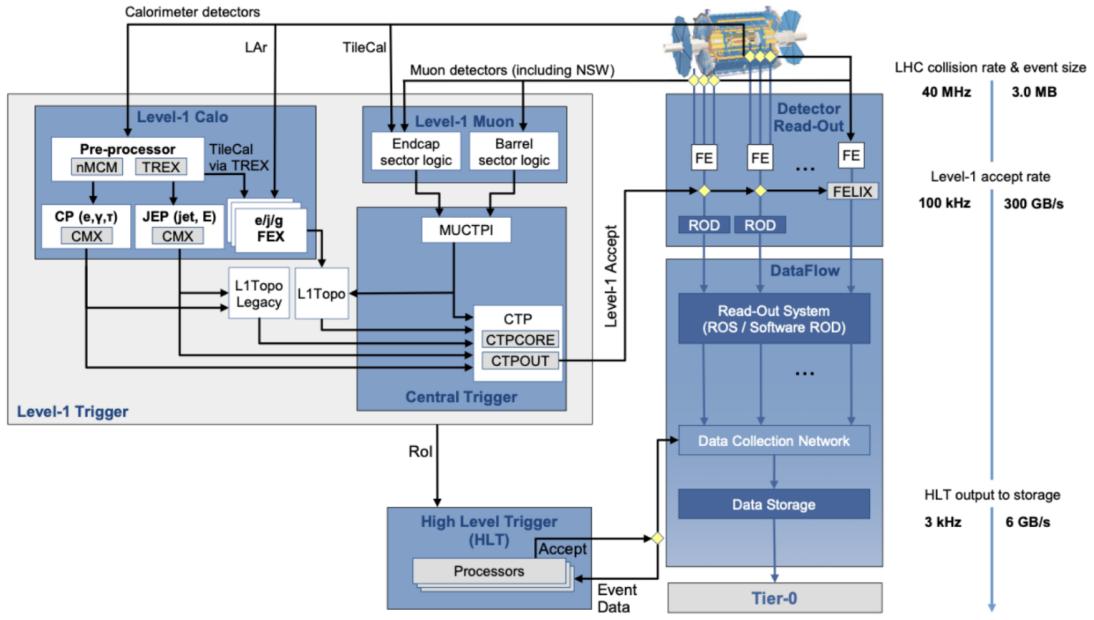


図 3.1: LHC-ATLAS 実験 Run 3 におけるトリガーシステムの概要 [21]。L1 及び HLT トリガーの選別を通過したイベントのみがデータストレージへと保存される。

出しレート 100 kHz のレートで受入れている。CTP には、最大 512 個の異なる L1 トリガー項目を設定することができる。L1 トリガーを通過したイベントは、ソフトウェアベースの後段トリガー (HLT) に送られる。HLT ではさらに詳細な事象選別を行うことでレートを数 kHz まで落とし、データ収集 (DAQ) システムに送られる。データ収集システムは、元のイベントサイズである約 3 MB から 2 MB 以下に圧縮し、オフライン処理にデータを転送する。

3.2 Run 3 におけるミューオントリガーシステム

本節では、本研究の対象であるミューオントリガーシステムについて、主に Run 3 での詳細を述べる。ミューオンはヒッグス粒子や B 中間子、またその他の新粒子が生成した際の終状態に含まれることが多い。トリガーシステムのうち、終状態にミューオンを含むような事象を選別するトリガーをミューオントリガーと呼ぶ。ミューオンは他の物質と相互作用を起こしにくいため、背景事象との区別が付きやすく、各物理の解析においてミューオンの情報を取得することが重要である。ミューオントリガーでは、磁場によって曲げられたミューオンの飛跡から横運動量 p_T を計算し、設定した p_T 閾値を超えてかのトリガー判定を行う。3.1 節で述べたとおり、ミューオントリガーでも L1 トリガーと HLT トリガーの 2 段階でトリガー判定を行っている。

Trigger	Typical offline selection	Trigger Selection		L1 Peak Rate [kHz]	HLT Peak Rate [Hz]
		L1 [GeV]	HLT [GeV]	L=2.0×10 ³⁴ cm ⁻² s ⁻¹	
Single leptons	Single isolated μ , $p_T > 27$ GeV	20	26 (i)	16	218
	Single isolated tight e , $p_T > 27$ GeV	22 (i)	26 (i)	31	195
	Single μ , $p_T > 52$ GeV	20	50	16	70
	Single e , $p_T > 61$ GeV	22 (i)	60	28	20
	Single τ , $p_T > 170$ GeV	100	160	1.4	42
Two leptons	Two μ , each $p_T > 15$ GeV	2×10	2×14	2.2	30
	Two μ , $p_T > 23, 9$ GeV	20	22, 8	16	47
	Two very loose e , each $p_T > 18$ GeV	2×15 (i)	2×17	2.0	13
	One e & one μ , $p_T > 8, 25$ GeV	20 (μ)	7, 24	16	6
	One loose e & one μ , $p_T > 18, 15$ GeV	15, 10	17, 14	2.6	5
	One e & one μ , $p_T > 27, 9$ GeV	22 (e, i)	26, 8	21	4
	Two τ , $p_T > 40, 30$ GeV	20 (i), 12 (i) (+jets, topo)	35, 25	5.7	93
	One τ & one isolated μ , $p_T > 30, 15$ GeV	12 (i), 10 (+jets)	25, 14 (i)	2.4	17
	One τ & one isolated e , $p_T > 30, 18$ GeV	12 (i), 15 (i) (+jets)	25, 17 (i)	4.6	19
Three leptons	Three very loose e , $p_T > 25, 13, 13$ GeV	20, 2×10	24, 2×12	1.6	0.1
	Three μ , each $p_T > 7$ GeV	3×6	3×6	0.2	7
	Three μ , $p_T > 21, 2×5$ GeV	20	20, 2×4	16	9
	Two μ & one loose e , $p_T > 2×11, 13$ GeV	2×10 (μ)	2×10, 12	2.2	0.5
	Two loose e & one μ , $p_T > 2×13, 11$ GeV	2×8, 10	2×12, 10	2.3	0.1
Single photon	One loose γ , $p_T > 145$ GeV	24 (i)	140	24	47

図 3.2: Run 2 における瞬間ルミノシティ最大 2.0×10^{34} cm⁻²s⁻¹ でのトリガーメニューの例 [22]。

3.2.1 トリガーチェイン

初段トリガーと後段トリガーのトリガー条件を組み合わせたものをトリガーチェインと呼び、各チェインには物理用途に合わせたアルゴリズムで構成されている。また、トリガーチェインとトリガーレートの配分をまとめたものをトリガーメニューと呼んでいる。トリガーチェインはそれぞれの役割によって複数用意されており、例えば物理解析のために使用されるプライマリートリガーや、効率や性能の測定、バックグラウンドの推定やモニタリングに使用されるサポートトリガーなどがある。図 3.2 に、トリガーメニューの一例を示す。ミューオントリガーでは、 B 中間子の崩壊の物理のための数 GeV のミューオンを捉えるためのものから、新物理探索のための高い運動量のミューオンを捉えるものなど、幅広く用意されている。物理としては基本的には高い p_T のものだけでなく低い p_T のミューオンも取得することが望ましいが、取得できるレートとの兼ね合いから、低い p_T のみを条件にミューオンをトリガーすることはできない。よって、より低い p_T のミューオンを取得するためには、レートを抑える工夫が必要である。例えば初段トリガーでは同時に複数のミューオンが存在するといった条件をかけることでレートを減らし、低い p_T のミューオンを取得可能なアルゴリズムが存在する。

3.2.2 初段ミューオントリガーシステム (L1 ミューオントリガー)

L1 ミューオントリガーは、RPC と TGC からのヒットを使用して、無限運動量のミューオンからのヒットパターンのずれを測定した後、無限運動量のミューオンに期待されるヒットパターンからの偏差の程度を用いてミューオンの横運動量 p_T を推定する。ここで、無限運動量のミューオンとは、磁場に曲げられることなく直線の飛跡を持つミューオンとして定義している。エンドキャップ領域における概念図を図 3.3 に示す。この p_T を推定するための電子回路をセクターロジックと

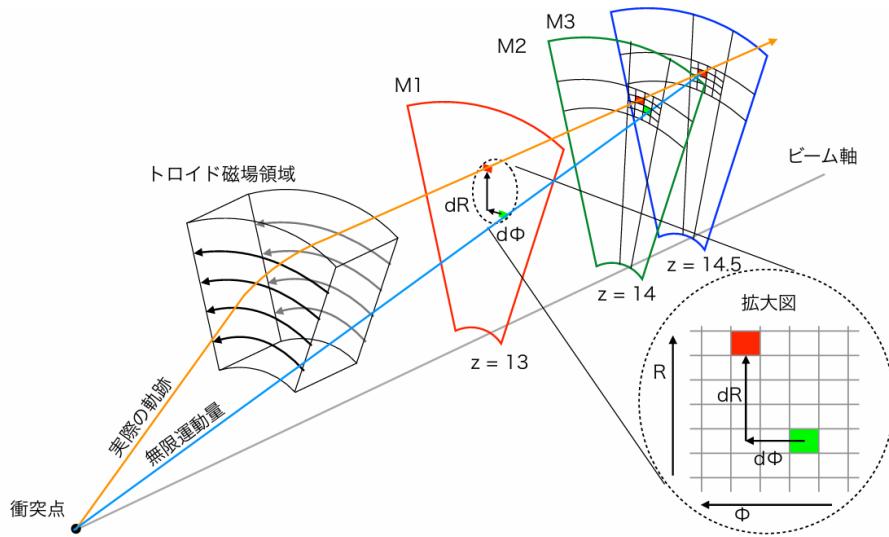


図 3.3: エンドキャップ領域におけるセクタロジックの概念図 [24]。無限大の運動量を持つミューオンを仮定し、磁場によって曲げられたミューオンとの位置の差 ($(R$ 方向: ΔR 、 ϕ 方向: $\Delta\phi$)) を計算することで p_T を見積もる。

呼び、あらかじめプログラムしてある ΔR , $\Delta\phi$ と p_T の参照表を Coincidence Window と呼ぶ。 Coincidence Window を用いて p_T を出力した後、 p_T 閾値を設定してトリガーを行う。

エンドキャップ領域に関して、Run 3 ではエンドキャップセクタロジックのアップグレードを行った。このアップグレードでは、低い運動量を持つ 2 つのミューオンのトリガーが必要な B 中間子の物理などの細かいトリガーの要求に対応するため、TGC の閾値の数を 6 から 15 に増やした [23]。図 3.4 に 2022 年のエンドキャップ領域のシングルミューオントリガーの効率を示す。また、エンドキャップ領域では衝突によって生成されたクォークがハドロン化し、前方の物質と反応することで生成した粒子がミューオン検出器に入ってくる事象が多くある。そのような低い運動量荷電粒子のレートを低減するために、Run 2 からは外側の TGC ステーションと内側の TGC ステーションまたはタイルカロリーメータとの間にコインシデンスを適用している。

バレル領域では、低い運動量と高い運動量でトリガーアルゴリズムを使い分けている。3 層の同心円状に配置された RPC の情報を使用してトリガーの決定を行い、その決定はコインシデンスロジックに依存する。このアルゴリズムの概念図を図 3.5 に示す。低い p_T トリガーでは中間の RPC 層 (RPC1, RPC2) でのコインシデンスが必要とされ、高い p_T トリガーでは低い p_T トリガーのロジックが満たされることに加えて、外側の RPC 層 (RPC3) でのコインシデンスを要求する。この場合、RPC2 のヒットがあることを要求し、ヒットがあった場合にのみ、ヒット周辺の領域 (ロード) に他のヒットがあるかを探索する。ロードは RPC2 のヒットと衝突点を結んだ直線を囲む範囲内と定義される。低い p_T のミューオンは大きく曲がるため、トリガー判定を行う際には、ロードが広く定義され、逆に高い p_T のミューオンはあまり曲がらないため、ロードが狭く定義される。図 3.6 に、シミュレーションサンプルを用いたバレル領域のミューオントリガーの効率を示

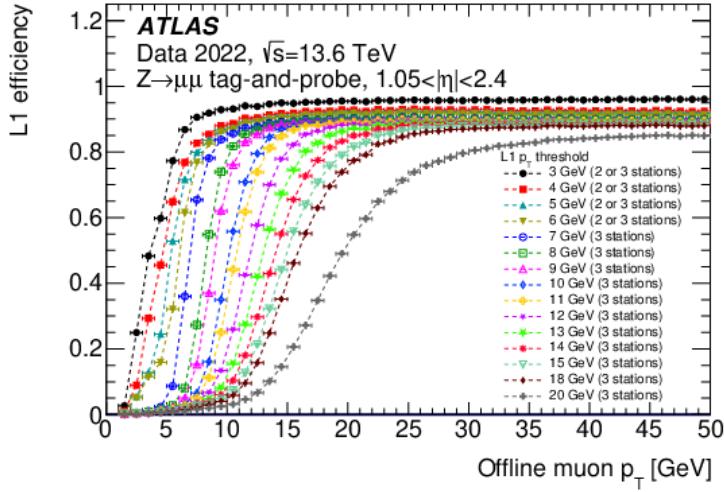


図 3.4: エンドキャップ領域の L1 シングルミューオントリガーの効率 [21]。15 段階のトリガー閾値が設けられている。黒色の 3 GeV 閾値では 2 ステーション以上の要求のみなのでトリガー効率が高くなっている。高い p_T ほど Coincidence Window の幅が狭くなるが、エンドキャップ部の磁場が複雑であるため全てをカバーすることは難しく、20 GeV 閾値のトリガー効率が最も低くなっている。

す。RPC の閾値の数は合計 6 つに設定されている。

初段トリガーの後に処理を行う後段トリガーでは、より精密なトリガー判定を行うため処理時間がかかる。そのため、再構成を行う範囲をあらかじめ限定する必要がある。そこで、初段トリガーにて設定された p_T 閾値以上のミューオンが通ったと判断された場合には、候補となるトリガーオブジェクトが特定された領域である限定的な関心領域 (Region of Interest: RoI) を定義する。この RoI を中心に、次節で述べる後段トリガーシステムが処理を行う。

3.2.3 後段ミューオントリガーシステム

後段ミューオントリガーのアルゴリズムは、中で大きく二つの段階に分かれており、初段トリガーよりも詳細にイベント再構成を行う。第一段階では、初段トリガーによって識別された RoI 内で高速再構成を行い、第二段階ではオンライン再構成で使用されるアルゴリズムと非常に近いアルゴリズムを用いて、検出器全体の情報を使用した再構成を行う。一部のトリガーでは、正確な p_T 測定に加え、 B 中間子や D 中間子などの比較的寿命が長い粒子から崩壊したミューオンである non-prompt ミューオンを排除するためのアイソレーションも要求される。2024 年の運転では、isolate された単一ミューオントリガーの最低 p_T 閾値は 26 GeV に設定している。一般的に低い p_T を持つミューオンの数は大変多いため、より低い閾値を持つトリガーは、 B ハドロンの崩壊やその他の事象の特徴に対応する複数のミューオンやオブジェクトを要求することで利用可能である。単一ミューオンを捉える代表的なチェインの場合、Run 3 ではミューオンの再構成はまず内部

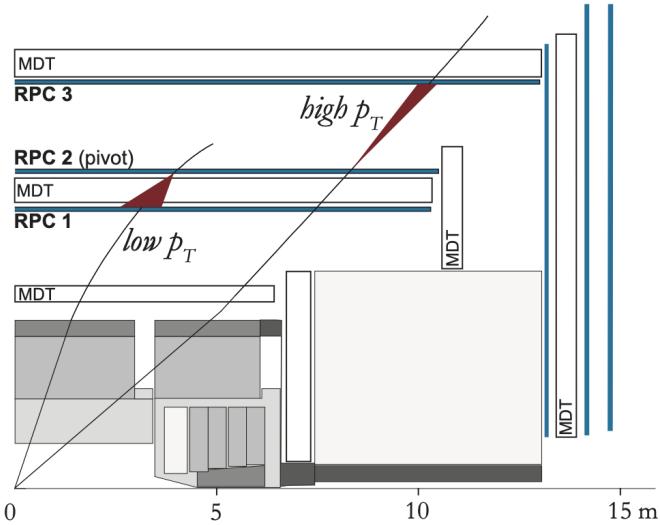


図 3.5: バレル領域の L1 ミューオントリガーアルゴリズムの概念図 [21]。赤く示しているのが、コインシデンスを要求する範囲 (ロード) である。高い p_T を狭く、低い p_T ほど広く設定している。

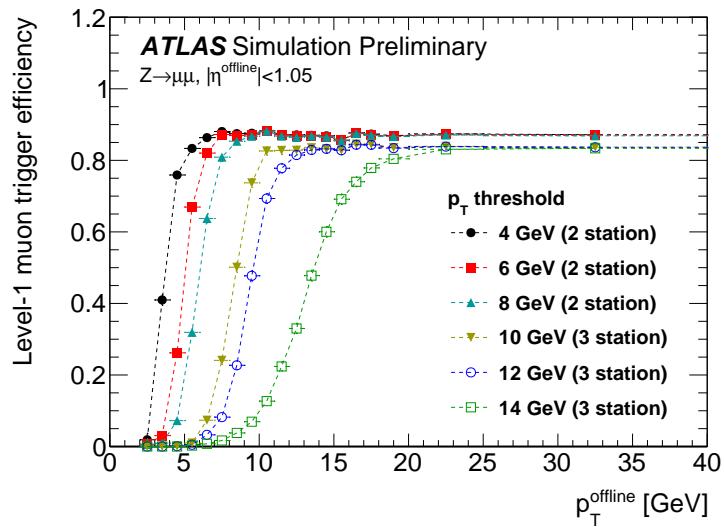


図 3.6: Run 2 シミュレーションを用いたバレル領域の L1 シングルミューオントリガーの効率 [25]。6 段階のトリガー閾値が設けられている。2 ステーションを要求する場合と 3 ステーションを要求する場合とでトリガー効率の最大値が異なる。

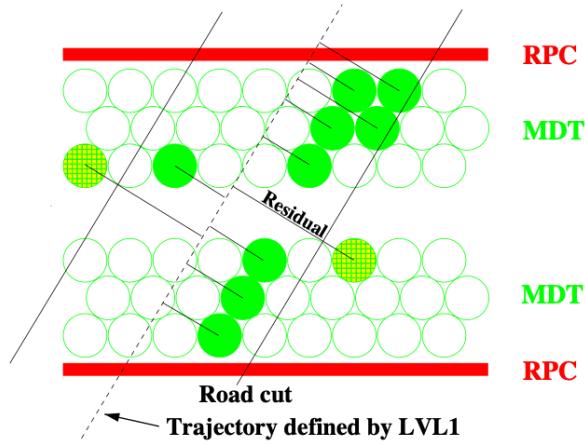


図 3.7: MDT 内のロードと residual [26]。破線は RPC データのみで計算したロード中心。residual は、各ヒットの MDT チューブ (塗りつぶされた円) からロード中心までの距離を表す。ロードの外側にあるヒットは再構成されたミューオントラックから除外される。

飛跡検出器 (ID) とミューオンスペクトロメータ (MS) で独立して行われ、1段階目の高速再構成 (MuonSA, MuComb) の後に、二段階目の詳細な飛跡再構成 (MuonEF) が走る。以下に詳細を述べる。

MuonStandAlone (MuonSA)

MuonSA では、MS 内でのミューオンの飛跡再構成を行う。まず初めに、ロードと呼ばれるミューオン再構成を行う範囲となる MDT ステーション内の領域を定義する。バレル領域では L1 で定義された RoI 付近の RPC の情報を用いてロードを決定する。RPC はミドルステーションとアウターステーションに設置されているため、二つのステーションでの RPC ヒットから大まかな飛跡の位置を求めてロードの中心を定義する。インナーステーションには RPC が設置されていないため、インナーステーションとミドルステーション間の磁場によりミューオンの飛跡が曲げられることを考慮して、ロード中心から外挿することでインナーステーションを見積もる。エンドキャップ領域では、同様に RoI 付近の TGC の情報を用いてロードを定義する。TGC のないインナーステーションの一部とアウターステーションでは、ミドルステーションのロードをインナーステーションまたはアウターステーションまで外挿し、これをロードとする。次に、ロード内にある背景事象のヒットを除去するために、図 3.7 に示すような residual を定義し、各層に 1 つのヒットしか残らなくなるまで、飛跡から最も residual が大きいヒットを除くという作業を繰り返す。また、ロード中心は residual が大きいヒットを除くたびに、残ったヒットの平均値をとって更新される。

続いて、各 MDT ステーション内で選択されたヒット (MDT チューブ) に対して、ドリフト時間測定を用いて飛跡のフィットを行う。この直線と MDT の中心を通る直線との交点を、MuonSA では図 3.8 のように Super Point と呼んでいる。Super Point は検出器内での粒子の飛跡の一部で

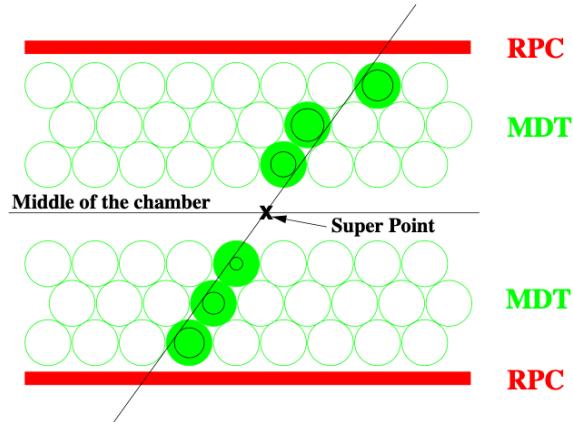


図 3.8: Super Point の定義 [26]

あり、位置と方向を持つため、複数のトラックセグメントを結びつけることで粒子の進行方向を判断することができ、飛跡を再構成するために使用される。これは、一般的にトラックセグメントと呼ばれるものである。本論文では、これらをセグメントと呼ぶ。

また、MuonSA では素早く p_T を推定するため、各ステーションごとのセグメント (Super Point) から p_T と相関のあるパラメータを求め、そのパラメータの値と p_T の対応関係をあらかじめ定義した Look Up Table(LUT) に保存しておく。 p_T と相関のあるパラメータとしては、以下に示す α , β , R_{curv} を主に使用する。

- α :

角度 α は、エンドキャップ領域の p_T と相関のあるパラメータである。図 3.9 に示すように、ミドルステーションのセグメントとアウターステーションのセグメントを結んだ直線と、ミドルステーションのセグメントと衝突点を結んだ直線のなす角で定義される。もしアウターステーション内でセグメントが再構成されなかった場合には、ミドルステーションのセグメントの傾きとミドルステーションのセグメントと衝突点を結んだ直線のなす角とする。

- β :

角度 β は、エンドキャップ領域の p_T と相関のあるパラメータである。図 3.10 に示すように、インナーステーションのセグメントの傾きと、ミドルステーションとアウターステーションのセグメントを結んだ直線とのなす角で定義される。 α と同様に、アウターステーションにセグメントが再構成されなかった場合には、ミドルステーションのセグメントの傾きを代わりに用いる。角度 β を用いることで、ミューオン検出器より内側にあるカロリメータなどの検出器内でミューオンが起こした多重散乱による飛跡の曲がりの影響を除くことができる。

- R_{curv} :

R_{curv} は、バレル領域の p_T と相関のあるパラメータである。インナーステーション、ミドルステーション、アウターステーションでのそれぞれのセグメント 3 点を通る円弧の半径で

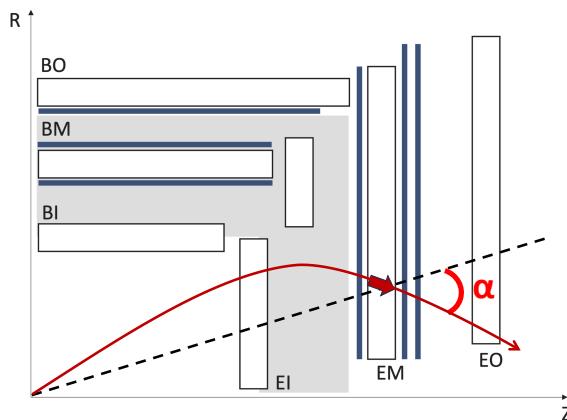


図 3.9: α の定義。ミドルステーションのセグメントとアウターステーションのセグメントを結んだ直線と、ミドルステーションのセグメントと衝突点を結んだ直線とのなす角である。

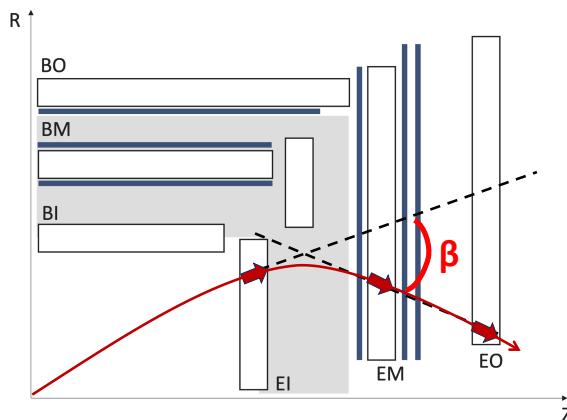
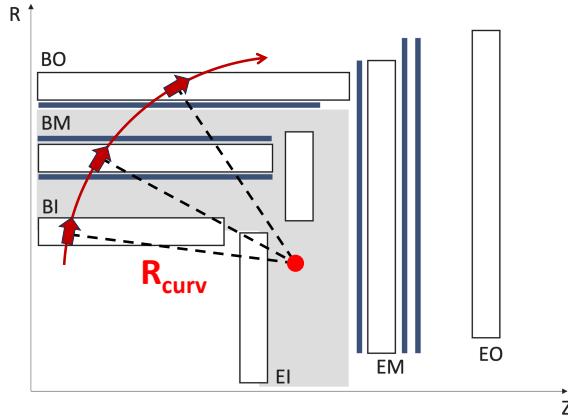


図 3.10: β の定義。インナーステーションのセグメントの傾きと、ミドルステーションとアウターステーションのセグメントを結んだ直線とのなす角である。

定義される。

最終的には、これらのパラメータからミューオン候補の p_T に閾値を設定し、その閾値以上の p_T を持つと判断されたミューオン候補については、その ROI 付近で Fast Track Finder (FTF) と呼ばれるアルゴリズムにより内部飛跡 (ID) のトラックが再構成される。FTF について以下に詳細を述べる。

図 3.11: R_{curv} の定義。

Fast Track Finder (FTF)

FTF は、MuonSA の後に走る内部飛跡の高速再構成のためのアルゴリズムである。内部飛跡はミューオン検出器に比べてかなり飛跡が多くなっているため、まず MuonSA で範囲を絞った後、さらにそれに基づいて再構成する範囲を決定している。FTF 内での RoI は、MuonSA の飛跡を衝突点まで外挿したものを中心として定義され、ID の RoI 内に残されたヒットを用いてパターン認識を行うことにより、ID 内の飛跡を再構成する。具体的には、RoI の中にあるシリコン検出器とピクセル検出器のヒットからクラスターを作り、そのクラスター中のヒットを用いて、カルマンフィルター [27] と呼ばれるアルゴリズムによって飛跡を再構成している。カルマンフィルターでは、測定されたヒットのパラメータを内層のヒット情報を基に再計算しパラメータの更新を行なっていくことで、内層から外挿へ向けて順にヒットの連なりをフィットして飛跡を再構成することが可能となっている。

MuComb

MuonSA, FTF の後に走る本アルゴリズムは、MuonSA と FTF の情報を組み合わせてミューオンの再構成を行い、 p_T を算出する。まず、MuonSA で再構成した飛跡を ID まで外挿する。外挿された飛跡の周辺で、FTF により再構成された飛跡を探索する。見つかった FTF の飛跡と MuonSA の飛跡の χ^2 を、 η , ϕ , p_T などの情報を用いて計算し、最も χ^2 が小さい飛跡を選択する。muComb で計算されるミューオンの横運動量 $p_{T,\text{CB}}$ は式 (3.1) のように定義される。

$$\frac{1}{p_{T,\text{CB}}} = \frac{\sigma_{\text{ID}}^2 \cdot \frac{1}{p_{T,\text{SA}}} + \sigma_{\text{SA}}^2 \cdot \frac{1}{p_{T,\text{ID}}}}{\sigma_{\text{ID}}^2 + \sigma_{\text{SA}}^2} \quad (3.1)$$

ここで、 σ_{ID} は $p_{T,\text{ID}}$ の精度、 σ_{SA} は $p_{T,\text{SA}}$ の精度を表す。MuonSA で再構成された飛跡の横運動量 $p_{T,\text{SA}}$ と FTF で再構成された飛跡の横運動量 $p_{T,\text{ID}}$ の精度の良い方が、より $p_{T,\text{CB}}$ に寄与す

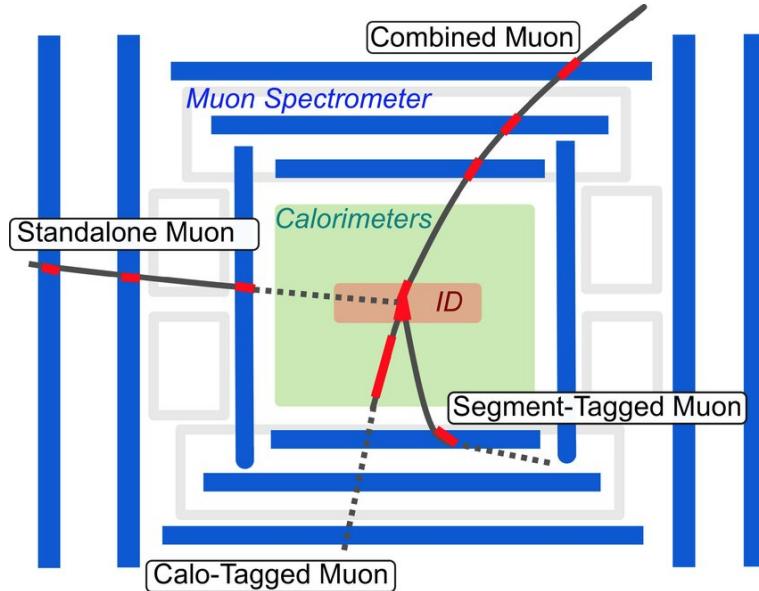


図 3.12: オフラインミューオン再構成アルゴリズムの概念図 [28]。

る。 $p_{T,SA}$ はカロリメータでのエネルギー損失の影響を受けることに加え、LUT で荒く見積もっているため、一般に精度は $p_{T,ID}$ の方が高い。しかし、衝突点から多量に生成されるハドロンとミューオンを FTF では分離することが難しいため、 $p_{T,ID}$ と $p_{T,SA}$ の平均を取ることで、よりミューオンの高い純度と p_T 分解能を得られるようにしている。MuComb により、大幅にトリガーレートが削減される。

MuonEF

MuonEF はオンライントリガーとしての最後のアルゴリズムであり、このアルゴリズムで再構成された結果は、のちの物理解析のために保存するかどうかの決定に使用される。このアルゴリズムでは、オフライン再構成で使用されるアルゴリズムと同程度の精度でミューオンの再構成が可能となっている。処理時間の制約が少し緩くなるため、MuonSA や MuComb とは異なり、RoI 基準ではなく全検出器の情報を使用し再びヒットレベルから再構成を行う。そのためかなり精密な再構成が可能であるとともに、各物理を目的として複数のミューオンが見つかる条件にした複雑なトリガーを考えることも可能になる。

オフラインミューオン再構成

オフライン再構成で行われるミューオン再構成では、どの検出器を用いて再構成を行うかによって、4 つのミューオンタイプが定義されている。各ミューオンタイプの概念図を図 3.12 に示す。

1. Combined muon :

最も多くのミューオンの再構成に使用するアルゴリズムである。飛跡再構成は FTF と MuonSA により ID と MS で独立に行われ、ID と MS 両方のヒットを用いて再度フィット

することで、二つの飛跡を組み合わせたコンバインドトラックが形成される。このフィットを行う過程では、フィットの質を向上させるために MS のヒットをトラックに追加したり削除したりすることもできる。ほとんどのミューオンは外側から内側に向かって再構成されるようになっており、まず MS で飛跡が再構成された後、その飛跡を内側まで外挿して ID トラックとマッチングを行うことでミューオン候補の再構成をおこなっている。

2. Segment-tagged muons :

ミューオンの p_T が低いか、MS のアクセプタンスが低下している領域を通過したことから、ミューオンが 1 つのステーションのみにヒットを残す場合を想定して使用される。このアルゴリズムでは、ID 内のトラックを MS に外挿した際に、MDT または NSW 内に少なくとも 1 つトラックに関連している可能性が高いセグメントが見つかった場合に、その ID トラックをミューオン候補として分類する。

3. Calorimeter-tagged muons :

このアルゴリズムでは、minimum-ionizing particle (MIP) に適合するカロリメータ内のエネルギーデポジットと ID トラックがマッチすれば、その ID トラックをミューオン候補として分類する。このタイプはすべてのミューオンタイプの中で最も純度が低いが、MS が内側の検出器のケーブルや冷却パイプなどのため配置できない領域において、アクセプタンスを上げるために使用されている。ミューオンの同定基準はその領域 ($|\eta| < 0.1$) と $15 < p_T < 100$ GeV の運動量範囲に最適化されている。

4. Extrapolated muons (Standalone muons) :

ID でカバーされていない $2.5 < |\eta| < 2.7$ の領域に対して使用される。このアルゴリズムでは、ミューオントラックは MS の情報のみをベースにし、さらに衝突点に由来するものとの互換性に関する条件も緩く設定して再構成を行う。ミューオントラックのパラメータは、カロリメータにおけるミューオンの推定エネルギー損失も考慮して定義される。

異なるミューオンタイプ間のオーバーラップは、物理解析に使用されるミューオンのコレクションを作成する前に解消する。2 つのミューオンタイプが同じ ID トラックを共有する場合、Combined muon, Segment-tagged muon, Calorimeter-tagged muon の順に優先される。Extrapolated muon とのオーバーラップは、よりトラックのフィットの質が高くヒット数の多いトラックを選択することで解消する。

また、オフラインで再構成されるセグメントは、ハフ変換 [29] を用いて検出器の軌跡上に整列したヒットを探索し、ヒットを結んだ直線のうちフィッティングにより最も確からしい直線をセグメントとして再構成される。本研究で開発したミューオン再構成アルゴリズムでは、高輝度化においてオフライン再構成のような手順でセグメントが再構成される場合を想定しているため、オフライン再構成されたセグメントを使用して開発・評価を行っている。

表 3.1: トリガーレート, レイテンシーの変更 [30]。レイテンシーが増えることで、より詳細な解析も可能になる。

	LHC Run 3	高輝度 LHC Run 4
初段トリガーレート	1 MHz	10 MHz
後段トリガーレート	1 kHz	10 kHz
初段トリガーレイテンシー	2.5 μ s	10 μ s

3.3 高輝度化に向けたトリガーシステムのアップグレード

本節では、高輝度化に向けたトリガーシステムの改良について述べる。

高輝度化により、平均パイルアップは Run 3 の 60 から少なくとも 140, 最大 200 と大幅に増加する見込みであり、ヒット数や飛跡数が増えることが予想される。現行の TDAQ システムのままでは、読み出し能力の限界があり、重要な物理の感度を落としてしまう。そこで、高輝度 LHC-ATLAS 実験に向けて、大規模な TDAQ システムの改良が行われる。それに伴い、トリガーレートと、バンチ交差が起こってからフロントエンドに初段トリガーの判定結果が届くまでの時間であるレイテンシーが表 3.1 のように変更される予定である。図 3.13 に高輝度 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示す。

また、高輝度化に向けた課題として計算資源の不足がある。図 3.14 に、LHC-ATLAS 実験において各年度で必要となる計算機資源量の見積りを示す。システムに改良を行わないと見積もった場合の予測では、年毎に計算機資源に投資する金額を 20% ずつ増加させても、必要となるリソース量に追いつかない見込みとなっている。また、再構成範囲を大幅に絞るなどのかなり大胆な改良を行った場合でも、10% ずつの資源の増設では対応できない。急増する要求リソースに設備投資のみで対応するのはコスト面からも非現実的であり、様々なアプローチから必要となる計算機資源量の削減を行い現実的に運用可能な値まで抑える必要がある。トリガーシステムにおいても、パイルアップが増加するほど 1 度の衝突で生成する粒子数も増加するため、図 3.15 に示すように、処理時間が指數関数的に増加することが見込まれている。すると、指定された時間内に計算を間に合わせるためにさらなる計算資源が必要になる。トリガーシステムにおける演算は後段トリガーでの再構成が大部分を占めている。必要な計算資源の増加を抑制しながらもオンラインでのトリガーシステムにおける処理を実現するためには、高輝度化に向けた高精度かつ処理速度もより高速となるような後段トリガーシステムの改良が必要である。

また、加速器を用いた素粒子実験は非常に大規模な実験であるため、その運用コストが膨大である。光速近くまで粒子を加速するためや、検出器の性能維持、超伝導マグネットの冷却、データ保存・解析のためのコンピューティングリソースなど、LHC 全体では小さな都市の電力消費に匹敵するような約 200 MW の電力が必要になる [34]。LHC 全体の消費電力量の中でもトリガーシステムが占める割合は無視できず、特に後段トリガーではサーバークラスのプロセッサが数千台規模で

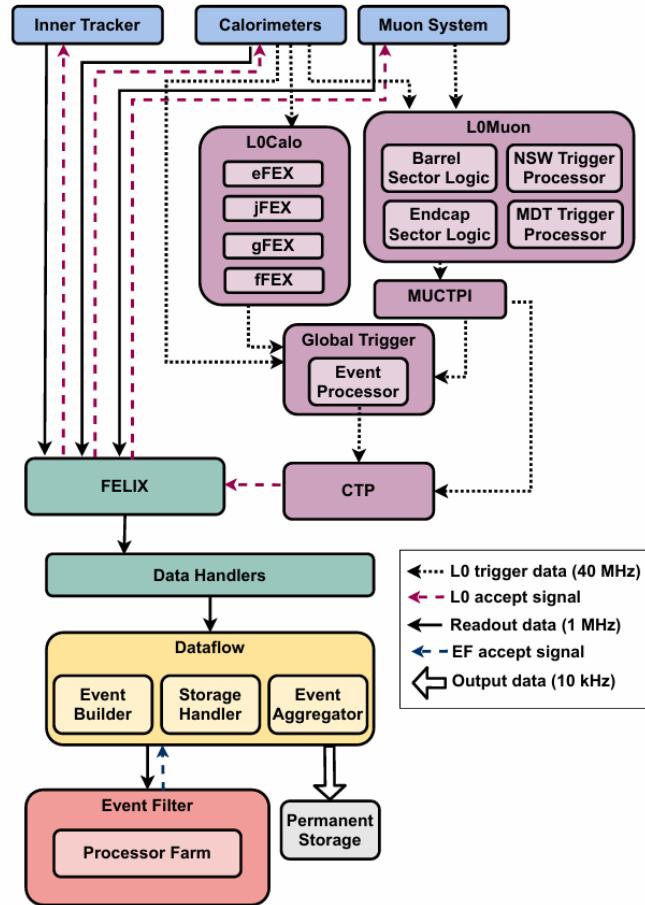


図 3.13: TDAQ Phase-II のアーキテクチャ [31]。黒い点線の矢印は、検出器システムから 40 MHz の初段 (L0) トリガーシステムへのデータフローを示す。L0 トリガーでは 10 μ s 以内に物理オブジェクトを識別し、その後データ収集システム (DAQ) システムを通して識別し、データ読み出しシステム (FELIX) で 1MHz のレートで読みだされる。EF システムは、イベントレートを 10 kHz に下げるためヘテロジニアスプロセッサファームで構成される。EF トリガ決定によって選択されたイベントは、永久保存される。

動作しており (Run 3においては 56,000 コア [35])、トリガーシステム全体の電力消費の大部分を占めている。このように消費電力量の増加も懸念されているため、持続可能な実験を行うためにもそのような問題を解決していく努力が必要である。

3.3.1 初段ミューオントリガーシステムのアップグレード

現在の初段ミューオントリガーシステムのグレードアップが必要な理由は、利用可能なレイテンシーとレートが限られていることと、トリガー効率と運動量分解能が比較的低いことである。高輝度 LHC-ATLAS 実験では、ミューオントリガーは 20 GeV 以上の p_T 閾値に対して 40 kHz

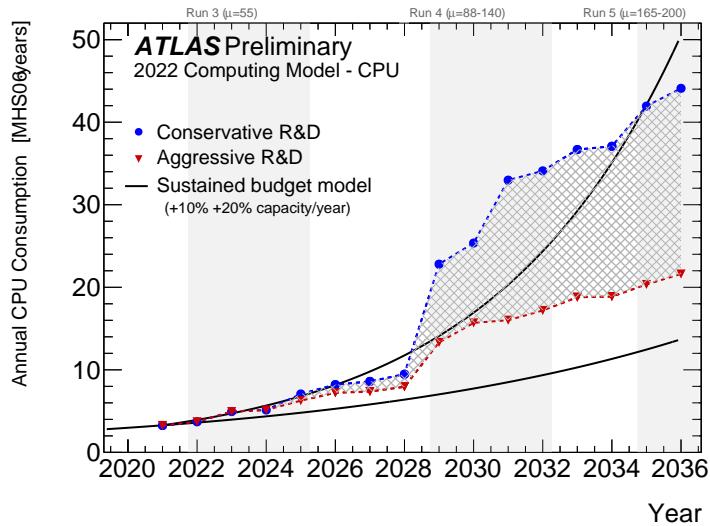


図 3.14: LHC-ATLAS 実験において各年度で必要となる計算機資源量の見積り [32]。青のマークは技術開発の進展を保守的に見積もった場合、赤のマークは技術開発が大きく進展した場合の必要な計算資源量を表す。黒の線がそれぞれ毎年 10% 及び 20% ずつハードウェアに投資する金額を増加させた場合に賄うことができる計算機資源量を示している。

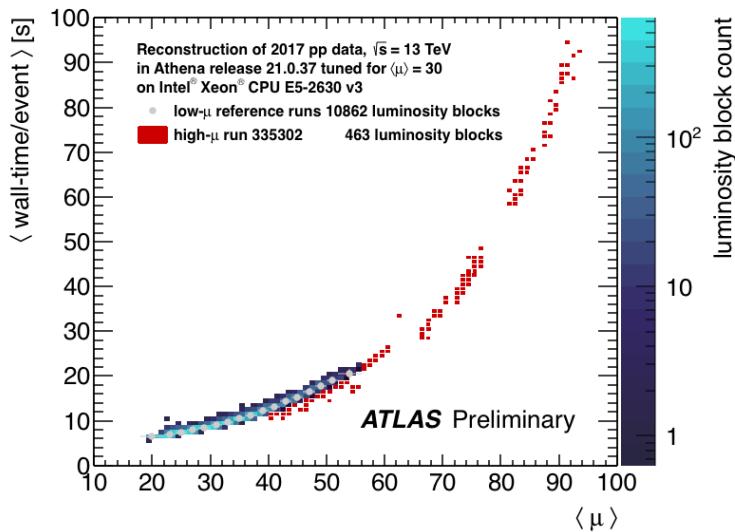


図 3.15: トリガーシステムにおけるパイルアップに対する処理時間の変化 [33]。パイルアップの増加に伴い、処理時間が指数関数的に増加する見込みとなっている。

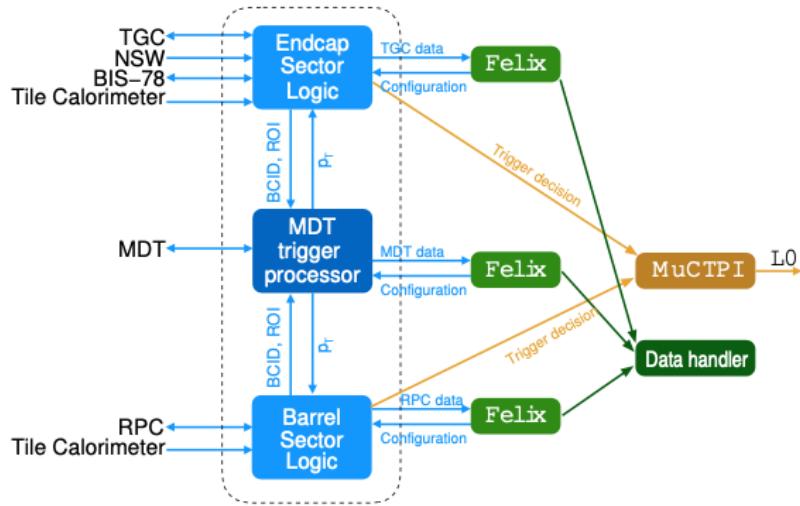


図 3.16: L0 ミューオントリガーの読み出しシステムの概要 [30]。ミューオントリガーチェンバー (TGC と RPC) からのデータ、タイルカロリーメータからのデータを用いて、エンドキャップとバレルセクターロジック (SL) で行われる。その後、SL から MDT トリガプロセッサにデータが転送され、SL で計算された運動量などをより正確な値で上書きし、再度 SL にデータを転送する。異なる SL モジュールのトリガ判定は、muon-to-central-trigger-processor interface (MuCTPI) によって収集される。すべてのミューオンヒットデータは、FELIX (Front-End Link Interface eXchange) を通して読み出され、FELIX モジュールから後段トリガーとダウンストリーム読み出しシステムに渡される。

以下のレートで高効率にシングルミューオンをトリガーする必要がある。一方、より低い p_T 閾値 ($p_T > 4 \text{ GeV}$) でもマルチミューオントリガーや複合トリガーで実行可能であるべきである。現在のシステムでは、この高輝度 LHC での読み出しきのレイテンシーとレートに対応することは不可能である。

トリガーと読み出しシステムのレイテンシーの変更やレートの向上に対応するため、RPC、TGC、MDT チェンバーのトリガーと読み出しえレクトロニクスに大きな変更が必要となる。新しい設計では、トリガーシステムの性能を最大化するため、RPC、TGC、MDT チェンバーのフルヒットデータは計数室 (USA15) に直接送られ、RPC と TGC のセクターロジック (SL) ボードと MDT トリガープロセッサーに送られる。高輝度 LHC-ATLAS 実験では、これまで MDT を使用していなかった初段トリガーでも MDT を使用する予定になっており、MDT のシステムも大幅なアップグレードが行われる。MDT フロントエンドエレクトロニクスは、初段トリガーに精密な p_T 測定を提供することが期待されているため、初段トリガーのトリガーレートとレイテンシーに適合させる必要がある。図 3.16 に、初段ミューオントリガーの読み出しシステムの概要を示す。

バレル領域でのトリガーロジックでは、第 2 章で述べた検出器のアップグレードに伴い、図 3.17 に示す BI ステーションの 3 面 (RPC0)、BM ステーションの内側の 2 面 (RPC1)、BM ステー

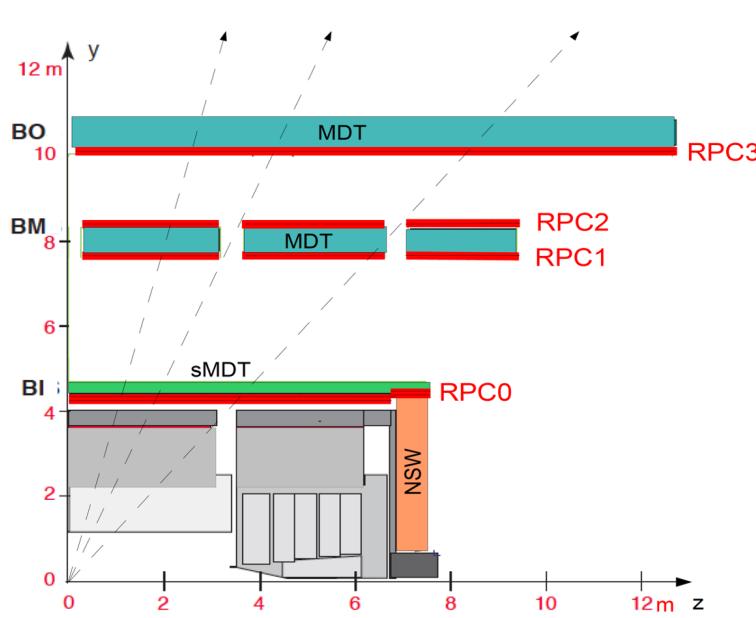


図 3.17: Phase-II アップグレード後の高輝度 LHC で使用する RPC [30]。

ションの外側の 2 面 (RPC2)、BO ステーションの 2 面 (RPC3) の 9 つの測定面を使用する。これらの導入により、特に低かったバレル領域の初段トリガー効率が向上する見込みである。

3.3.2 後段ミューオントリガーシステムのアップグレード

初段トリガーに比べて計算処理が多い後段トリガーでは、電力とコスト、また計算資源増設のために必要なスペースに関するリスクを軽減するために、アルゴリズムの最適化や新たな計算機資源の利用などが要求されている。今後持続可能な実験を行うためにも大幅な改良が必要であり、高輝度 LHC の後段トリガーにおいて、どのような計算機アーキテクチャを使用するかの決定が 2025 年中頃に行われる。

Phase-II での後段トリガー (EventFilter: EF) の課題は、高輝度環境下でのパイルアップ増加によるアルゴリズム実行時間の上昇を緩和しつつ、増加した入力レートに対応することである。これを解決するには、必要な計算能力を提供するための計算機ファーム (ハードウェア) と、必要なセレクションと高速なアルゴリズムを提供するソフトウェアの両方の改良が必要である。近年多くのコア数を備えたマルチコア Central Processing Unit (CPU) や、第 4 章で述べる GPU や FPGA を CPU と組み合わせて演算を行うヘテロジニアスコンピューティングを利用したシステムが発展してきている。Graphics Processing Unit (GPU) や Field Programmable Gate Array (FPGA) を搭載した CPU がすべて同じパッケージに統合され、それらの間で高速メモリ転送ができる可能性もある。近年、これらの状況を考慮して、GPU や FPGA を使用して飛跡再構成を行う試み [36] や、特に並列計算が多く GPU や FPGA の利点を活かせる機械学習を使用した飛跡再構成の研

究 [37] が盛んに行われている。そこで、本研究では高輝度化に向けたトリガーシステムの改良案として、ヘテロジニアスコンピューティングのトリガーシステムへの導入を検討し、特にそれらの利点を活かせる機械学習を用いた新たなトリガーアルゴリズムに注目した。両者については、第4章で詳しく述べる。

また、後段トリガーの飛跡再構成における Run 3 からの大きな変更点は、後段トリガーの処理を行うファームとは別に、内部飛跡再構成専用のファームが新たに設置され、より内部飛跡再構成にリソースをかけられるようになることである。その場合、現在のように MuonSA で予め範囲を絞った後でなくとも内部飛跡の再構成が可能になり、ミューオン再構成の初めの段階から内部飛跡を利用することができる。3.2.3 節でも述べたとおり、一般的にミューオン検出器内でのみ再構成された飛跡よりも、内部飛跡の方が精度が高い。また、内部飛跡検出器が ITk に置き換わることによりさらに精度の良い飛跡を得られる予定である。これらのことから、本研究ではミューオン再構成の初めの段階から内部飛跡を利用した新たなトリガーアルゴリズムの開発と評価を行った。このアルゴリズムについては、第5章で詳しく述べる。

第4章

機械学習を用いたヘテロジニアスコンピューティングの評価

まず、第3章で言及した機械学習とヘテロジニアスコンピューティングについて、実際にトライガーラーに導入するにあたりどのようなメリットが得られるかを確認する必要がある。本章では、これらの評価について述べる。

4.1 機械学習

機械学習とは、コンピュータが明示的なプログラムによる指示を受けずに、データからパターンや法則を学習し、それをもとに予測や意思決定を行う技術や方法論のことである。機械学習は人工知能の一分野であり、データを活用してモデルを構築し、そのモデルを用いて様々なタスクを実行することができる。素粒子実験は膨大なデータを扱う分野であり、機械学習の手法はこのような大規模データの解析やモデリングに非常に有効であるため、近年素粒子実験分野でも機械学習が使用してきた。代表的なものには、信号と背景事象を区別するためによく使用される Boosted Decision Trees (BDT) などがある。機械学習は学習の方法に応じて様々な種類に分類されるが、本研究ではそのうちの1つである教師あり学習を用いた。教師あり学習は、ラベル付きデータを用いて学習する方法であり、入力値と出力値の関係性を学習する。主なタスクとしては分類と回帰がある。以下に詳しく述べる。

分類

分類の機械学習では、データをあらかじめ定義されたカテゴリ（ラベルやクラス）に分けることを目的としている。モデルは「入力データ（特徴）」と「正解ラベル」のペアで構成されたデータから学習を行い、新しいデータに対して適切なクラスを予測する。図4.1に、分類タスクの例を示す。

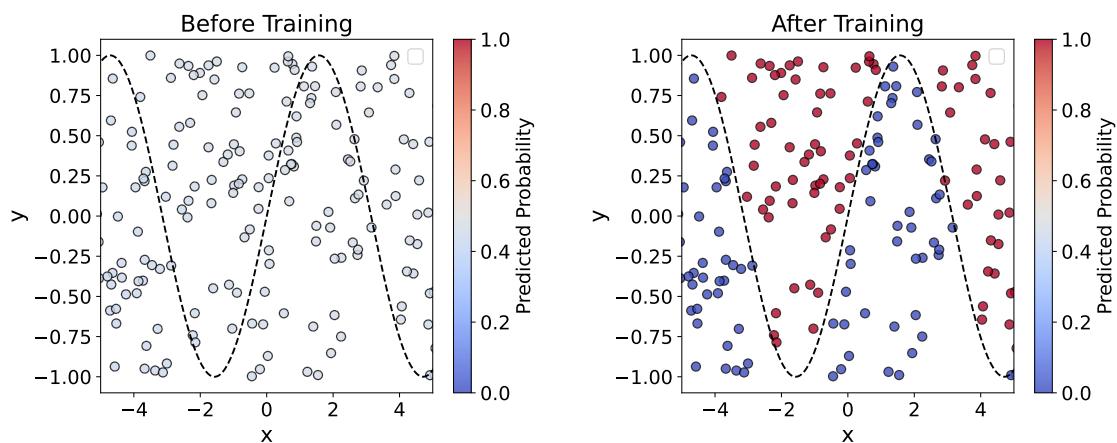


図 4.1: 分類タスクの例 ($f(x) = \sin x$ よりも大きいか小さいかの分類)。 $\sin x$ より大きいと予測すれば 1 (赤色) に近く、小さいと予測すれば 0 (青色) に近くなる。入力値には x, y を、ラベル (正解値) は $\sin x$ より大きければ 1, 小さければ 0 を使用して分類の学習をさせる。学習後に、赤色と青色の点が $f(x) = \sin x$ を境に分類されていることがわかる。

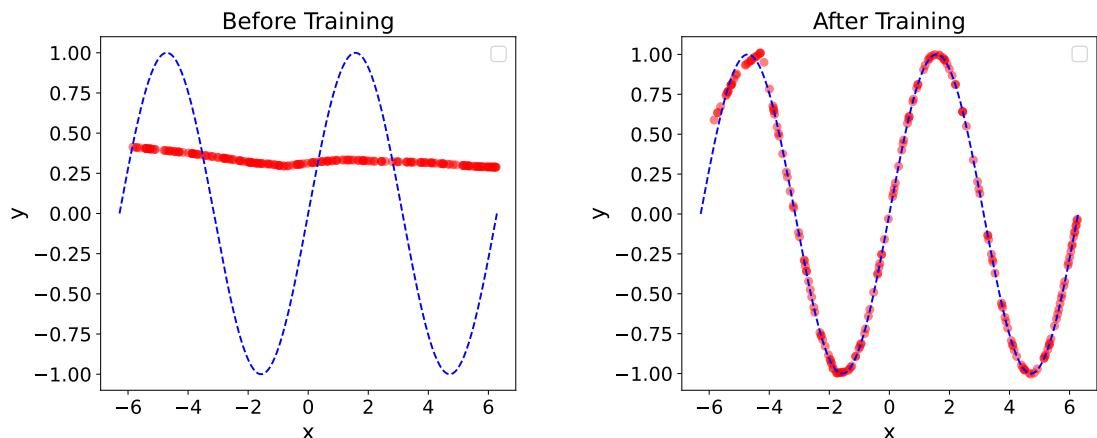


図 4.2: 目標値 $f(x) = \sin x$ に対する回帰学習の例。入力値には x, y を、ラベル (正解値) には $\sin x$ の値を使用する。学習前はバラバラに分布していた点が、学習後には $f(x) = \sin x$ 上に並んでいることがわかる。

回帰

回帰学習では、入力値に対して別の数値を予測することを目的としている。モデルは入力データ (特徴量) と目標値 (出力) の関係を学習し、未知のデータに対して数値を予測する。図 4.2 に、回帰タスクの例を示す。

4.1.1 ニューラルネットワーク

機械学習には数多くの種類があるが、本節では本研究で主に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とは、人間の脳内にある神経細胞（ニューロン）とそのつながりを数式的なモデルで表現したものである。つまり人間の脳に似た方法で意思決定を行う機械学習プログラムまたはモデルのことで、生物学的なニューロンが連携して現象を特定し、選択肢を検討し、結論を導き出す方法を模倣したプロセスを使用している機械学習の一種である。特に大量のデータを用いたパターン認識や予測問題に強力な手法である。すべてのニューラルネットワークは、1つの入力層、1つ以上の隠れ層、1つの出力層を含むノードの層で構成される。

パーセプトロン（ニューロン）

パーセプトロンは生物の神経細胞を模倣したもので、情報を受け取り、それを処理して次の層に伝える基本単位である。パーセプトロンの概念を表したもののが図 4.3 である。式 (4.1) に表されるように、パーセプトロンは n 個の入力の数値 $x_i(x_1, x_2, \dots, x_n)$ にそれぞれ重み $w_i(w_1, w_2, \dots, w_n)$ を掛け合わせて和を求め、さらにバイアス b を加える。この値 a を、式 (4.2) にあるように活性化関数 f に入力して出力を求める。

$$a = \sum_{i=1}^{n-1} (x_i \times w_i) + b \quad (4.1)$$

$$y = f(a) \quad (4.2)$$

活性化関数 f は一般的にシグモイド関数 ($\frac{1}{1+e^{-x}}$) や双曲線正接関数 ($\tanh x$)、ReLU 関数などが用いられる。近年最も使用されているのは ReLU 関数で、入力が 0 以下であれば 0、0 より大きければその値を返す関数である。非常にシンプルな関数のため、計算量が少なく計算速度が速いほか、他の関数に比べて上限値が 1 でなく表現が広いので、学習が進まなくなることを防ぎやすいという利点がある。また、分類の最終出力によく使用される活性化関数は softmax 関数で、全ての出力値の合計が 1 になるように入力値を変換する。こうすることにより、各分類クラスの確率のよう直感的に理解しやすい値を出力することができる。学習とはバイアス b と重み w_i を調整し最適化することで、学習により入力に対して期待する出力が可能となる。

ニューラルネットワークには様々な種類があるが、よく使用されているものの一つに多層パーセプトロン (Multi-Layer Perceptron: MLP) がある。MLP はパーセプトロンを複数接続したものである。図 4.4 に、「入力層」「隠れ層」「出力層」で構成される MLP の構造例を示す。単一パーセプトロンの欠点には、出力が 1 つの値に限定されており、線形分離可能な問題にしか使うことができないということがあった。しかし、MLP では入力層と出力層との間に中間層があり、表現量（調整可能なパラメータ）が増加し、MLP 全体として複雑な出力が可能となった。また、中間層は何層にも追加することができ、4 層以上の層を使用した学習を深層学習と呼ぶ。層が多いほど複雑な特徴を表現できるため、一般には層が多いほど精度が高くなるが、学習が複雑になるという問題も

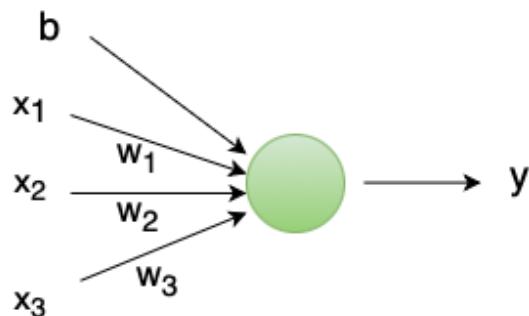


図 4.3: 単一パーセプトロン。

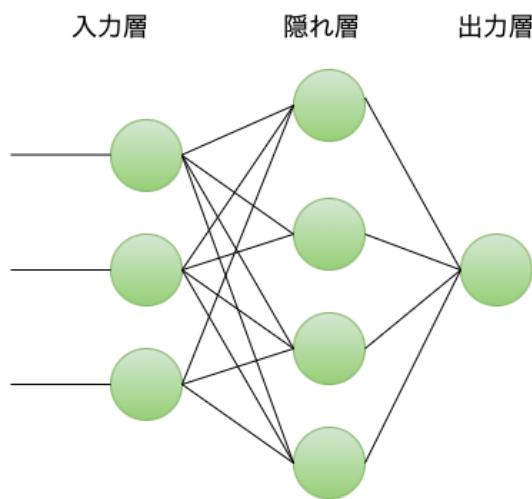


図 4.4: 3 層で構成される多層パーセプトロンの例。各パーセプトロンは前の層にある全てのパーセプトロンからの入力を受ける。

ある。

深層学習の代表的な例には、MLP の他に主に画像認識で使用される CNN (Convolutional Neural Network, 畳み込みニューラルネットワーク) がある。ある画像を学習させる際に、画像が持っている数値を入力値として 1 次元の配列にした場合、つながっていた 1 つの特徴量が離れた場所に配置されてしまったり、画像ごとに特徴量がある位置が異なっていてモデルが別の物体として認識してしまったりする可能性がある。そこで、同じ特徴であれば、特徴の位置が受容野内ですれていっても同じ特徴 (特徴量の移動不变性) として扱えるようにしたのが CNN である。

CNN は一般的に入力層、畳み込み層、プーリング層、全結合層、出力層で構成されている。図 4.5 に代表的な構造例を示す。畳み込み層は局所的な特徴量の抽出の役割、プーリング層は特徴量の移動不变性の付与を行う役割を担っている。まず畳み込み層では、入力画像と同じ次元サイズを持つが入力画像よりサイズが小さいカーネルフィルターを使用する。カーネルフィルターが入力画像の上を 1 ステップずつスライドし、カーネルフィルターの重みと入力画像のピクセル値の内積を計算することで、特徴量を抽出した二次元のマップが生成される。畳み込み層の概念を図 4.6 に示す。

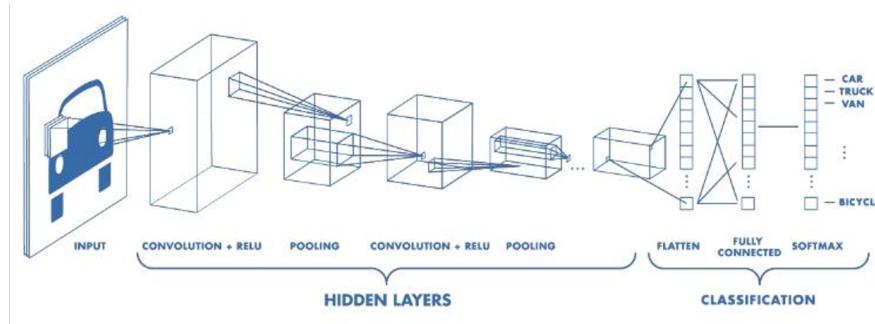


図 4.5: CNN の構造例 [38]。

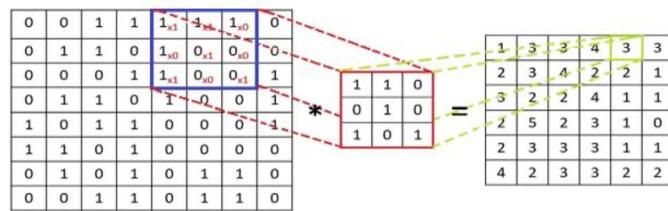


図 4.6: 豊み込み層の概念図 [38]。

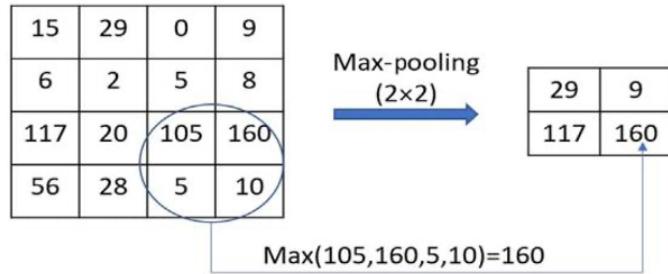


図 4.7: CNN の構造例 [38]。

続くプーリング層では、各豊み込み層の最大値または平均値を採用することで連続する豊み込み層を結合し、次元を減らすとともに更なる特徴量の抽出を行う。最大値を取る場合の例を図 4.7 に示す。そして、最後の層では最終プーリング層または豊み込み出力層から入力を受け取り、それらを一次元に変換した後、一般的には MLP で分類を行う。

モデルの学習と最適化

各モデルのパフォーマンスには、さまざまな要素が関係する。最終的に出力された値は、損失関数により正解値との誤差の評価を行い、その誤差を最小化するように重みパラメータの更新を行うことで学習が進む。損失関数としてよく使用される関数には、主に回帰問題で用いられる平均二乗

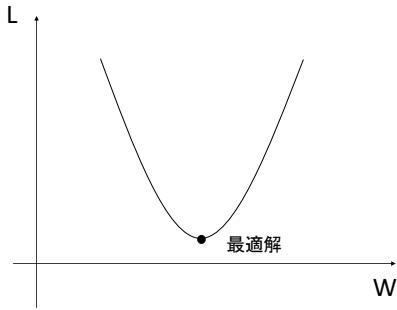


図 4.8: シンプルな二次関数の場合の損失関数 L と重みパラメータ W のイメージ。

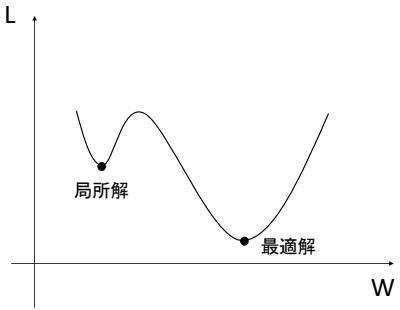


図 4.9: 谷が二つある二次関数で表される損失関数 L と重みパラメータ W のイメージ。

図 4.10: 損失関数 L と重みパラメータ W のイメージ。

誤差 (Mean Squared Error)

$$E = \frac{1}{N} \sum_{n=1}^N (\hat{y}_n - y_n)^2, \quad (N: \text{サンプル数}, \text{正解値: } y_n, \text{出力値: } \hat{y}_n) \quad (4.3)$$

や、主に分類問題で用いられる多クラス交差エントロピー (Categorical Cross Entropy)

$$E = - \sum_{n=1}^N \sum_{c=1}^C y_c \log \hat{y}_c, \quad (N: \text{サンプル数}, \text{分類クラス数: } C, \text{正解値: } y_c, \text{出力値: } \hat{y}_c) \quad (4.4)$$

などがある。損失関数が小さければ小さいほど、正解の値に近付いていることになる。

損失関数を小さくするための最適なパラメータを見つけるために使用される勾配降下法は、機械学習や最適化の分野で広く使用される最適化アルゴリズムの一つである。基本的に損失関数は、二乗誤差などの2次関数で表される。損失関数の値を L として調整したいパラメータの値を w とすると、図 4.8 のようなグラフで表すことができる。勾配降下法とはこのような2次関数で表された勾配を下っていき、パラメータ繰り返し操作して最適なパラメータを求める方法である。まず、通常はランダムの値または 0 でスタート位置を決定し、現在のパラメータ w_i における損失関数の勾配を偏微分することによって求める。次に、求めた勾配 $\partial L / \partial w_i$ を使用して、一般的には $w_{i+1} = w_i - \eta \partial L / \partial w_i$ の更新式でパラメータを更新する。この一度の更新で変更するパラメータの大きさ η を学習率と呼ぶ。学習率が大きすぎると最小値を通り越してしまったり、小さすぎると収束まで果てしない時間がかかってしまうなど、学習率の設定も大きく学習に関わる。また、パラメータの更新回数をエポック数と呼ぶ。シンプルな二次関数ではなく、図 4.9 のように谷が二つある場合もよくあり、最適解ではない解 (局所解) を求めてしまうことがある。そのため、最適解に辿り着くように設定する工夫が必要である。

勾配降下法にはいくつかの種類がある。まず、最もシンプルなのが最急降下法で、全ての学習データ(バッチ)を使用して損失関数が最小になるよう、勾配を使用してパラメータの更新を行う。この場合、最小値から遠い場合は勾配が大きくなるためパラメータの更新がしやすいものの、最初値付近では勾配が0に近く、ほとんどパラメータが更新されない。そのため、上にあげたような局所解に陥った場合に抜け出せなくなることがある。この問題を解決したのが確率的降下法(SGD)である。SGDと最急降下法の違いは、パラメータの1回の更新に全データではなく、ランダムにピックアップした1つのデータを使うことである。毎回ランダムに違うデータを使っているため、1つ前のデータで局所解に陥ったとしても、次にランダムに選んだデータでは損失が大きくなる(または小さくなる)。そのため、再びパラメータが大きく更新され局所解から脱出できる。しかし、この方法では1つのデータによる勾配を更新しないと次に進めず、並列化ができないため学習に多くの時間がかかるてしまう。そこで、ミニバッチ学習SGDとよばれる手法が開発された。ミニバッチ学習SGDでは1回の更新で一定数のデータを使い学習を行う。このデータの塊を小さいバッチという意味でミニバッチと呼び、ミニバッチあたりのデータ数をバッチサイズと呼ぶ。しかし、ミニバッチSGDでも鋭いくぼみを持つ局所解があった場合には振動してしまい、抜け出すのに時間がかかるため学習の収束が遅くなってしまう。そのため、さらに効率よく学習を行うための最適化手法が開発してきた。その中で近年最もよく使用されているのはAdamで、勾配の大きさに応じて学習率を調整していること(RMSProp[39])、損失が下がる方向を先に見つけてから重みを更新する手法(加速勾配法NAG[40])を採用することで、SGDで陥りがちであった振動を回避し、より早い収束が可能になっている。

エポック数や学習率、学習に関わる人間が設定する値をハイパーパラメータと呼んでおり、その値によってモデルのパフォーマンスも変化する。本研究ではハイパーパラメータを決定するにあたり、Optuna[41]を使用してモデルの最適化を行った。

4.2 ヘテロジニアスコンピューティング

ヘテロジニアスコンピューティングは、異なる種類のプロセッサ(CPU、GPU、FPGAなど)を組み合わせて使用する計算手法である。それぞれのプロセッサが得意とするタスクを分担することで、システム全体のパフォーマンスやエネルギー効率を最大化することが期待できる。近年GPUを使用して機械学習の推論を行うためのツールが発展しており、学習に長時間必要な機械学習についても、GPUを使用することでかなり短縮できるようになった。また、ハードウェア言語の記述が必要なため使用が難しかったFPGAに関しても、機械学習をFPGAに実装するためのツールが急速に発展しており、ヘテロジニアスコンピューティングを用いた機械学習の使用が注目されている。第3章でも述べた通り、今後大規模素粒子実験では計算速度の向上と消費電力量の削減がともに課題となっている。ヘテロジニアスコンピューティングでの並列計算による効率化や、各プログラムに特化した回路を組むことによって期待できる省消費電力効果により両課題の解決につながる可能性がある。そこで、本研究ではヘテロジニアスコンピューティングに注目し、消費電力量と推論速度の観点からそれらの評価を行った。

4.2.1 アクセラレータ

アクセラレータとは、特定のタスクや処理を高速に実行するために設計された専用ハードウェアや装置のことである。特定の計算や処理の負荷を軽減し、全体のパフォーマンスを向上させるために活用される。以下に、本研究で主に使用したアクセラレータについて述べる。

Graphics Processing Unit (GPU)

GPUでは、複数のコアが並列に配置されているのが特徴で、画像や映像などのグラフィックス処理を高速に行うためのプロセッサを搭載した拡張カードである。近年では、膨大な並列計算を必要とするアプリケーションにおいて、CPUを補完するアクセラレータとしても広く利用されている。これにより、大量の計算処理を同時に実行することが可能である。CPUは少数の高性能コアを持ち、プログラムの実行やデータ処理、システムの管理など複雑なタスクを効率的に処理するのに向いているのに対し、GPUは数千のコアで同時に並列計算を行う。そのため、一般的なシングルスレッドのタスクなどではCPUに比べて速度が低いという特徴も持ち合わせるが、並列計算を多く伴う行列計算やベクトル計算でCPUに比べて数倍から数十倍のパフォーマンスを発揮する。機械学習は多くの行列計算を伴うため、GPUを使用することで計算の効率化が可能である。

Field Programmable Gate Array (FPGA)

Field Programmable Gate Array の文字通り、設計者が現場で論理回路の構成をプログラムできる論理回路を集積したデバイスである。通常の集積回路とは異なり、製造後にプログラム可能であり、様々な用途に合わせて機能を柔軟に変更できるため、エレクトロニクスの分野で非常に重要な役割を果たしている。例えば機械学習の行列計算において、特に計算量が多い部分は大規模な並列処理を実行させ、それ以外のところでは使用するリソースを減らすというように、プログラム内の各処理に対して最も効率的な回路設計が可能となる。また、FPGAではクロックごとに決まった動作を行うため、処理時間が決まっていると制御しやすいトリガーシステムには特に適していると言える。ただし、FPGAを使用するためには、機械学習で一般に使用するような高位言語ではなく、一般にVHDLやVerilogを用いた設計が必要であるため、ソフトウェア開発者にとっては4.2.2節に示す高位合成が必要になるなど、使用が難しいデバイスとなっている。

4.2.2 高位合成

高位合成 (High-Level Synthesis: HLS) とは、CやC++などの高位言語で記述されたプログラムコードを、VHDLやVerilogなどのハードウェア記述言語に変換する技術である。高位合成を利用することで、ソフトウェア開発者にも馴染みやすい高位言語を使って、ハードウェア設計を効率的に行うことが可能となる。近年 FPGA メーカーである AMD と Intel の両方から Vivado HLS および Intel HLS コンパイラ [42] が無償で提供されるようになったほか、機械学習のモデルを高

表 4.1: 評価に用いる CPU である Intel i9-13900K と i9-10920X の主な仕様。

モデル	コア	スレッド	コアアーキテクチャ	最大メモリ容量
i9-13900K [45]	24	32	hybrid	256 GB
i9-10920X [46]	12	24	noemal	192 GB



※この画像は EQP400-2GER2 です

図 4.11: 使用した GPU(NVIDIA Quadro P400) [48]。

位合成するためのツールも発達している。例として、主にリソース制約が厳しいハードウェア環境での低レイテンシー推論に重点を置いている HLS4ML [43] や、FPGA 上での機械学習推論を効率化し、性能を最大化することを目的とした FINN [44] といったツールがある。

しかし、高位合成ツールを使用しても FPGA 上で高い性能を出すのが難しいほか、高位合成ツールの使用自体が難しく、使用できるライブラリやモデル構造が限られていたりするなどまだ課題がある。

4.3 評価方法

GPU や FPGA を使用した機械学習の推論をトリガーシステムに導入するにあたり、重要な処理速度、消費電力を本研究で測定した。本節ではこの手法と結果について述べる。

4.3.1 使用した CPU とアクセラレータ

本研究では、CPU 二種類と GPU、FPGA アクセラレータの比較を行った。CPU は Intel の第 13 世代 CPU [45] と第 9 世代 CPU [46] を用いた。主な仕様を表 4.1 に示す。

GPU は、図 4.11 の NVIDIA Quadro P400 [47] を使用した。NVIDIA Quadro P400 には、256 基の CUDA コアと 2 GB の高速メモリが搭載されている。Quadro P400 の主な仕様を表 4.2 に示す。また、Mini DisplayPort 1.4 コネクタ 3 系統を搭載し、4K 解像度でモニター 3 画面出力など、柔軟な接続が可能な仕様となっている。

FPGA は図 4.12 の AMD Alveo U200 [49] を用いた。Alveo アクセラレータカードは、FPGA

表 4.2: Quadro P400 の主な仕様 [47]。

CUDA コアプロセッサ	メモリ	メモリインターフェース	メモリバンド幅
256 コア	2 GB GDDR5 SDRAM	64 bit	最大 32 GB/sec



図 4.12: 使用した FPGA アクセラレータ (Alveo U200) [49]。

表 4.3: Alveo U200 の主な仕様 [49]。

インターフェース・メモリ			FPGA リソース		
ネットワーク	PCI Express	メモリ	LUT	総帯域幅	最大電力量
2 × QSFP28	Gen3 ×16	DDR4 64 GB	892k	77 GB/s	225 W

に Virtex Ultra Scale+ シリーズを搭載する大規模なアクセラレータである。Alveo U200 の主な仕様を表 4.3 に示す。機械学習の推論、ビデオトランスコーディング、データベース検索/分析などの一般的なワークロードに対して、CPU の最大 90 倍の性能を提供する。

4.3.2 使用した機械学習モデル

本研究では、よく画像認識のテストで使用される MNIST dataset [50] を用いて、推論時 (分類) の消費電力、処理時間の測定を行った。使用したモデルは、図 4.13 の構造を持つ畳み込みニューラルネットワークである。使用したライブラリは PyTorch [51] で、トリガーシステムで使用することを想定するため、1 度に送信するデータ数は 1 データに設定し推論を行った。その他、Loss 関数は多クラス交差エントロピー、ラーニングレートは 0.001、活性化関数は ReLU 関数を用いた。エポック数は 20 で、精度はどのデバイスでも 98% である。

また、今回は C++, Python の 2 言語での比較を行った (FPGA は Python のみ)。C++ での推論では LibTorch [52] を使用し、C++ で使用できるモデルでありながら Python で使用するものとできるだけ差が出ないようにしている。

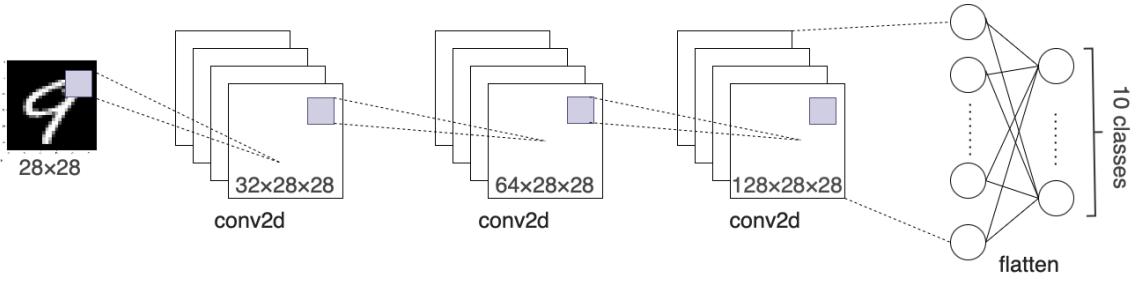


図 4.13: 評価に使用した畳み込みニューラルネットワーク。

4.3.3 各デバイスへの実装

GPUへの実装

GPU では、PyTorch ライブラリを用いて機械学習を実装した。GPU を一般的な用途に利用する枠組みとしては、NVIDIA の GPU コンピューティングプラットフォームである CUDA が近年最もスタンダードである。PyTorch は CUDA をサポートしており、本研究では CUDA 11.8 対応の PyTorch を使用して GPU での機械学習の推論を行った。

FPGAへの実装

4.2.2 節で述べたとおり、機械学習モデルを高位合成し、FPGA に実装することは難しい。そこで、本研究ではあらかじめ実装・最適化された回路を使用して FPGA 上での推論を行うことができる Vitis-AI [53] を使用した。Vitis-AI は、AMD が提供する FPGA、および Versal といった Adaptive Compute Acceleration Platform (ACAP) 向けの AI 推論プラットフォームであり、学習済みのディープラーニングモデルを FPGA 用に最適化するためのツール（コンパイラ、最適化ツール、デバッガなど）を提供している。Vitis-AI と他の機械学習のための高位合成ツールで大きく違う点は、Vitis-AI では深層学習プロセッキングユニット (DPU) を使用することである。DPU はディープニューラルネットワーク向けに最適化されたプログラマブルなエンジンであり、既にハードウェアに実装されているがパラメーター指定可能な IP コア (FPGA 開発において既に開発済みで使用することができるもの) である。そのため、配置/配線を記述する必要がない。図 4.14 に示すように、各デバイスに対応した DPU が用意されている。

今回使用した DPU は DPUCADF8H [54] である。DPUCADF8H は、Alveo U200/U250 カード向けに最適化された DPU である。この DPU は高スループットアプリケーションをターゲットとしており、畳み込みニューラルネットワークを幅広くサポートしている。表 4.4 に、DPUCADF8H の主な仕様を示す。

Vitis-AI での学習済みモデルの実装は以下の手順で行う。

1. 量子化

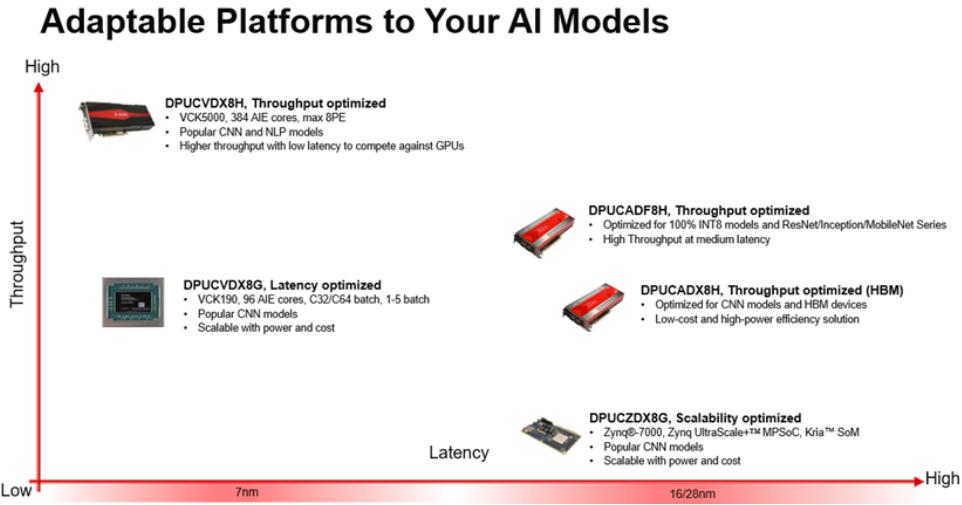


図 4.14: Vitis-AI v2.0 に用意されている DPU [53]。各デバイスに合わせた DPU が用意されており、右上に表示されているのが、本研究で使用した DPUCADF8H である。

表 4.4: DPUCADF8H の主な仕様 [54]。

LUT	Register	UltraRAM	DSP
138.9 k	333.8 k	320	2056

FPGA のようなリソースが限られるハードウェアに機械学習を実装するためには、量子化と呼ばれる、ニューラルネットワークの重みや入力データのビット精度を低減することで、モデルのサイズや計算量を削減する手法を実行する必要がある。今回は量子化を考慮して学習を行う手法である Quantization-Aware Training ではなく、モデルの学習後に量子化を行う Post-Training Quantization を用いた。Vitis-AI でモデルに対し量子化を行う Vitis AI Quantizer は、前処理として各層の入力値の正規化、推論に不要なノードの削除を行った後、重み・バイアスや活性化関数を INT8 の固定小数点に量子化する。その際、各中間層での出力値の分布を考慮して INT8 の整数値にスケーリングすることで、予測精度を損なうことなく計算の複雑レベルを軽減することができる。このような固定ビット数のネットワークモデルの方が必要なメモリ帯域幅が狭く、速度と電力効率が向上するという利点がある。

2. コンパイル Vitis AI compiler は、量子化されたモデルを FPGA アーキテクチャに最適化し、FPGA が直接実行できる中間コード（バイナリ）に変換する。モデルの各レイヤーや演算を FPGA 上のリソース（DSP、LUT、メモリなど）にマッピングし、最適な形で配置するとともに、レイヤーの融合などの最適化を実行し、オンチップメモリを可能な限り再利用するような処理も行う。

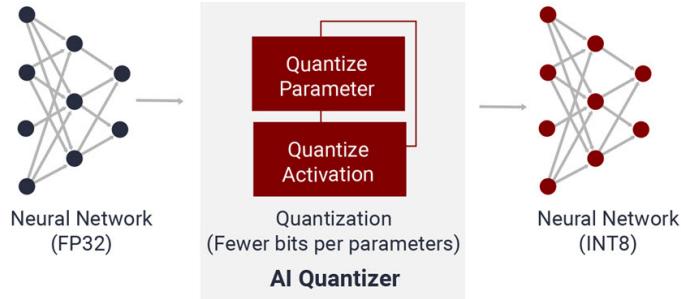


図 4.15: Vitis-AI Quantizer のイメージ [53]。まず重みやバイアスなどのパラメータを量子化した後 (Quantize Parameter)、各中間層の出力値をスケーリングする (Quantize Activation)。

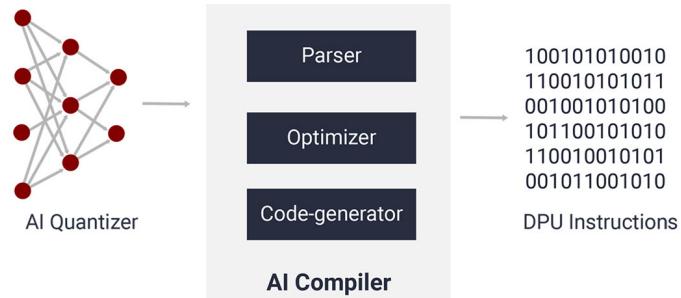


図 4.16: Vitis-AI Compiler のイメージ [53]。

3. 推論の実行

Vitis AI runtime [53] を使用して FPGA での機械学習の推論の実行を行う。Vitis AI runtime は、Xilinx の FPGA および ACAP 上で AI 推論モデルを効率的に実行するためのソフトウェアライブラリおよび API である。Python や C++ から簡単に FPGA 上でディープラーニングモデルの推論を実行できるため、ハードウェアの詳細に触れることなく、柔軟かつ効率的にモデルを実行できる。また、FPGA とホスト間のデータ転送を効率化し、推論速度を向上させるよう最適化されている。今回は Xilinx Intermediate Representation(XIR) [55] をベースにした Vitis AI runtime を使用した。

4.3.4 消費電力測定方法

消費電力の測定には、図 4.17 の RATOC Systems のワットチェッカー RS-BTWATTCH2 [56] を用いた。RS-BTWATTCH2 の主な仕様を、表 4.5 に示す。このワットチェッカーを挟んで PC に電源を繋ぐことで、推論時の PC 全体の消費電力を測定する。このワットチェッカーは Bluetooth 接続が可能になっており、測定する時間範囲を指定することができる。実際にこのワットチェッカーを通して出力される消費電力は図 4.18 のようになっており、図中に示した通り推論時間、平均消費電力、消費電力量を定義している。

表 4.5: RS-BTWATCH2 の主な仕様 [56]。

消費電力表示範囲	10.000W～1500.000W
保証測定範囲	±1%
最小測定間隔	1 s



図 4.17: 使用したワットチェッカー RS-BTWATCH2 [56]。

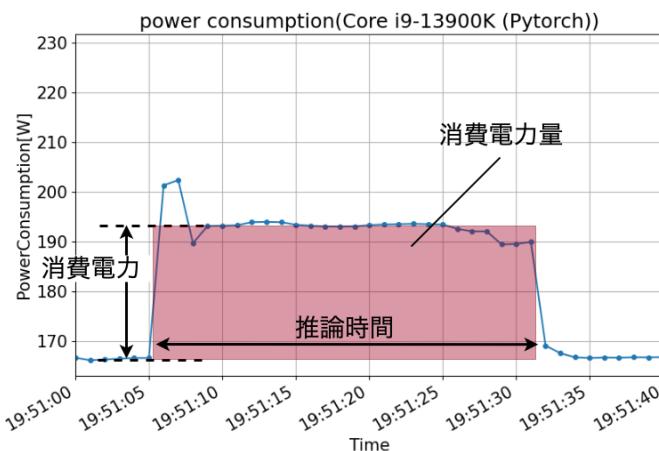


図 4.18: ワットチェッカーで出力される消費電力 (CPU の i9-13900K で推論実行時)。推論中の消費電力は多少上下するが、図のように各測定点での消費電力の平均を消費電力と定義し、消費電力量はその消費電力と測定時間の積で定義する。

4.4 機械学習を用いたヘテロジニアスコンピューティングの評価

4.4.1 CPU のスレッド数を 1 で固定した場合

まず、CPU のスレッド数を 1 に固定し、各測定を行った結果を述べる。

各言語を使用した推論時の各デバイスの平均消費電力は図 4.19 のようになった。C++ と Python のどちらの実行時も i9-13900K が高く、Python で推論時の FPGA が最も低い結果と

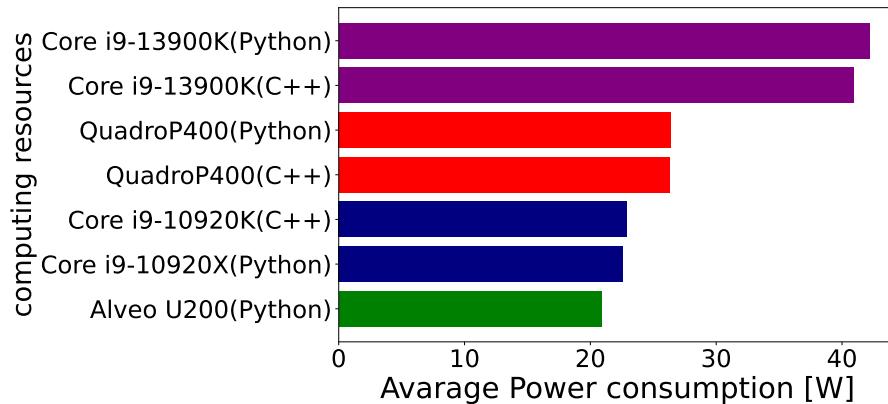


図 4.19: 推論時の平均消費電力。I9-13900K の消費電力が他の 3 つのデバイスと差をつけて最も高い。Alveo U200 は最も少ない消費電力である。

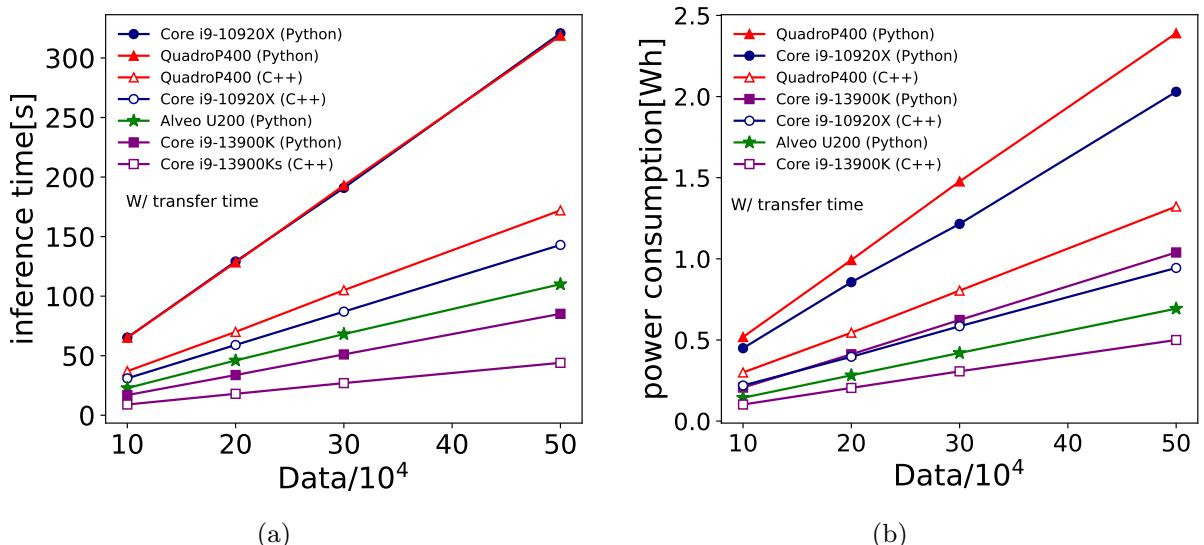


図 4.20: (a) 転送時間も含めたデータ量に対する推論時間。i9-13900K が最も高速である。(b) 転送時間も含めたデータ量に対する消費電力量。平均消費電力は i9-13900K が最も高かったものの、推論速度が速いため C++ で実行時の i9-13900K が最も低消費電力である。

なった。

続いて、データ量に対して推論時間、消費電力量をそれぞれプロットしたのが図 4.20 である。図 4.20(a) を見ると、推論時間は i9-13900K が最も高速であった。Quadro P400 は最も遅く、あまり GPU の利点を活かせていない結果となった。全体的にみて、Python よりも C++ の方が高速に処理できるようである。一方で、図 4.20(b) を見ると、i9-13900K の消費電力が高いぶん、推論が早くても消費電力量が大差をつけて低いことはなく、特に Python で実行時の i9-13900K は、Python で実行時の Alveo U200 と C++ で実行時の i9-10920X よりも高くなっている。

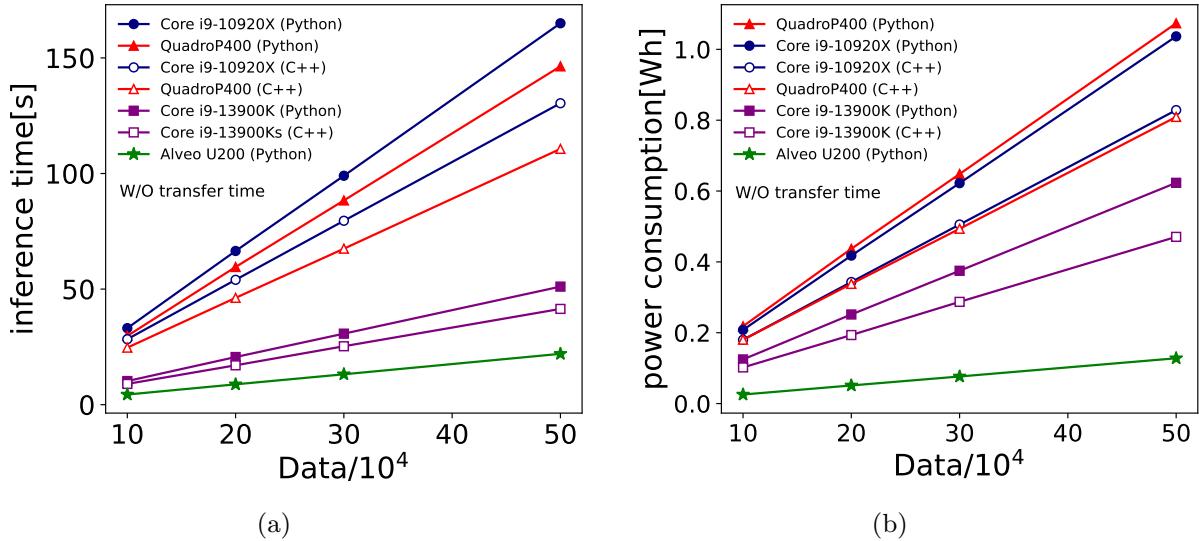


図 4.21: (a) 転送時間を含めずに純粋な推論時間のみで測定した場合のデータ量に対する推論時間。Quadro P400, Alveo U200 ともに転送時間を含めた場合と比較して推論時間が短くなっている。 (b) 転送時間を含めずに純粋な推論時間のみで測定した場合のデータ量に対する消費電力量。Alveo U200 が他と大差をつけて低消費電力量となっている。

4.2 節でも述べた通り、ヘテロジニアスコンピューティングで CPU での実行時と GPU や FPGA などのアクセラレータでの実行時の差にはデータの転送時間も影響するため、その転送時間の影響がどのくらいかを確認する必要がある。そこで、全体の実行時間だけでなく、転送時間を含めずに純粋な推論時間のみで測定した場合の推論時間と消費電力量をプロットしたのが図 4.21 である。推論時間に関しては、図 4.21(a) を見ると Alveo U200 が最も高速であり、また Quadro P400 に関しても、C++, Python それぞれでの実行時の推論時間が i9-10920X よりも高速であることが分かった。さらに、消費電力量に関しては、図 4.21(b) を見ると、Alveo U200 が他のデバイスと大差をつけて消費電力量を抑えられることがわかった。

続いて、今回あまり強みを活かせていないかった GPU に関して、今度はバッチサイズを変化させた場合にどのように CPU と異なるか測定をした。図 4.22 に示すのは、バッチ数を変化させた場合の推論時間の変化である。今回、Alveo U200 はバッチ数が 1 の場合のみで比較している。C++ 実行時では、バッチ数が 1 の場合では他と大差をつけて速かった i9-13900K と比較しても、あるバッチ数を超えると Quadro P400 の推論速度の方が速くなっている。今回は PyTorch の torch ライブラリを使用して CUDA を作動していたが、より GPU の利点を活かすためには、自身で CUDA のコードを作成するなどさらなる最適化が必要である。

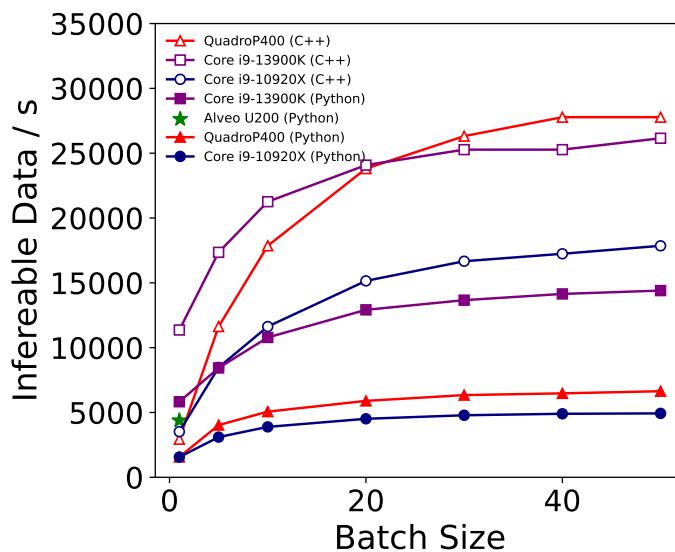


図 4.22: バッチ数による推論時間の変化。バッチ数が 20 を超えたあたりから C++ で実行時の Quadro P400 の推論速度が逆転していることがわかる。

4.4.2 CPU のスレッド数を変化させた場合

続いて、CPU のスレッド数を 1 から変化させた場合の推論時間と消費電力量を測定した結果について述べる。図 4.23 に示すのが、転送時間込み、転送時間なしの純粋な推論時間のみの測定結果である。各測定点は、左を始点として 1 から 10 までのスレッド数での結果を表している。全体的な傾向としては、スレッド数が増えるにつれて推論速度も上がるものの、消費電力量も大きくなっている。ただし、i9-13900K に関しては 9 スレッド目以降から推論速度が落ちているのがわかる。Intel CPU では第 12 世代以降 CPU の性能を重視しており、CPU のパフォーマンスを高める P (Performance) コアと、省電力化を重視しており、CPU が消費電力を抑えつつも効率的に作業できるよう動作する E (Efficient) コアの 2 つのコアが搭載されている。今回使用した i9-13900K には、8 個の P コアと 16 個の E コアが搭載されているため、今回のように無理やり指定したスレッド数で処理を行う場合、9 スレッド以上では P コアに加えて E コアも使用する必要があるため、消費電力量が少し落ちる代わりに推論速度が落ちていると考えられる。また、転送時間なしの場合では、どのスレッド数の場合よりも Alveo U200 の推論時間が速く、消費電力量も小さい。

これらの結果から、FPGA や GPU のメリットを活かすためには、転送時間が大きく影響するため、転送時間を早めるような工夫が必要である。また、FPGA や GPU の並列計算が得意な強みを活かし、例えばより複雑で計算量が多いモデルを使用する場合など、この転送時間のロスを上回るくらいに推論時間が早い場合、トリガーシステムに FPGA や GPU を使用するメリットは十分にあると言える。

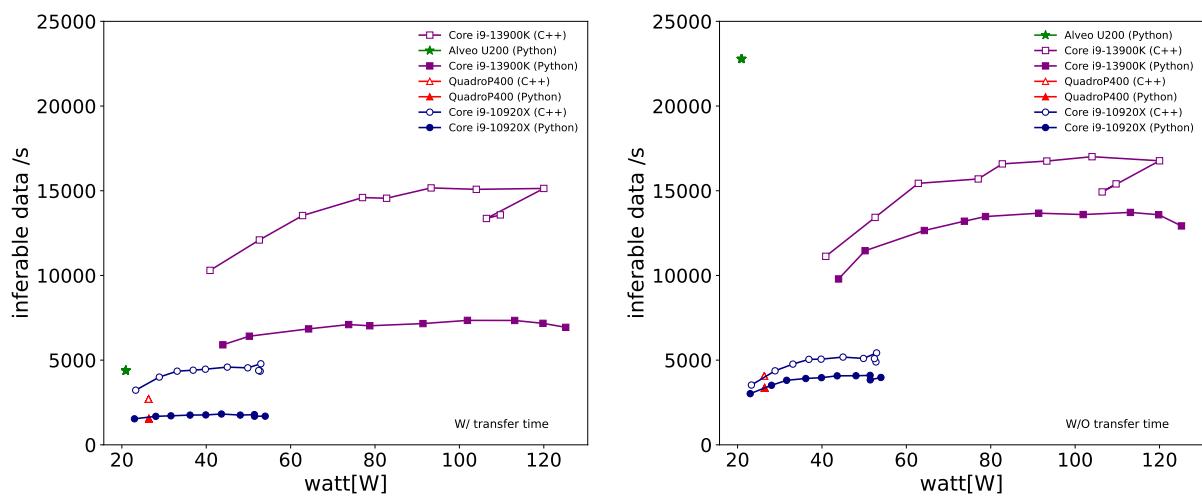


図 4.23: 平均消費電力あたりの推論データ量。(左) はデバイス間の転送時間込みの場合、(右) は転送時間を除いた推論時間のみの場合。CPU の各測定点は、順にスレッド数を 1 から 9 まで変化させた場合の測定結果。CPU はスレッド数を多くするほど推論速度も上がっているが、i9-13900K に関して 9 スレッド以上では P コアに加えて E コアも使用する必要があるため、消費電力量が少し落ちる代わりに推論速度が落ちていると考えられる。転送時間有り無しで、Alveo U200(星) の 1 秒あたりの推論速度が大きく異なる。

第5章

高輝度化に向けた高速ミューオン再構成アルゴリズムの開発

本章では、本研究で新たに開発したミューオンの高速再構成アルゴリズムについて述べる。まず使用した機械学習の学習方法について述べた後、高輝度環境下である平均パイルアップ $\langle\mu\rangle=200$ のデータ、また2024年に取得したRun 3のデータを用いて行った本研究アルゴリズムの評価について述べる。

5.1 本研究アルゴリズムの概要

本節では、本研究で新たに開発したミューオンの高速再構成アルゴリズムの特徴・概要を述べる。

5.1.1 現在のアルゴリズムの問題点

第3章で述べたように、既存のアルゴリズムはまずミューオン検出器内の飛跡を再構成し、その後そのミューオン飛跡を内部飛跡検出器まで外挿し、位置や運動量を考慮して内部飛跡とミューオン検出器内の飛跡のマッチングを行う。第2章で述べた通り、ATLAS実験の磁場は一定でなく複雑である。外挿の際はヒットを探索する座標ごとの磁場の情報を参照してローレンツ力を計算し、予測範囲で次のヒットを探索することを繰り返す。そのためCPUの演算量が大変多い。現在のアルゴリズムではミューオン検出器内の飛跡を再構成する際と、ミューオン検出器内の飛跡と内部飛跡のマッチングを取る際の計2回外挿を行なっており、ミューオントリガーの中でも外挿にかかる時間が大きい。今後さらに内部飛跡数が増えた際に大幅に処理時間が増加してしまう可能性がある。

またミューオン再構成の初めの段階ではマッチングする内部飛跡があるかどうかは考慮していないため、例えば図5.1に示したように、ビームの衝突によって発生した粒子や放射線が、ATLAS検出器内で散乱し、エンドキャップ領域に入射するものや、LHCビームの陽子が加速器の構造物と相互作用することで生成されるミューオンなど、衝突点由来でない粒子の飛跡も再構成してしま

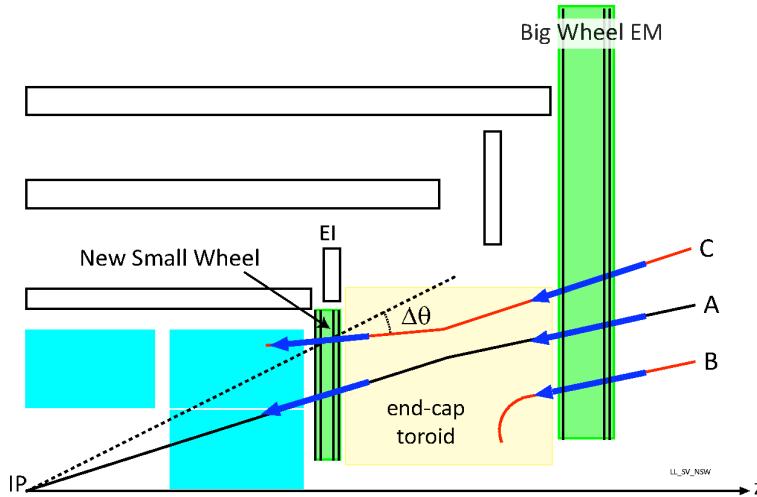


図 5.1: (A) 衝突点由来の粒子 (B),(C) が背景事象の粒子 [57]。

うことがある。その場合、効率が悪くさらに時間もかかってしまう。一般的にこういった粒子はパイルアップの増加に伴い増加するため、早い段階から背景事象を排除できることが望ましい。

より効率が良く、より高速にミューオンのトリガーを行う策として、本研究では機械学習の導入により外挿の過程を減らすこと、またミューオンの再構成において初めから内部飛跡を使用してミューオン検出器内の飛跡を決定することで、早い段階で背景事象を排除するようなアルゴリズムの開発を試みた。また、第4章で述べたヘテロジニアスコンピューティングと機械学習を組み合わせることを視野に入れ、計算時間と消費電力量の削減を目指すとともに、トリガー効率を向上させることを目的としている。

5.1.2 機械学習を用いたミューオン高速再構成

現在 ROI はミドルステーション内で定義されており、本研究でもミドルステーション内に ROI が定義されることを仮定してアルゴリズムの開発を行う。本研究では、ROI 内のセグメントがバレル側にあるかエンドキャップに側にあるかでアルゴリズムを区別しており、本論文において前者をバレル領域、後者をエンドキャップ領域のアルゴリズムと呼ぶ。本研究アルゴリズムでは、ミューオン検出器内の飛跡の決定や内部飛跡との接続には機械学習を用いている。バレル領域のアルゴリズムでは機械学習を 2 つ、エンドキャップ領域のアルゴリズムでは機械学習を 1 つ使用してミューオンの再構成を行う。本節ではそのアルゴリズムの概要について述べる。ミューオン検出器内の飛跡の決定のアルゴリズムの概要を図 5.2 に、内部飛跡との接続のアルゴリズムの概要を図 5.3 に示す。

$\langle\mu\rangle=200$ ではこれまでよりも多くの粒子が 1 度に衝突するため、1 イベントあたりにかなり多くの内部飛跡が存在する。そのため、まず初めに ROI 内のセグメントとの位置の差や最低閾値以上の運動量があるかどうかの条件をかけ、ミューオン候補として選択しうる内部飛跡の候補を絞るこ

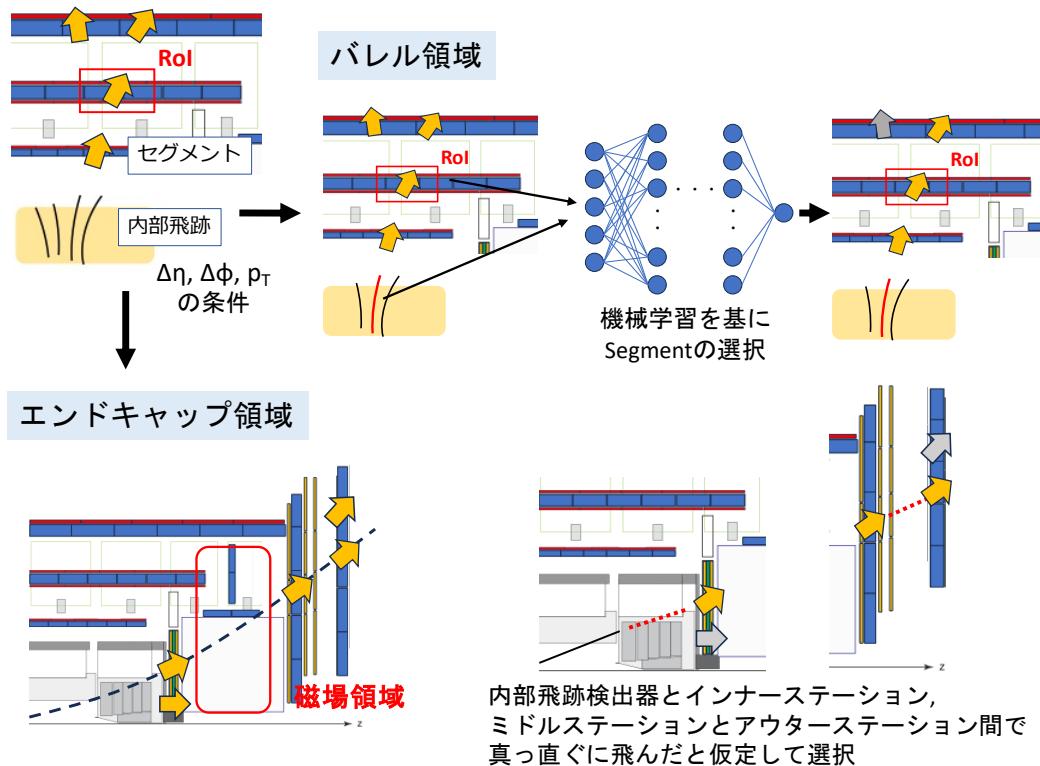


図 5.2: ミューオン検出器内の飛跡の決定のアルゴリズムの概要。バレル領域ではセグメントの位置を予測する機械学習を用いてセグメントを選択する。エンドキャップ領域では磁場がない領域で真っ直ぐ飛んだと仮定してセグメントを選択する。

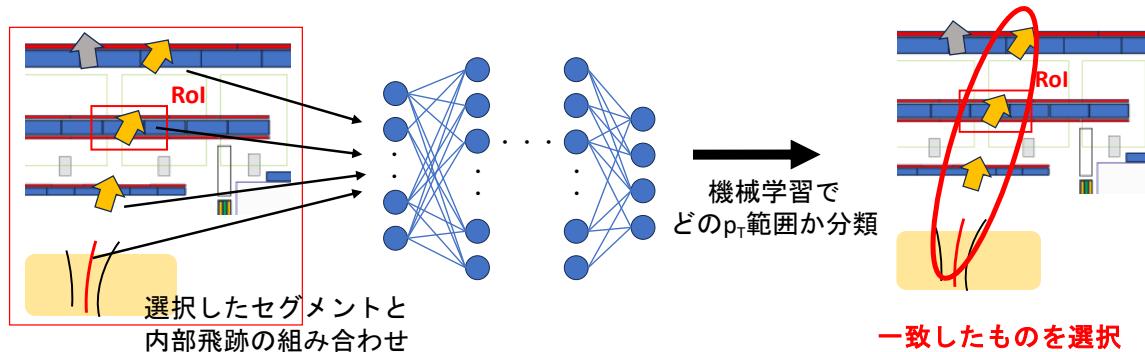


図 5.3: 内部飛跡との接続のアルゴリズムの概要。選択したセグメントと内部飛跡の特徴量から、高い横運動量、中程度の横運動量、低い運動量を持つかを予測して分類する。

とした。その後、機械学習を用いてミューオンの再構成を行う。

バレル領域では、先にミューオン検出器内の飛跡の決定、つまりどのセグメントをミューオンの再構成に使用するかの決定に機械学習を使用する。現在のアルゴリズムでは、RoI を基に衝突点由来であると仮定して、大まかな範囲を決定することによりセグメントを選択している。これに対し本研究アルゴリズムでは、ミューオン候補の内部飛跡の情報と RoI 内のセグメントの情報から、それらと接続しうる残りのインナーステーションで再構成されたセグメント、アウターステーションで再構成されたセグメントを選択する。第1章でも述べたように、ミューオン検出器の周りには運動量を測定するための磁場が存在する。そのため、本来であれば外挿するなどして飛跡としての整合性を確認する必要があるが、本研究アルゴリズムでは機械学習に内部飛跡の横運動量や電荷などの情報を読み込ませることで、ある運動量での飛跡の曲がり具合を学習させ、セグメントの位置を予測させることを試みた。エンドキャップ領域に関しては、内部飛跡検出器とインナーステーション間、ミドルステーションとアウターステーション間に磁場がないため、その間で真っ直ぐ飛跡が通ったと仮定し接続するセグメントを選択する。

続いて、バレル領域とエンドキャップ領域の双方で内部飛跡との接続に機械学習を使用する。具体的には、一つ前の段階で選択したセグメントとその選択に使用した内部飛跡の整合性を取る形で使用する。5.3節で詳しく述べるが、初めに内部飛跡を絞った時点では2つ以上の内部飛跡候補を持つイベントが多く存在する。またパイルアップの多い環境下では、セグメント同士の距離が近いこともあるため、実際にミューオンの飛跡でない内部飛跡を使用してセグメントの位置予測を行なった場合にもセグメントが見つかる可能性がある。これらのことから、実際に選択したセグメントと内部飛跡が実際に同じミューオンに属しているかどうかを判定するような機械学習を挿むことを試みた。具体的には、選択した内部飛跡とセグメントの特徴量を入力として、実際にその組み合わせがミューオンであった場合にどのような運動量であるかということを機械学習に予測させ分類させる。その結果と機械学習の入力として使用している内部飛跡の運動量が一致していれば、そのセグメントと内部飛跡の組み合わせをミューオン候補として選択する。再構成したミューオンの横運動量 p_T は、選択した内部飛跡の p_T として定義する。

5.2 シミュレーションサンプルの作成

5.2.1 検出器シミュレーション

本研究アルゴリズムは、高輝度 LHC で使用することを想定している。高輝度環境下での検出器、物理を想定したトリガーシステムの開発を行うため、アルゴリズムに使用する機械学習の学習、アルゴリズムの評価にはシミュレーションデータを使用した。現在の ATLAS 実験における CPU リソースの半分以上はシミュレーションサンプルの作成に用いられている。ATLAS 実験の検出器シミュレーションには、Geant4 [58] を用いて荷電粒子と検出器の相互作用をシミュレートするフルシミュレーションと、粒子に対する検出器の応答をパラメータ化して計算を行うファストシミュレーションの2種類が存在する。フルシミュレーションは検出器の粒子に対する応答を詳細に記述

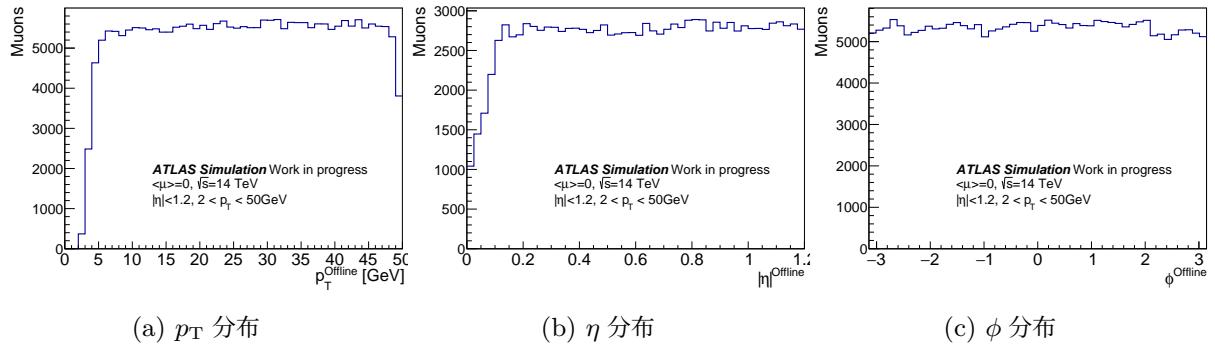


図 5.4: 学習データセットの各変数分布 (パレル領域)。

する一方で、計算コストが大きい。ファストシミュレーションはフルシミュレーションと比較して 10–100 倍程度高速である一方、その手法の性質上、再現度に限界がある。

本研究では実際の実験環境に近づけるため、フルシミュレーションを使用してサンプルの作成を行った。フルシミュレーションにて各検出器における粒子のエネルギーデポジットなどの情報が得られた後、実際の検出器の検出効率やチャンネルの読み出しなどを再現し、粒子のヒット情報を実際のデータのフォーマットに変換する (Digitization) 処理を行う。これにより、シミュレーションデータも実データと同じように扱い、同じソフトウェアで事象再構成をすることが可能となる。

本研究では、Run 3 のものではなく Phase-II アップグレード後の検出器でシミュレーションを行った。これらは Athena [59] という ATLAS 実験の様々な用途に使われるソフトウェアパッケージを用いて行うことができる。

5.2.2 機械学習の学習に使用するデータセット

本研究では機械学習の学習のために、シミュレーションデータを使用する。機械学習の学習には、1 回のイベントに対してミューオンが 1 個存在するシングルミューオンのシミュレーションサンプルを用いる。運動量が $2 < p_T < 50$ GeV にフラットな分布をしており、パレル用のサンプルは $|\eta| < 1.2$ 、エンドキャップ用のサンプルには $0.8 < \eta < 2.5$ の座標で生成させる。また、学習には全てオンライン再構成されたものを使用する。オンライン再構成されたミューオン (オンラインミューオン) の運動学的変数の分布を図 5.4、図 5.5 に示す。

以下に、各機械学習モデルの学習データとして使用する際のミューオンの選別や条件について述べる。

・ ミューオンの選別

学習データ、正解データにはオンラインミューオンの情報を用いる。オンラインミューオンには複数の再構成アルゴリズムがあり、それぞれが異なる物理的目的のために設けられている。本研究では、精度が良く最も一般的に用いられるミューオンのみを捉えることを目的にするため、特別な

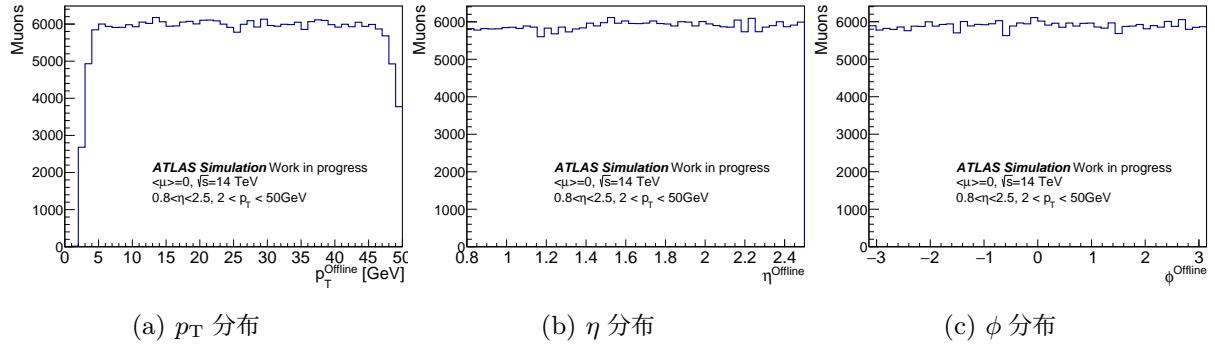


図 5.5: 学習データセットの各変数分布(エンドキャップ領域)。

物理解析用に使用される MuGirl [60] と MuGirlLowBeta [60] 以外のアルゴリズムで再構成されたオフラインミューオンを使用する。また、ある程度内部飛跡検出器内にヒット数があるなどを要求している、物理解析におけるミューオンの識別基準 MCP recommendation を通ったオフラインミューオンのみを使用する。

・セグメントの選別

機械学習の学習に使用するミューオンステーション上のセグメントは、すべて実際にオフラインミューオンの再構成に使用したものとした。5.1 節で述べたように、セグメントの選択の機械学習はバレル領域でのみ使用しており、ミドルステーションの RoI 内に再構成されたセグメントに加え、インナーステーション、アウターステーションのチェンバーで再構成されたセグメントのみを用いた¹。もし検出器が一部重なっている構造により、同じミューオンによるセグメントがインナー、アウターステーション内それぞれに 2 つ以上作られている場合は、よりオフラインミューオンに距離が近いものを選択することとした。

・内部飛跡の選択

横運動量 p_T の分類のための機械学習の学習には、各セグメントと内部飛跡の特徴量を使用する。セグメントの選別の条件を通して選択したセグメントを入力として使用し、内部飛跡に関しては実際にオフラインミューオンの再構成に使用した内部飛跡を正解の飛跡として使用する。

モデルの設計、学習は全て PyTorch [51] を使用して行った。また、モデルの構造には全結合層のモデル (MLP) のみで構成した。よく画像認識などに使われる畳み込みニューラルネットワークは局所的な特徴量を見出すのに優れているが、今回は全ての特徴量を考慮して結果を出力することを狙っている。使用する全結合モデルは層間の全てのペーセプトロンが接続されているため、情報をフルに活用して推論を行うことができる。最も単純な構造で設計がしやすく、今後実際にトリガー

¹本研究では、BE や EE などのカバレッジを補完するための特殊なチェンバーは使用しない。

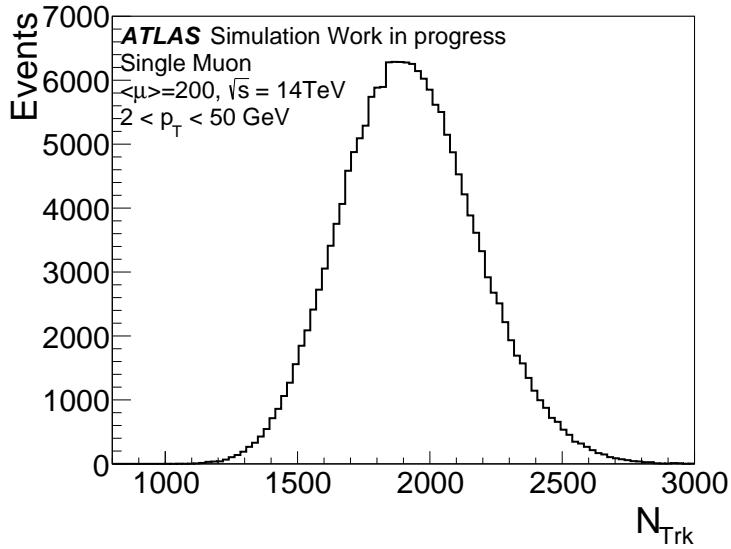


図 5.6: 1 イベントあたりの内部飛跡の数。1 イベントあたり平均 2000 本の飛跡がある。

として使用するうえで、調整が必要な場合もチューニングがしやすいことも利点である。また、使用が難しい FPGA への実装が他の機械学習モデルに比べて比較的容易にできる。

5.3 機械学習を用いたミューオンの高速再構成

本節では、本研究アルゴリズムの各段階でのセレクションや機械学習モデルについて詳しく述べる。

5.3.1 内部飛跡の絞り込み

図 5.6 に示すように、 $<\mu>=200$ の場合に 1 イベントあたりの内部飛跡の数は平均約 1800 本である。今回、新たに初めから内部飛跡を使用するミューオンの再構成アルゴリズムの開発を行うが、全ての内部飛跡に対して機械学習などのプロセスを走らせるることは時間的にも処理能力的にも不可能であり、カットやセレクションをかけてミューオンの内部飛跡としての候補を絞る必要がある。

ミューオンの再構成は、第 3 章でも述べた通り、大体どれくらいの位置にミューオンが来たかどうかを示し、再構成を行う範囲を決定する基準である RoI を基に行われる。本アルゴリズムでは、まず RoI 内のセグメントからどれくらい距離が離れているかで 1 段階目のカットを行う。値の決定は、オンラインミューオンの再構成に使用した RoI 内のセグメントと内部飛跡との距離の差を基準に行う。図 5.7, 図 5.8 に示すのが、バレル領域、エンドキャップ領域それぞれにおける、オンラインミューオンの再構成に使用した RoI 内のセグメントと内部飛跡との座標 (η, ϕ) の差である。この結果をもとに、RoI 内のセグメントとの $|\Delta\eta|, |\Delta\phi|$ がバレル領域では $|\Delta\eta| < 0.2, |\Delta\phi| < 0.3$ 、エンドキャップ領域では $|\Delta\eta| < 0.1, |\Delta\phi| < 0.2$ を満たす内部飛跡であることを要求する。

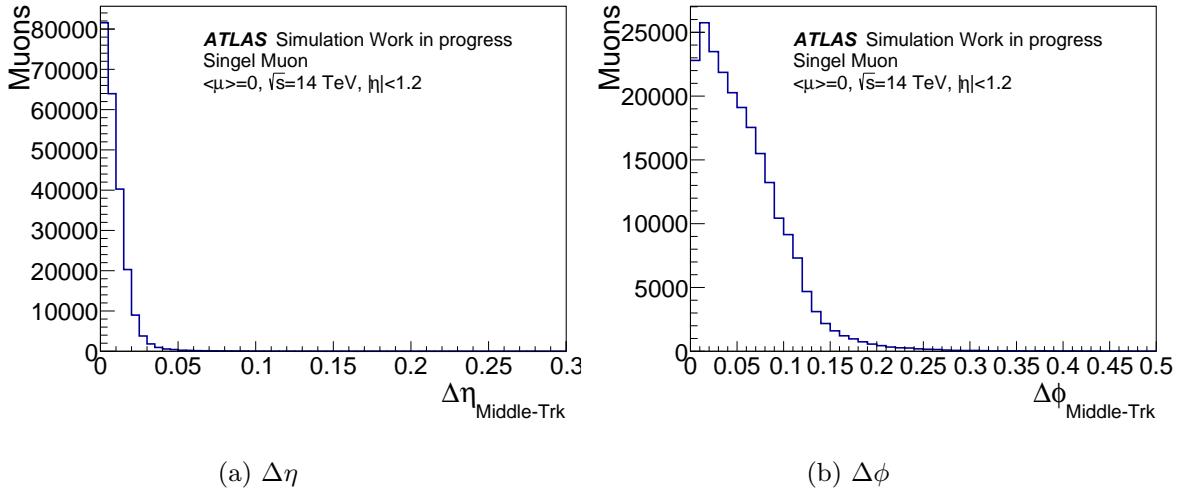


図 5.7: ミドルセグメントと内部飛跡の位置の差 (バレル領域)。

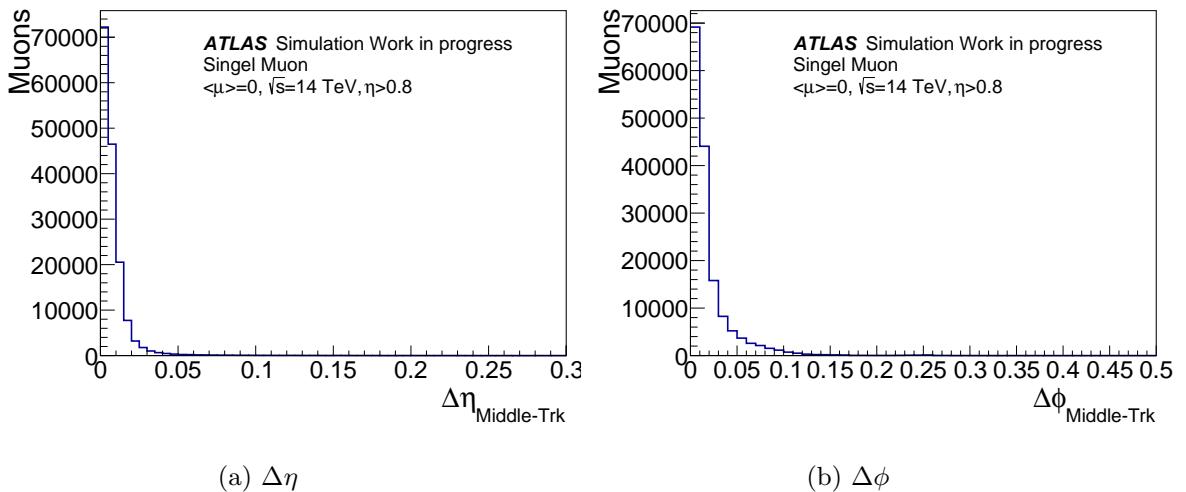
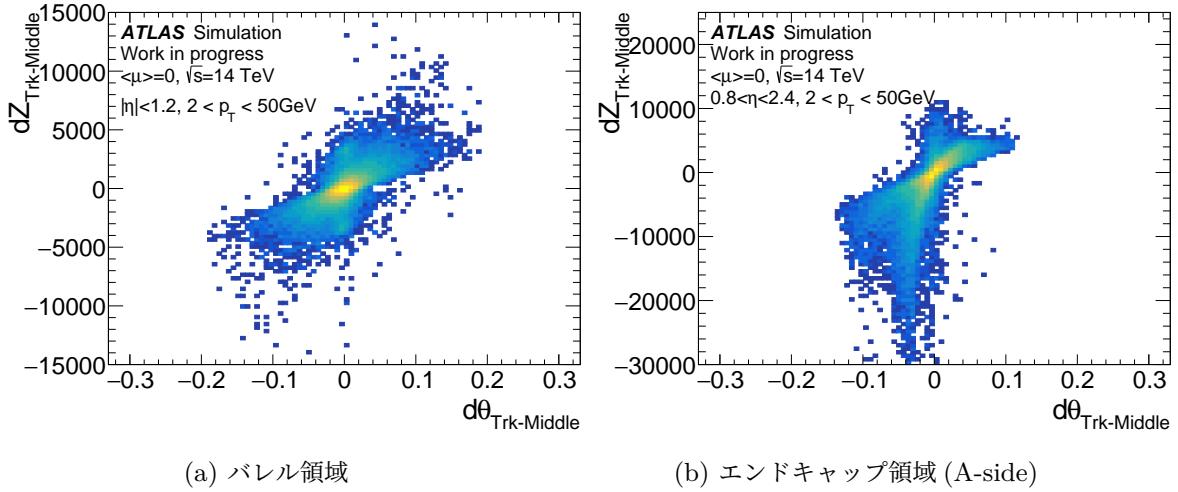


図 5.8: ミドルセグメントと内部飛跡の位置の差 (エンドキャップ領域)

次に、内部飛跡の横運動量 p_T に着目したカットを要求する。パイルアップ 200 では内部飛跡の数が非常に多くなるが、そのほとんどは p_T が小さいものである。そのため、 p_T のカットを要求することで大幅に内部飛跡の数を減らすことが期待できる。Run 3 では、トリガーメニュー内での最も小さい p_T 閾値は 4 GeV である。そこで、内部飛跡のオンライン再構成の分解能も考慮して、 $p_T > 3$ GeV の内部飛跡であることを要求する。

最後に要求するのは、セグメントの傾きを考慮したカットである。正しいセグメントと内部飛跡の組み合わせであれば、運動量が小さく内部飛跡候補からのセグメントの傾きが大きければ大きいほど、その傾きを真っ直ぐ z 軸に落とした z 座標と内部飛跡が持っている z 座標との差が広まるはずである。逆に、運動量が大きく内部飛跡候補からのセグメントの傾きが小さい場合は、 z 座標の差は小さいはずである。本研究アルゴリズムでは、その傾きと z 座標の差の相関を見ることでセグ

図 5.9: セグメントの傾きと z 座標の相関。

メントの傾きを考慮したカットを考え、別のバーテックスからの内部飛跡とセグメントの組み合わせを削減することを試みた。オフラインミューオンの再構成に使用したセグメントと内部飛跡の組み合わせで確認したところ、図 5.9 のような相関が見られた。よって、バレル・エンドキャップそれぞれにこの相関を考慮したカットを要求する。エンドキャップ領域に関しては、 $\eta > 0$ の A-side 側のみのサンプルを用いているため、負の方向だけにテールが伸びている分布となっている。

上で述べた全てのカットを要求した結果、内部飛跡の候補数は図 5.10 のように変化する。バレル領域ではどのカットも内部飛跡候補を減らす効果があるものの、エンドキャップ領域ではより狭い範囲で $\Delta\eta$, $\Delta\phi$ を設定できているため、全体的にバレル領域での内部飛跡候補数よりも少なく、セグメントの傾きを考慮したカットは効いていないことが分かった。全てのカットにより、全体の平均 1800 本からほとんどが 5 本以内と、内部飛跡の候補数を大幅に削減できていることが確認できる。

5.3.2 セグメントの選択

本節では、セグメントの選択方法と、そのために使用した機械学習モデルについて述べる。ATLAS 実験では磁場をかけることで飛跡の曲がり具合から各荷電粒子の横運動量を推定しているが、運動量が分かっていない状態では位置の近さや角度などからセグメントを選択することが難しい。そのため、これまで外挿を行うことでセグメントを選択し、ミューオン検出器内の飛跡を再構成してきた。そこで、本研究では内部飛跡やセグメントの特徴量から、ある横運動量 p_T での傾向を機械学習に学習させ、インナーステーション内とアウターステーション内それぞれのセグメントの位置を予測させることとした。ミューオンスペクトロメータ (RPC) の ϕ 方向の分解能があり良いことから、本研究では θ 方向で大きく絞ることを目的に、セグメントの θ 方向の位置予測を行う機械学習を用いる。ただし、エンドキャップでは内部飛跡検出器とインナーステーション、

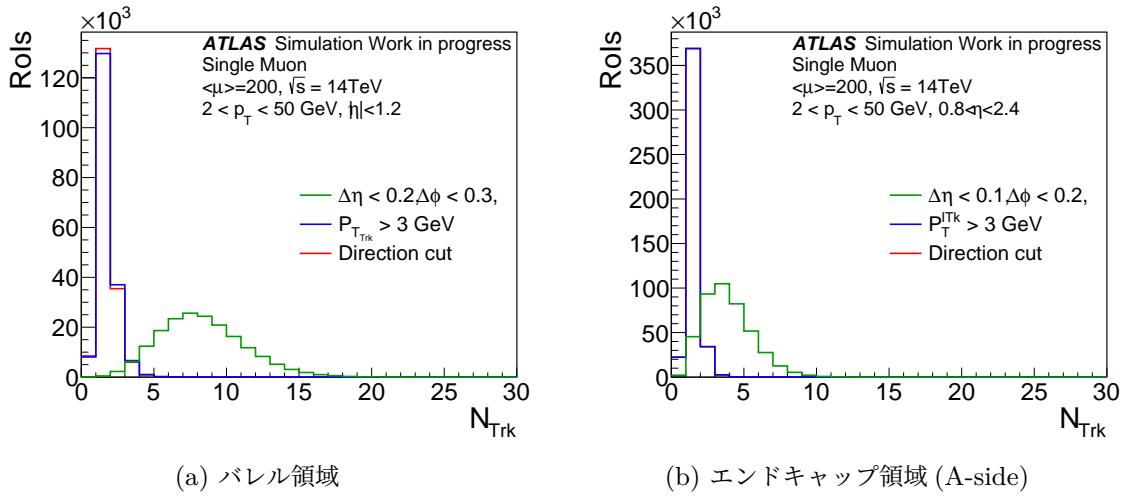


図 5.10: 各段階での内部飛跡候補数の変化。緑色で示すのが RoI からの $\Delta\eta, \Delta\phi$ によるカット, 青色で示すのが p_T によるカット, 赤色で示すのがセグメントの傾きを考慮したカットである。

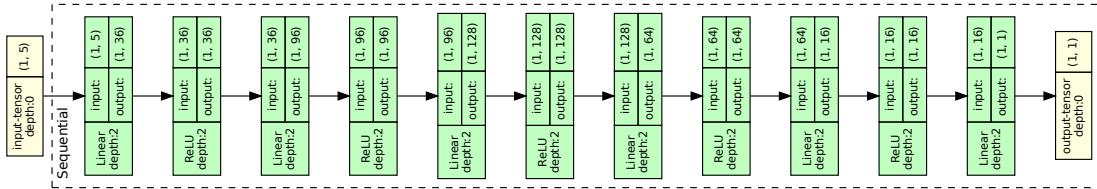


図 5.11: セグメントの選択のために使用するモデルの構造。6 層の全結合 MLP で構成される。

ミドルステーションとアウターステーションの間に磁場がない。そのためバレルと同じ機械学習モデルで行うとすると、十分な特徴量が得られず学習がうまく進まなかった。そこで、エンドキャップ領域では機械学習を使用せず、インナーステーションと内部飛跡、アウターステーションとミドルステーション間それぞれで真っ直ぐに飛跡が通ったと仮定し、各セグメントを選択することとした。以下では、バレル領域におけるセグメント選択のためのモデルと学習の詳細を述べる。

・モデル構造

セグメントの選択に使用したモデルは、6 層の全結合層のモデルである。モデルの構造を図 5.11 に、モデルの詳細を表 5.1 に示す。入力には、内部飛跡の絞り込みにより候補として残った内部飛跡候補の各特徴量と、RoI 内のセグメントの 5 つの特徴量を用いる。入力変数の詳細を表 5.2 に示す。出力は、選択したいインナーステーション内のセグメントの位置 (θ_{Inner})、アウターステーション内のセグメントの位置 (θ_{Outer}) を出力する回帰モデルである。

表 5.1: セグメントの選択に使用した機械学習モデルの詳細。

モデル構造	層数	活性化関数	入力	出力
MLP	6	ReLU	5 nodes	1 nodes

表 5.2: セグメント選択のモデルへの入力。

特徴量	
内部飛跡	横運動量 (p_T), 電荷 (q), 位置 (θ)
RoI 内のセグメント	セグメントの傾き α (第3章参照), 位置 (θ)

表 5.3: セグメントの選択の機械学習に使用したハイパーパラメータ。学習率の ReduceLROnPlateau は、`lr_scheduler.ReduceLROnPlateau` を用い、指定したエポック間学習の進捗が見られない場合に学習率を減少させる。今回は、スタート時の学習率は 0.01, 5 エポック間学習の進捗が見られない場合に学習率を 0.5 倍に減少させる。

エポック数	バッチサイズ	学習率	損失関数
40	128	ReduceLROnPlateau	二乗平均誤差

・学習

磁場により θ_{Inner} と θ_{Outer} で傾向が異なるため、それぞれの予測には別々に学習を行う。5.2.2 節で述べたように、正解値としてはオフラインミューオンの再構成に使用したセグメントを使用して学習を行った。学習に使用したハイパーパラメータを表 5.3 に示す。 θ_{Inner} , θ_{Outer} 予測のためのそれぞれの学習について、学習データと検証データの遷移はそれぞれ図 5.12 のようになった。これらから、両者のモデルとも学習が収束していることが確認できる。また、予測値とラベル値 (オフラインミューオンの再構成に使用した θ_{Inner} , θ_{Outer}) との差を図 5.13 に示す。 θ_{Inner} , θ_{Outer} ともにうまくセグメントの位置を予測できていることが確認できる。

・機械学習の推論を基にしたセグメントの選択

上に述べた θ 方向予測のための機械学習により、大幅に θ 方向のセグメントの探索範囲を絞ることができるが、数多くあるセグメントからミューオン再構成のために選択するには、 ϕ 方向も絞る必要がある。そこで、まず各セグメントの ϕ (ϕ_{Inner} , ϕ_{Outer}) と RoI 内のセグメントの ϕ (ϕ_{Middle}) との差でカットをかける。今回正解の基準としている「オフラインミューオンの再構成に使用したセグメント」に関して、RoI 内のセグメントと各セグメントの $\Delta\phi_{\text{Middle}-\text{Inner}}$, $\Delta\phi_{\text{Middle}-\text{Outer}}$ を

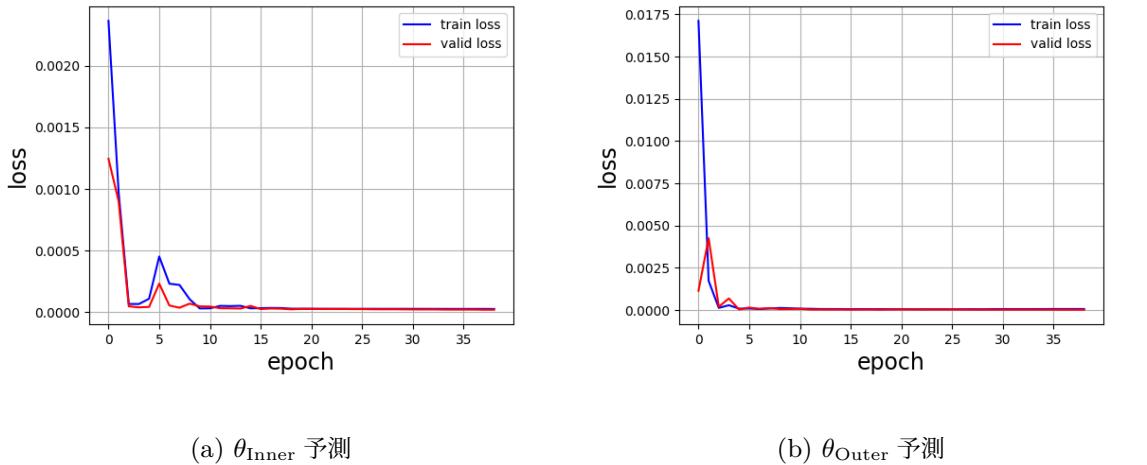
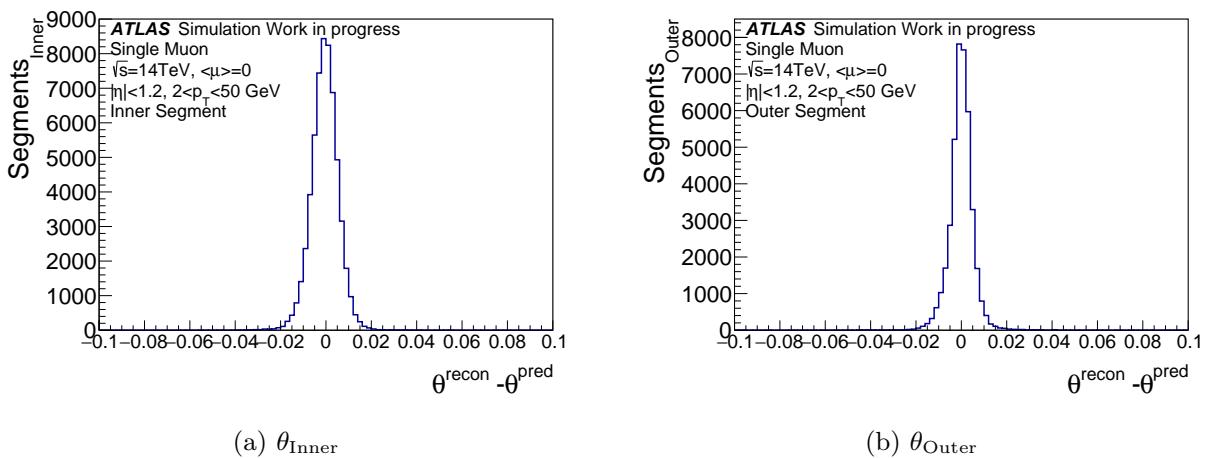
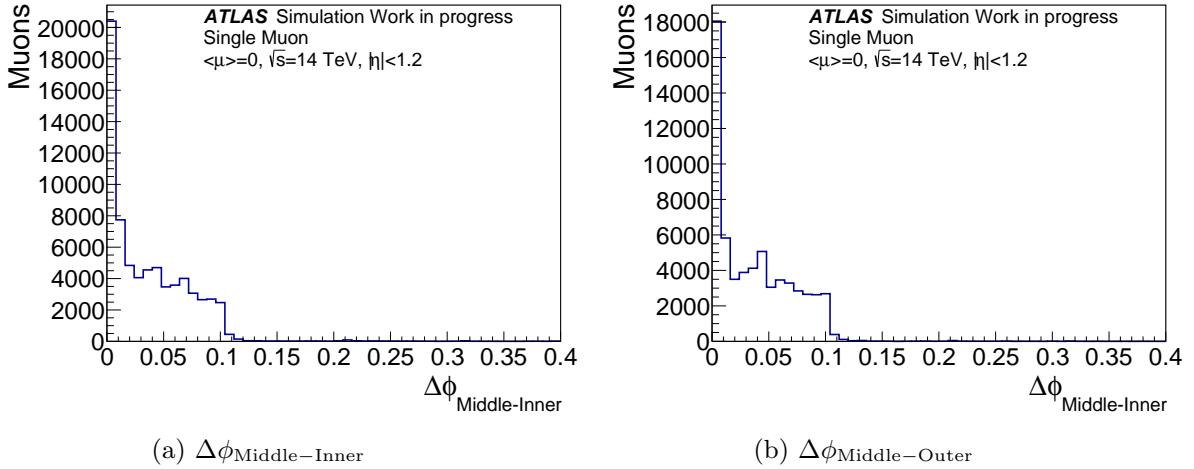


図 5.12: 各セグメント予測学習の Loss

図 5.13: 各セグメントの位置予測モデルの予測値とラベル値 (θ_{Pred}) との差。どちらも差が ± 0.04 以内に収まっている。

示したのが図 5.14 である。これとセグメントの θ 位置予測の学習結果から、インナーステーション内のセグメント、アウターステーション内のセグメントとともに、 θ 方向はモデル予測値から ± 0.04 , ϕ 方向は $\Delta\phi_{\text{Middle-Inner}} < 0.2$, $\Delta\phi_{\text{Middle-Outer}} < 0.2$ の範囲内で実際に再構成されたセグメントの探索を行う。その範囲内で複数のセグメントが見つかった場合には、最も機械学習での予測値に近い θ を持つものを選択することにする。

また、エンドキャップ領域のアルゴリズムでは、 θ , ϕ 方向ともに機械学習を使用せずにセグメントの選択を行う。まず ϕ 方向については、バレル領域と同様に $\Delta\phi_{\text{Middle-Inner}}$, $\Delta\phi_{\text{Middle-Outer}}$ を基準にカット条件を設定する。オフラインミューオンの再構成に使用したセグメントに関して、 $\Delta\phi_{\text{Middle-Inner}}$, $\Delta\phi_{\text{Middle-Outer}}$ を図 5.15 に示す。第 2 章で述べた通り、インナーステーション

図 5.14: 各セグメントと ROI 内のセグメント (Middle) との $\Delta\phi$ (バレル領域)。

とアウターステーションを構成する検出器が異なるため両者で傾向が異なっている。続いて、インナーステーション内のセグメントは内部飛跡との距離、アウターステーション内のセグメントは ROI 内のセグメントとの距離を基準に条件を設定する。図 5.16 に示すのが、内部飛跡とインナーステーション内のセグメントの距離

$$\Delta R_{\text{Trk-Inner}} = \sqrt{(\Delta\eta_{\text{Trk-Inner}})^2 + (\Delta\phi_{\text{Trk-Inner}})^2} \quad (5.1)$$

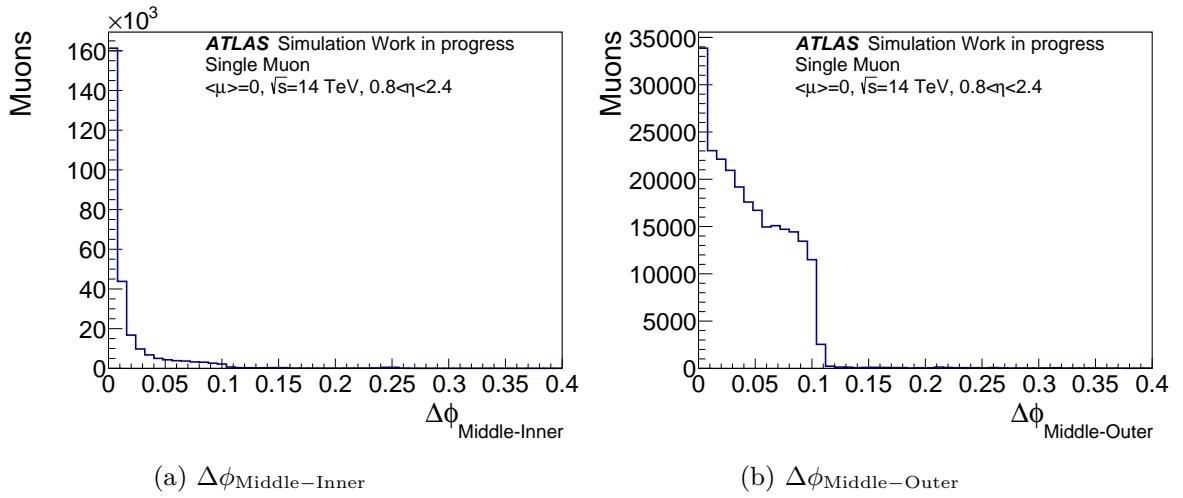
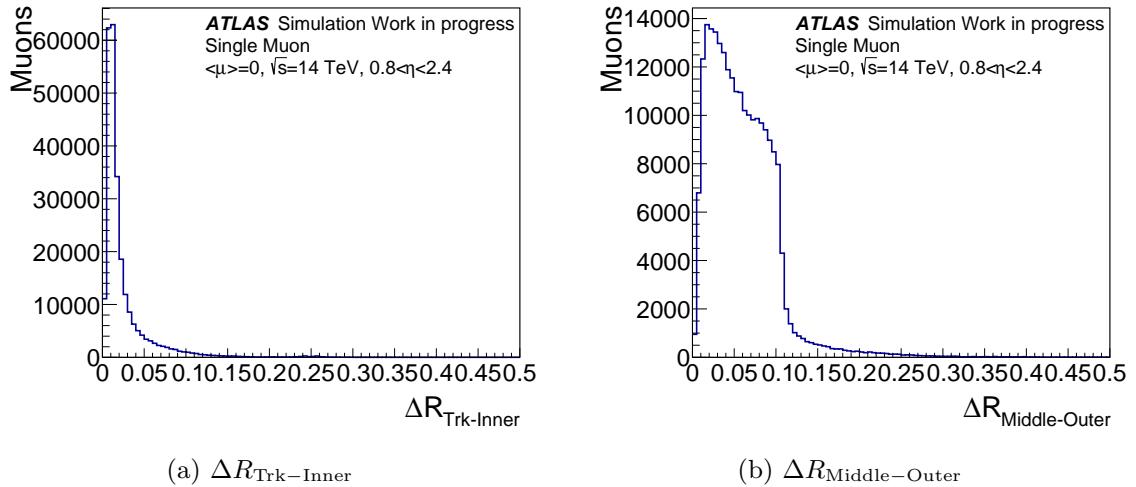
と、ROI 内のセグメントとアウターステーション内のセグメントの距離

$$\Delta R_{\text{Middle-Outer}} = \sqrt{(\Delta\eta_{\text{Middle-Outer}})^2 + (\Delta\phi_{\text{Middle-Outer}})^2} \quad (5.2)$$

の分布である。 ΔR の分布に関しても、 $\Delta R_{\text{Middle-Outer}}$ については ϕ 方向の分解能の悪さから 0 から離れたところにも多く分布している。そこで候補をさらに絞るため、図 5.17 に示す ROI 内のセグメントとアウターステーション内のセグメントの $\Delta\theta_{\text{Middle-Outer}}$ も条件に加えることにする。最終的な条件としては、インナーステーション内のセグメントについては $\Delta R_{\text{Trk-Inner}} < 0.1$ 、アウターステーション内のセグメントについては $\Delta R_{\text{Middle-Outer}} < 0.15$ かつ $\Delta\theta_{\text{Middle-Outer}} < 0.05$ の範囲内で再構成されたセグメントの探索を行う。その中で複数のセグメントが見つかった場合には、セグメントの傾きを参考に、磁場のない領域で真っ直ぐ飛んだと仮定した際の位置に最も近いセグメントを選択する。

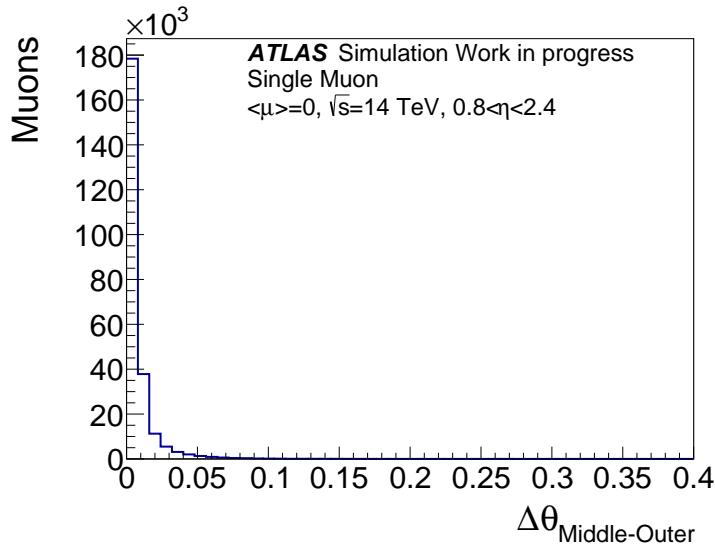
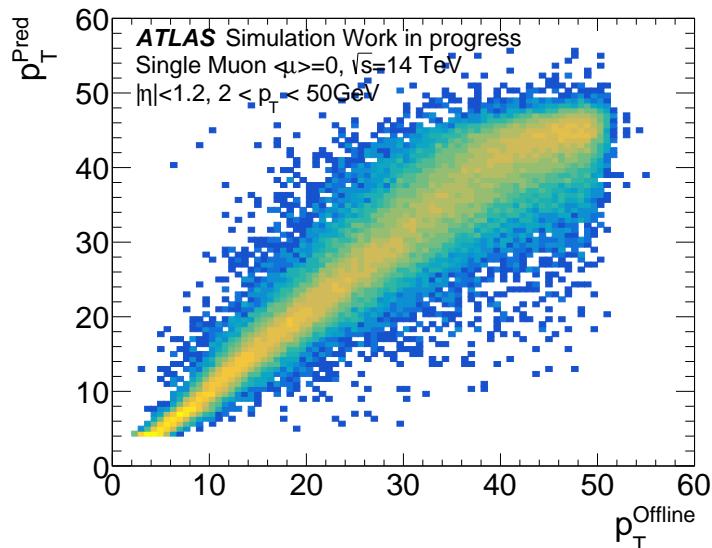
5.3.3 横運動量 p_T の分類

本節では、選択したセグメントと内部飛跡の組み合わせの整合性を確認するための、横運動量 p_T を分類する機械学習モデルについて述べる。本研究で開発したアルゴリズムでは、選択したセグメントと内部飛跡の組み合わせが同じ飛跡に属する場合に予測される p_T を、機械学習により p_T

図 5.15: 各セグメントと RoI 内のセグメントとの $\Delta\phi$ 分布 (エンドキャップ領域)。図 5.16: ΔR 分布 (エンドキャップ領域)。

の大きさに基づいたいくつかのグループに分類する。その後、実際に使用した内部飛跡の p_T が、機械学習の分類と一致するかを確認することで整合性をとる。

磁場で飛跡が曲げられることにより p_T の判別が可能になっているが、飛跡は p_T が大きくなるほど直線に近くなるため、高い p_T ほど厳密な判別が難しくなる。実際にフィットなどを行い飛跡の再構成をした後も、一般的に低い p_T であるほど分解能が良く、高い p_T になるほど分解能が悪くなる。本来であれば機械学習で直接 p_T を導出することが望ましいが、以上の理由によりある一定の p_T を超えたあたりから特徴量のみで判別することが難しくなってしまう。試しに直接 p_T を導出する機械学習をしてみた場合の結果を図 5.18 に示す。高い p_T になるほど、分解能が悪くなっていることが確認できる。また、トリガーシステムという観点からは、ある閾値以上の p_T を持つミューオンを判別できるのであれば厳密に p_T の値を測定しなくとも良いことから、このような形

図 5.17: $\Delta\theta_{\text{Middle-Outer}}$ 分布 (エンドキャップ領域)。図 5.18: p_T を直接導出する機械学習の推論結果。正しく推論できているために低い p_T ではみられる濃い直線が、 p_T が高くなっていくにつれてぼやけているのが分かる。

式を採用することにした。

・モデル構造

p_T 分類に使用したモデルは、10層の全結合層のモデルである。モデルの詳細を表 5.4 に、モデルの構造を図 5.19 示す。入力には、内部飛跡の絞り込みにより候補として残った内部飛跡候補、RoI 内のセグメント、また一つ前のステップで選択したインナーステーション内のセグメント、アウターステーション内のセグメントの計 12 の特徴量を用いた。入力の詳細を表 5.5 に示す。出力

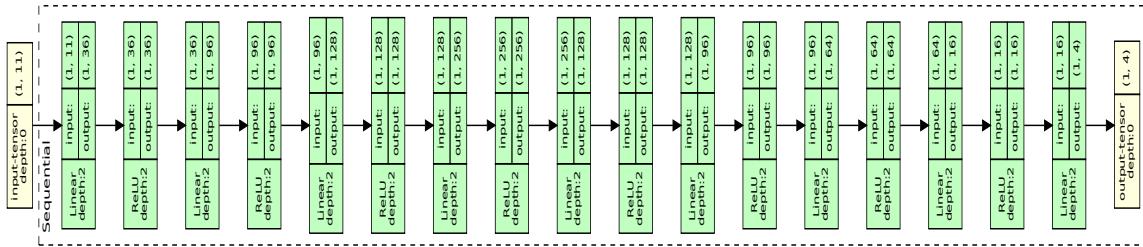


図 5.19: p_T 分類のために使用するモデルの構造。

表 5.4: 運動量の分類に使用した機械学習モデルの詳細。

モデル構造	層数	活性化関数	入力	出力
MLP	10	ReLU	12 nodes	4 nodes

表 5.5: p_T 分類のモデルへの入力。ただし、全ての θ は $\frac{\pi}{2} - \theta \times \text{sign}(\cos \theta)$ として再計算したもの用いる。

特徴量	
内部飛跡	電荷と運動量の比 (q/p), RoI 内のセグメントとの θ, ϕ の差
インナーステーション内のセグメント	セグメントの傾き α (第 3 章参照), RoI 内のセグメントとの θ, ϕ の差
RoI 内のセグメント	セグメントの傾き α (第 3 章参照), 位置 (θ, ϕ)
アウターステーション内のセグメント	セグメントの傾き α (第 3 章参照), RoI 内のセグメントとの θ, ϕ の差

は、4 クラスの値を出力する分類モデルであり、選択したセグメントと内部飛跡がミューオン候補であった場合にどのような運動量を持つかの分類を行う。1 クラス目は、1 つでも見つかった場合はデータを取得するような、高い p_T である 26 GeV を確実に取得するための $p_T > 20 \text{ GeV}$, 2 クラス目は 2 つ以上みつかればトリガーを発行するような $10 \text{ GeV} < p_T < 20 \text{ GeV}$, 3 クラス目は比較的低い p_T であるがいくつかのトリガーメニューで使用されている $4 \text{ GeV} < p_T < 10 \text{ GeV}$, 4 クラス目はデータを取得する対象に入らない $p_T < 4 \text{ GeV}$ の 4 クラスを設定した。

表 5.6: 横運動量の分類の機械学習に使用したハイパーパラメータ。学習率の ExponentialLR は、PyTorch の `lr_scheduler.ExponentialLR` を用い、スタート時は 0.01、毎エポック 0.98 倍で減少させた。

エポック数	バッチサイズ	学習率	損失関数
100	1024	ExponentialLR	CrossEntropy

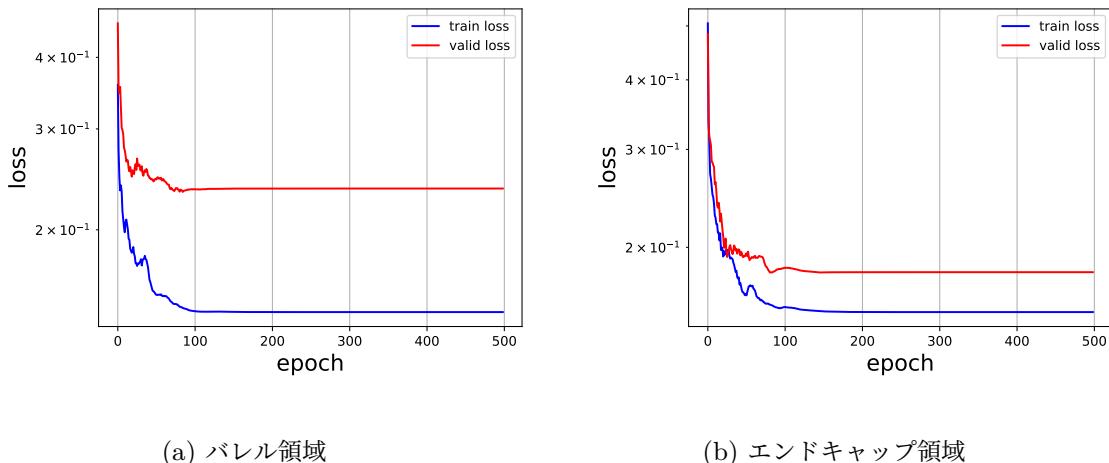


図 5.20: p_T 分類学習の Loss

・学習

実際にデータ測定を行った際、検出器の構造や精度からセグメントが 3 つとも再構成されず 1 つや 2 つのみのことは珍しくない。現在のアルゴリズムでは衝突点由来を仮定することで、また今回のアルゴリズムでは内部飛跡の情報を用いることで、セグメントを必ず 3 つを使用しなくても p_T の推定が可能である。機械学習では入力のノード数が固定されるため、特徴量を各入力ごとで揃えなくてはならないが、元々オンラインミューオンの再構成に使用したセグメントがない場合にはその特徴量を 0 として入力する。ただし、バレル領域では少なくとも 2 つのセグメントを使用することを要求する。

学習に使用したハイパーパラメータを表 5.6 に示す。バレル領域、エンドキャップ領域での学習について、学習データと検証データの遷移はそれぞれ図 5.20 のようになった。両者のモデルとも学習が収束していることが確認できる。また、各領域での学習結果は図 5.21 のようになっており、各モデルの精度は表 5.7 となっている。バレル領域、エンドキャップ領域ともにある程度分類できているが、高い p_T になればなるほど特徴量が掴みにくく、分解能が悪くなっている。

表 5.7: 各モデルの精度

モデル	精度
バレル領域	93.2%
エンドキャップ領域	92.6%

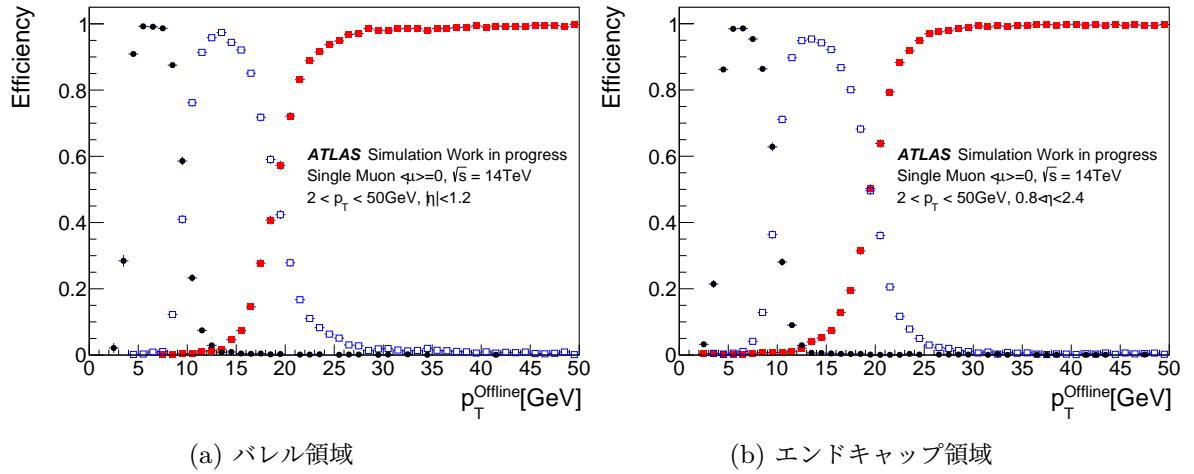
図 5.21: p_T 分類学習の結果。赤色で示す最も高い p_T 分類クラス ($p_T > 20$ GeV) では、黒色で示す最も低い p_T 分類クラス ($p_T < 4$ GeV) に比べてテールが大きい。

表 5.8: 機械学習の推論結果と内部飛跡とのマッチングに要求する値。

分類クラス	内部飛跡の p_T
$p_T > 20$ GeV	12 GeV –
$10 \text{ GeV} < p_T < 20 \text{ GeV}$	7 GeV – 34 GeV
$4 \text{ GeV} < p_T < 10 \text{ GeV}$	4 GeV – 15 GeV

5.3.4 ミューオンの再構成

最終的にミューオン候補としては、推論の分類結果と機械学習の入力に使用した内部飛跡の p_T が一致したセグメントと内部飛跡の組み合わせを選択する。しかし、図 5.21 にあるように、各クラス分類の境目では分解能が少し悪くなっていることから、学習結果を基にある程度幅を持たせて一致を要求することにする。その値を表 5.8 に示す。また、ミューオン候補の横運動量 p_T は、最終的に選択した内部飛跡の p_T として定義する。複数内部飛跡が選択された場合には、トリガーシステムという観点から、最も高い横運動量 p_T をもつ内部飛跡を含むセグメントと内部飛跡の組み合わせをミューオン候補として選択することとした。

5.4 各変数の結果への寄与

機械学習により、モデルがどのような過程でどう結論を出したかは、通常ブラックボックスになっていて知ることができない。そこで近年モデルの判断を可視化したりするなど、AIの意思決定プロセスを人間に理解可能な形で説明する技術である Explainable Artificial Intelligence (XAI) [61] が注目されている。本研究では、XAIを使用できるライブラリを用いてモデルの解釈を行う。結果の確認や制度改善のため、特にどの変数がモデルの結果に寄与しているかや、使用した変数が狙い通りに働いているかを確認したかったため、その説明に特化している SHAP [62] を用いてモデル解釈を行った。どのように各特徴量がモデルの推論結果に寄与しているかどうかは、SHAP 値と呼ばれる値で評価することができる。SHAP 値とは、それぞれの特徴量が予測結果にどのように寄与しているかの指標である。モデルが output する全データの平均や中央値を基準値として設定され、各特徴量が予測結果に与える寄与をすべての可能な特徴量の組み合わせを考慮しながら計算される。本研究では、SHAP に用意されている複数のツールの中から、深層学習モデルに特化した DeepExplainer を使用して評価を行った。

・セグメント選択のための機械学習モデル

まず、セグメントの選択を行う際のモデルについてモデル解釈を行った。図 5.22 に結果を示す。それぞれの色は各特徴量の値の大きさを表し、ピンクに近いほど大きく、青に近いほど小さい値となっている。横軸は SHAP 値を表しており、SHAP 値が大きいほど推論値の数値を大きい方向に持っていく、小さいほど小さくする方向に持っていくように各特徴量が寄与していることを示している。 θ_{Inner} , θ_{Outer} を推論させる回帰モデルであるため、RoI 内のセグメントと内部飛跡の θ がモデルの推論値に大きく寄与しており、 θ が小さければ予測値も小さく、逆に θ が大きければ予測値も大きくなるよう、 θ_{Middle} と θ_{Trk} が線形に結果に影響を与えていていることが図 5.22 から読み取れる。また、 θ_{Outer} 予測モデルの結果を表す図 5.22 (右) を見ると、電荷が正の場合は予測値を小さく、逆に負の場合は大きくするようになっていることから、バレル領域の磁場環境下において飛跡の曲がる方向を学習していることが分かる。また、 p_T が低い場合も正負に SHAP 値が分布しており、同様に p_T が関係する α の変数も傾きが大きい場合に正負に SHAP 値が分布していることから、 θ の情報以外を持つ残りの変数も磁場を考慮した推論結果に寄与していることがわかる。

・ p_T 選別のための機械学習モデル

続いて、 p_T 分類を行うモデルについてもモデル解釈を行った。図 5.23, 図 5.24 に示すのが、それぞれバレル領域とエンドキャップ領域についての結果である。図 5.22 と同様にそれぞれの色は各特徴量の値の大きさを表し、ピンクに近いほど大きく、青に近いほど小さい値となっている。横軸は各分類の決定にかかわるファクターの大きさを表しており、正に大きいほどその分類クラスを選択する動きに貢献し、負になるほど選択しない動きに貢献していることになる。

図 5.23 から分かるように、バレル領域でモデルの判断に最も寄与が高いのはアウターステー

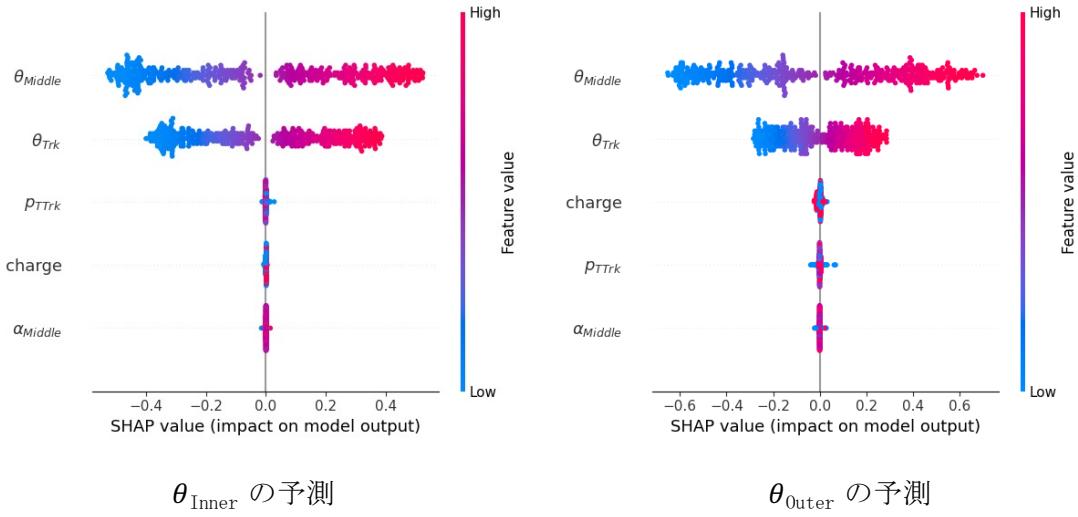


図 5.22: セグメント選択のための機械学習モデルにおける各分類クラスの SHAP 値。 θ_{Middle} と θ_{Trk} が線形に結果に影響を与えている。

ション内のセグメントの傾き (α_{Outer}) である。これは、最も外側のセグメントで磁場の影響を受けているため、運動量の特徴が出やすいためだと考えられる。各セグメントは、傾きがほとんどなく真っ直ぐな 0 の値に近い場合は高い運動量を持っている傾向があるので、高い運動量の分類クラスである $p_T > 20 \text{ GeV}$ においては正の SHAP 値, $p_T < 4 \text{ GeV}$ においては負の SHAP 値を持っていることが望ましく、逆に傾きが大きいほど $p_T > 20 \text{ GeV}$ においては負の SHAP 値, $p_T < 4 \text{ GeV}$ においては正の SHAP 値を持っていることが望ましい。図 5.23 で確認すると、傾きがほとんどなく真っ直ぐな 0 の値に近い場合 (α_{Outer} は正負の値をもっているため図 5.23 中の紫色)、 $p_T > 20 \text{ GeV}$, $10 < p_T < 20 \text{ GeV}$ では正の SHAP 値を持ち、逆に $p_T < 10 \text{ GeV}$ では負の SHAP 値を持っており、そのクラス選択を行わないように働いていることが分かる。逆に、傾きが大きい場合 (図 5.23 中の青色またはピンク色) には $4 < p_T < 10 \text{ GeV}$, $p_T < 4 \text{ GeV}$ のクラスを選択する方向に働いている。また、RoI 内のセグメントと各セグメントとの位置の差に関しては、差が小さく、つまり磁場による曲がり方が小さく高い運動量の特徴を持っている場合 (青色) には $p_T > 10 \text{ GeV}$ のクラス選択に貢献し、大きい場合 (ピンク色) には逆に $p_T > 10 \text{ GeV}$ を選択しないように働いていることが確認でき、概ね狙い通りに変数が正しい分類に働いているといえる。また、図 5.24 をみると、エンドキャップ領域ではモデルは RoI 内のセグメントの傾き (α_{Middle}) にもっとも影響を受けていることが分かる。特に $p_T > 4 \text{ GeV}$ の選別には顕著に働いているようである。また、バレル領域では 3 番目に影響力が大きかったアウターステーション内のセグメントと RoI 内のセグメントの位置の差に関して、エンドキャップ領域ではミドルステーションとアウターステーションの間に磁場がないため、バレル領域に比べて影響力が落ちていることが確認できる。

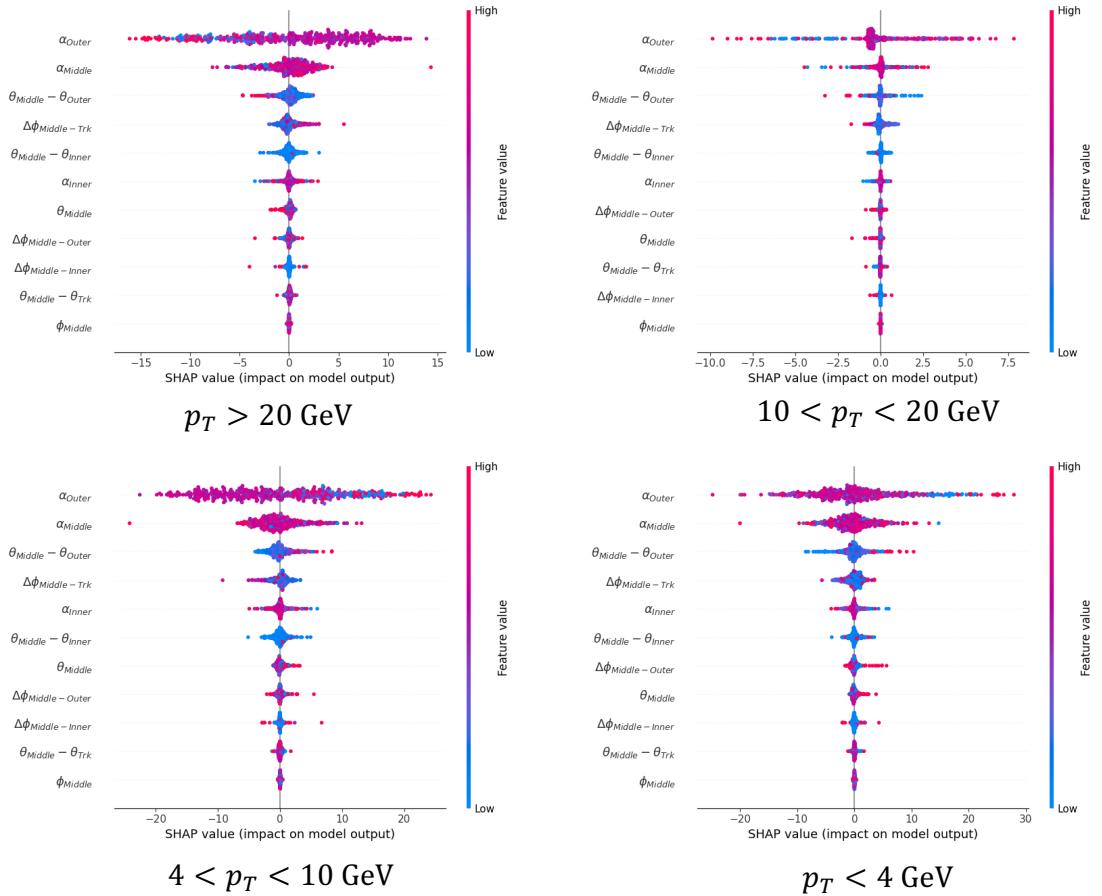


図 5.23: p_T 選別のための機械学習モデルにおける各分類クラスの SHAP 値 (バレル領域)。それ以上から寄与が高い順に特徴量が並んでいます。最も寄与が高いのは α_{Outer} である。

その代わりに、間に磁場が存在するインナーステーション内のセグメントと ROI 内のセグメントの ϕ , θ の差がバレル領域よりも大きな影響力を持っていることが確認でき、モデルが効率よく特徴量を学習していることが確認できる。

5.5 本研究アルゴリズムの評価

本節では、5.3 節で述べたように、本研究で開発した新たなミューオン再構成アルゴリズムの評価について述べる。

・アルゴリズムの実行

全ての過程を通してアルゴリズムの性能を確認する際には、これまで述べた PyTorch モデルを Open Neural Network eXchange (ONNX) [63] フォーマットに変換して使用した。ONNX とは、

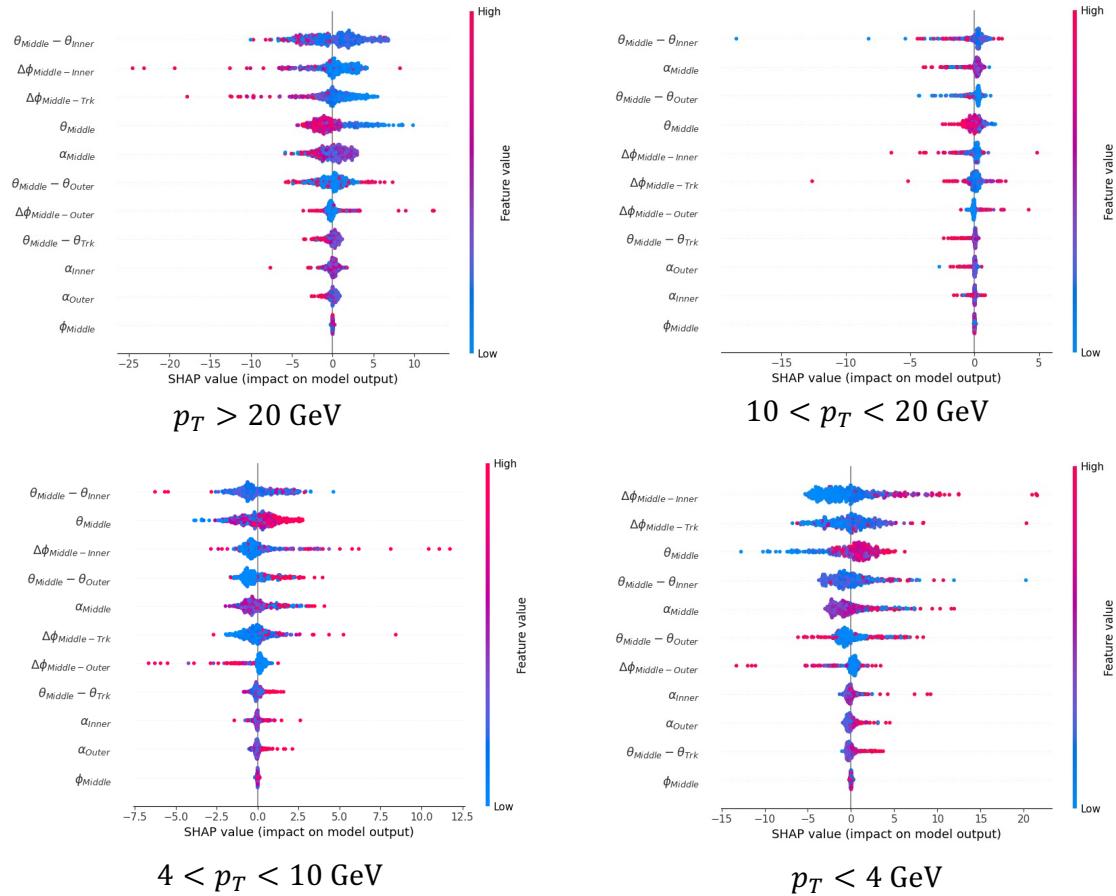


図 5.24: p_T 選別のための機械学習モデルにおける各分類クラスの SHAP 値 (エンドキャップ領域)。それぞれ上から寄与が高い順に特徴量が並んでいる。インナーステーション内のセグメントと RoI 内のセグメントが持つ変数の差を表す特徴量の寄与が高いことがわかる。

異なるフレームワーク間でモデルを交換し、効率的にデプロイするためのオープンフォーマットである。モデルを特定のフレームワークに縛られず Python や C++ などの環境で使用できるのが利点であり、一般的には ONNX runtime ライブラリ [64] を使用して推論を実行できる。また、ONNX は推論に特化したフォーマットであり、一般的に元のフォーマットよりも高速に推論できる。C++ での実行も比較的容易であり、さらに GPU や FPGA といったアクセラレータにも対応していることから、高輝度 LHC-ATLAS 実験の解析用フレームワークにも新たに導入される予定である。そのため、本研究でも ONNX モデルを使用して全てのアルゴリズムを C++ で実行した。

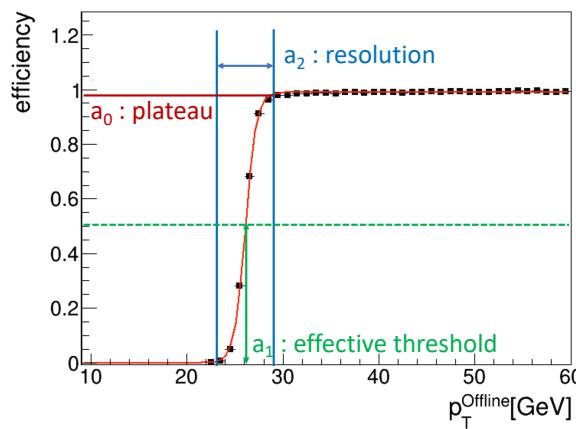


図 5.25: turn-on curve とトリガー効率の性能を表すパラメータ。

・評価方法

全てのオフライン再構成されたミューオンのうち、ある p_T 閾値以上のミューオンに対してトリガーが発行された割合をトリガー効率として式 (5.3) で定義する。

$$E = \frac{\text{ある } p_T \text{ 閾値以上のトリガーが発行されたミューオンの数}}{\text{全オフライン再構成されたミューオンの数}} \quad (5.3)$$

また、各 p_T に対するトリガー効率を式 (5.4) の関数でフィットすることで得られる図 5.25 のような Trun-on curve を用いて、定量的に評価を行う。

$$f(p_T) = \frac{a_0}{\exp \frac{p_T - a_1}{a_2} + 1} \quad (5.4)$$

式中のトリガーの性能を表すパラメータは図 5.25 のように定義する。

- a_0 : Plateau
turn-on curve が横ばいになった時のトリガー効率を表す。1 に近い方がトリガーで取るべきであるミューオンを取れている確率が高い。
- a_1 : Effective threshold
トリガー効率が Plateau の値の 50% になる時の p_T の値であり、実行的なトリガーの p_T 閾値を表す。
- a_2 : Resolution
トリガーの運動量分解能を示す。この値が小さいほど turn-on curve の立ち上がりが鋭く、トリガー性能が良いといえる。

本研究アルゴリズムの評価では、前段トリガーを通過したミューオンに対してのトリガー効率で評価を行うこととする。ただし、Phase-II サンプルにおいてはまだトリガーシミュレーションが完成していないため、前段トリガーを通過したと仮定して、ミドルステーションでセグメントが見つかったイベントを対象に評価を行う。

5.5.1 $\langle\mu\rangle=200$ Phase-II シミュレーションサンプルを用いた評価

本節では、5.2.1 節で述べた Phase-II シミュレーションのシングルミューオンサンプルを使用して行った本研究アルゴリズムの評価について述べる。

トリガー効率

3.2 節でも述べたように、ミューオントリガーでは様々な用途のために横運動量 p_T の閾値を設定しトリガーを行っている。isolation を要求した後、単独でもトリガーされる場合の閾値である 26 GeV, 2 つ以上存在することを要求してトリガーされる際の閾値である 14 GeV, di-muon, tri-muon trigger で使用される閾値の 8 GeV に着目し、 p_T の閾値を 8 GeV, 14 GeV, 26 GeV に設定した場合のトリガー効率について評価を行った。この p_T の判定には、5.3.4 節で述べたとおり、選択した内部飛跡の p_T を用いる。

バレル領域、エンドキャップ領域それぞれの本研究アルゴリズムのトリガー効率を図 5.26 に示す。 $\langle\mu\rangle=200$ の高輝度環境下でも、ある閾値以上の p_T を持つミューオンを識別できていることが確認できる。続いて、図 5.27 に示すのが、各トリガー効率の η, ϕ の位置依存性である。全体的な傾向として、 η, ϕ ともに一定のトリガー効率を保っている。図 5.26 に関して、第 2 章でも述べた通り $\eta = 0$ にはミューオン検出器が存在しないため、トリガー効率が下がっているのが確認できる。

オフラインミューオンとのマッチング率

全ての段階を通して、バレル領域、エンドキャップ領域での内部飛跡の候補数は図 5.28 のようになります。バレル領域では磁場の構造上、セグメントがインナーステーションまたはアウターステーションに少なくとも 1 つ見つかることを条件にしている。バレル領域、エンドキャップ領域とともに、最後の内部飛跡とのマッチングで効果的に飛跡候補を減らしていることが分かる。

8 GeV 以上の p_T を持つ全オフラインミューオンに対し、実際に本研究アルゴリズムがミューオンとして再構成し、さらにそれがオフラインミューオンと一致しているとみなせる割合を示したのが、図 5.29 である。マッチング率はバレル領域が 99 % で、エンドキャップ領域が 98.9 % となっている。特に特定の η で悪くなる場所もみられず、シングルミューオンに関しては高い割合で正しく再構成できているといえる。

また、図 5.30 に、本研究アルゴリズムで選択したセグメントが正解としている「オフラインミューオンの再構成に使用したセグメント」と一致した割合を示す。まずインナーステーション内のセグメントについて、バレル領域でエンドキャップ領域と比較して一致した割合が低くなっている

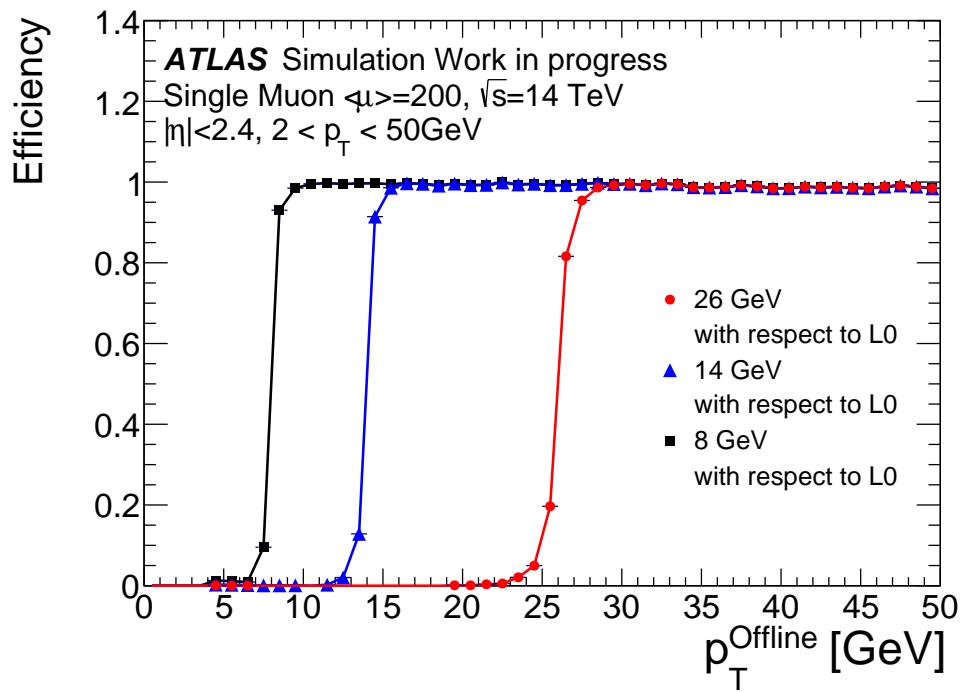


図 5.26: $\langle \mu \rangle = 200$ サンプルでのトリガー効率。それぞれ四角が 8 GeV, 三角が 14 GeV, 丸が 26 GeV の p_T 閾値でのトリガー効率を示している。

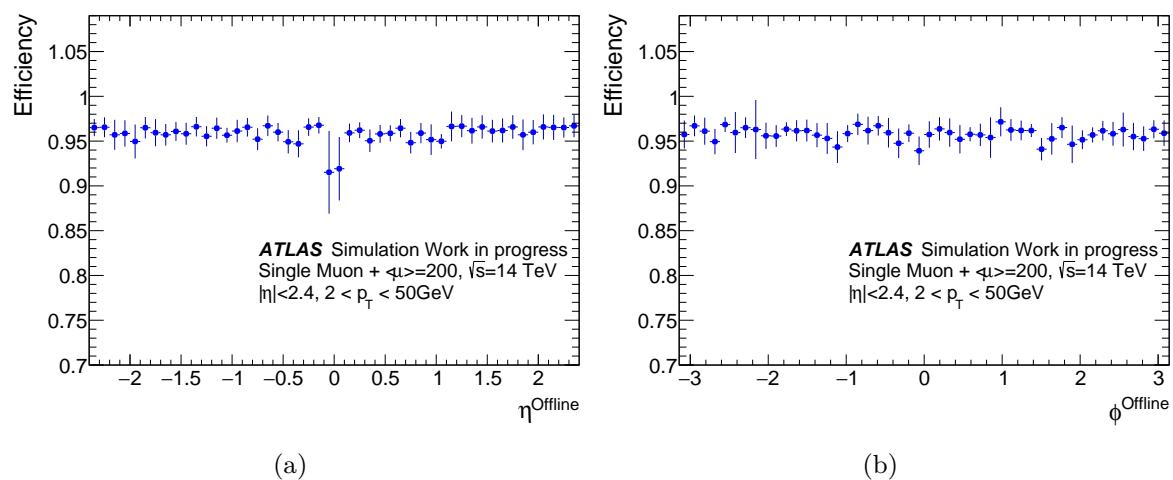


図 5.27: トリガー効率の位置依存性。(a) が η によるトリガー効率の変化, (b) が ϕ によるトリガー効率の変化。(a) の $\eta = 0$ 付近で、トリガー効率が下がっているのが確認できる。

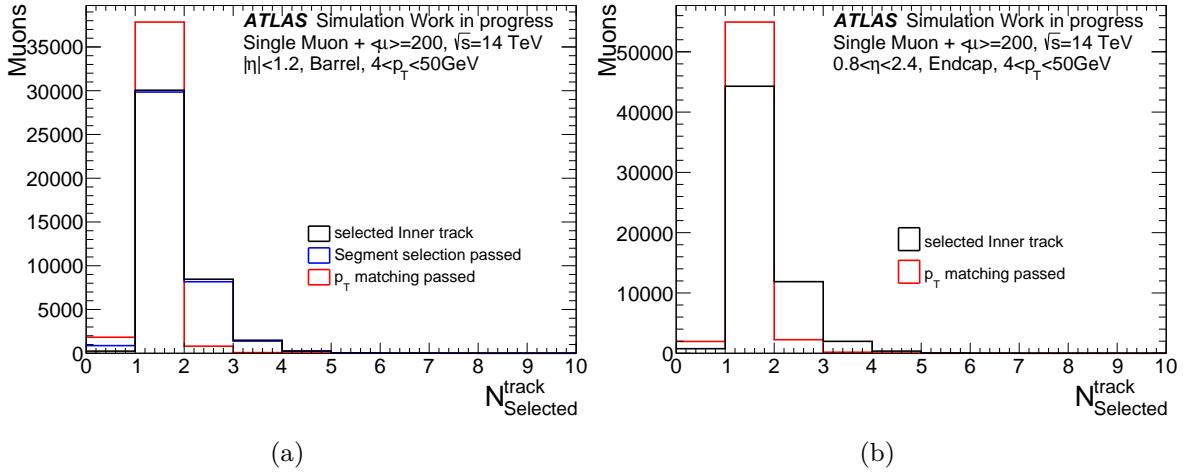


図 5.28: 各段階での内部飛跡の候補数の変化。黒色が内部飛跡選別後、青色がセグメント探索後、赤色が内部飛跡とのマッチング後の分布を示す。

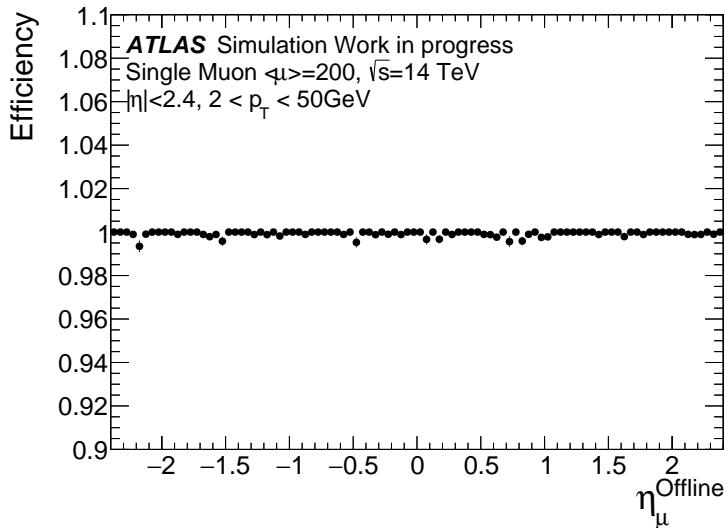


図 5.29: 本研究で再構成したミューオンがオフラインミューオンとのマッチングした割合。

いる。アウターステーション内のセグメントについては、エンドキャップ領域で精度が悪くなっている。これに対してオフラインミューオンとのマッチング率は高くなっているが、5.3節で述べた通り、 p_T 選別の機械学習モデルはバレル領域ではアウターステーション内のセグメント、エンドキャップ領域ではインナーステーション内のセグメントを重視して推論を行っている。バレル領域ではインナーステーション内のセグメントのマッチング率が高く、エンドキャップ領域ではアウターステーション内のセグメントのマッチング率が高いため、うまく機械学習によって正しい p_T が判断されていると考えられる。

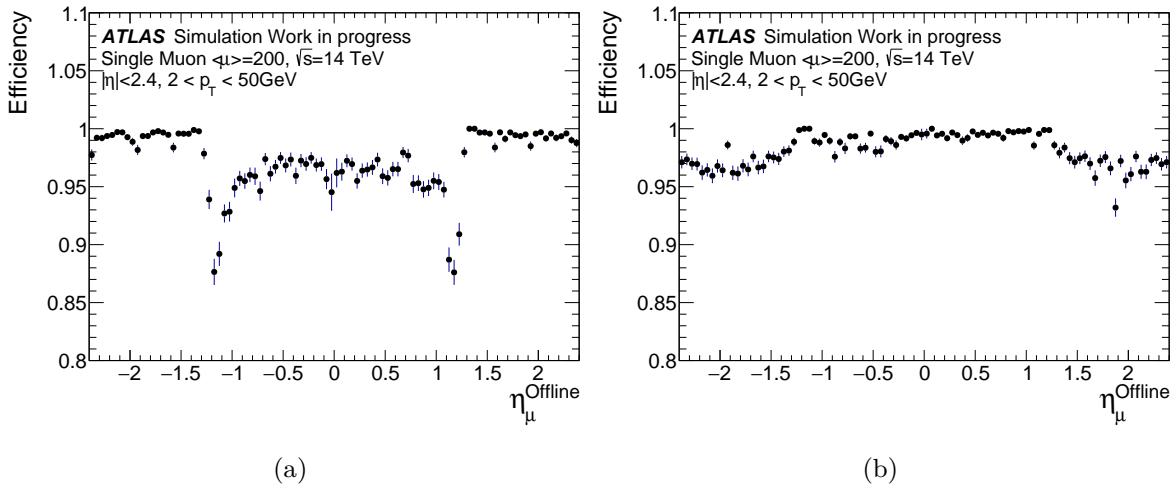


図 5.30: $\langle\mu\rangle=200$ サンプルでの本研究アルゴリズムで選択した各セグメントとオフラインミューオンの再構成に使用したセグメントがマッチングした割合。(a) ガインナーステーション内のセグメントがマッチングした割合, (b) オターステーション内のセグメントがマッチングした割合。

5.5.2 Run 3 データを用いた評価

実際のデータ取得環境での影響を確認するため、Run 3 データでも本研究アルゴリズムの評価を行った。本節では、本研究アルゴリズムの Run 3 データでのトリガー性能と、現行の Run 3 アルゴリズムと本研究アルゴリズムを比較した結果について述べる。

トリガー効率

MC サンプルで評価する場合には式 (5.3) の通りトリガー効率を算出すれば良いが、実データで評価を行う場合にはトリガーによって選別された粒子の情報のみが保存されているため、バイアスがかかる可能性があることに注意が必要である。そこで、そのバイアスを取り除く方法として Tag-And-Probe 法を用いる。Tag-And-Probe 法では、一般的に Z ボソンや J/ψ の崩壊など 2 つのミューオンが生成される物理プロセスを用いて評価を行う。このペアのうち、一方を Tag、もう一方を Probe として使用し、Tag ミューオンが事象選択のトリガーとしてトリガーが発行された場合、Probe ミューオンをトリガー効率の評価に用いる。本研究では、オフライン再構成された $Z \rightarrow \mu\mu$ 事象由来のミューオンを用いて評価を行う。それらのミューオン候補のうち、任意の 2 つの電荷が異符号となっているミューオンペアを選び出し、不变質量 M_Z を再構成する。再構成した不变質量が $81 \text{ GeV} < M_Z < 101 \text{ GeV}$ であれば、選択したミューオンペアが Z ボソン由来のミューオンであると判断する。これらのミューオンのうち、まず、Tag ミューオンがトリガーを発行したかどうかの判定には、HLT の 26 GeV 以上のシングルミューオントリガーである HLT_mu26_ivarmedium_L1MU14FCH を使用する。トリガーを発行したとする定義には、

$\Delta R = \sqrt{(\Delta\eta)^2 + (\Delta\phi)^2}$ を基準として使用する。ここで $\Delta\eta$, $\Delta\phi$ はデータに保存されているトリガーを発行した飛跡情報と、オフライン再構成された Tag ミューオンの η 方向、 ϕ 方向の差分である。本研究では $\Delta R < 0.004$ を満たせば Tag ミューオンがトリガーを発行したとみなす。Tag ミューオンが HLT を発行しているとみなされた際、もう一方の ミューオンを Probe ミューオンとして使用する。Probe ミューオンはデータ保存のために発行されたトリガーとは独立なミューオンであるため、トリガーのバイアスはない。また、純粋に本研究アルゴリズムのみでどれくらいのトリガー効率かを確認するため、初段トリガーを通過したミューオンに対してのトリガー効率で評価を行う。

今回使用した Run 3 データの $Z \rightarrow \mu\mu$ サンプルについて、あらかじめ以下のミューオンのセレクションがかけられたものを使用する。

- 少なくとも 2 つのミューオンがあり、少なくとも 1 つは $|\eta| < 2.1$
- ミューオンの $p_T > 20$ GeV
- 電荷が異なるミューオンのペアがある
- そのペアのミューオンで組んだ不变質量 $m_{\mu\mu}$ が $60 < m_{\mu\mu} < 120$ GeV である
- 衝突点由来である ($|d_{xy}^{\text{corr}}| < 0.02$ cm)
- Z ボソン由来のミューオンを取るための isolation を要求する ($\sum_{\text{Trk}}^{\text{all}} p_T^{Trk} / p_T^\mu$ (cone=0.4) < 0.2)

この Run 3 データを使用したトリガー効率の評価では、isolate されたシングルミューオントリガーの最低閾値である 26 GeV の p_T 閾値で評価を行う。また、本研究アルゴリズムの Phase-II シミュレーションサンプルを用いた評価にはオフライン再構成された内部飛跡を使用していたが、Run 3 データを用いた評価では FTF で再構成された内部飛跡を使用する。

Run 3 データの $Z \rightarrow \mu\mu$ での Tag-And-Probe 法を用いて測定したトリガー効率を図 5.31 に示す。白抜きの丸 (青) で示しているのが現行アルゴリズム、黒塗りの四角 (赤) で示しているのが本研究のアルゴリズムのトリガー効率である。プラトーに関してはほとんど同じか少し下回る値となっているが、立ち上がりが良くなっている。取得できるイベントレートは決まっているが、立ち上がりが良くなると、その分設定した閾値以下の p_T を持つミューオンのイベントをより落とすことができる。そのため、これまで取得イベントの制限から設定できなかったより低い閾値や条件を設定することが可能になり、物理の感度を高めることができる。両アルゴリズムのトリガー効率について、エンドキャップとバレル領域でそれぞれ式 (5.4) を用いてフィットしたところ、表 5.9, 表 5.10 のようになった。バレル領域では全てにおいて現行アルゴリズムを上回っている結果となった。

また、トリガー効率の η 依存性を図 5.32 に示す。バレル領域では全体的に現行のアルゴリズムより高くなっているが、エンドキャップ領域では全体的に低くなってしまい、特に $|\eta| > 1.3$ からトリガー効率が落ちており、特に $\eta = 1.3$ から $\eta = 2.0$ 付近にかけて大きく下がっている。第 2 章で述べた通り、NSW はエンドキャップ領域の $1.3 < |\eta| < 2.7$ をカバーし、インナーステーションと

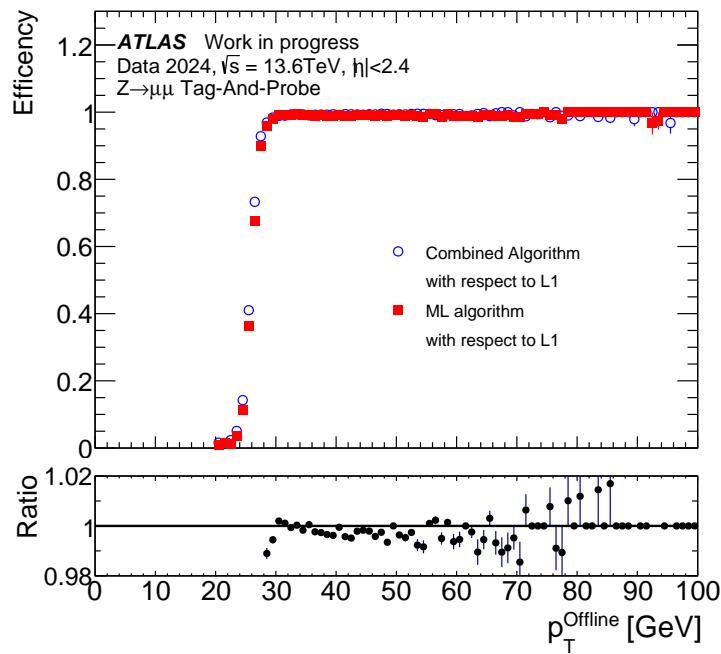


図 5.31: Run 3 データ (2024 年取得) でのトリガー効率。(上) 白抜きの丸 (青) で示しているのが現行アルゴリズム、黒塗りの四角 (赤) で示しているのが本研究のアルゴリズムのトリガー効率。(下) 現行アルゴリズムと本研究アルゴリズムの比。

表 5.9: Run 3 データ (2024 年取得) の turn-on curve のフィッティング結果 (バレル領域)。全ての項目で本研究アルゴリズムが現行アルゴリズムを上回っている。

	現行アルゴリズム	本研究アルゴリズム
Effective threshold [GeV]	25.8	25.9
Plateau	0.988	0.997
Resolution [GeV]	0.59	0.56

表 5.10: Run 3 データ (2024 年取得) の turn-on curve のフィッティング結果 (エンドキャップ領域)。Effective threshold, Plateau は現行アルゴリズムの方が良い結果となった。

	現行アルゴリズム	本研究アルゴリズム
Effective threshold [GeV]	25.6	25.8
Plateau	0.995	0.981
Resolution [GeV]	0.747	0.749

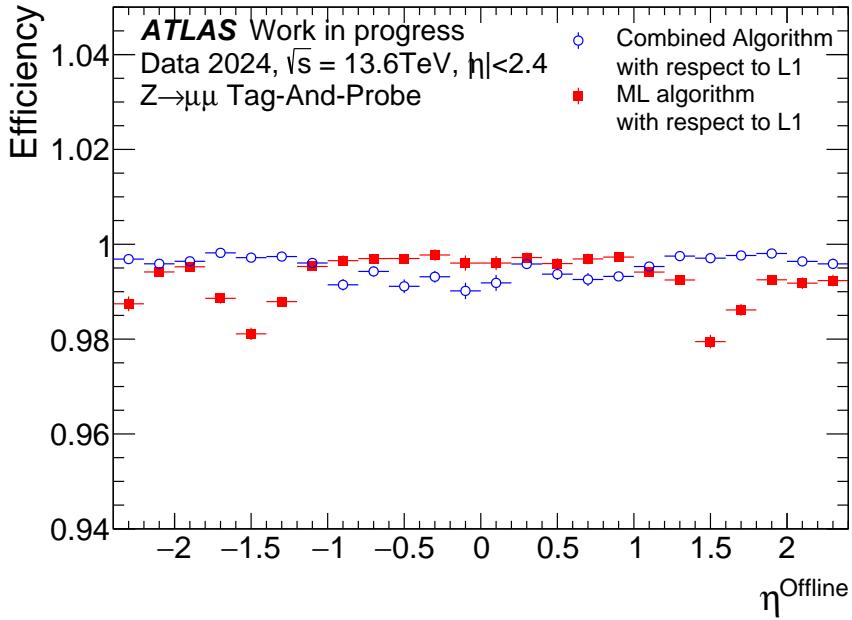


図 5.32: Run 3 データ (2024 年取得) でのトリガー効率の η 依存性。白抜きの丸 (青) で示しているのが現行アルゴリズム、黒塗りの四角 (赤) で示しているのが本研究のアルゴリズムのプラトー効率である。エンドキャップ領域で大きく下がっているのが分かる。

してミューオンのヒット情報の取得に使用されている。しかし、この NSW によるヒットはシミュレーションによる想定と実際の測定データとで大きな差がある [65]。現時点ではあまり分解能がよくないため、現行アルゴリズムでは NSW の情報を使用せずに再構成を行っている。一方、本研究アルゴリズムでは NSW の情報を使用していることに加えて、機械学習モデルは全てシミュレーションデータを用いて学習されているため、NSW のシミュレーションとデータの差による影響を受けている可能性が高い。また、NSW には図 5.33 のように $\eta = 1.5$ 付近でギャップがあり、ヒットを取得できない部分がある。まだ Phase-II アップグレードに向けた検出器でのシミュレーションは未完成で詳細が実装されていない部分も多く、 $\eta = 1.5$ 付近で大きく下がる部分に関してもシミュレーションとデータでの差が影響していると考えられる。 $\eta \leq -2.4$ 付近の C-side のみでトリガー効率が下がっているところに関しては、この Run 3 のデータ取得時に一部 NSW のセクターが正しく動作していなかったことによる影響である。この部分に関しても、現行アルゴリズムでは使用しないので影響は出でていない。

両アルゴリズムにおいて、バレル、エンドキャップそれぞれで使用したセグメントの数は図 5.34 のようになっている^{*2}。各アルゴリズムで取得できなかったミューオンに関してはセグメント数を 0 としてカウントしている。現行のアルゴリズムよりもトリガー効率が高かったバレル領域では、現行アルゴリズムで取得できなかったミューオンに対し本研究では 3 つのセグメントを使用した場

^{*2}現行アルゴリズムのセグメント数には、BE や EE などの特殊なチャンバーも含む

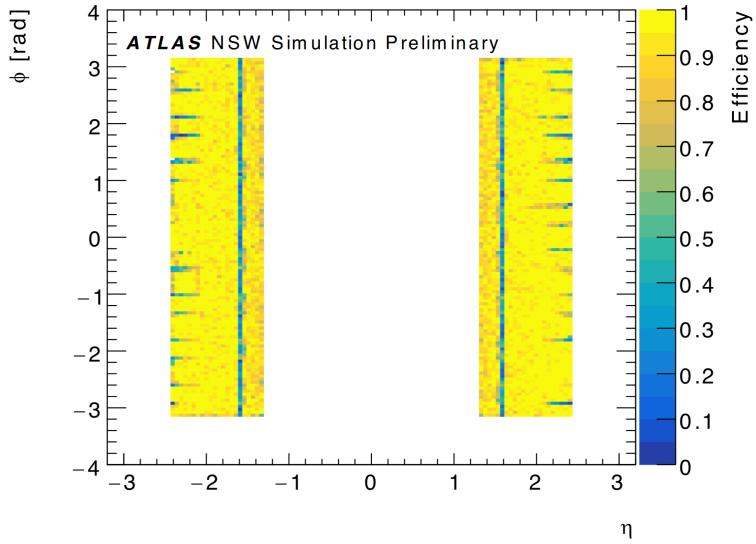


図 5.33: $10 < p_T < 100$ GeV でフラットな分布のミューオンのシミュレーションサンプルにおける MM のトリガー効率 [66]。 $\eta = 1.5$ 付近で取得できていないのが分かる。

合が最も多い。また、本研究アルゴリズムの方が閾値以下のミューオンを落とすことができていたが、全体的には現行アルゴリズムが 3 個、本研究アルゴリズムが 2 個のセグメントを使用した場合が最も多い。このことから、本研究アルゴリズムは機械学習によってセグメント位置を予測し選択することで、精度が悪かったり、 p_T の傾向とは少し異なる場所にあるが再構成されたようなセグメントを使用したりすることなく、より精度が良い再構成を行えると考えられる。

続いてエンドキャップ領域については、現行アルゴリズムが 2 個、本研究アルゴリズムが 3 個セグメントを使用した場合が最も多くなっており、本研究アルゴリズムが取得できなかったミューオンに対して現行アルゴリズムが使用したセグメント数は、2 個の場合が多いことが分かった。Run 3 において現行アルゴリズムでは、NSW の分解能が良くないことを考慮して NSW 内で再構成されたセグメントを使用しないことにしており、エンドキャップ領域では 3 個のセグメントを使用した場合が少なくなっている。エンドキャップ領域のトリガー効率は現行のアルゴリズムよりも低くなっていたが、本研究アルゴリズムではエンドキャップ領域でも 3 個のセグメントを使用して再構成を行っている場合が最も多いので、NSW の情報を使用して再構成されたインナーステーション内のセグメントも使用している場合が多い。NSW の情報は上に述べたようなシミュレーションとデータとの差が大きいため、データとシミュレーションの差の影響を受けてトリガー効率が下がっていると考えられる。機械学習では、NSW の実際の精度を考慮した学習を行うことも可能であるため、今後実際の測定に使用する際には、測定されたデータの情報を使用した学習を行うなど、実際の測定環境や精度に適応するような学習が必要である。

本研究アルゴリズムで取得でき、現行アルゴリズムで取得できなかった $p_T > 26$ GeV のミューオンの η, ϕ 分布は図 5.35 (左) のようになった。バレル領域において、 $\phi \approx -1, \phi \approx -2$ 付近で統計が少し多くなっているのが確認できるが、これは ATLAS 検出器の足の部分である。図 2.8 を

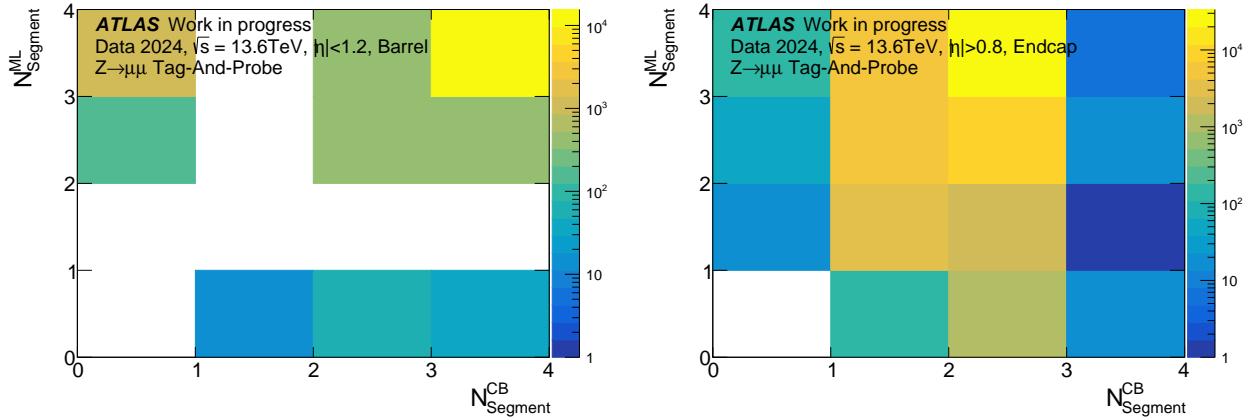


図 5.34: 各アルゴリズムで使用したセグメントの数。 x 軸が現行アルゴリズム、 y 軸が本研究アルゴリズムが使用したセグメントの数。(左) はバレル領域、(右) はエンドキャップ領域での結果。

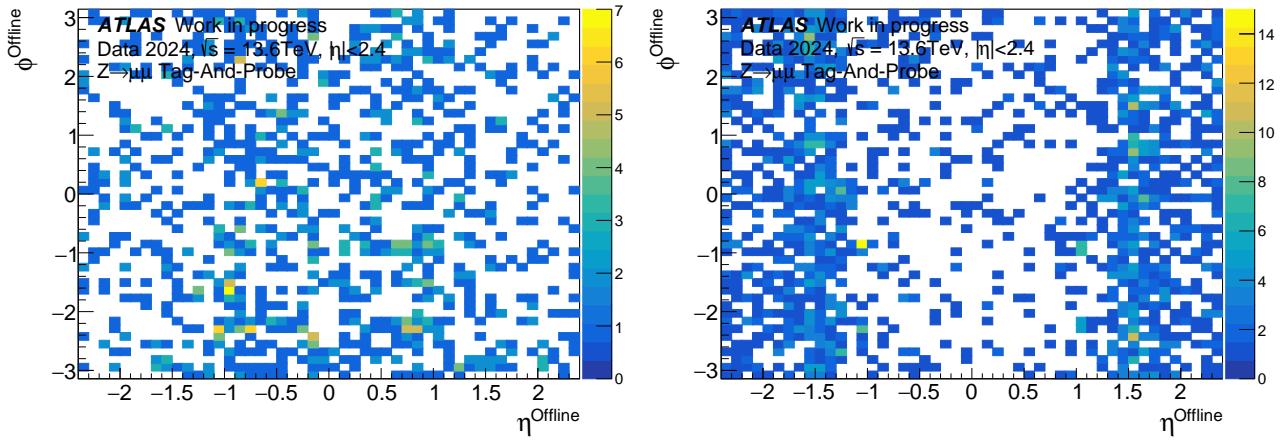


図 5.35: (左) 本研究アルゴリズムで取得でき、現行アルゴリズムで取得できなかった $p_T > 26$ GeV のミューオンの η , ϕ 分布。 $|\eta| < 1.05$ のバレル領域において、 $\phi \approx -1$, $\phi \approx -2$ 付近の統計が少し多くなっている。これは ATLAS 検出器の足の部分に該当する。(右) 現行アルゴリズムで取得でき、本研究アルゴリズムで取得できなかった $p_T > 26$ GeV のミューオンの η , ϕ 分布。NSW がヒットを取得できない $\eta = \pm 1.5$ で統計が多くなっている。

見ると分かるように、ATLAS 検出器の足の部分では少し他の場所と検出器の配置が異なり、難しい。その部分に関して、機械学習ではミューオン検出器の配置ごと学習できていたと考えられる。また、逆に現行アルゴリズムで取得でき、本研究アルゴリズムで取得できなかった $p_T > 26$ GeV のミューオンの η , ϕ 分布を図 5.35 (右) に示す。エンドキャップ側の、特に NSW でヒットを取得できない $\eta = 1.5$ 付近に固まっているのが分かる。

また、バレル領域において特に現行アルゴリズムよりもトリガー効率が高かった $0.8 < |\eta| < 1.1$ では、図 5.36 のようなトリガー効率の立ち上がりになっており、より高いプロト-効率を保ちな

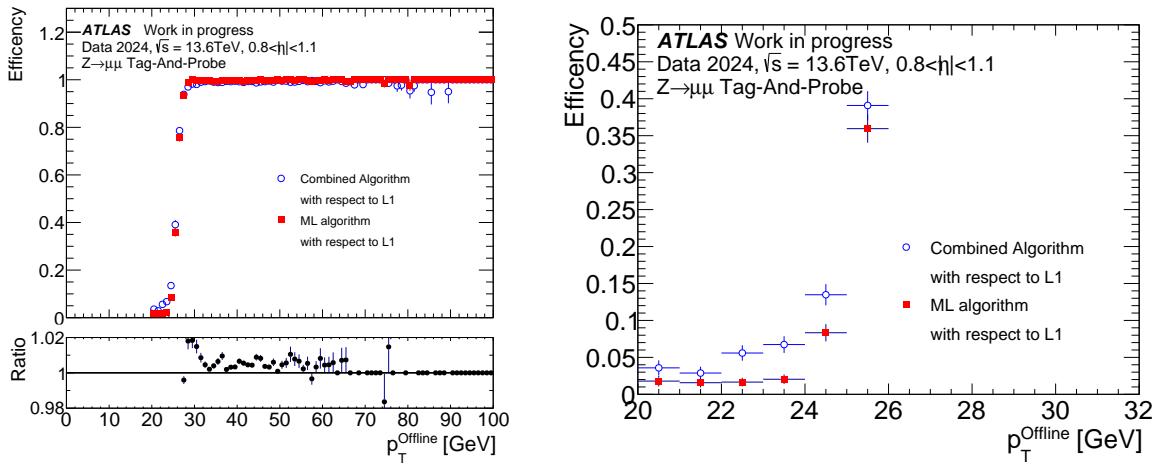


図 5.36: $0.8 < |\eta| < 1.1$ での Run 3 データ (2024 年取得) のトリガー効率。白抜きの丸 (青) で示しているのが現行アルゴリズム、黒塗りの四角 (赤) で示しているのが本研究のアルゴリズムのトリガー効率。(右) は閾値 26 GeV 付近を拡大したものであり、本研究アルゴリズムがテールを削減できていることが分かる。

がらも低い運動量のミューオンを多く削減できていることが分かる。

p_T residual

実際に測定された p_T の値と、再構成された飛跡から予測される p_T との間の偏差を表す p_T residual の判定には、式 (5.5) を用いる。

$$p_T \text{ resolution} = \frac{\frac{1}{p_T^{\text{ML selected}}} - \frac{1}{p_T^{\text{Offline}}}}{\frac{1}{p_T^{\text{Offline}}}} \quad (5.5)$$

p_T residual の評価については、式 (5.6) に示すガウス関数を用いてフィットを行い、定量的に評価を行う。

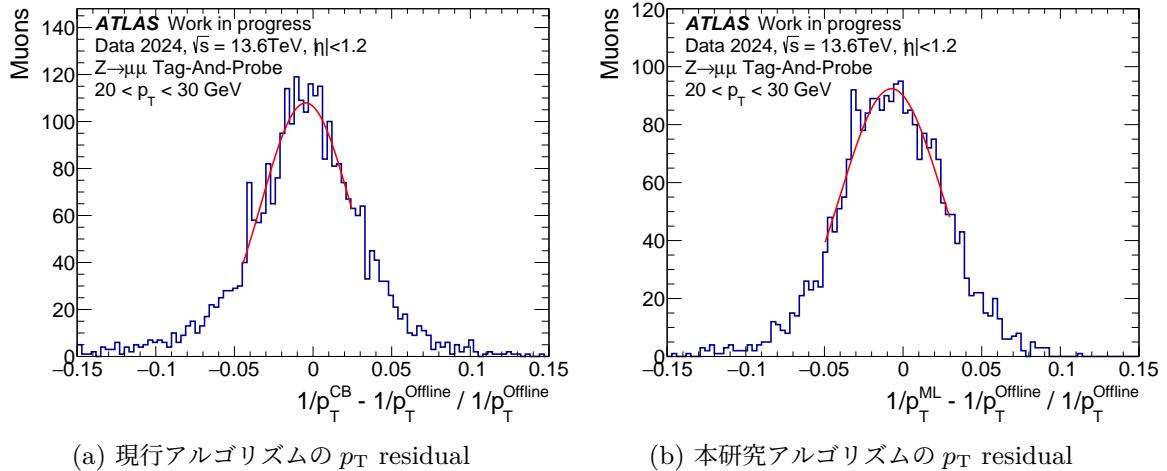
$$f(\theta) = A \exp \left(-\frac{(\theta - \mu)^2}{2\sigma^2} \right) \quad (5.6)$$

p_T residual が小さな値であるほど精度良く p_T を算出できている。トリガーにおいて、本来の p_T にどれほどの精度で近い値が出せているかの分解能だけでなく、大きく見積もったり小さく見積もったりするなどの傾向を捉えることが重要である。ある p_T 以上のミューオンを取得したい際に設定する p_T 閾値をその傾向を考慮したうえで決定することで、より立ち上がりが良く、欲しい p_T のミューオンを取得することができる。また、トリガー性能を確認するうえでは、分解能だけでなく本来の p_T から大きく離れて見積もった数を確認することも必要である。

図 5.37、図 5.38 に示すのは、それぞれバレル領域、エンドキャップ領域の $20 < p_T < 30$ GeV における本研究アルゴリズムと現行アルゴリズムの p_T residual である。それぞれガウス関数で

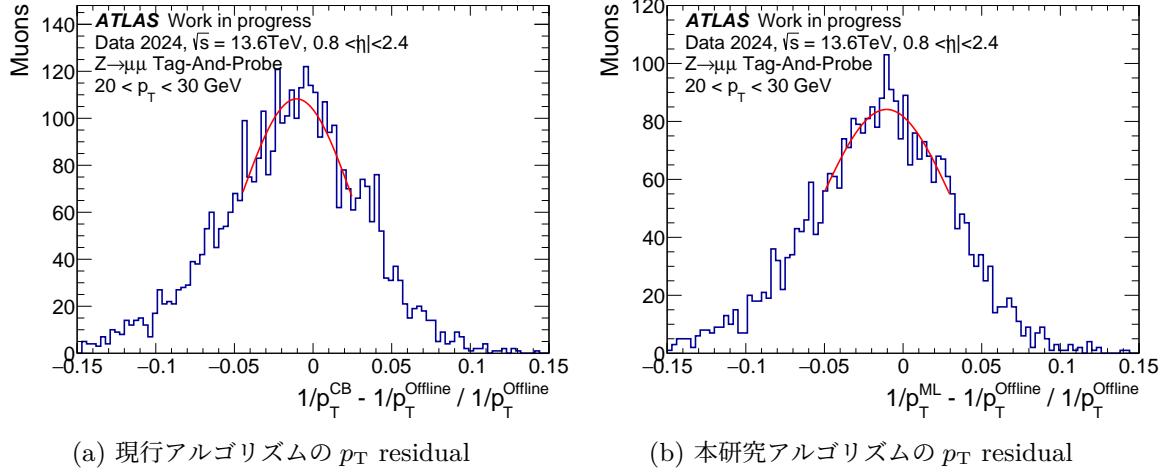
表 5.11: p_T residual の測定結果。

	Mean	σ	tail
現行アルゴリズム (バレル領域)	-3.6×10^{-3}	2.4×10^{-2}	11%
本研究アルゴリズム (バレル領域)	-6.8×10^{-3}	2.9×10^{-2}	2.0%
現行アルゴリズム (エンドキャップ領域)	-1.1×10^{-2}	3.6×10^{-2}	4.8%
本研究アルゴリズム (エンドキャップ領域)	1.1×10^{-2}	4.4×10^{-2}	1.0%

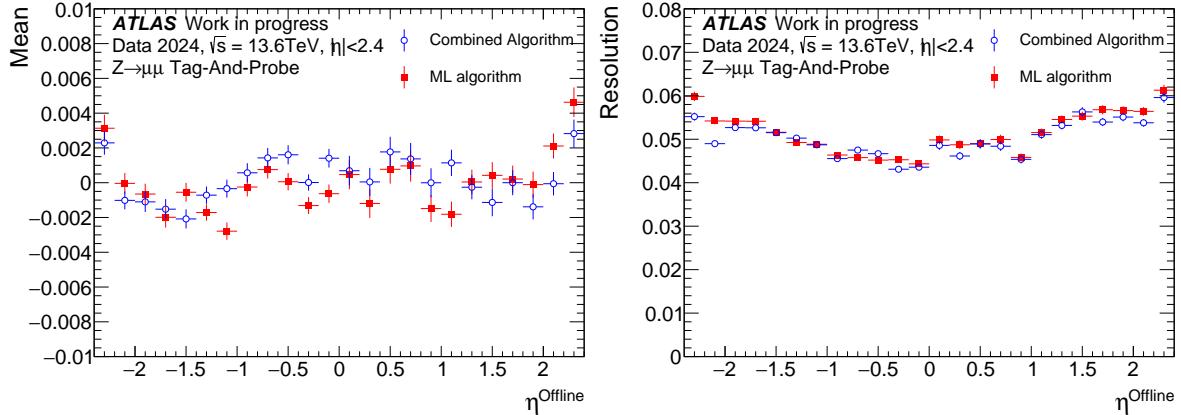
図 5.37: $20 < p_T < 30$ GeV での p_T residual の比較 (バレル領域)。

フィットした結果、分布の中心値で p_T のバイアス分解能を示す Mean や分解能を表す σ 、ガウス分布から 3σ 以上離れている量である tail は、表 5.11 のようになった。全体的な分布としては、本研究アルゴリズムがよりガウス分布に近くなっているが、 σ は現行アルゴリズムの方が小さく、 p_T 再構成の精度が良いといえる。ただし、本研究アルゴリズムではトリガーという目的に特化しており、最終的に 2 本以上の内部飛跡候補が残った場合はトリガーシステムの観点から最も高い p_T を持つ内部飛跡を選択することにしている。そのため、実際の飛跡よりも大きく見積もった事象が多く、Mean が現行のものに比べて負の方向に寄っている。実際のトリガー効率を確認すると、低い p_T を持つミューオンを識別できており、トリガーとしての性能には大きく影響しないと考えられる。また、現行アルゴリズムは本研究アルゴリズムと比較して tail が多くなっており、本研究アルゴリズムの方がよりガウス分布に近く、分布の中心から離れて見積もった数が少ないといえる。

また、Mean, σ の η 每の分布を図 5.39 に示す。まず Mean について、バレル領域では全体的に本研究アルゴリズムの Mean が現行アルゴリズムのものより小さく、 p_T を大きく見積もっていることが分かる。一方、エンドキャップ領域では全体的に現行アルゴリズムの Mean が大きくなっている。現行アルゴリズムは、バレル領域よりもエンドキャップ側で運動量を高く見積もる傾向があることが分かる。また、分解能を表す σ については、検出器の中心から離れるほど悪くなる傾向が

図 5.38: $20 < p_T < 30$ GeV での p_T resolution の比較 (エンドキャップ領域)。

あることが分かった。図 5.40 に示すのは σ の p_T 依存性である。両アルゴリズムとも p_T が高くなるにつれて、分解能が悪くなっている。

図 5.39: Mean, σ の η 每の分布。(左) が Mean, (右) が σ の分布を表す。

5.6 性能評価のまとめとトリガー導入への課題

本研究では、後段ミューオントリガーの高速再構成において、新たに機械学習を使用したトリガーアルゴリズムの開発を行った。このアルゴリズムでは外挿の過程を代わりに機械学習を導入している。また、フィットを用いて詳細な p_T を出す過程を除き、閾値以上の p_T をもつミューオンを選び出すトリガーに特化したアルゴリズムになっている。

本研究アルゴリズムは、高輝度環境下での $\langle \mu \rangle = 200$ シミュレーションサンプルにおいて、任意の閾値衣装の p_T を持つミューオンを識別できていることを示した。また、Run 3 データを用いた

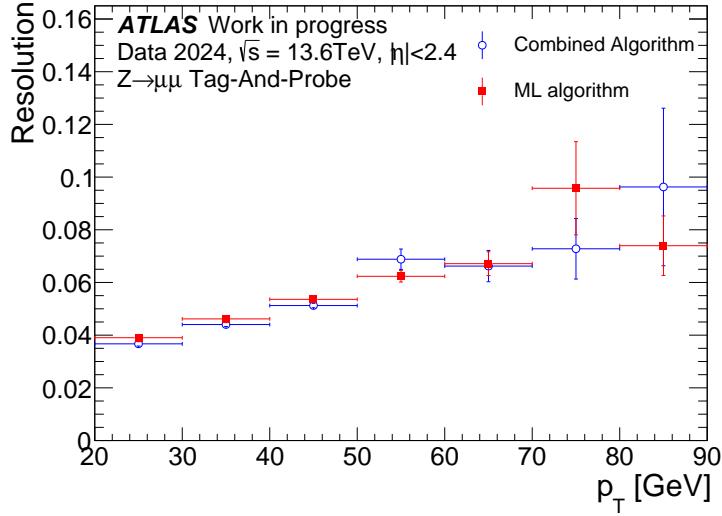


図 5.40: p_T 分解能 σ の p_T 依存性。白抜きの丸 (青) で示しているのが現行アルゴリズム、黒塗りの四角 (赤) で示しているのが本研究のアルゴリズムである。 p_T と比例して分解能も悪くなっていく。

比較においても、高輝度 LHC で使用する予定の内部飛跡検出器と Run 3 で使用している内部飛跡検出器で構造に大差がないバレル領域では、現行のアルゴリズムよりも高いプラトー効率を保ち、かつテールを削減できていることを示した。

本研究アルゴリズムを実際にトリガーに導入するためには、まずトリガーにおいて重要である処理時間を現行のものと比較する必要がある。その際、CPU だけでなく GPU や FPGA などのアクセラレータを使用した場合での処理時間や消費電力量の測定も行うことが必要である。また、isolate されたミューオンのみでなく、より近い距離にあるミューオンやハドロンが多く存在する環境下での本研究アルゴリズムの評価ならびに最適化が必要である。

また、現行アルゴリズムでは、RoI があるミドルステーションから外挿を行い、残りのステーションのセグメントを再構成する大まかな範囲を決めた後に、その範囲内で各ステーションに 1 つのセグメントを再構成・選択を行う。そのため、既存のアルゴリズムでは 1 つの RoI 内でお互いが近接しているミューオンを取得することが難しく、一つのミューオンのように処理されてしまう。しかし、ダークマター候補の一つであるダークフォトンは、標準模型のフォトンとは異なり弱い相互作用を持つ可能性があるため、ダークフォトンからブーストされた 2 つの近接したミューオン対が生成される可能性があり、このような新物理の手がかりとして近接したミューオンの事象は重要である。本研究アルゴリズムは、1 つの RoI 内に 2 つ以上セグメントがある場合でも、セグメントごとに内部飛跡の候補を選び、残りのステーション内のセグメントの選択を行う。そのため、本研究アルゴリズムをベースに改良を行った結果、近接したミューオンを取得できる可能性がある。ただし、フォトンは電荷を持たず内部飛跡検出器に飛跡を残さないため、ミューオンの崩壊点の再構成が必要などの課題もあることを言及しておく。

第6章

まとめと展望

2030年に開始予定の高輝度 LHC-ATLAS 実験では、これまでの LHC-ATLAS 実験から大幅に瞬間ルミノシティ、1バンチ交差あたりの陽子衝突数が増加する。それに伴い、背景事象や飛跡数が増加することが予想され、興味のある物理事象を選別するトリガーシステムにおいても大幅な改良が必要である。ソフトウェアトリガーにおいては、増加する背景事象を削減するためのアルゴリズムや、より複雑になった事象に対してのより効率的なアルゴリズムの開発が必要である。また、トリガーシステムでは精度だけでなく高速に事象選別のための処理や演算を行うことが重要であり、高輝度化でのイベントレートに対応するためエレクトロニクスが刷新されるほか、計算資源の増設などが予定されている。しかし、増加するイベントレートに対応するためには、現在の改良速度では必要な計算資源を補えない見込みとなっており、必要な計算機資源量の増加を抑制することが必要である。さらに、計算資源の増加に伴う消費電力量の増加も持続可能な実験を行うための課題となっている。

本研究では、以上の課題を踏まえ、新たな計算資源に対する導入可能性の評価と新たなトリガーアルゴリズムという二つの観点から、高輝度 LHC における後段トリガーの改良に向けた研究を行った。まず前者の計算資源については、近年急激に発展しているヘテロジニアスコンピューティングに着目した。GPU や FPGA は CPU と比較して並列演算に優れており、複雑な計算に対しても高速な処理を行うことができる。また、行列計算の多い機械学習と相性が良く、近年機械学習の推論を GPU や FPGA 上で行うためのツールも急速に発展している。そこで、GPU や FPGA を使用した機械学習の推論について、トリガーへ導入する際の評価を課題解決のために重要な処理速度と消費電力量に着目した評価を行った。FPGA に関して、機械学習モデルを実装するハードルが高いというデメリットはあるが、処理速度が高速でありながらも低消費電力量で推論を行えることを確認できた。また、バッチサイズが大きいほど CPU と比較した場合の GPU の推論速度が高速になるという結果が得られ、例えば同じ領域内で一斉に飛跡を再構成するなど、多くの処理を並列で実行するのに GPU が向いているといえる。一方で、GPU, FPGA ともに CPU からの転送時間の影響が大きく、トリガーシステムに導入する際には効率の良いデータ転送を行うための工夫が必要である。

新たなトリガーアルゴリズムについては、機械学習の使用に着目した。機械学習はあらかじめ学

習させておくことで、通常多くの演算が必要な処理や膨大な時間がかかる計算に対し、高速に処理できる可能性がある。本研究では特に後段ミューオントリガーに焦点を当て、機械学習を使用した新たなアルゴリズムの開発を行った。現在のアルゴリズムではミューオン検出器内の飛跡再構成や、その飛跡と内部飛跡との接続に外挿の手順を踏んでいるが、この外挿の処理は検出器における複雑な磁場に応じた計算が必要であり、処理時間、CPU消費量ともに大きい。そこで機械学習を使用してその過程を置き換えることによる再構成を試みた。これまでにはミューオン検出器と内部飛跡検出器で別々に飛跡再構成を行っていたのに対し、初めから両者の情報を使用した再構成を行うことで、早い段階から衝突点以外からのミューオンを落とすことを試みた。また、本研究のアルゴリズムはトリガーの目的に特化しており、フィットによる詳細な横運動量を演算する手順を省き、効率よく高横運動量を持つミューオンを選別することを試みた。その結果、本研究アルゴリズムを用いて、シングルミューオンのモンテカルロサンプルに高輝度環境下であるパイルアップ数200を足したシミュレーションサンプルにおいても、任意の閾値以上の横運動量を持つミューオンを識別できていることを確認した。また、2024年に取得したRun 3のデータを使用して現行のアルゴリズムとの比較を行い、Run 3と高輝度LHCでの検出器の構造やデータとシミュレーション間で大きな違いがないバレル領域では、現行アルゴリズムよりも高いトリガー効率を保ちながらも運動量分解能を改善し、閾値以下のミューオンを削減できていることを確認した。

今後の課題としては、外挿の手順を省き、代わりに機械学習を利用したことによる処理速度と消費電力量を現行のアルゴリズムと比較する必要がある。その際には、アルゴリズムをCPUだけでなく、GPUやFPGAなどのアクセラレータに実装した際にも同様の測定を行う必要がある。また、本研究で開発したアルゴリズムは、解析などで最も広く利用する内部飛跡検出器とミューオン検出器の双方に飛跡を残したミューオンを対象としている。ミューオン検出器内の飛跡も内部飛跡の情報を使用して再構成を行っているため、内部飛跡検出器に飛跡を残さなかったミューオンなど、内部飛跡の情報を使用せずにミューオンの再構成を行うようなチェーンを本研究アルゴリズムで置き換えることができない。そのため、機械学習に用いる変数を変更する、または転移学習[67]といったモデルを発展させる手法により、様々なトリガーチェインに対応したアルゴリズムの開発も必要となる。

これに加えて今後の展望としては、本研究で開発したアルゴリズムは、現在のアルゴリズムで取得することが難しいお互いが近接しているミューオン対を取得できる可能性がある。近接ミューオン対は、ダークフォトンの探索などで重要なプローブである。既存のアルゴリズムでは1つのRoIに対して1つのセグメントを再構成し、そのセグメントを中心に決定した範囲を基に各ステーションに1つのセグメントを再構成している。そしてそのセグメントを基にミューオン検出器内でのみ飛跡を再構成し、その飛跡と内部飛跡を組み合わせることでミューオンの再構成をおこなっている。そのため、もし同じRoI内で近い距離にミューオンがあった際には両方を取得することが難しいことが予想される。一方、本研究アルゴリズムでは、オフライン再構成のように全てのミューオン検出器内のヒットを使用しセグメントを再構成できれば、各ミドルステーション内のセグメントに対して、内部飛跡の情報をから他のミューオンステーションのセグメントを選択し、ミューオンをトリガーできることを示した。そのため将来、本研究のようなアルゴリズムをベースにして、近

い位置にセグメントが再構成された場合に、それぞれの内部飛跡とミドルステーションのセグメントの特徴量から双方をトリガーできる可能性がある。

本論文では、以上のように、高輝度化に向けた計算リソース量・消費電力量の削減に向けた計算機システムの評価、及び機械学習を使用した後段ミューオントリガーアルゴリズムの開発を新たにを行い、高輝度 LHC-ATLAS 実験における後段トリガー開発への新たな道を拓いた。

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。ご指導いただいた、また修士生活を支えてくださった全ての方々に感謝申し上げます。

指導教員である前田順平先生には、学部4年生の卒業研究から修士の2年間、大変お世話になりました。疑問に思うことがあるとよく質問に行っていましたが、お忙しい際にもいつも快く受け入れてくださり、実験の基礎からプログラミングのことまで大変多くのことをご教授いただきました。海外出張や様々な発表の機会も多くいただき、この修士論文に限らず、日ごろからの発表資料も何度も添削をしていただきました。また、初めて英語での発表を行う際に不安だと騒ぐ私に、発表時間の夜遅くまで一緒に大学に残ってくださったり、修士論文の提出前には差し入れとともに一緒に遅くまで残ってくださったりと、研究生活の様々な場面でも支えていただきました。前田先生のご指導は時には厳しいこともありましたが、それに必死に着いていこうとして、研究室配属当時は何も知らなかった私が多くの知識や技術を得ることができました。研究に関して学生のことは一人の研究者として対等だと思っている、とお話ししてくださったおかげで、研究に関して意見がある時には遠慮なく自分の意見を伝えることができました。1時間以上議論することがあったり、時には失礼な態度を取ったりしたこと也有ったかと思いますが、どんな時も暖かいご指導をいただいたこと、心より感謝申し上げます。

神戸ATLASグループの藏重久弥先生、山崎祐司先生、越智敦彦先生には、日ごろのミーティングにてご指導いただき、行きづまった際には的確なアドバイスをいただきました。また、藏重先生、よくみかんをくださりありがとうございました。忙しい日も、ビタミン不足にならずに済みました。

神戸大学粒子物理学研究室の、竹内康雄先生、身内賢太朗先生、鈴木州先生、東野聰先生には研究室内でのコロキウム等でご助言を頂きました。身内先生、東野先生は、普段のご飯も一緒にできて楽しかったです。研究グループが違うにも関わらず、時折飲みにも誘っていただきありがとうございました。研究部屋での何気ない会話も息抜きになり楽しかったです。

ATLAS Japanグループの皆様には大変お世話になりました。長野邦浩先生、山口洋平先生、清水志真先生には、日ごろのミーティングで助言やコメントをいただき、研究を前進させることができました。また、中浜優先生、長野先生、2度のCERN出張ならびに国際会議での発表の貴重な機会をいただきありがとうございました。CERN出張中には、先生方、先輩方、同期の皆さんに生活面でも研究面でも大変助けられました。海外生活は不安なことも多かったですが、皆様のおかげ

で本当に楽しく過ごすことができました。ありがとうございました。

I would like to express my sincere gratitude to Faouzia, Teri, Carolina, Lida, Latifa, thank you so much for everything you've done for me during my stay at CERN. I truly enjoyed staying with all of you and got precious memories.

研究室同期の水引龍吾くん、生井凌太くん、西将汰くん、樋口流雲くん、鈴木大夢くん、研究は楽しいことばかりではありませんでしたが、皆さんとする他愛ない会話に助けられていました。特に水引くん、生井くんは同部屋ということもあり、コンビニにもよく一緒に行ってくれてありがとうございます。水引くん、よく大学にいて、同じ ATLAS グループということで心強かったです。ドクターに進学して海外生活になんでもダジャレを続けて下さい。DM 部屋の前のスペースのダジャレの更新を楽しみにしています。生井くん、いつも騒がしく話しかけてすみません。私がつけたあだ名が研究室中に広まってしまいましたが、もっと仲良くなろうとそのあだ名をつけたときよりもずいぶんと仲良くなれて嬉しいです。ドクターでも頑張ってね。西くん、卒業研究の時からお世話になりました。研究の邪魔をしてくる時がありましたが良い息抜きの時もありました。アルバイトも紹介してくれてありがとうございます。これからも筑波で頑張ってください。樋口くん、会う機会は少なかったけれど、良い音楽とかを教えてくれてありがとうございます。同期で唯一社会人になるとすることで、お互い頑張りましょう。鈴木くん、修論の執筆時期からもっと仲良くなれた気がします。提出前日の深夜に食べた味噌汁おいしかったね。末端冷え性が良くなりますように。

ATLAS 神戸グループ後輩の張力くん、佐倉慶汰くん、佐野友麻くん、山口凜太郎くん、浅見優輝くん、笹田真宏くん、田中亮祐くん、毎週のミーティングの発表で、私の研究範囲外の ATLAS の知識をつけることができて勉強になりました。あまり先輩らしいことはできませんでしたが、楽しく会話してくれてありがとうございました。皆さんの研究がうまくいくように願っています。

粒子物理学研究室の 1 つ下の後輩である和田伸一郎くん、曾根貴将くん、谷口紘大くん、鈴木啓司くん、同じく先輩らしいことは何もできませんでしたが、時折話しかけてくれて、研究グループは違えど飲みや出張先で一緒にご飯に行けて嬉しかったです。これからも頑張ってください。また 2 つ下の後輩である青山真也くん、稻葉有哉くん、猪上竣くん、門田佳吾くん、河野朱慧くん、神吉陽介くん、遠山和佳子さん、西上真央さん、西田汐里さん、野村脩貴くん、番原大登くん、柳凜くん、山内康輝くん、部屋が違うのでたくさんは話せなかったけれど、院生部屋に行った時は話してくれてありがとうございました。遅くまで残って卒業研究を頑張っていて、いつもすごいなと思っていました。これからも頑張ってください。

最後に、突然理系に行くと言いくてから今日まで、家族には色々と心配をかけたと思います。大学院進学も快く受け入れてくれ、いつでも私のやりたいことを何も言わずに応援し、支えてくれた家族に感謝の意を表して、謝辞とします。

参考文献

- [1] ATLAS Open Data, The Standard Model of Particle Physics and Beyond, https://opendata.atlas.cern/docs/documentation/introduction/SM_and_beyond/, Accessed on 28/1/2025.
- [2] ATLAS Collaboration, The ATLAS experiment at the CERN large hadron collider, JINST, vol.3, S08003, 2008.
- [3] CMS Collabpration, The CMS experiment at the CERN LHC, JINST, vol.3, S08004, 2008.
- [4] J. Alonso-Gonzalez, A. de Giorgi, L. Merlo, S. Pokorski, Searching for BSM physics in Yukawa couplings and flavour symmetries, FTUAM-21-3, IFT-UAM/CSIC-21-94, 2021.
- [5] ATLAS Collaboration, A detailed map of Higgs boson interactions by the ATLAS experiment ten years after the discovery, Nature, vol.607, pp.52–59, 2022.
- [6] ATLAS Collaboration, Search for di-Higgs production with the ATLAS detector, ATL-PHYS-PROC-2017-170, 2018.
- [7] M. Francis, A sort of particle-free supersymmetry found in exotic materials <https://arstechnica.com/science/2014/04/a-sort-of-particle-free-supersymmetry-found-in-exotic-materials/>, Accessed on 29/1/2025.
- [8] D. Manuel, H. Fazlollah, Neutralino Dark Matter in Scenarios with Early Matter Domination <https://arstechnica.com/science/2014/04/a-sort-of-particle-free-supersymmetry-found-in-exotic-materials/>, JHEP, vol.2018, pp.1–28, 2018.
- [9] ALICE Collabpration, The ALICE experiment at the CERN LHC, <https://alice-collaboration.web.cern.ch/>, JINST, vol.3, S08002, 2008.
- [10] CERN, The LHCb detector at the LHC JINST, vol.3, S0800, 2008.
- [11] E. Lopienska, The CERN accelerator complex layout in 2022, <https://cds.cern.ch/record/2800984>, 2022.
- [12] ATLAS Collaboration, The ATLAS experiment at the CERN Large Hadron Collider: a description of the detector configuration for Run 3, CERN-GRAPHICS-2022-001.

- [13] CERN, High Luminosity LHC Project,
<https://hilumilhc.web.cern.ch/content/hl-lhc-project>, Accessed on 9/12/2024.
- [14] ATLAS Collaboration, ATLAS Magnetic Field
<http://atlas.web.cern.ch/Atlas/GROUPS/MUON/magfield/>.
- [15] Y. Takubo, ATLAS IBL operational experience, ATL-INDET-PROC-2016-012, 2017.
- [16] ATLAS Collaboration, Expected tracking and related performance with the updated ATLAS Inner Tracker layout at the High-Luminosity LHC, ATL-PHYS-PUB-2021-024. 2021.
- [17] ATLAS Collaboration, Standalone Vertex Finding in the ATLAS Muon Spectrometer, CERN-PH-EP-2013-185, 2014.
- [18] ATLAS Collaboration, The ATLAS New Small Wheel new Muon Stations Ready for LHC Run3, ATL-MUON-PROC-2022-003, 2023.
- [19] ATLAS Collaboration, New Small Wheel Technical Design Report, CERN-LHCC-2013-006, ATLAS-TDR-020, 2013.
- [20] ATLAS Collaboration, Certification of a new generation of Resistive Plate Chambers for the Phase-I BIS78 upgrade of the ATLAS Muon Spectrometer, ATL-MUON-PROC-2021-002, 2022.
- [21] ATLAS Collaboration, The ATLAS Trigger System for LHC Run 3 and Trigger performance in 2022, CERN-EP-2023-299, 2024.
- [22] ATLAS Collaboration, Trigger menu in 2018 ATL-DAQ-PUB-2019-001, 2019.
- [23] 塩見 崇宏, LHC-ATLAS 実験における第三期運転に向けた初段ミューオントリガーアルゴリズムの開発, 神戸大学 修士学位論文, 2021.
- [24] 赤塚 駿一, LHC-ATLAS 実験 Run-3 に向けたミューオントリガーの改良, 京都大学 修士学位論文, 2017.
- [25] M. Aoki, J. Maeda, Y. Hayashi, T. Saito, Y. Okumura, L1Muon public plots for ICHEP2022, ATL-COM-DAQ-2022-049, 2022.
- [26] ATLAS Collaboration, A muon trigger algorithm for Level-2 feature extraction, ATL-DAQ-2000-036, 2000.
- [27] R. E. Kalman, A New Approach to Linear Filtering and Prediction Problems, Transactions of the ASME-Journal of Basic Engineering, v.82, pp.35–45, 1960.
- [28] ATLAS Collaboration, Muon identification and performance in the ATLAS experiment, ATL-PHYS-SLIDE-2019-457, 2019.
- [29] J. Illingworth, J. Kittler, A survey of the Hough transform, Computer vision, graphics, and image processing, vol.44, pp.87–116, 1988.
- [30] ATLAS Collaboration, Technical Design Report for the Phase-II Upgrade of the ATLAS TDAQ System, CERN-LHCC-2017-020, ATLAS-TDR-029, 2017.
- [31] ATLAS Collaboration, Technical Design Report for the Phase-II Upgrade of the ATLAS

- Trigger and Data Acquisition System-Event Filter Tracking Amendment, CERN-LHCC-2022-004, ATLAS-TDR-029-ADD-1, 2022.
- [32] ATLAS collaboration, ATLAS Software and Computing HL-LHC Roadmap, CERN-LHCC-2022-005, LHCC-G-182, 2022.
- [33] ATLAS Collaboration, ATLAS EXPERIMENT - PUBLIC RESULTS - Computing and Software - Public Results, <https://twiki.cern.ch/twiki/bin/view/AtlasPublic/ComputingandSoftwarePublicResults>.
- [34] CERN, Powering CERN <https://www.home.cern/science/engineering/powering-cern>.
- [35] ATLAS Collaboration, The ATLAS trigger system for LHC Run 3 and trigger performance in 2022, JINST, vol.19, P06029, 2024.
- [36] traccc development team, CTD2022: traccc-GPU Track reconstruction demonstrator for HEP, https://indico.cern.ch/event/1184037/contributions/5053634/attachments/2516667/4326919/introducing_traccc_sept_2022_v3.pdf.
- [37] A. Lazar et al., Accelerating the inference of the Exa. TrkX pipeline, Journal of Physics: Conference Series, v.2438, P012008, 2023.
- [38] P. Purwono, A. Ma’arif, W. Rahmani, H.I.K. Fathurrahman, A.Z.K. Frisky, Q.M. ul Haq, Understanding of Convolutional Neural Network (CNN): A Review, International Journal of Robotics and Control Systems, vol.4, pp.739–748, 2022.
- [39] PyTorch project team, RMSprop, <https://pytorch.org/docs/stable/generated/torch.optim.RMSprop.html#rmsprop>, Accessed on 26/1/2025.
- [40] J. Lin, C. Song, K. He, L. Wang, J. Hopcroft, Nesterov accelerated gradient and scale invariance for adversarial attacks, arXiv preprint arXiv:1908.06281, 2019.
- [41] T. Akiba, S. Sano, T. Yanase, T. Ohta, M. Koyama, Optuna: A Next-generation Hyperparameter Optimization Framework, 2019.
- [42] Intel Co. Ltd, Intel HLS Compiler, <https://www.intel.co.jp/content/www/jp/ja/software/programmable/quartus-prime/hls-compiler.html>, Accessed on 3/2/2024.
- [43] J. Duarte et al., Fast inference of deep neural networks in FPGAs for particle physics, JINST, vol.13, P07027, 2018.
- [44] Y. Umuroglu, N.J. Fraser, G. Gambardella, M. Blott, P. Leong, M. Jahre, K. Vissers, Finn: A framework for fast, scalable binarized neural network inference, Proceedings of the 2017 ACM/SIGDA international symposium on field-programmable gate arrays, pp.65–74, 2017.
- [45] Intel Co. Ltd, Intel Core i9-13900K Processor,

- <https://www.intel.co.jp/content/www/jp/ja/products/sku/230496/intel-core-i913900k-processor-36m-cache-up-to-5-80-ghz/specifications.html>, Accessed on 23/1/2025.
- [46] Intel Co. Ltd, Intel Core Corei9-10920X Processor,
<https://www.intel.com/content/www/us/en/products/sku/198012/intel-core-i910920x-xseries-processor-19-25m-cache-3-50-ghz/specifications.html>, Accessed on 23/1/2025.
- [47] NVIDIA Corporation, uNMAtCheD PoWer. uNMAtCheD CreAtIVe FreeDoM.NVIDIA QUADRO P400, <https://www.nvidia.com/content/dam/en-zz/Solutions/design-visualization/productspage/quadro/quadro-desktop/quadro-pascal-p400-data-sheet-us-nv-704503-r1.pdf>, Accessed on 23/1/2025.
- [48] 株式会社 エルザ・ジャパン, NVIDIA Quadro P400
<https://www.elsa-jp.co.jp/products/detail/quadro-p400/>, Accessed on 20/11/2024.
- [49] Advanced Micro Devices, AMD Alveo U200 Data Center Accelerator Card (Active),
<https://www.amd.com/ja/products/accelerators/alveo/u200/a-u200-a64g-pq-g.html>, Accessed on 20/11/2024.
- [50] L. Deng, The mnist database of handwritten digit images for machine learning research [best of the web], IEEE signal processing magazine, vol.19, pp.144–142, 2012.
- [51] PyTorch project team, PyTorch documentation,
<https://pytorch.org/docs/stable/index.html>, Accessed on 5/12/2024.
- [52] PyTorch project team, PyTorch C++ API, <https://pytorch.org/cppdocs/>, Accessed on 5/12/2024.
- [53] Advanced Micro Devices, Vitis-AI instruction, <https://docs.amd.com/r/3.0-日本語/ug1414-vitis-ai/Versal-AI-コア-シリーズ-DPUCVDX8G>, Accessed on 20/11/2024.
- [54] Advanced Micro Devices, PG400 - DPUCADF8H for Convolutional Neural Networks Product Guide (PG400) (v1.0), <https://docs.amd.com/r/en-US/pg400-dpucadf8h>. Accessed on 25/1/2025.
- [55] Advanced Micro Devices, Vitis AI -Adaptable Real-Time AI Inference Acceleration, https://github.com/Xilinx/Vitis-AI/tree/master/src/vai_runtime/xir.
- [56] RATOC Systems Inc, Bluetooth ワットチェック RS-BTWATTCH2
<https://www.ratocsystems.com/products/sensor/watt/rsbtwattch2/>, Accessed on 11/10/2024.
- [57] P. Losel, R. Muller, Design and Construction of Large Size Micromegas Chambers for the Upgrade of the ATLAS Muon Spectrometer, arXiv:1508.02541, 2015.
- [58] S. Agostinelli et al., A Simulation Toolkit, Nucl. Instrum. Meth. A, vol.506, pp.250–303,

- 2003.
- [59] ATLAS software group, ATLAS Athena documentation,
<https://atlassoftwaredocs.web.cern.ch/athena/>.
 - [60] S. Tarem, Z. Tarem, N. Panikashvili, O. Belkind, MuGirl–Muon identification in the ATLAS detector from the inside out, 2006 IEEE Nuclear Science Symposium Conference Record, vol.1, pp.617–621, 2006.
 - [61] A. Sadiji et al., Explainable Artificial Intelligence (XAI): What we know and what is left to attain Trustworthy Artificial Intelligence, *Information Fusion*, 2023.
 - [62] SHAP project team, SHAP documentation,
<https://shap.readthedocs.io/en/latest/>, Accessed on 09/12/2024.
 - [63] ONNX developers, ONNX, <https://onnx.ai>.
 - [64] ONNX Runtime developers, ONNX Runtime, <https://onnxruntime.ai/>.
 - [65] 山下 智愛, LHC-ATLAS 実験 Run-3 における新ミューオントリガーアルゴリズムの動作検証と改良, 神戸大学 修士学位論文, 2023.
 - [66] ATLAS Collaboration, Micromegas trigger simulation plots,
<https://atlas.web.cern.ch/Atlas/GROUPS/MUON/PLOTS/MDET-2022-07/>.
 - [67] S.J. Pan, Q. Yang, A survey on transfer learning, *IEEE Transactions on knowledge and data engineering*, vol.22, pp.1345–1359, 2009.