修士学位論文

LHC-ATLAS 実験 Run-3 における 初段ミューオントリガーの機械学習を用いた最適化

令和5年2月3日

專 攻 名 物理学専攻

学籍番号 211S114S

氏 名 中村 竜也

神戸大学大学院理学研究科博士課程前期課程

概要

Large Hadron Collider (LHC) は、欧州原子核研究機構 (CERN) に建設された世界最高エネル ギーの陽子陽子衝突型加速器である。ATLAS 検出器は、LHC の衝突点の1つに設置された大型 汎用検出器であり、TeV エネルギー領域の陽子衝突で生成される粒子を測定することで、新粒子 の直接探索やヒッグス粒子の精密測定を行い、素粒子標準模型を超えた新物理の発見を目指して いる。

LHC における陽子陽子衝突は高頻度であるため、すべての衝突事象を記録することはできない。 そのためトリガーシステムを使用し、物理として興味のある事象のみを選別し保存している。LHC 及び ATLAS 検出器は 2019 年から 2022 年までの期間にアップグレードが行われ、2022 年 7 月か ら重心系エネルギー 13.6 TeV での第三期運転 (Run-3) として実験が行われている。

ルミノシティの増加に伴って事象数も増加するため、物理事象の選別を行うトリガーシステムの 改良が必要不可欠である。トリガーシステムの中でも初段トリガーに分類されるエンドキャプ部 の初段ミューオントリガーは、Thin-Gap Chambers (TGC) というミューオン検出器を用いて横 方向運動量を指針としたトリガー判定を行っている。このとき、ミューオンの飛跡の曲がり具合と 横方向運動量の対応を関連づけた Coincidence Window (CW) と呼ばれる参照表を用いることで、 短時間で飛跡情報からミューオンの横方向運動量を算出している。

初段ミューオントリガーのトリガー性能の改善に向けて、CW を Run-3 に対応したものに作り 直す必要がある。CW はシミュレーションデータから作成しているため、実際の検出器のズレや 歪みが考慮されておらず、そのまま実際の測定に使用するとトリガー性能が低下してしまう。そこ で、検出器のズレや歪みに対する補正を行うことで CW を最適化し、トリガー性能を向上させる 手法が先行研究によって確立されてきた。しかし、従来の手法では CW の作成の手間の多さや手 動で行う最適化の作業量が膨大であることが問題となり、従来の手法に代わる効率的な CW の作 成及び最適化手法が求められた。そこで、機械学習を用いて効率的に CW を作成し最適化を行う 手法の開発を行う。

本研究では、実際の実験データを機械学習のトレーニングに使用することで、自動的に検出器の ズレや歪みに対する補正を行うことのできる手法の開発を行い、CW 作成の効率化を図った。ま た、作成した CW を用いた際のトリガー性能について、従来の手法で作成した CW と比較を行い、 本研究の手法によってトリガー性能を向上させることが可能であることを示した。本発表では、開 発した CW の作成手法と、作成した CW のトリガー性能の評価について述べる。

目次

第1章	序論	1			
第2章	章 LHC-ATLAS 実験				
2.1	LHC 加速器	3			
2.2	LHC-ATLAS 実験	5			
	2.2.1 ATLAS 検出器における座標系	5			
	2.2.2 マグネットシステム	7			
	2.2.3 内部飛跡検出器	8			
	2.2.4 カロリメータ	9			
	2.2.5 ミューオン検出器	11			
2.3	ATLAS トリガーシステム	18			
	2.3.1 トリガーメニュー	21			
第3章	初段ミューオントリガーシステム	23			
3.1	エンドキャプ部初段ミューオントリガー.................	23			
	3.1.1 トリガーアルゴリズムの概要	23			
	3.1.2 初段ミューオントリガーにおけるエレクトロニクス	27			
3.2	従来の CW の作成及び最適化手法	32			
	3.2.1 従来の CW の作成方法	32			
	3.2.2 CW の最適化手法	33			
3.3	本研究の目的	35			
第4章	機械学習を用いた Coincidence Window の作成手法	36			
4.1	機械学習	36			
	4.1.1 ニューラルネットワーク	37			
4.2	機械学習を用いた CW 作成手法	40			
	4.2.1 入力データに対する事前処理	41			
	4.2.2 機械学習モデルの設計方法とトレーニング	45			
	4.2.3 出力データを <i>p</i> _T 閾値に変換	50			

第5章	初段ミューオントリガーの性能評価		
5.1	機械学習を用いて作成した CW の 15 段階閾値の評価		
	5.1.1 作成した CW の 15 段階の p_{T} 閾値	57	
	5.1.2 CW の最適化の効果	58	
	5.1.3 現行のトリガーとのトリガー性能の比較	60	
	5.1.4 トリガーレートの評価	66	
5.2	性能評価のまとめ	69	
第6章	結論と展望	70	
謝辞		72	
参考文献		74	

第1章

序論

我々の身の回りにある物質を構成する最小単位は素粒子である。物質の最小単位である素粒子 と、素粒子の相互作用を記述した理論として、標準模型が存在している。素粒子物理学において、 自然界には電磁相互作用、強い相互作用、弱い相互作用、重力相互作用といった4種類の基本相互 作用が存在すると考えられており、標準模型では重力相互作用以外の3種類の相互作用が記述され ている。標準模型は図 1.1 に示すように、12種類のフェルミオン、4種類のゲージボソン、ヒッグ ス粒子の計 17種類の粒子から構成されており、唯一実験的に未確認であったヒッグス粒子も 2012 年に発見された [1]。

現在、標準模型は多くの物理事象を説明することができているが、暗黒物質の存在やヒッグス粒 子の質量階層性問題などの多くの未解決問題が残されている。この問題を解決するためには、標準



図 1.1: 標準模型を構成する 17 種類の素粒子 [2]。

模型を超える新しい物理が必要であり、この新物理を探索するためのアプローチとして世界中で 様々な実験が行われている。

新物理探索の実験の一つとして、ジュネーブ郊外に位置する欧州原子核研究機構 (CERN) [3] の 地下に設置された Large Hadron Collider (LHC) [4] を用いる高エネルギーの陽子陽子衝突実験が ある。この LHC を使った衝突実験の 1 つである ATLAS 実験 [5] では、ATLAS 検出器と呼ばれ る大型汎用検出器を用いて高エネルギーの陽子衝突から粒子の測定を行い、TeV スケールまでの 新粒子探索や素粒子の精密測定などの探索を行っている。

LHC ではバンチと呼ばれる約 10¹¹ 個の陽子の塊を単位として陽子を加速させている。LHC で 行われている陽子陽子衝突実験において、このバンチ衝突の頻度は 40 MHz の高頻度のため、計算 機リソースやデータ記憶容量など制限から全ての衝突事象を保存することができない。そのため、 トリガーシステムと呼ばれる事象選別のアルゴリズムを用いることで、膨大な量の衝突事象から物 理として興味のある事象を選別し、保存可能なデータ量まで事象数を減らしてから保存している。

ATLAS 検出器では大きく分けて 2 段階のトリガーシステムを実装している。1 段目にはハード ウェアベースの高速処理が可能な初段 (L1) トリガーがあり、測定したデータに対して一番初めに トリガー判定を行い、100 kHz 以下まで事象数を落とす。2 段目にはソフトウェアベースで詳細な 解析が可能な後段トリガーがあり、L1 トリガーで選別した事象に対して厳密なトリガー判定を行 うことで、さらに数 kHz まで事象数を落とす。

LHC 及び ATLAS 検出器は 2018 年から 2022 年までの期間にアップグレードが行われ、2022 年7月から第三期運転 (Run-3) が再開された。Run-3 では陽子陽子衝突の重心系エネルギーの増 強や高いルミノシティでの安定した運転に伴い、事象頻度がさらに増加する。したがって、限られ たデータ容量の中で物理事象を最大限の効率で取得するために、初段トリガーにおいてもトリガー システムの改良を行い、トリガー効率を向上させる必要がある [6]。

ミューオンは陽子陽子衝突実験において様々な物理事象のサインとして重宝されており、ATLAS 実験のトリガーシステムの中にもミューオンを用いたトリガーが実装されている。例えば、ヒッグ ス粒子の崩壊先である Z ボソンや W ボソンの終状態として高い運動量のミューオンが観測されや すいことや、ボトムクォークやチャームクォークが含まれる粒子の終状態には運動量が低いミュー オンが含まれている。そのため、ミューオンを用いたトリガーは重要な役割を担っている。本研究 では、この初段トリガーの中でもミューオンの運動量を指針として事象選別を行う初段ミューオン トリガーに着目する。

本論文ではミューオンをターゲットにして事象選別を行う初段ミューオントリガーを改良し、 トリガー性能の評価を行う。第2章でLHC-ATLAS実験のの概要について述べ、第3章で初段 ミューオントリガーシステムについて述べる。第4章で本研究の主題である機械学習を用いた Coincidence Window (CW)の作成手法の詳細について説明し、第5章で作成した CW を用いた 際のトリガー性能の評価について述べた後、第6章で本研究の成果をまとめ、今後の展望について 述べる。

 $\mathbf{2}$

第2章

LHC-ATLAS 実験

LHC-ATLAS 実験とは、Large Hadron Collider (LHC) [4] を用いた高エネルギーの陽子陽子衝 突によって生成された粒子を ATLAS (A Troidal LHC ApparatuS) 検出器によって検出し、標準 模型の精密測定や新粒子探索などを行う実験である [5]。LHC は 2018 年に第 2 期運転 (Run-2) を 終了し、2019 年から 2021 年にかけて LHC 及び ATLAS 検出器のアップグレードが行われ、2022 年 7 月からは Run-3 として運転を再開している。

本章では、Run-3 における LHC 及び ATLAS 検出器の概要と ATLAS 実験で採用されているト リガーシステムについて述べる。

2.1 LHC 加速器

Large Hadron Collider (LHC) は、スイスのジュネーブ郊外にある欧州素粒子原子核研究機 構 (CERN) [3] の地下に建設された、周長約 27 km の世界最大の大型ハドロン衝突型加速器 である。LHC の全体像を図 2.1 に示す。LHC は重心系エネルギー 14 TeV、瞬間ルミノシティ 1.0 × 10³⁴ cm⁻²s⁻¹ で陽子陽子衝突が可能なように設計されている。ここで、ルミノシティとは 衝突型加速器における粒子同士の衝突頻度を表している。瞬間ルミノシティが毎秒あたりの衝突頻 度、時間で積分したものが積分ルミノシティと定義され、観測されるデータ量はこの積分ルミノシ ティに比例する。

LHC は陽子ビームが反対方向に周回するための 2 つのリングから構成されており、4 か所あ る衝突点にそれぞれ検出器が設置されている。その衝突点の一つに ATLAS 検出器が設置され、 陽子陽子衝突から生成される粒子を検出する。他 3 か所にも検出器が設置されており、それぞれ CMS (Compact Muon Solenoid) [7]、LHCb (Large Hadron Collider b) [8]、ALICE (A Large Ion Collider Experiment) [9] である。ATLAS と CMS の 2 つの検出器は、標準模型の検証から 標準模型を超える現象の探索まで可能な汎用検出器である。LHCb と呼ばれる検出器は、B-ハド ロン系の物理を研究するために設計されたものである。最後の ALICE は、QCD 現象を探るため に重イオン衝突の研究に最適化された検出器である。

図 2.2 に LHC 加速器の運転計画を示す。LHC は 2010 年から本格的に実験を開始し、2010 年



図 2.1: LHC 加速器の全体図 [10]。地下 100m に設置された LHC の 4 つの衝突点に ATLAS、 CMS、ALICE、LHCb などの検出器が配置されている。

から 2012 年にかけて行われた運転を Run-1、2015 年から 2018 年にかけて行われた運転を Run-2 と呼ぶ。Run-1 では重心系エネルギー 7-8 TeV、瞬間最高ルミノシティ 0.77 × 10^{34} cm⁻²s⁻¹ で の運転を行い、Run-2 では重心系エネルギー 13 TeV、瞬間最高ルミノシティ 2.0 × 10^{34} cm⁻²s⁻¹ での運転を行った。2019 年から 2022 年初旬までの Long Shutdown 2 (LS2) の期間に加速器の アップグレードが行われ、2022 年 7 月から 2025 年にかけて行われる Run-3 では陽子陽子衝突の 重心系エネルギーを 13.6 TeV、瞬間ルミノシティ 2.0× 10^{34} cm⁻²s⁻¹ での運転を行い、Run-2 で 取得したデータと合わせて積分ルミノシティ 350 fb⁻¹ のデータを取得する予定である。さらにそ の後、アップグレードを経て 2029 年からはより高いルミノシティでの高輝度 LHC-ATLAS 実験 (HL-LHC) の運転が予定されている。

LHC では陽子同士を衝突させるまでに、いくつかの前段加速器を使用して TeV スケールの エネルギーまで陽子を加速している。図 2.3 に概略図を示す。初めに負水素イオン (H⁻、水 素原子に電子を加えたもの)を線形加速器である LINAC4 [13] で 160 MeV まで加速する。次 に、強い電場をかけることで負水素イオンから 2 個の電子を剥ぎ取り、陽子だけの状態にする。 そして、Proton Synchrotron Booster (PSB) [14] に陽子を入射し 1.4 GeV まで加速した後、 Proton Synchrotron (PS) [15] で陽子を 26 GeV まで加速し、40 MHz のバンチ構造を持った陽子



図 2.2: LHC 加速器の運転とアップグレード計画 [11]。LHC では 2019 年から 2022 年初旬までの 間に Phase-1 Upgrade が行われ、現在は Run-3 として運転を再開している。

ビームを形成する。その後、Super Proton Synchrotron (SPS) [16] で 450 GeV まで加速した後、 陽子ビームは LHC に入射され最大で 7 TeV まで加速される。陽子ビームは 25 ns のバンチ間隔 で入射されているため、陽子陽子衝突を起こす際の各バンチの衝突頻度は 40 MHz となっている。

2.2 LHC-ATLAS 実験

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 [5]。ATLAS 検出器の全体像を図 2.4 に示す。ATLAS 検出器は複数の検出器 を組み合わせて構成されており、内側から内部飛跡検出器、カロリメータ、ミューオン検出器と いった検出器が設置されている。また、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いる。これらの検出器から得ら れる情報を組み合わせることで、粒子識別や粒子のエネルギーなどの測定を行っている。

2.2.1 ATLAS 検出器における座標系

ATLAS 実験では図 2.5 に示すような直行座標系と円筒座標系が使用されている。直行座標系で は、検出器の中心を原点として、ビーム軸に沿って *z* 軸を取る。ビーム軸に垂直な平面を *x* – *y* 平 面としたときに、加速器の中心方向を正とする *x* 軸及び、地面に対して垂直方向上向きを正とする



図 2.3: CERN に設置されている加速器群 [12]。

y軸を設定する。円筒座標系では、ビーム軸に沿ったz軸に対し、動径方向をR、ビーム軸周りの 角度を方位角 ϕ 、ビーム軸からの角度を極角 θ としている。

また、ATLAS 実験で使用される座標系として、

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

と定義される擬ラピディティ η が用いられる。ATLAS 検出器は円筒形をしており、 $|\eta| < 1.0$ の側面部分をバレル領域、 $|\eta| > 1.0$ の底面部分をエンドキャップ領域と呼ぶ。



図 2.4: ATLAS 検出器の全体図 [5]。直径 25 m、長さ 44 m の円筒型をしており、内部飛跡検出 器、カロリーメータ、ミューオン検出器などの検出器を組み合わせて粒子の測定を行っている。



図 2.5: ATLAS 検出器における座標系。

2.2.2 マグネットシステム

ATLAS 実験では、荷電粒子の運動量測定のために超伝導磁石を用いて磁場をかけている。超伝 導磁石は2種類あり、衝突点付近で発生した荷電粒子の運動量測定のために用いられるソレノイ



図 2.6: ATLAS 検出器で用いられる超伝導磁石の配置 [5]。

ド磁石とミューオンの運動量測定のために用いられるトロイド磁石が設置されている。図 2.6 に ATLAS 検出器に設置されている超伝導磁石の配置を示す。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、この電磁石が作り出す磁場によって荷電粒子を曲げ、内部飛跡 検出器でその曲率を測定することによって横方向運動量を測定する。トロイド磁石はバレル部とエ ンドキャップ部に分けられ、それぞれ ϕ 方向に 8 つずつ等間隔で配置されてる。そのため、8 回転 対象の磁場構造を生み出しており、この磁場構造を考慮した上で様々な検出器が設置されている。 トロイド磁石によって生じる磁場の η 分布を図 2.7a に、x - y 平面での磁場の分布を図 2.7b に 示す。

2.2.3 内部飛跡検出器

内部飛跡検出器はビーム衝突点に最も近い位置に設置され、衝突点で発生した荷電粒子の飛跡を 測定する。内部飛跡検出器は内側からピクセル検出器 (Pixel)、Semiconductor Tracker (SCT)、 Transition Radiation Tracker (TRT) で構成されている。図 2.8 に内部飛跡検出器の概略図を 示す。

Pixel は最内層に設置された $|\eta| < 2.5$ の領域をカバーする半導体検出器であり、バレル部では 同心円状に 4 層、エンドキャップ部ではディスク状のものが 3 層設置されている。位置分解能は バレル部で $R - \phi$ 平面で 10 μ m、z 軸方向で 115 μ m、エンドキャップ部においては $R - \phi$ 平面 で 10 μ m、R 方向で 115 μ m であり、高い位置分解能を持つ [5]。SCT は Pixel の外側に位置さ れており $|\eta| < 2.5$ の領域をカバーしている。マイクロストリップと呼ばれる細長い有感領域をシ リコン上に施した半導体検出器であり、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。位置分解能はバ レル部で $R - \phi$ 平面で 17 μ m、z 軸方向で 580 μ m、エンドキャップ部においては $R - \phi$ 平面で





(a) トロイド磁石による磁場の η 分布 [5]。

(b) ビーム軸から見た x - y 平面での磁場の分布 [17]。

図 2.7: トロイド磁石の磁場の分布。設置位置の影響により磁場構造が一様ではない。

17 μm、*R* 方向で 580 μm である [5]。TRT は内部飛跡検出器の最外層に位置する検出器であり、 飛跡のトラッキングのほかに遷移輻射を利用した電子の同定も行っている。直径 4 mm のドリフ トチューブをバレル部では 73 層、エンドキャップ部では 160 層に積み重ねることで構成されてい る。ドリフトチューブはバレル部ではビーム軸方向に、エンドキャップ部では放射状に並べられて いる。 1 つのドリフトチューブの位置分解能は *R* – φ 平面で 130 μm である。

また、横方向運動量に対する分解能は式 (2.2) で表される [5]。

$$\frac{\sigma_{p_T}}{p_T} = 0.05\% \times p_T \oplus 1\% \tag{2.2}$$

第1項は電子数をエネルギーに換算する際の統計的な揺らぎにの項であり、第2項はエネルギー較 正の精度や温度の揺らぎによる項である。

2.2.4 カロリメータ

カロリメータは内部飛跡検出器の外側に設置されており、内側から電磁カロリメータ、ハドロン カロリメータの順に配置されている。電磁カロリメータは電磁シャワーを用いて電子と光子のエネ ルギーや位置を測定し、ハドロンカロリメータは強い相互作用によるハドロンシャワーを用いてハ ドロンのエネルギーやそれを組み合わせたジェットのエネルギーを測定する。図 2.9 に ATLAS 検 出器で用いられるカロリメータの概略図を示す。

電磁カロリメータ

電磁カロリメータでは、電磁相互作用をする粒子である電子及び光子の同定、それらのエネル ギーを精密に測定する。ATLAS 検出器には、|η| < 1.5 にバレル部をカバーするバレルカロリメー



(a)

(b)

図 2.8: 内部飛跡検出器の全体像及び断面図。(a): 全体像 [5]、(b): バレル部の断面図 [18]。内側か ら順に Pixel, SCT, TRT 検出器が設置されている。

タ、1.4 < |η| < 3.4 の両側のエンドキャップ部をカバーするエンドキャプカロリメータが設置され ている。バレル部とエンドキャプ部ともに、吸収層の鉛と検出層の液体アルゴンで構成されたカロ リメータであり、電磁相互作用を起こす光子や電子のエネルギーと位置を測定する役割を担って いる。

また、エネルギー分解能 σ_E は式 (2.3) のように表される [5]。

$$\frac{\sigma_E}{E} = \frac{10\%}{\sqrt{E}} \oplus 0.7\% \tag{2.3}$$

ハドロンカロリメータ

ハドロンカロリメータは電磁カロリメータの外側に設置されており、タイルカロリーメータ、エ ンドキャップカロリーメータ、フォワードカロリーメータの3つに分類され、それぞれ異なる η の 範囲をカバーする。バレル部では、鉄の吸収体とタイル状のシンチレータから構成されたタイルカ ロリメータが設置されている。 $1.5 < |\eta| < 3.2$ のエンドキャプ部では、銅の吸収体と液体アルゴン から構成されたエンドキャプカロリメータが使用されている。さらに、 $3.1 < |\eta| < 4.9$ フォワード 領域では銅とタングステンの吸収体と液体アルゴンからなるフォワードカロリメータが設置されて いる。

また、式 (2.4) にバレル部、式 (2.5) にエンドキャップ部の単一のハドロン粒子に対するエネル



図 2.9: ATLAS 検出器におけるカロリメータの構成 [5]。電磁カロリメータは、バレル領域および エンドキャップ領域の 2 種類設置されている。ハドロンカロリメータは、バレル領域のタイル、エ ンドキャップ領域、フォワード領域の液体アルゴンカロリメータの 3 種類設置されている。

ギー分解能を示す [5]。

$$\frac{\sigma_E}{E} = \frac{50\%}{\sqrt{E}} \oplus 3\% \quad (バレル及びエンドキャップ部)$$
(2.4)

$$\frac{\sigma_E}{E} = \frac{100\%}{\sqrt{E}} \oplus 10\% \quad (7 \star 7 - F \ddot{B})$$
(2.5)

2.2.5 ミューオン検出器

ミューオン検出器は ATLAS 検出器の最外層に設置されており、カロリメータを通過した ミューオンを検出するために用いられおり、Resistive Plate Chamber (RPC) と Thin Gap Chamber (TGC) という2種類のトリガー検出器と、Monitored Drift Tube (MDT)の精密測定 用の検出器によって構成される。Run-3 からは磁場領域より内側に New Small Wheel (NSW) と いう検出器が新たに設置された。図 2.10 にミューオン検出器の配置図を示す。

ミューオン検出器では、検出器を層状にまとめたステーションと呼ばれる単位で構成されてお り、エンドキャップ部ではビーム軸に対して垂直に円盤状のステーションを、バレル部では筒状の ステーションによって構成されている。これらのステーションはエンドキャップ部、バレル部それ ぞれ3つずつ設置されており、衝突点に近い方から Inner (I), Middle (M), Outer (O) と呼ぶ。ま た、図 2.11 と図 2.12 に示すように、ミューオン検出器はトロイド磁石と干渉しないように配置す るため、φ 方向においては Large Sector (L) と Small Sector (S) の 2 種類の検出器を組み合わせ



図 2.10: ミューオン検出器の配置図 [5]。バレル部には RPC、MDT、エンドキャップ部には TGC、 MDT、CSC が配置されている。

てステーションを構成している。そのため、ミューオン検出器も磁石と同じく 8 回転対象になるよ うに配置されている。

Resisitive Plate Chamber (RPC)

RPC は $|\eta| < 1.05$ のバレル部のミューオントリガー判定に用いられる平行電極板のガス検出器 である。図 2.13 に RPC 検出器の構造を示す。2 枚の高抵抗プレートの間に幅 2 mm の絶縁体を 挟み込んでおり、プレート間のには約 4.9 kV/mm の電場が形成されている。電場に沿ってガスか ら電離した電子が雪崩増幅を起こし、プレートの外面に取り付けられたストリップで信号を読み 取り、直交するストリップの情報から $\eta \ge \phi$ の位置を導出する。RPC の位置分解能は z 方向に 10 mm、 ϕ 方向に 10 mm である。

図 2.11b に示す BIS は Barrel Inner Small sector の略であり、RPC の最内層に設置された検 出器である。RPC の最内層の検出器は z 軸に沿って 1 から 8 までナンバリングされており、その 7 番目と 8 番目の位置の検出器は Run-3 から新たに導入された検出器である。この RPC BIS78 は $1.0 < |\eta| < 1.3$ における領域をカバーしており、3.1.1 節で述べるインナーコインシデンスの際 に重要な役目を果たす。



(a) Large Sector でのミューオン検出器の配置図



(b) Small Sector でのミューオン検出器の配置図

図 2.11: R - x 方向からみたミューオン検出器の配置図 [19] Large Sector と Small Sector では、 トロイド磁石の配置の関係で磁場領域より内側にある検出器の配置が大きく異なる。



図 2.12: ビーム軸から見たバレル部のミューオン検出器の配置図 [5]。トロイド磁石および支持構 造に干渉しないように、Large Sector と Small Sector を組み合わせて設置されている。

Thin Gap Chambers (TGC)

TGC はエンドキャプ部の 1.05 < $|\eta|$ < 2.7 の領域に設置されているミューオン検出器である。 図 2.14 に TGC 検出器の配置図を示す。TGC は Multi Wire Proportional Chamber (MWPC) の一種で、ワイヤーとストリップによる 2 次元読み出しを行うことでミューオンのヒット位置を測 定する。図 2.15 に TGC の構造を示す。アノードワイヤーには直径 50 μ m の金メッキをしたタン グステンワイヤーを用い、カソードには片面に表面抵抗 1 MΩ のカーボンを塗布したガラスエポキ シ板を用いている。反対側の面には銅で出来たストリップがワイヤーに直交するように張られてい る。ミューオンの位置情報のうち *R* をアノードワイヤーで、 ϕ をカソードストリップで測定する ことで 2 次元での読み出しが可能となっており、TGC の分解能は *R* 方向に 2~6 mm、 ϕ 方向に 3~7 mm である。

図 2.16 に示すように、TGC を構成する検出器には 2 層構造の Doublet と 3 層構造の Triplet の 2 種類がある。Doublet はワイヤー面 2 層とストリップ面 2 層から信号の読み出しを行う。Triplet は 3 層構造になっているが、真ん中の層にストリップ面はないためワイヤー面 3 層とストリップ面 2 層から信号の読み出しを行う。

図 2.14 に示すように TGC 検出器はトロイド磁石による磁場領域より内側に EI (Endcap Inner), FI (Forward Inner) と呼ばれる 2 つのステーション、磁場領域より外側に M1, M2, M3 (Middle 1, Middle 2, Middle 3) と呼ばれる 3 つのサブステーションが配置されており、M1,



図 2.13: RPC の構造 [5]

M2, M3 の 3 つのステーションを合わせて TGC Big Wheel (TGC BW) と呼ぶ。M1 は Triplet 構造であり、EI/FI、及び M2、M3 は Doublet 構造である。M1, M2, M3 は図 2.17 のように複数 のチェンバーを組み合わせた円盤状の検出器である。

Monitored Drift Tube (MDT)

MDT はミューオンの飛跡の精密測定を目的とした検出器であり、直径約 30 mm のドリフト チューブを 6 層または 8 層並べた構造をしている。MDT の構造図を図 2.18 に示す。ドリフト チューブには Ar/CO₂ を封入している。電離によって生じた電子は、ドリフトチューブの中心に 張られている直径 50 µm のアノードワイヤーで集められ、読み出される。MDT の位置分解能は 35 µm である。

New Small Wheel (NSW)

New Small Wheel (NSW) は高ヒットレート環境での飛跡測定効率の向上とミューオントリ ガーの改良を目的として、エンドキャップ部の磁場領域より内側に Run-3 から導入された新検出 器である [21]。図 2.19 に NSW の全体像を示す。NSW はエンドキャプ領域の $1.3 < |\eta| < 2.7$ の 全 ϕ 領域を覆うように設置されており、small-strip TGC (sTGC) と MicroMegas (MM) の 2 種 類の検出器を 4 層ずつ組み合わせた構造をしている。

small-strip TGC (sTGC) は TGC と同様の MWPC である。図 2.20 に示すように sTGC は TGC と異なり、ストリップを用いて η 方向の位置座標を、ワイヤーを用いて φ 方向の位置座標を 測定する。sTGC にはパッドと呼ばれる読み出しカソードがあり、ストリップとパッドでアノード ワイヤーを挟む構造になっている。

Micromegas (MM) は、平面の電極と金属のメッシュで構成されている。図 2.21 に MM の概要



図 2.14: TGC 検出器の配置図 [5]。磁場領域の内側に EI、FI、外側に TGC-BW と呼ばれる 3 層 のステーション (M1, M2, M3) が設置されている。Run-3 では内側の EI, FI に代わり、NSW が 設置されている。



図 2.15: TGC 検出器の構造 [5]。ガスギャップ 2.8 mm、ワイヤー間隔 2.8 mm の MWPC (Multi Wired Proportional Chamber) の構造をしている。



図 2.16: TGC Triplet と Doublet の断面図 [5]。

図を示す。厚さ 5 mm のドリフト領域と 128 μm の増幅領域がメッシュで隔てられており、読み 出された信号の時間差を用いることで飛跡の z 方向の情報を再構成することがでる。



図 2.17: TGC 検出器 の M1,M3 ステーションの概要図 [20]。実線で囲まれたマスが 1 つのチェ ンバーに対応する。



図 2.18: MDT の構造図 [5]。ドリフトチューブを積み重ねたような構造となっている。

2.3 ATLAS トリガーシステム

ATLAS 実験では、LHC を用いて 40 MHz での頻度で陽子バンチの衝突を行っている。しかし、 データ記憶容量の制限が存在するためすべての衝突事象を保存することはできず、現在の制約では



図 2.19: NSW の構造 [22]。Large Sector と Small Sector の 2 種類のチェンバーを交互に配置し ている。sTGC quadruplet の間に、4 層で構成されている MM が 2 つ挟まれており、合計 16 層 で構成されている。



図 2.20: sTGC の断面図 [21]。 パッド、ストリップを用いて η を、ワイヤーを用いて ϕ を計算する。

事象頻度 (トリガーレート)を数 kHz まで削減する必要がある。そのため、トリガーシステムと呼 ばれる膨大なデータの中から物理として興味のある事象のみを効率よく取得するアルゴリズムを用 いて事象選別を行っている。ATLAS 検出器では大きく分けて 2 段階のトリガーを実装している。 1 段目にはハードウェアベースの高速処理が可能な初段トリガー、2 段目にはソフトウェアベース で精密処理が可能な後段トリガーが実装されている。トリガーシステムの構成を図 2.22 に示す。

初段トリガー (L1 Trigger)

初段トリガーである L1 Trigger では、ATLAS 検出器から送られてくる 40 MHz イベント レートの事象を 2.5 µs 以内にトリガー判定を行い、100 kHz まで落とす必要がある。高速なト リガー判定を実現するために、Application Specific Integrated Circuit (ASIC) や Field Programmable Gate Array (FPGA) などの論理回路で構成した電子回路で実装されている。ASIC



図 2.21: MM の概略図 [21]。メッシュによってドリフト領域と増幅領域に分けられる。ドリフト 領域で生成された電子はメッシュを通過し、増幅領域で電場により増幅される。



図 2.22: Run-3 における ATLAS トリガーシステムの概要及びデータ読み出しの流れ [23]。トリ ガーシステムは L1 Trigger と High-Level Trigger の 2 段階のトリガーで構成されている。

は特定の用途向けに複数の回路を 1 つにまとめたもので、高速な動作速度や低い消費電力を実現 できる一方、回路の修正が困難である。FPGA は ASIC と同様に特定の処理を行うように設計可 能な集積回路で、ASIC と比較して処理速度が遅い一方で、何度でも書き換え可能であるというメ リットがある。

図 2.22 に示すように、L1 Trigger はカロリメータの情報を用いてトリガー判定を行う L1Calo、

ミューオン検出器の情報を用いてトリガー判定を行う L1Muon に加え、L1Calo と L1Muon で 発行されたトリガーを組み合わせたトリガー判定を行う Central Trigger から構成されている。 L1Calo は電磁カロリメータとハドロンカロリメータの情報を統合して、電子/光子と τ 候補、 ジェット候補の判定を行う。L1Muon はバレル部の RPC とエンドキャップ部の TGC から情 報を受け取り、それぞれ独立にミューオン候補の判定を行う。バレル部とエンドキャップ部で 独立に判定された L1Muon の情報は Muon-to-CTP interface (MUCTPI) で統合される。その 後、L1Calo と L1Muon からの情報は Central Trigger Processor (CTP) に送られるのと同時に、 Topology Processor (L1Topo) に送られる。L1Topo では L1Muon と L1Calo の情報を組み合わ せて、それぞれの情報から複合的な判定を行う。最後に L1Muon、L1Calo、L1Topo の情報は CTP に集められ、100 kHz に収まるようにプリスケールがかけられた後、トリガーが発行される。

後段トリガー (High-Level Trigger: HLT)

HLT では、L1 Trigger でトリガー判定に用いた領域に対して、ソフトウェアを使用したオフラ イン解析に近いアルゴリズムでミューオン、電子、光子などを再構成することで精密なトリガー判 定を行う。Level-1 Trigger で用いられなかった内部飛跡検出器の情報、MDT やなどの精密測定 用のミューオン検出器及び、カロリメータの情報などを用いて、飛跡再構成やより高精度な *E_T*、 *p_T*の計算を行う。トリガーレートは HLT を用いて最終的に数 kHz まで削減される。

2.3.1 トリガーメニュー

ATLAS 実験で用いられているトリガーシステムでは、限られたレートの中に必要な情報を収め なければならない。そのため、L1 Trigger と HLT にはそれぞれに条件が設定されている。これを トリガーアイテムと呼ぶ。例として、L1Muon ではミューオンの横方向運動量 $p_{\rm T}$ に閾値を設定し たトリガーアイテムがある。基本的に低い $p_{\rm T}$ のミューオンを取得することが物理としては望まし いが、取得できるレートとの兼ね合いから、この $p_{\rm T}$ 閾値が決定されている。より低い $p_{\rm T}$ 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り、L1Muon では同時に複数のミューオ ンの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 $p_{\rm T}$ のミューオンを取得可能な トリガーアイテムが存在する。そして、L1 Trigger と HLT のトリガーアイテムを組み合わせたも のをトリガーチェインを呼び、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がトリ ガーメニューである。表 2.1 に Run-3 におけるの L1Muon のトリガーメニューの一例を示す。

L1 Trigger ではハードウェア上に 512 個のトリガーアイテムが用意されており、そのいずれか が鳴ったときにトリガーが発行される。一方で、HLT ではソフトウェアベースのトリガー判定を 行うため、トリガーアイテムの個数の制限はない。L1 Trigger と HLT のトリガーアイテムを組み 合わせたトリガーチェインは大きく分けて 2 種類であり、物理解析に使用されるデータの収集のた めの主要なトリガーであるプライマリートリガーと、効率や性能の評価やモニタリングに使用され るサポートトリガーが存在する。その中には、新粒子探索に用いる高い *p*T の電子やミューオンな どを取得するためのトリガーチェインや、*B* 粒子の崩壊などからの低い運動量の粒子を取得するた 表 2.1: Run-3 におけるプライマリーミューオントリガーのメニューの一例 [24]。L1 及び HLT の プライマリートリガーのトリガーアイテムと Run-3 で予想されるレートを示す。

L1 Target	Category	Trigger item	
MU	L1	L1_MU14FCH	
	HLT 1mu isolation	HLT_mu26_ivarmedium	195 Hz
		$HLT_mu24_ivarmedium$	$229~\mathrm{Hz}$
	HLT 1mu	HLT_mu26_ivarmedium	38 Hz
		HLT_mu60_0eta105_msonly	10 Hz
		$HLT_mu80_msonly_3layersEC$	8 Hz
	HLT 2mu	HLT_mu22_mu8noL1	$45~\mathrm{Hz}$
		HLT_mu20_ivarmedium_mu8noL1	$19~\mathrm{Hz}$
		HLT_mu20_ivarmedium_mu4noL1_10invmAB70	$12 \mathrm{~Hz}$
		HLT_2mu50_msonly	$6~\mathrm{Hz}$
	HLT 3mu	HLT_mu20_2mu4noL1	6 Hz
2MU	L1	L1_2MU8F	2.2 kHz
	HLT 2mu	HLT_2mu14	23 Hz
		HLT_mu10_ivarmedium_mu10_10invmAB70	$15~\mathrm{Hz}$
2MU	L1	L1_MU10BOM	0.9 kHz
	HLT 2mu	HLT_2mu10_l2mt	1 Hz
3MU	L1	L1_3MU5VF	0.2 kHz
	HLT 3mu	HLT_3mu6	$5~\mathrm{Hz}$
		HLT_3mu6_msonly	27 Hz
4MU	L1	L1_4MU3V	0.4 kHz
	HLT 4mu	HLT_4mu4	1 Hz

めの低い閾値のトリガーチェインなど、多くのトリガーが用意されている。しかし、トリガーレー トに制限があるため、すべてのトリガーを使ってデータを取得することは現実的にはできない。そ のため、ATLAS 実験のトリガーシステムにはプリスケールと呼ばれる値がトリガーアイテムごと に設定されており、高いレートになってしまうトリガーに関してもレートを下げてトリガー発行す ることが可能になっている。しかし、プリスケールをかけるとその分だけ実効的なルミノシティが 下がってしまうため、トリガーレートとプリスケールファクターの兼ね合いが重要である。

第3章

初段ミューオントリガーシステム

ATLAS 実験における初段ミューオントリガーは、RPC を用いるバレル部と TGC を用いるエ ンドキャップ部に分かれている。本章では、Run-3 におけるエンドキャプ部の初段ミューオントリ ガーシステムについて述べる。

3.1 エンドキャプ部初段ミューオントリガー

エンドキャプ部の初段ミューオントリガーはさらに 2 つの領域に分けられ、 $1.05 < |\eta| < 1.9 を$ エンドキャップ領域、 $1.9 < |\eta| < 2.4 をフォワード領域と呼ぶ。$

3.1.1 トリガーアルゴリズムの概要

ミューオンの横方向運動量の判定

エンドキャップ部の初段ミューオントリガーで用いられるトリガー判定の概要を図 3.1 に示す。 衝突点で生成されたミューオンはトロイド磁石の磁場領域より内側にある検出器を通過した後、ト ロイド磁場領域を通り TGC に到達する。トロイド磁石による磁場は ϕ 方向にかかっているため、 ミューオンの飛跡はトロイド磁場中で η 方向に曲げられる。さらに、衝突点付近のソレノイド磁石 で生じる z方向の磁場成分と、トロイド磁石付近で生じた R方向の磁場成分によって、ミューオ ンの飛跡は ϕ 方向にも曲げられる。ミューオンの飛跡の曲がり具合は横方向運動量 $p_{\rm T}$ の大きさに よって変化するため、測定した飛跡情報からミューオンの $p_{\rm T}$ を算出することができ、トリガー判 定に使用することができる。

トロイド磁場によって曲げられたミューオンは、TGC-BW の M1, M2, M3 を通過し、それぞれ のヒット情報から飛跡を再構成される。この時、衝突点と M3 のヒット位置を結んだ直線をミュー オンが無限運動量で通過したと仮定した場合の飛跡として扱う。この無限運動量を持つミューオ ンの飛跡と磁場によって曲げられた実際の飛跡を比較し、M1 におけるヒット位置の R 方向と ϕ 方向のずれ (dR, d ϕ)を計算する。この dR と d ϕ の値が大きいミューオンは、磁場中で大きく曲 げられたことを意味しているため小さい $p_{\rm T}$ として判定される。逆に dR と d ϕ の値がが小さいほ



図 3.1: ATLAS 検出器エンドキャップ領域におけるトリガースキームの概念図 [?]。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 (d*R*, dφ) を用い て *p*_T を計算する。

ど、磁場中ではあまり曲がらないミューオンの飛跡であるため大きな $p_{\rm T}$ として判定される。初段 ミューオントリガーでは (dR, d ϕ) からトリガー判定に用いる $p_{\rm T}$ を算出する際に、あらかじめ保 持しておいた、(dR, d ϕ) と $p_{\rm T}$ の対応関係を表した Look-Up Table (LUT) を参照することで、短 時間での $p_{\rm T}$ の算出を実現している。

 $p_{\rm T}$ を算出する際に参照する LUT は Coincidence Window (CW) と呼ばれており、図 3.2 のような CW が FPGA 上に保存されている。図 3.2 の CW が色分けされているように、 $(dR,d\phi)$ によって判定される $p_{\rm T}$ は異なり、Run-3 においては 15 段階の $p_{\rm T}$ を判定することができる。この 15 段階の $p_{\rm T}$ の閾値は先行研究 [25] によって定められており、表 3.1 に $p_{\rm T}$ 閾値を示す。このとき、図 3.2 に示す CW のマスの中の数字は表 3.1 に示す閾値と対応しており、符号はミューオンの電荷に対応している。図 3.3 に 2022 年 Run-3 で用いられた CW のトリガー効率を示す。

インナーコインシデンス

Run-1 おけるエンドキャップ部の初段ミューオントリガーは TGC-BW 単体のヒット情報から トリガー判定を行っていた。しかし TGC-BW 単体のヒット情報だけでは、陽子衝突由来でない 荷電粒子が TGC-BW に入射した際にもトリガーを発行してしまうため、トリガーレートを上げ る要因になっていた。このような陽子衝突由来でない荷電粒子により発行されたトリガーをフェイ



図 3.2: Run-3 での TGC における 3 ステーションの Coincidence Window の例 [25]。ミューオン のヒットがあった時にそれぞれの検出位置のの CW を参照し、(d*R*, dφ) からミューオンの *p*_T を 15 段階で見積もる。マスの中の数字は表 3.1 に示す閾値と対応しており、符号はミューオンの電 荷に対応している。

クトリガーと呼ぶ。そこで Run-2 では、TGC-BW のヒット情報に対して TGC-EI/FI と Tile カ ロリメータの情報を使ったコインシデンス (インナーコインシデンス) を取ることでフェイクトリ ガーを大きく削減することができた。しかし、1.9 < |η| < 2.4 の領域ではインナーコインシデンス をとるためのトリガー用の検出器が設置されていないため、フェイクトリガーが多く残っていた。 Run-3 からは新たに NSW と RPC BIS78 を導入することにより、Run-2 より広範囲でインナー コインシデンスをとることが可能となるため、フェイクトリガーをより削減できることが期待され る。Tile カロリメータとコインシデンスだけでなく、新たに導入される NSW や RPC BIS78 をイ ンナーコインシデンスに用いた場合に期待されるトリガー発行数の分布を図 3.4 に示す。

閾値番号	L1 items	条件
1	L1_MU3	$p_{\rm T} \ge 3 { m ~GeV}$
2	L1_MU4	$p_{\rm T} \ge 4 { m ~GeV}$
3	L1_MU5	$p_{\rm T} \ge 5 { m ~GeV}$
4	L1_MU6	$p_{\rm T} \ge 6 {\rm ~GeV}$
5	L1_MU7	$p_{\rm T} \ge 7 { m ~GeV}$
6	L1_MU8	$p_{\rm T} \ge 8 { m ~GeV}$
7	L1_MU9	$p_{\rm T} \ge 9 {\rm ~GeV}$
8	L1_MU10	$p_{\rm T} \ge 10 { m ~GeV}$
9	L1_MU11	$p_{\rm T} \ge 11 { m ~GeV}$
10	L1_MU12	$p_{\rm T} \ge 12 { m ~GeV}$
11	L1_MU13	$p_{\rm T} \ge 13 { m ~GeV}$
12	L1_MU14	$p_{\rm T} \ge 14 { m ~GeV}$
13	L1_MU15	$p_{\rm T} \ge 15 { m ~GeV}$
14	L1_MU18	$p_{\rm T} \ge 18 { m ~GeV}$
15	L1_MU20	$p_{\rm T} \ge 20 {\rm ~GeV}$

表 3.1: Run-3 初段ミューオントリガーにおける 15 段階の p_T 閾値 [25]。

トリガー判定に用いられる位置情報

TGC のトリガー判定に用いられる単位の模式図を図 3.5 に示す。TGC の検出領域は ϕ 方向にエンドキャプ領域では 48 個、フォワード領域では 24 個に分割しており、トリガー回路的 に独立していて"トリガーセクター"と呼ばれる。このトリガーセクターはさらに小さな領域で ある Region of Interest (RoI) に分割され、エンドキャップ領域の 1 つのトリガーセクターは η 方向に 37 分割、 ϕ 方向に 4 分割されるため 148 個の RoI で構成されており、フォワード領 域の 1 つのトリガーセクターは η 方向に 16 分割、 ϕ 方向に 4 分割されるため 64 個の RoI で 構成されている。RoI は L1Muon が持つミューオンの検出位置の最小単位であり、トリガー発 行したミューオンの位置情報はこの RoI の場所を示す。 $p_{\rm T}$ 判定に用いる CW は RoI ごとに作 成しているため、TGC の A-side、C-side、エンドキャップ部、フォワード部を考慮すると合計 (148 × 48 + 64 × 24) × 2 = 17,280 個の CW が作成されている。



図 3.3: 2022 年 Run-3 で使用した 15 段階閾値の Turn-on curve [25]。シングルミューオンのシ ミュレーションサンプルに対してのトリガー効率を示している。

3.1.2 初段ミューオントリガーにおけるエレクトロニクス

3.1.1 節で述べたトリガーシステムは様々な電子回路を組み合わせることで実現している。本節 では、初段ミューオントリガーで実装されているエレクトロニクスについて述べる。

エンドキャップ部初段ミューオントリガーで用いられるエレクトロニクスは、トリガー判定と 検出器のヒット情報の読み出しの2つの役割を担っている。TGCの電子回路とデータの流れを 図 3.6 に示す。以下では各エレクトロニクスについて説明する。

Amplifier Shaper Discriminator $\vec{n} - \vec{k}$

Amplifier Shaper Discriminator (ASD) ボードは TGC のワイヤーとストリップからアナログ 信号を受け取り、デジタル信号への変換を行う。ASD ボード上の ASD において TGC からのア ナログ信号を増幅・整形し、閾値電圧を超えた信号だけが LVDS 信号として出力される。1 枚の ASD ボードは 4 つの ASD-ASIC を搭載しており、ASD-ASIC は 4 つの信号の受信・処理を行う。 そのため、同時に 16 チャンネルの信号を処理することが可能である。



図 3.4: Run-3 で期待される *p*_T 閾値が 20 GeV におけるトリガー発行数の η 分布 [26]。白色、水 色、黄色の領域はそれぞれ Tile カロリメータ、RPC BIS78、NSW を用いたインナーコインシデ ンスを導入した場合に削減できるトリガー発行数を示す。青色の領域は Run-3 で期待されるトリ ガー発行数、赤色の領域は発行されたトリガーのうちオフラインで再構成されるミューオンの数を 示す。緑の分布はオフラインで再構成されたミューオンのうち、*p*_T が 20 GeV 以上のミューオン の数を示す。

Patch-Panel ASIC

Patch-Panel ASIC (PP ASIC) では ASD からワイヤーとストリップそれぞれの LVDS 信号を 受け取り、タイミング調整とバンチ識別を行う。陽子衝突由来のミューオンが検出器に到達する時 間や、ケーブルの長さの違いにより、信号が送られてくるタイミングが各チャンネルごとに異な る。そのため、PP ASIC でタイミングの調整を行う。



図 3.5: TGC におけるトリガーセクターと RoI の模式図 [27]。緑の線で囲まれた領域が1つのト リガーセクターを表し、赤の線で囲まれたマスが1つの RoI を表す。

Slave Board ASIC

Slave Board ASIC (SLB ASIC) は読み出しとトリガー判定の2種類の処理を行う。トリ ガー判定で行う処理としては、各チャンネルの情報を用いてコインシデンスを取ることである。 TGC Triplet (M1 ステーション)ではワイヤーの3層中2層にヒットがあることを要求し、スト リップの場合は2層中1層にヒットがあることを要求する。2つの TGC Doublet (M2、M3 ス テーション)では、ワイヤーとストリップでそれぞれ4層中3層以上にヒットがあることを要求す る。これらのコインシデンス結果は LVDS 信号で後段の High PT ボードに送る。

High PT ボード

High-PT (HPT) ボードは、M1 の SLB と M2, M3 の SLB からのコインシデンス結果を受け取 り、M1, M2, M3 の 3 つのステーション間のコインシデンスを行う。M1 と M3 の位置情報から (dR, d ϕ) を計算し、次の Sector Logic に送る。Sector Logic にはボードごとに、位置情報 R と ϕ 、位置の差の情報 dR と d ϕ を G-Link 通信を用いて送信する。



図 3.6: TGC のエレクトロニクスとデータの流れ [5]。赤い線はトリガー信号の流れを、青い線は 読み出しデータの流れを示している。

New Sector Logic

Sector Logic (SL) は HPT ボードから受け取った TGC-BW のワイヤー・ストリップの情報と、 磁場領域より内側にある検出器から受け取った信号を組み合わせてトリガー判定を行う。Run-3 では、NSW の導入に伴いトリガー判定に用いるデータ量が増え、従来の SL では処理できないた め New Sector Logic (NSL) に刷新された。図 3.7 に Run-3 における NSL を用いた初段ミューオ ントリガーの概要を示す。

NSL には TGC-BW の HPT から、ミューオン候補の情報が G-Link 通信で送られてくる。この 情報から M3 のヒット位置の RoI を表す η 、 ϕ 及びコインシデンスが取れた M1 とのヒット位置の ずれ (dR, d ϕ)を取得し、FPGA 上に保存されている Coincidence Window を参照することで $p_{\rm T}$ の判定を行う。次に、RPC BIS78、Tile カロリメータ、TGC-EI/FI からは検出器におけるヒット 情報、NSW からは通過したミューオンの飛跡情報が送られてくる。NSW の情報には、ヒット位 置を表す η , ϕ 及びミューオンが飛来した角度 θ が含まれる。これらの検出器から送られてくる情 報を用いてインナーコインシデンスを取ることでトリガー判定を行う。そして、トリガー判定の結 果を後段の MUCTPI に送信する。



図 3.7: Run-3 における NSW を用いた初段ミューオントリガーの概要図 [27]。NSL には TGC-BW の他に NSW、RPC BIS78、タイルカロリメータ、EI からの入力がある。これらの検出器か らの情報を用いてコインシデンスをとり、トリガー判定を行う。

NSL が MUCTPI へ送信するデータフォーマットを図 3.8 に示す。Run-3 では各トリガーセク ターごとに最大 4 個のミューオン候補の情報を送ることができる。また、表 3.2 に示すように各 ミューオン候補の情報には、ミューオンの電荷情報に 1-bit、フラグに 3-bit、15 段階の $p_{\rm T}$ 閾値の 情報に 4-bit、TGC-BW でのヒット位置 (RoI) の情報に 8-bit の合計 16-bit が割り当てられてい る。フラグの 3-bit には、3 ステーションコインシデンスフラグ、hot roi フラグ、インナーコイン シデンスフラグが割り当てられている。3 ステーションコインシデンスフラグとは TGC-BW の 3 つのステーション全てにヒットしたミューオンを判定するフラグである。これにより、偶然 2 つの ステーションのみにヒットしたミューオンのイベントを取り除くことができる。また、図 2.7 に示 したようにエンドキャップ領域における磁場構造は複雑なため、上手く $p_{\rm T}$ 判定を行えない領域が 存在する。hot roi フラグは、その領域に入射したミューオンかどうかを示すフラグである。これ により、上手く $p_{\rm T}$ 判定できなかったイベントを取り除くことができる。インナーコインシデンス フラグは、磁場の内側の検出器とコインシデンスを取ることによって、衝突点由来でない粒子によ るヒットを取り除くことができる。
Data format from Sector Logic to MuCTPi

Words(16 bit)				first	byte			second byte								
	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1	0
Word-0	Muon Candidate 1															
Word-1	Muon Candidate 2															
Word-2	Muon Candidate 3															
Word-3	Muon Candidate 4															
Word-4	Global flags BCID															
Word-5	CRC								comma (0xfd)							
Word-6	0xc5								comma (0xbc)							
Word-7	0xc5							0xc5								

8b/10b encoding \times 8 bytes = 6.4 Gbps

図 3.8: MUCTPI へ送信するデータフォーマット [28]。

表 3.2: MUCTPI へ送信するミューオン候補の情報 [28]。

Muon Candidate							
charge	flag	p_{T}	RoI				
1-bit	3-bit	4-bit	8-bit				

3.2 従来の CW の作成及び最適化手法

3.2.1 従来の CW の作成方法

実際の検出器では磁場構造や構造物による影響などの様々な要素を考慮する必要があるため、 ミューオンの *p*_T を数式で計算して CW を作成するのは困難である。そこで、ミューオンのシミュ レーションデータを用いて、ミューオンの *p*_T と各 RoI における d*R*, dφ の対応を調べることで CW を作成している。従来の CW を作成する流れについて以下に述べる [25]。

- シングルミューオンサンプル (1 イベントに対してミューオンが 1 個のみ存在するシミュ レーションサンプル)を用意し、dR, dφの2次元分布図 (ヒットマップ)を各 RoI ごとに作 成する。これを、1 GeV から 40 GeV まで 1 GeV 刻みに行う。
- 作成したヒットマップにはミューオンの多重散乱などが原因で、孤立しているマス、穴の空いているマスが存在する。そこで、ヒットマップのエントリー数などの条件をかけることでヒットマップに対する処理を行う。
- 3. 各 RoI、各 $p_{\rm T}$ 毎に処理を行った 40 段階の $p_{\rm T}$ のヒットマップから、15 個のヒットマップ を選別し、15 段階の CW を作成する。



図 3.9: TGC 検出器のズレ d ρ を表すパラメータの定義 [30]。x 軸方向のズレを dr、z 軸方向のズ ν を dz tan θ と表し、全体としてのズレを d ρ =dr-dz tan θ と定義する。

3.2.2 CW の最適化手法

TGC の設置位置の測定

TGC は ATLAS 内部の検出器の入れ替えなどのために移動させることがあり、結果として TGC の設置位置 (アライメント) にズレが生じてしまう。TGC のアライメントのズレの測定方法はこれ までの研究 [29] で既に確立されており、TGC のズレを示すパラメータを図 3.9 のように定義す る。TGC の理想位置からの x 軸方向のズレを dr、z 軸方向のズレを-dz tan θ と表し、全体として のズレを d $\rho = dr - dz$ tan θ と定義する。d ρ >0 は TGC が動径方向 (R 方向) の正の方向にズレ ていることを表し、d ρ <0 は負の方向にズレていることを表している。図 3.10 に Run-2 での実際 のデータを用いて測定した TGC のアライメントのズレの値を示す。

Run-2 における最適化手法

2.2.2 節で述べたように、ATLAS 検出器のエンドキャップ領域ではトロイド磁石によって 8 回 転対象の磁場が形成されている。そのため、従来の CW 作成手法ではシミュレーションデータを 用いて 1 回転分の CW を作成し、1 つの CW を TGC-BW の8ヶ所に対応させていた。しかし、 シミュレーション上では TGC は設計通りの位置に設置されているが、実際の検出器ではアライメ ントにズレが生じている。このため、TGC における磁場構造は厳密には 8 回転対象ではなくなっ ている。しかし、シミュレーションをもとに作成した 8 回転対象が前提の CW には実際の検出 器アライメントのズレの影響が考慮されていない。そのため、この CW をトリガーに適応すると ミューオントリガーの運動量分解能の低下やトリガーレートの増加を招く原因となる。そこで、ト リガー性能の向上のためには CW に補正を行うことで、TGC のアライメントに対して最適化する



図 3.10: Run-2 での検出器のズレの測定図。マスの中の数字がチェンバーごとのズレの値を表す。 (a):C-side。(b):A-side。動径方向に最大 20 mm、ビーム軸方向に最大 40 mm ずれている [30]。

必要がある。CW の最適化方法はこれまでの先行研究で開発されている。2016 年までに行われて いた手法では実際のデータから検出器のズレの大きさを各 TGC チェンバー毎に見積もり、その値 に従って CW に補正を加えることでトリガー効率を改善させていた [30]。2017 年以降では、実際 のデータを用いて CW のマスごとの p_T 分布を評価することで CW の補正を行っており、11 GeV, 15 GeV, 20 GeV のトリガーに対して最適化を行ったことでトリガー性能が改善された [31]。

以下にシミュレーションデータから作成された CW における *p*_T 閾値が 20 GeV のトリガーに 対する 2017 年以降の Run-2 で行われた最適化の流れを示す。

- 1. Run-2 の実データから dR, d ϕ の情報を抜き出し、dR, d ϕ のヒットマップを各 RoI 毎に作成する。これを $p_{\rm T} < 20$ GeV 及び $p_{\rm T} > 20$ GeV に分割して行う。
- 2. 作成したヒットマップに対して、ヒットマップの各マスごとに式 (3.1) で定義するパラメー タ *x* を計算する。

$$x = \frac{N_{p_{\rm T}>20 \text{ GeV}}}{\sqrt{N_{p_{\rm T}>20 \text{ GeV}}^2 + N_{p_{\rm T}<20 \text{ GeV}}^2}}$$
(3.1)

ここで、 $N_{p_{\rm T}>20~{
m GeV}}$ は $p_{\rm T}>20~{
m GeV}$ のヒットマップのマスにおける $p_{\rm T}>20~{
m GeV}$ の ミューオン数、 $N_{p_{\rm T}<20~{
m GeV}}$ は $p_{\rm T}<20~{
m GeV}$ のヒットマップのマスにおける $p_{\rm T}<20~{
m GeV}$ のミューオン数である。

3. すべてのヒットマップの各マスでで計算した x の値を指針として、CW のマスが示す $p_{\rm T}$ 閾値が正しいかどうかを判断し、必要に応じて CW の閾値を一段階変更する。

この手順を各 p_T 閾値に対して高い p_T 閾値から順番に行うことで CW の最適化を行う。

3.3 本研究の目的

2022 年の運転で一時的に瞬間ルミノシティ 2.5×10³⁴ cm⁻²s⁻¹ まで到達したことを受け、2023 年以降の運転ではより高いルミノシティで安定した運転を行うことが予定されている。そのため、 2022 年度のトリガーシステムのままではトリガーレートが大幅に増加してしまうため、さらなる トリガー性能の向上が喫緊の課題である。

初段ミューオントリガーの改善にはいくつか方法があるが、その中でも CW に対して検出器ア ライメントの補正を行う方法がある。ATLAS 検出器のトロイド磁石は等間隔に 8 個設置されてお り、エンドキャップ領域では 8 回転対象の磁場が形成されている。そのため、従来の手法ではシ ミュレーションデータを用いて 1 回転分の CW を作成することで、8 回転のすべての箇所に適応 させることができた。しかし、実際には検出器アライメントのズレによって、TGC における磁場 構造は厳密には 8 回転対象ではなくなってしまい、トリガー性能の向上のためには各 RoI ごとに 補正を行い、CW を最適化する必要がある。

Run-2 では 3.2 節で示すように、先行研究によって開発された手法を用いて手動で補正を行っ ていたが、この手法は p_T 閾値に対して柔軟な対応が難しい上に、補正には多大な作業量が必要に なってくる。そのため、15 段階に増設された Run-3 の p_T 閾値に対して従来の手法で補正を行う ことは難しい。そこで、従来の手法に代わって Run-3 の 15 段階閾値に対応した CW を効率よく 補正する手法の開発が必要である。

本研究では効率化する方法として、近年急速に発展している機械学習に着目し、機械学習を用い た新たな CW の最適化手法の開発を行う。機械学習は近年大きな注目を集めている技術であり、 様々な分野で活用されている。機械学習とは、人がコンピュータにルールや知識を明示的に与える 代わりに、学習するためのデータを与え、コンピュータ自身がそのデータからルールや知識を獲得 する手法である。そのため、ATLAS 実験で実際に取得したデータを機械学習に与えることで、多 大な作業量を必要とする CW の作成及び最適化の作業の自動化が期待できる。

35

第4章

機械学習を用いた Coincidence Window の作成手法

第3章では ATLAS 実験で実装されているトリガーシステムの概要について説明し、初段ミュー オントリガーで使用されている Coincidence Window (CW)の作成及び Run-2 における最適化手 法について述べ、効率的な最適化手法の開発が必要であることを示した。本章では近年発展が著し い機械学習についての概説を述べ、本研究の主題である機械学習を用いた効率の良い CW の作成 及び最適化手法について述べる。

4.1 機械学習

コンピュータ自身がデータから「ルールや知識を獲得」(学習) するアプローチを機械学習と呼 ぶ。そして、学習した結果を用いて予測や認識、作成など様々なタスクを行うことができる。「複 数人の専門家が数年かかって作っていく」ようなルールや知識などは、作成自体にも、作成後の調 整や変更にも膨大な時間とコストがかかるが、機械学習を用いることで学習用のデータを機械にか けて数日待てば自動的に作成することができるようになる [32]。機械学習が行う代表的なタスクと して「クラス分類」と「回帰分析」がよく知られている。クラス分類とは、分析したいデータが属 するカテゴリーやクラス、種類が何なのかを予測する手法である。特に、予測するクラス数が2ク ラスの場合には 2 値分類、2 クラスより多い分類予測については多クラス分類と呼ばれる。図 4.1a にクラス分類の概要図を示す。高エネルギー物理学実験では、粒子の同定や探索の対象としている 信号事象 (シグナル) とその背景事象 (バックグラウンド) の分離などに応用されている。回帰の主 な目的は、連続値などの値を学習データの傾向をもとに予測することである。過去の気温から明日 の気温を予測することや企業における売り上げの予測などが回帰に当てはまる。回帰分析には、線 形回帰、多項式回帰などが存在し、図 4.1b に線形回帰の概要図を示す。回帰問題では、入力デー タを線形関数もしくは多項式関数を用いて近似することで、データの傾向を表す関数を作成する。 高エネルギー物理学実験では、粒子の衝突で得られたデータを入力変数とし、粒子のエネルギー測 定の補正を行う解析などに応用されている [33]。





(a) クラス分類

(b) 回帰分析

図 4.1: 機械学習の代表的な分析手法の概要図。

機械学習の学習手法は、正解の値 (教師データ)を与えた状態で傾向を学習させる「教師あり学 習」と教師データを用いずに学習を行う「教師なし学習」の2つに大きく分けられる。最も広く使 われている学習手法である教師あり学習は、正解のデータが用意されており、正しい出力ができる ように入力データの特徴やルールを学習していく手法である。教師あり学習は、既存のデータをも とに、タスクごとに設定されたいくつかのクラスに識別する「クラス分類」と、連続する値を予測 する「回帰分析」を行うことができる。本研究では、この「教師あり学習」によるトレーニングを 行い「回帰分析」による連続値の予測に着目する。

4.1.1 ニューラルネットワーク

機械学習には多くの種類があるが、その内の一つがニューラルネットワークを使った手法であ 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、つ まり神経回路網を人工ニューロン (パーセプトロン)という数式的なモデルで表現したものである。 個々のパーセプトロンは単純な仕組みであるが、多数組み合わせる事で複雑な関数近似を行う事が できるのがニューラルネットワークの大きな特徴である。パーセプトロンを複数組み合わせ多層化 し、複雑な表現を可能としたものを多層パーセプトロン (MLP: Multilayer perceptron)と呼ぶ。

図 4.2 に示すように、一つ一つのパーセプトロンは入力と出力で構成される。パーセプトロンで は、式 (4.1) で表すように、n 個の入力変数 x_i に対し重み w_i を作用させバイアス b を足し合わせ た入力値 a が、関数 f(a) によって変換されて出力値 y として出力される。このバイアス b と重み w_i のパラメータを調節することで、入力に対して様々な出力が可能となる。

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

$$y = f(a) \tag{4.2}$$



図 4.2: 単一パーセプトロンの概念図。



図 4.3: 機械学習で用いられる活性化関数の例。(a): sigmoid 関数、(b): ReLU 関数。

このとき、式 (4.2) で表す f(a) の事を「活性化関数」と呼び、活性化関数には、sigmoid 関数、tanh 関数、ReLU 関数 (Rectified Linear Unit)」、softmax 関数などが良く使われている。sigmoid 関 数及び ReLU 関数の概形を図 4.3a, 図 4.3b に示す。sigmoid 関数はニューラルネットワークでよ く用いられてきた関数であり、式 (4.3) のような関数で表される。ReLU 関数は式 (4.4) のような 関数で示される。

$$y = \frac{1}{1 + \exp(-x)}$$
(4.3)

$$y = max(0, x) \tag{4.4}$$



図 4.4: MLP の概形。パーセプトロンを複数組み合われており、ある層のパーセプトロンからの出 力は全結合されて次の層の各パーセプトロンに入力される。

このような、パーセプトロンを図 4.4 に示すように複数組み合わせたものが MLP である。

多層パーセプトロン

MLP は隠れ層と呼ばれる層が複数追加されたネットワーク構造を持ち、各層の間は全結合し ているような構造になっている。この様な構造を持つニューラルネットワークの事を「全結合型 ニューラルネットワーク」と呼ぶ。MLP はパーセプトロンを複数接続したことにより、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。そこで教師あり学習では、 入力変数に対する出力ができる限り教師データと一致するようなパラメータ (w_i , b) を求めること で学習を行う。このようなパラメータは、「最適化問題を解く」ことで求めることができる。最適 化問題とは変数 a,b とある関数 L(a,b) が与えられたとき、関数 L(a,b) の値が最小となるような変 数の組 (a,b) を探す問題である。機械学習において L(a,b) は「損失関数」と呼ばれ、学習データで 与えられる正解値に対し、機械学習の予測がどれだけ間違っているのかを評価する関数である。具 体的には、学習データからの入力 x_n に対して設定したパラメータ (w_i ,b) の時の予測値 y を、損 失関数を用いて正解値 t と比較することで機械学習の予測精度を表現することができる。損失関数 は主に、予測が正しいほど小さい値を返すような関数が用いられ、特に式 (4.5) に示すような関数 で表される平均二乗誤差 (MSE: Mean Squared Error) が多く用いられる。他には、平均絶対誤 差 (MAE: Mean Absolute Error) や平均二乗誤差の平方根 (RMSE: Root Mean Squared Error) などが用いられる。

$$L = \frac{1}{n} \sum_{i=1}^{n} (y_i - t_i)^2$$
(4.5)

機械学習のトレーニングでは、この損失関数の値が最小になるようにパラメータの値を増減させて 調整を行う。そして、機械学習による予測と損失関数による評価を繰り返すことによって予測の精 度を向上させていく。このパラメータを更新していく方法を勾配降下法と呼ぶ。図 4.5 に勾配降下 法によるパラメータの更新の流れを示す。



図 4.5: 損失関数 L の最小化の流れ。ある重み w_i の時の勾配 $\partial L/\partial w$ を計算し、この勾配が小さ くなるように重みを更新することを繰り返す。この際、更新量を調整するために学習率 η を設定す る。バイアス b に対しても同様に最小化を行う。

勾配降下法は現在のパラメータ w_i における勾配 $\partial L/\partial w_i$ を求め、パラメータを

$$w_{i+1} = w_i - \eta \frac{\partial L}{\partial w_i} \tag{4.6}$$

として更新する。ここで、ηは学習率 (Learning rate) と呼ばれ、一度のパラメータの更新で変更 する値の大きさを表す。そして、新しく設定したパラメータでの勾配を求め、さらに更新していく ことで、損失関数が小さくなる方向にパラメータを調節することができる。この更新を行う回数 をエポック数 (epoch) と呼び、学習率などと合わせて人間が設定する値をハイパーパラメータと 呼ぶ。

4.2 機械学習を用いた CW 作成手法

本節では機械学習の学習方法及び CW を作成する手法について述べる。 従来の作成手法では、シミュレーションデータを用いて CW を作成し、その後実際のデータを



図 4.6: 機械学習を用いた CW 作成の流れ。dR, d ϕ 、Eta_Index、Phi_Index の 4 変数を入力値、 横方向運動量 $p_{\rm T}$ を出力値とした機械学習を用いる。出力された $p_{\rm T}$ は連続値であり、これを 15 段 階の $p_{\rm T}$ 閾値に変換することで CW を作成する。

使用して磁場の影響や検出器のズレに最適化させるといった方法を行っていた。一方本研究で開発 する手法では、実際のデータを学習に利用した機械学習を用いてミューオンの *p*_T の予測を行い、 予測値を使用して CW を作成する。また、実際のデータから作成した CW は逆にシミュレーショ ンでは使用できないことが予想されるため、シミュレーション上のトリガーで使用する CW もシ ミュレーションデータを用いて同様の手法で作成する。

本研究の手法では、初めにトレーニングに使用するシミュレーションデータおよび実際のデータ をトレーニングに適した形式に変更する。次に図 4.6 に示すように、TGC におけるミューオンの ヒット位置の情報とミューオンの飛跡情報の 4 変数から、横方向運動量 $p_{\rm T}$ の値を出力する MLP をトレーニングする。この時、オフラインで内部飛跡検出器や MDT などの情報も用いて再構成さ れたミューオンの $p_{\rm T}^{\rm offine}$ を正解データとして用いる。分析手法として回帰分析を行うため、出力 される値は連続値となる。そこで、出力された $p_{\rm T}$ の値を 15 段階の閾値に変換するために、任意 の値で $p_{\rm T}$ を 15 個に区切り、15 段階の $p_{\rm T}$ 閾値に対応した CW を作成する。

4.2.1 入力データに対する事前処理

本節では学習に用いるシミュレーションデータおよび実際のデータに対して処理を行い、本研究 の機械学習のトレーニングに適した形式に変換する方法について述べる。

本研究ではトレーニングのために、シミュレーションデータ及び実際の測定データを使用する。 シミュレーション用の CW を作成するための機械学習のトレーニングには、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使用する。オフラ イン再構成されたミューオンに対して、TGC の M3 におけるヒット情報が存在することを要求す



図 4.7: TGC におけるトリガーセクターと RoI のナンバリングの概要 [20]。

る。そして、TGC M3 におけるヒット情報からヒット位置の情報 (トリガーセクターの番号、RoI の番号) と飛跡の情報 (d*R*, dφ) を取得する。また、実際の測定に使用する CW を作成するための 機械学習のトレーニングには、2018 年 Run-2 で収集されたデータを用いる。使用するイベントに は HLT のシングルミューオントリガーである「HLT_mu26_ivarmeduium」を要求する。シミュ レーションデータと同様に、イベントの中でも TGC M3 おけるヒット情報が存在するオフライン 再構成されたミューオンをすべて使用し、TGC M3 におけるヒット位置の情報 (トリガーセクター の番号、RoI の番号) と飛跡の情報 (d*R*, dφ) を取得する。

TGC の位置情報におけるナンバリングの変換

トレーニングには、TGC のヒット位置の情報としてトリガーセクターの番号と RoI の番号を使 用する。しかし、図 4.7 に示すように RoI はトリガーセクターごとに設定された番号が与えられて おり、あるトリガーセクターの一番端の列の RoI の番号は隣接するトリガーセクターの RoI の番 号と関連性がない。しかし、隣り合った場所に位置する RoI は似通った磁場構造を持っているた め、トレーニングするにあたって隣り合った RoI の情報も上手く利用できるように工夫した。そ の方法として、TGC におけるヒット位置を表すトリガーセクターの番号と RoI の番号を、新たに 隣り合った RoI の番号が連続するようなナンバリングに変換する。図 4.8 に新たなナンバリング の概要を示す。Eta_Index は RoI を η 方向に 0 から 37 の番号に、Phi_Index は RoI を ϕ 方向に 0 から 191 の番号に読み替えた。

			Phi_	Index	ĸ												
		0	1	2	3	4	5	6	7					188	189	190	191
	Sector0			Sector1				1				Sector47					
X	0	0	1	2	3	3	2	1	0					3	2	1	0
Inde	1	4	5	6	7	7	6	5	4					7	6	5	4
Eta	2	8	9	10	11	11	10	9	8	•	•	•	•	11	10	9	8
	3	12	13	14	15	15	14	13	12					15	14	13	12
	4	16	17	18	19	19	18	17	16					19	18	17	16
•																	
•																	
	33	132	133	134	135												
	34	136	137	138	139												
	35	140	141	142	143												
	36	144	145	146	147												

図 4.8: 新たなナンバリングの概要。マスの中で数字は RoI の番号を表しており、奇数の番号のト リガーセクターでは読み出し回路の関係から RoI のナンバリング順が反転している。TGC におけ るヒット位置の情報 (Sector 番号、RoI 番号) を新たに (Eta_Index, Phi_Index) で指定する。

磁場構造を考慮した学習領域の分割

ATLAS 検出器のトロイド磁石が 8 回転対象に設置されていることにより TGC における磁場構 造は図 4.9 に示すように一様ではない。そのため、本研究では TGC の全領域を一つの機械学習で トレーニングさせるのではなく、図 4.9 で色付けされた領域が示すように、入力データとして使用 する領域を分割して複数の機械学習をトレーニングする。本研究では、TGC のエンドキャプ部を φ方向に 48 分割、η方向に 9 分割、フォワード部をφ方向に 24 分割、η方向に 4 分割し、それぞ れの領域に対して個別の機械学習のトレーニングを行う。トレーニングを行う際には学習させる領 域の周りの領域のみを入力データとして使用する。

ミューオン情報の選別

トレーニングに使用するデータには、多重散乱などの影響で予想とは違った (d*R*, dφ) を持った ミューオンが存在する。CW の精度を上げるために、このようなミューオンの情報はトレーニング に使用したくない。そこで、各 RoI おけるヒットマップを作成し学習に使用するミューオンの選



図 4.9: TGC における磁場構造と磁場構造を考慮するための学習領域の分け方。青線は磁力線を示 している。赤色の領域に対するトレーニングを行う際には緑色で囲まれたの領域のデータを使用す る。

別を行う。

図 4.10 にミューオン情報の選別を行った前後のミューオンのヒットマップの例を示す。図 4.10a に示すように、作成したヒットマップには孤立しているマスや空いているマスが存在する。これは 多重散乱などの影響を受けたミューオンによるもので、このままトレーニングに用いると本来 *p*T を判定する必要のないマスまで学習してしまい、トリガーレートの増加に繋がってしまう。そのた め、以下に説明する手順に沿ってヒットマップを用いたミューオンの選別行う。

- 1. トレーニングに使用するデータを $p_{\rm T}>25~{
 m GeV}$ と $p_{\rm T}<25~{
 m GeV}$ のミューオンに分けて、そ れぞれにおいてヒットマップを作成する。
- ヒットマップに対して、あるマスのエントリー数が x_{cut} 以下の場合にそのマスを削除する パラメータ x_{cut}=(ヒットマップの全エントリー数)/1000 を計算する。
- 3. あるマスに隣接する周囲の8マスのうち、ミューオンがヒットしたマスが2マス以下である 場合、そのマスは削除する。

最後にミューオン情報がないマスには0 GeV のミューオン情報を付与する。



図 4.10: ミューオン情報の選別を行った前後のミューオンのヒットマップの例。(a):選別前。(b): 選別後。

4.2.2 機械学習モデルの設計方法とトレーニング

本節では飛跡の曲がり具合と位置情報からミューオンの横方向運動量 *p*_T を予測させる機械学習 モデルの設計について述べる。

機械学習モデルの設計

本研究において機械学習モデルの構築には、Google 社によって開発された機械学習を用いるた めのオープンソースのフレームワークである TensorFlow [34] と、ニューラルネットワークライブ ラリである Keras [35] を用いた。

本研究で使用する機械学習モデルは、4 つの入力変数を持つ入力層、5 つの隠れ層、p_Tの値を出 力する 1 つの出力層となるような、回帰分析を行う全結合型 MLP モデルを構築する。図 4.11 に 機械学習モデルの概要図を示す。MLP の各隠れ層は以下の表 4.2.2 に示す要素から構成される。

1. Dence layer:前の層からのすべての出力の線形結合を入力としたパーセプトロンの層。1 つの層に存在するパーセプトロンの数をノード数と呼ぶ。

- 2. Batch normalization layer:入力に対し正規化を行う層。
- 3. Dropout unit:学習中にランダムに選ばれたノードの一定割合をゼロにする層。過学習の 抑制のために用いられ、ドロップアウトする割合はハイパーパラメータとして設定する。
- 4. Activation unit:活性化関数を設定する層。

出力層には ReLU 関数を活性化関数として使用する。これは、目的とする出力の *p*_T の値が必ず正 の値を取るためである。誤差逆伝搬法には RMSprop を用いて勾配降下法を行っている。

ハイパーパラメータ

隠れ層の数、ノード数、ドロップアウト率、損失関数、学習率の5個のハイパーパラメータを 表 4.2.2 のように変化させることで評価を行い最適なモデルを選択した。評価には Preferred Networks 社が開発したハイパーパラメータの最適化を自動で行うフレームワークである Optuna [36] を使用し、以下の5項目のハイパーパラメータの範囲に対して最適なものを選んだ。

- 1. 隠れ層の数: 3層から6層
- 2. ノード数: 128, 256, 512, 1024
- 3. ドロップアウト率: 0.01, 0.02, 0.03, 0.04, 0.05
- 4. 活性化関数: Sigmoid 関数、ReLU 関数
- 5. 学習率: 0.01, 0.001, 0.0001

これらの中でいくつかの組み合わせで同等の性能が得られることがわかったが、学習可能なパ ラメータの数が最も少ないネットワークを選択した。パラメータとその値は、ドロップアウト 率 0.05、活性化関数 ReLU、学習率 0.001、そして 5 つの隠れ層と [256, 256, 256, 256, 256] の ノード数を選択する。また、エポック数 (トレーニングを繰り返す回数) を 50、batch_size (トレー ニングデータを分割したサブセットの 1 個当たりのイベント数) を 3000 とした。

トレーニング

シミュレーション用の CW を作成するための機械学習のトレーニングには、シングルミューオ ンのシミュレーションサンプルを使用し、実際の測定用の CW を作成するための機械学習のト レーニングには、2018 年 Run-2 で収集されたデータを使用する。このシミュレーションデータ及 び実際のデータに対して事前処理を行ったものを機械学習トレーニングの入力データとする。正解 のデータとしてはオフライン再構成されたミューオンの $p_T^{offline}$ を利用する。トレーニングデータ の総数は、シミュレーションデータが 500 万イベント、2018 年 Run-2 データが約 1 億イベントで ある。図 4.12 にトレーニングに用いたミューオンの $p_T^{offline}$ 分布を示す。図 4.12b でわかるよう に、本研究で用いたトレーニングに使用する実際のデータは、低い p_T のミューオンの統計量を少 しでも多く得るために、トリガー発行されたイベントのミューオンをすべて使用している.そのた め、トリガーの閾値である $p_T = 26$ GeV のミューオンの数が多くなっている。



図 4.11: 機械学習モデルの概要図。4つの入力、各層に 256 個のノードを持つ 5 つの隠れ層、 $p_{\rm T}^{\rm offline}$ を出力とする全結合型 MLP を構築する。

機械学習モデルの性能評価

本節では、機械学習モデルについての評価を行う。まず、MLP で予測した予測値 p_T^{ML} と正解値 $p_T^{offline}$ の比較を行った。シミュレーションデータをトレーニングに用いた MLP の結果を図 4.13a に示し、実際のデータをトレーニングに用いた MLP の結果を図 4.13b に示す。シミュレーション データをトレーニングに用いた MLP は線形的な予測が行えていることが見て取れる。一方で、実 際のデータをトレーニングに用いた MLP の残差分布は 25 GeV 付近で境目が確認できる。これは トレーニングに用いた学習データの p_T 分布がそのまま影響している。さらに、正解値 $p_T^{offline}$ に対 する予測値 p_T^{ML} の分布にガウシアンフィットした際のの mean 値をを図 4.14 に示す。シミュレー ション用と実際の測定用のそれぞれにおいて、 $p_T^{offline}$ に対して予測値はほぼ線形的な予測が行えて いる事が見て取れ、TGC のヒット位置とミューオンの飛跡情報からミューオンの $p_T^{offline}$ の予測が 行えていることが確認できる。

次に、学習に用いた正解値 (p_T^{offline}) と予測値 (p_T^{ML}) の残差の分布を図 4.15 に示す。それぞれの 残差の分布において、0 を中心とした分布が見て取れ、トレーニングした MLP は p_T の予測がで きている。また、残差の分布を各 p_T^{offline} ごとに作成し、Gaus 関数を用いてフィッティングを行っ た際の mean 値を図 4.16 に示す。図 4.16a に示したシミュレーションデータを用いてトレーニン グを行った MLP の p_T^{offline} ごとの残差の分布から、高い p_T^{offline} の予測になるにつれて予測が正解 値からズレていることがわかる。また、図 4.16b に示した 2018 年 Run-2 のデータを用いてトレー



図 4.12: トレーニングに用いたミューオンの *p*_T 分布。(a):シングルミューオンのシミュレーショ ンサンプル。(b):2018 年 Run-2 のデータ。



図 4.13: MLP の $p_{\rm T}^{\rm offline}$ に対する $p_{\rm T}^{\rm ML}$ の分布。(a): シミュレーションデータを用いてトレーニン グを行った MLP。(b): 2018 年 Run-2 のデータを用いてトレーニングを行った MLP。

ニングを行った MLP の p_T^{offline} ごとの残差の分布は、 $p_T^{\text{offline}} = 20$ GeV 付近で予測が正解値から ズレていることが見て取れる。 p_T^{offline} が p_T が 20 GeV 付近のの予測の精度が悪くなっていること から、トレーニングデータの p_T によるバイアスの影響が表れていると考えられる。そのため、重 みとして $1/p_T$ をかけたトレーニングを行うこと p_T によるバイアスを抑えることができ、MLP の 予測精度が向上する可能性がある。



図 4.14: ある p_T^{offline} に対して、p_T^{ML} の分布をガウシアンフィットした場合の mean 値の分布。 (b):シミュレーションデータを用いてトレーニングを行った MLP。(b):2018 年 Run-2 のデータ を用いてトレーニングを行った MLP。



図 4.15: 学習に用いた正解値 (p_T^{offline}) と予測値 (p_T^{ML}) の残差分布。(a):シミュレーションデータ を用いてトレーニングを行った MLP。(b):2018 年 Run-2 のデータを用いてトレーニングを行った MLP。



図 4.16: ある p_T^{offline} に対して、p_T^{ML} の分布をガウシアンフィットした場合の mean 値の分布。 (b):シミュレーションデータを用いてトレーニングを行った MLP。(b):2018 年 Run-2 のデータ を用いてトレーニングを行った MLP。

4.2.3 出力データを p_T 閾値に変換

トリガー効率の算出

全オフライン再構成されたミューオンの内、ある $p_{\rm T}$ 閾値以上のトリガーが発行された割合 ϵ を式 (4.7) と定義し、トリガー効率の算出を行った。このとき得られるトリガー効率を $p_{\rm T}$ の関数で表したプロットを Turn-on curve と呼ぶ。

$$\epsilon = \frac{\delta \delta p_{\rm T} 閾値以上のトリガーを発行したミューオンの数}{全オフライン再構成したミューオンの数}$$
(4.7)

トリガー効率を算出する際には、Tag-And-Probe法を用いて評価に用いるデータの処理を行う。

実際の実験データ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、そのま まのデータを用いてトリガーの性能評価を行うとバイアスがかかる可能性がある。そこで、このバ イアスを除く手法として Tag-And-Probe 法を用いる。

Tag-And-Probe 法では、一般的に Z ボゾンや J/ψ 粒子の崩壊で生じた 2 つのミューオンを使 用し評価を行う。崩壊由来の 2 つのミューオンのうち、片方のミューオン (Tag) 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、もう一方のミューオン (Probe) をトリガー効率の評価に用 いる。Probe ミューオンに対してトリガーが発行されたかを見ることで、実際の測定でトリガーに よって取得されたミューオンというバイアスをなくしてトリガー効率を見積もることができる。

本研究では、内部飛跡検出器とミューオン検出器でそれぞれ独立にオフライン再構成された Z ボソン由来のミューオンを用いて評価を行う。1回の衝突事象に対し、2つ以上のミューオン 候補が存在するイベントのみを用いる。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、不変質量を再構成する。再構成した不変質量が 80 GeV< M_Z <100 GeV であることを要求することで Z ボソン由来のミューオンと判断する。こ れらのミューオンのうち、一方を Tag ミューオン、もう一方を Probe ミューオンと定義する。まず、 Tag ミューオンがトリガーを発行したかどうかを判定する。Run-2 での実験データを解析に使用す る際のトリガー判定には、HLT のシングルミューオントリガーである「HLT_mu26_ivarmeduium」 を使用する。ここでトリガー発行の判定を行うために $\Delta R = \sqrt{(\Delta \eta)^2 + (\Delta \phi)^2}$ を定義する。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。図 4.17 に Tag ミューオンと HLT の $\Delta R \approx p_{\rm T}$ の関数として表した 2 次元分布を示す。本研究では $\Delta R < 0.001$ 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時、もう一つの 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バイアスの影響はない。



図 4.17: Tag ミューオンと HLT の ΔR 分布。 $\Delta R < 0.001$ ならば Tag ミューオンが HLT を発行 したものとする。

次に、Probe ミューオンを使用してエンドキャプ部のトリガー性能を評価するために、Probe ミューオンと TGC のヒット情報を一致させる。図 4.18 に Probe ミューオンと TGC のヒット情 報の $\Delta R \ e \ p_T$ の関数として表した 2 次元分布を示す。本研究では $\Delta R < 0.04$ を満たせば Probe ミューオンが TGC のヒット情報と一致したものとする。この Probe ミューオンの情報と一致し た TGC のヒット情報を使って評価を行う。



図 4.18: Probe ミューオンと TGC のヒット情報との ΔR 分布。 $\Delta R < 0.04$ ならば Probe ミューオンが TGC のヒット情報と一致したものとする。

フィッティング関数の定義

式 (4.8) を用いて Turn-on curve にフィッティングを行うことでトリガー効率を定量的に評価 する。

$$f(p_{\rm T}) = \frac{a_0}{\exp(\frac{p_{\rm T} - a_1}{a_2}) + 1} \tag{4.8}$$

ここで、トリガーの性能を表す 3 つのパラメータ *a*₀, *a*₁, *a*₂ を以下のように定義する。Turn-on curve にフィッティングした様子を図 4.19 に示す。

1. a_0 : Plateau Efficiency

Turn-on curve が横這いになった時のトリガー効率を表す。Plateau Efficiency が1に近い 方が高性能である。

2. a_1 : Effective Threshold

トリガーの実効的な $p_{\rm T}$ の閾値を表す。トリガー効率が Plateau efficiency の値の 50% となる時の $p_{\rm T}$ の値である。

3. a_2 : Resolution

トリガーの運動量分解能を表す。運動量分解能は Turn-on curve の立ち上がりの鋭さに対応しており、Resolution の値が大きくなると Turn-on curve の立ち上がりが緩くなるため、 トリガーの運動量分解能が悪くなる。



図 4.19: Turn-on curve に対する fitting の例。 a_0 を Plateau efficiency、 a_1 を Effective threshold、 a_2 を Resolution と定義する。

15 段階 p_T 閾値への変換

図 4.20 に示すように、機械学習の予測のターゲットとする $p_{\rm T}$ の値は MLP から連続値として 出力される。そこで任意の値で $p_{\rm T}$ の値を区切り、15 段階の $p_{\rm T}$ 閾値に変換を行う。方法として は、任意の値で $p_{\rm T}$ を区切った時のトリガー効率を求め、Turn-on curve に対して式 (4.8) を用いて フィッティングを行う。フィッティング結果から Effective threshold を求め、Effective threshold が 3.1.1 節で述べた Run-3 における 15 段階閾値となる任意の区切り方を探す。

本研究では出力された $p_{\rm T}$ を 1 GeV から 30 GeV まで 0.1 GeV 刻みで区切り、図 4.21 に示す ように、それぞれの Turn-on curve を導出する。そして、Turn-on curve に対してフィッティング を行い、フィッティング結果から 15 段階の $p_{\rm T}$ 閾値に変換を行った。図 4.22 に Turn-on curve に フィッティングを行って導出した Effective threshold を示す。 $p_{\rm T}$ が 5 GeV から 20 GeV までは 線形的な変換を行うことができているが、一方で $p_{\rm T}$ が 5 GeV 以下の変換はできていないことが見 て取れる。これは、低い $p_{\rm T}$ に対するトレーニングが十分に行われていなかった可能性がある。今 後、トレーニングデータに含まれる低い $p_{\rm T}$ のミューオンのデータ数を増やすことや、低い $p_{\rm T}$ に大 きい重みをかけてトレーニングを行うことで、低い $p_{\rm T}$ に対する予測性能が向上する可能性がある。 最終的に、先行研究 [25] で決定した $p_{\rm T}$ 閾値になるように、フィッティング結果から表 4.1 に示

す値で 15 個に区切り、15 段階閾値の CW を作成した。図 4.23 に本研究で作成した CW の一例 を示す。



図 4.20: MLP から出力された $p_{\mathrm{T}}^{\mathrm{ML}}$ の dR-d ϕ 分布の一例。



図 4.21: 1 GeV から 30 GeV まで 0.1 GeV 刻みで区切り、算出した 300 個の Turn-on curve。こ れらの Turn-on curve から 15 段階の p_T 閾値となるものを 15 個選ぶ。



図 4.22: MLP から出力された $p_{\rm T}$ を 0.1GeV 刻みで区切った時の Turn-on curve における Effective threshold。

	$p_{\rm T}$ 閾値 [GeV]	MLP から出力された $p_{\mathrm{T}}[\mathrm{GeV}]$								
1	3	1.0								
2	4	2.0								
3	5	3.0								
4	6	4.7								
5	7	6.2								
6	8	7.4								
7	9	8.4								
8	10	9.6								
9	11	10.6								
10	12	11.7								
11	13	12.8								
12	14	13.9								
13	15	15.0								
14	18	21.7								
15	20	25.1								

表 4.1: 機械学習からの出力値におけるの 15 段階閾値。



図 4.23: MLP から出力された $p_{\rm T}$ を 15 段階閾値に変換した CW の例。

第5章

初段ミューオントリガーの性能評価

本章では、第4章で述べた手法を用いて作成した2種類の Coincidence Window(シミュレー ション用の CW と実際の測定用の CW)を用いたトリガーの性能の評価を行う。

5.1 機械学習を用いて作成した CW の 15 段階閾値の評価

便宜上、本研究の手法で作成した 2 種類の CW について、シミュレーション用の CW を CW_{Simu}、実際の測定用の CW を CW_{Data} と呼び、比較対象として 2022 年度 Run-3 で使用された CW を CW₂₀₂₂ と呼ぶこととする。

2.3 節で述べた L1 トリガーには、ミューオンの不変質量を指針としたトリガーを持つ L1Topo が存在する。しかし、不変質量を計算するときに使用するミューオンの運動量は、L1Muon から送 られてくる $p_{\rm T}$ 閾値であるため、L1Muon の $p_{\rm T}$ 閾値の細かさがそのまま L1Topo のトリガー性能 に影響する。そこで、Run-3 では L1Muon における判定可能な $p_{\rm T}$ 閾値を 6 段階から 15 段階に増 設することで、より細かい精度での $p_{\rm T}$ 判定を可能とし、L1 トリガー全体としてのトリガー性能の 向上を図った。したがって、本研究で作成する CW にも正確に 15 段階の $p_{\rm T}$ 判定ができることが 要求される。

本節では、全オフライン再構成されたミューオンの内、ある p_T 閾値以上のトリガーが発行され た割合 ϵ を計算し、トリガー効率の算出を行った。また、 ϵ をオフライン再構成した p_T の関数と して表した Turn-on curve を描き、式 (4.8)の関数によってフィッティングを行う事で、トリガー 性能の評価を行った。このとき、Tag-And-Probe 法を用いて評価に用いるデータの処理を行う。

5.1.1 作成した CW の 15 段階の p_T 閾値

図 5.1a に CW_{Simu} を用いてを要求した 15 段階の p_T 閾値における Turn-on curve を示す。評価には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た。CW₂₀₂₂ と同様に、本研究の手法で作成した CW_{Simu} は 15 段階に分かれた Turn-on curve を描けていることがわかる。また、図 5.1b に CW_{Data} を用いて 15 段階の p_T 閾値における Turn-on curve を示す。評価には 2018 年



図 5.1: 機械学習を用いて作成した CW の 15 段階の閾値における Turn-on curve。

Run-2 のデータに対して $Z \rightarrow \mu\mu$ による Tag-And-Probe 法を用いた。こちらも同様に、本研究 の手法で作成した CW_{Data} は 15 段階に分かれた Turn-on curve を描けていることがわかる。本 研究の手法によって作成された 2 種類の CW は、2022 年度 Run-3 において使用された CW₂₀₂₂ と同様に細かい精度で 15 段階の判定が可能であり、本研究の手法を用いて 15 段階の閾値を持った CW を作成できることが確認できた。

5.1.2 CW の最適化の効果

TGC のチェンバーごとにミューオンの電荷別にトリガー効率を算出することで CW の最適化 の効果を評価する。ある TGC チェンバーにおける CW_{Data} と CW₂₀₂₂ のミューオンの電荷別に 計算した $p_{\rm T}$ 閾値が 14 GeV のトリガー効率を図 5.2 に示す。磁場中のミューオンは電荷によって 曲がる方向が違うため、検出器アライメントのズレがある場合にはトリガー判定にミューオンの電 荷依存が生じる。図 5.2a に CW₂₀₂₂ における電荷別に計算した Turn-on curve を示す。CW₂₀₂₂ は検出器のズレに対する補正を行っていないために、ミューオンの電荷別に計算したトリガー効 率に大きな差が出ることが確認できる。一方、図 5.2b に示すように、本研究の手法で作成した CW_{Data} は最適化されたことにより、ミューオンの電荷別に計算した Turn-on curve がほとんど 一致していることが見て取れる。さらに、この評価を TGC の全チェンバーに対して行い、正電荷 と負電荷のミューオンに対するトリガー効率の Effective Threshold の差を図 5.3 に示す。図 5.3a に示すように CW₂₀₂₂ では多くのチェンバーで Effective Threshold の差がみられるが、図 5.3b に示すように CW_{Data} では CW が最適化されたことにより、Effective Threshold の差がなくなっ ていることが見て取れる。これより、本研究の手法による最適化によって検出器アライメントのズ レに対する補正が正しく行われていることが確認できる。

次に、2018 年 Run-2 データを評価に用いた時の、CW_{Data} と CW_{Simu} の性能の比較を行うこと

58



図 5.2: あるチェンバーにおける電荷別に計算した $p_{\rm T}$ 閾値 14 GeV の Turn-on curve の比較。赤 が正電荷、青が負電荷。



図 5.3: TGC の全チェンバーにおける正電荷と負電荷のミューオンに対するトリガー効率の Effective Threshold の差の分布。pT 閾値 14 GeV のトリガー効率を評価している。

で、本研究の手法がトレーニングデータの違いを学習できているかを確認する。図 5.4 に *p*_T 閾値 14 GeV における Turn-on curve を比較したプロットを示す。最適化が行われた CW_{Data} を用い たトリガーの方が、実際のデータに対してのトリガー効率が良くなっているのが見て取れる。

本研究の手法では、実際のデータを機械学習のトレーニングに用いたことで、TGC 検出器の位置による磁場構造の違いや検出器のズレを自動で補正することができ、CW が最適化されたことを示している。



図 5.4: CW_{Data} と CW_{Simu} の Turn-on curve。p_T 閾値 14 GeV のトリガー効率の比較を行う。

5.1.3 現行のトリガーとのトリガー性能の比較

次に、それぞれの 15 段階の pr 閾値のトリガー性能について評価を行う。

トリガー効率の評価

まず、CW_{Simu} と CW₂₀₂₂ の比較と、CW_{Data} と CW₂₀₂₂ の比較を行う。それぞれの評価には、 シングルミューオンのシミュレーションデータと 2018 年 Run-2 のデータを評価に用いる。ここで は、式 4.7 で示したトリガー効率 *ϵ* を用いて比較を行う。

図 5.5a には $p_{\rm T}$ 閾値が 14 GeV の時の、CW₂₀₂₂ と CW_{Simu} の Turn-on curve の比較を示し、 図 5.5b には $p_{\rm T}$ 閾値が 14 GeV の時の、CW_{Data} を CW₂₀₂₂ の Turn-on curve の比較を示す。 2022 年度 Run-3 で使用されている CW₂₀₂₂ に比べて、本研究の手法ので作成した CW の方が Turn-on curve の立ち上がりが鋭くなっており、トリガー性能が良くなっていることが見て取れ る。このとき、CW₂₀₂₂ はトリガー効率が 85.4% であったのに対し、CW_{Data} ではトリガー効率 が 86.7% となったことから、約 1% の向上が確認できた。また、図 5.6 と図 5.7 に他の $p_{\rm T}$ 閾値に おける比較を示す。15 段階の閾値において、本研究の手法によって作成された 2 種類の CW は、 2022 年度 Run-3 において使用された CW₂₀₂₂ と同様に鋭く立ち上がっていることが見て取れる。

さらに、これらの Turn-on curve に式 (4.8) によるフィッティングを行い、パラメータの比較 を行う。図 5.8a に CW_{Simu} と CW₂₀₂₂の各 p_T 閾値の Resolition の比較、図 5.8b に CW_{Data} と CW₂₀₂₂の各 p_T 閾値の Resolition の比較を示す。また、図 5.9a に CW_{Simu} と CW₂₀₂₂の 各 p_T 閾値の Plateau Efficiency の比較、図 5.9b に CW_{Data} と CW₂₀₂₂の各 p_T 閾値の Plateau



図 5.5: p_T 閾値 14 GeV における Turn-on curve の比較。

Efficiency の比較を示す。

まず、シミュレーションデータをトレーニングに用いて作成した CW_{Simu} と 2022 年 Run-3 で 使用された CW₂₀₂₂ を比較すると、Resolition 及び Plateau Efficiency がほとんど一致しているこ とがわかる。このことから、本研究の手法は従来の手法と同様の性能を維持できる CW の作成が 可能であることが確認できた。次に、実際のデータをトレーニングに使用した CW_{Data} と 2022 年 Run-3 で使用された CW₂₀₂₂ を比較すると、 $p_{\rm T}$ 閾値が 14 GeV のトリガーでは Resolition が改善 され、Plateau Efficiency が約 2% 向上したことが見て取れる。これは、実際のデータをトレーニ ングに用いたことで、検出器アライメントの最適化が行われたことを表している。

p_T 判定精度の評価

 $p_{\rm T}$ の判定精度を式 (5.1) で計算する $p_{\rm T}$ residual を用いて評価する。

$$(p_{\rm T} \text{ residual}) = \frac{p_{\rm T}^{\rm L1} - p_{\rm T}^{\rm offline}}{p_{\rm T}^{\rm offline}}$$
(5.1)

ここで、 $p_{\rm T}^{L1}$ は L1Muon で CW を用いて判定される $p_{\rm T}$ 閾値、 $p_{\rm T}^{\rm offline}$ はオフライン再構成された ミューオンで $p_{\rm T}$ ある。そのため、 $p_{\rm T}^{\rm offline}$ に対して正しく $p_{\rm T}^{L1}$ を判定できていれば 0 に近づき、0 から離れるほど $p_{\rm T}^{L1}$ が $p_{\rm T}^{\rm offline}$ とずれていることを表す。

この $p_{\rm T}$ residual を 1 GeV ごとの $p_{\rm T}^{\rm offline}$ に対して計算し、細かい $p_{\rm T}$ に対する判定制度の評価 を行う。まず、本研究の手法で作成した CW_{Simu} と 2022 年度 Run-2 で使用された CW₂₀₂₂ の比 較を行う。図 5.10 に 1 GeV ごとの $p_{\rm T}^{\rm offline}$ に対する $p_{\rm T}$ residual 分布を示す。図 5.11 には 1 GeV 刻みの $p_{\rm T}$ residual 分布の Mean 値と標準偏差を示した。CW₂₀₂₂ と比べ CW_{Simu} は同程度のパ フォーマンスが得られることが確認できる。一方で低い $p_{\rm T}$ に対する判定精度は CW₂₀₂₂ と比べて 悪くなっている。これは、 $p_{\rm T}$ 閾値の選択方法の影響が表れていると考えられる。CW₂₀₂₂ を作成



図 5.6: $p_{\rm T}$ 閾値 3 GeV~20 GeV における CW_{Simu} と CW₂₀₂₂ の Turn-on curve の比較。評価に はシングルミューオンのシミュレーションデータを使用した。



図 5.7: p_T 閾値 3 GeV~20 GeV における CW_{Data} と CW₂₀₂₂ の Turn-on curve の比較。評価に は 2018 年 Run-2 のデータを使用した。



図 5.8:各 $p_{\rm T}$ 閾値における Resolution の比較。



図 5.9: 各 p_T 閾値における Plateau Efficiency の比較。

した先行研究 [25] では、この判定精度が向上するような $p_{\rm T}$ 閾値の選択方法を確立し、15 段階の $p_{\rm T}$ 閾値を選んでいた。そのため、CW₂₀₂₂ と本研究の手法で作成した CW の判定精度と比較する と判定精度が悪くなっている。しかし本研究の手法は、機械学習の出力からの $p_{\rm T}$ 閾値の選択方法 を変えることで、15 段階 $p_{\rm T}$ 閾値を柔軟に選択できる。そのため、図 5.11b に示すように CW₂₀₂₂ と同程度以上の標準偏差を得られていることから、CW₂₀₂₂ と同程度の判定精度を持つような $p_{\rm T}$ 閾値を選択できると見込まれる。

同様にして、本研究の手法で作成した CW_{Data} と 2022 年度 Run-2 で使用された CW₂₀₂₂ の比較を行う。図 5.12 に 1 GeV ごとの $p_{\rm T}^{\rm offline}$ に対する $p_{\rm T}$ residual 分布を示し、図 5.13 には 1GeV



図 5.10: TGC における 1GeV 刻みの pT residual 分布 (3~18 GeV)。青が本研究の手法で作成した CW_{Simu} を用いた結果、黒が 2022 年度 Run-2 で使用された CW₂₀₂₂ を用いた結果である。



図 5.11:本研究の手法で作成した CW_{Simu} と 2022 年度 Run-2 で使用された CW₂₀₂₂ の $p_{\rm T}$ residual の比較。

刻みの $p_{\rm T}$ residual 分布の Mean 値と標準偏差を示す。本研究の手法で作成した CW_{Data} は、2022 年度 Run-2 で使用された CW₂₀₂₂ と比べて高い $p_{\rm T}$ では判定精度の向上が確認できる。一方で、 低い $p_{\rm T}$ における判定精度の mean 値が悪くなっているが、標準偏差を比べると改善されているこ とから、CW_{Simu} の評価で述べたように、機械学習の出力からの $p_{\rm T}$ 閾値の選択方法によって低い $p_{\rm T}$ における判定精度の改善が見込まれる。

5.1.4 トリガーレートの評価

次に、本手法で作成した CW を使用したときのトリガーレートの評価を行う。トリガーレート とは、実験データにおけるトリガーが発行された事象数である。ここでは 2016 年の Run-2 デー タを用いてトリガーレートを計算する。Run-2 データには HLT でのプリスケールによるバイアス が存在するため、バイアスのない状態でトリガーレートを計算するために、「HLT_noalg_L1MU4」 を要求する。このトリガーは L1 トリガーにおいて $p_{\rm T}$ 閾値が 4GeV 以上を要求するが、HLT に よる事象選別のない (Pass-through) トリガーチェインである。その後、HLT_noalg_L1MU4 が 鳴ったイベントの中で L1_MUx が鳴ったイベントがいくつ存在するかを調べ、ルミノシティが 2 × 10⁴³ cm⁻²s⁻¹ の時の L1_MU4 のトリガーレートをかけることで MUx のトリガーレートを見 積もる。式 (5.2) にトリガーレートの計算式を示す。

$$MUx のレート [kHz] = \frac{MUx が鳴ったイベント数}{HLT_noalg_L1MU4 が鳴った全イベント数} \times L1_MU4 のレート [kHz] (5.2)$$

図 5.14 に 2016 年で取得されたデータを用いて算出したトリガーレートを示す。

プライマリートリガーである pT 閾値 14 GeV のトリガーレートは、本研究の手法で作成した



図 5.12: TGC における 1GeV 刻みの pT residual 分布 (3~18 GeV)。赤が本研究の手法で作成した CW_{Data} を用いた結果、黒が 2022 年度 Run-2 で使用された CW₂₀₂₂ を用いた結果である。


図 5.13:本研究の手法で作成した CW_{Data} と 2022 年度 Run-2 で使用された CW_{2022} の p_T residual の比較。



図 5.14: TGC におけるシングルミューオンのトリガーレート。

 CW_{Data} では 15 kHz、2022 年度 Run-2 で使用された CW_{2022} では 16 kHz となり、トリガーレートの削減が確認できた。また、 p_T 閾値 7 GeV 以上のトリガーにおいて、 CW_{Data} のトリガーレートの値は CW_{2022} と同等であることが見て取れる。しかし、 p_T 閾値 4 GeV、5 GeV、6 GeV のトリガーに関してはトリガーレートの増加が見られた。これはトレーニングデータに含まれる多重散乱の影響を受けた低い p_T のミューオンによるものだと考えられる。シミュレーション上でも多重

散乱を考慮してミューオンの運動をシミュレートしているが、完全に多重散乱の影響をシミュレー ションできているわけではない。そのため、シミュレーションデータには含まれていないような多 重散乱したミューオンの影響で、CW_{Data}における低い *p*_Tの判定領域が大きく広がったことが原 因だと考えられる。本研究で開発した手法では、*p*_T 閾値を柔軟に選択することができるため、ト リガーレートの削減に焦点を置いた *p*_T 閾値の選択をすることでトリガーレートを抑えることので きる CW を作成可能である。

5.2 性能評価のまとめ

本章では本研究の手法で作成した CW の評価を行った。

まず、本研究の手法で期待される機械学習による最適化の評価を行った。ミューオンの電荷別に トリガー効率を算出したところ、2022 年 Run-3 で使用された CW₂₀₂₂ で見られたトリガー効率の 電荷依存が、本研究の手法で作成した CW では見られなくなった。このことから、検出器アライ メントの最適化が行えていることが確認できた。

次に、15 段階のトリガー効率の評価を、Turn-on Curve の Plateau Efficiency と Resolution と いった観点から評価を行っ結果、本研究の手法で作成した 2 種類の CW は CW₂₀₂₂ の Turn-on Curve と比べてトリガー効率の向上が確認できた。また、L1Muon のプライマリートリガーであ p_{T} 閾値 14 GeV のトリガー効率について、CW₂₀₂₂ はトリガー効率が 85.4% であったのに対 し、CW_{Data} ではトリガー効率が 86.7% となったことから約 1% の向上が確認できた。

さらに、 $p_{\rm T}$ 判定精度の評価を $p_{\rm T}$ residual を計算することで評価を行った。本研究の手法で作成 した CW は、CW₂₀₂₂ と比べて判定精度の向上がみられる。しかし、低い $p_{\rm T}$ における $p_{\rm T}$ residual では、mean 値が悪くなっている。一方で Resolution を比べると改善されていることから、機械学 習の出力からの $p_{\rm T}$ 閾値の選択方法を変更することによって低い $p_{\rm T}$ における判定精度の向上が見 込まれる。

最後に、トリガーレートの評価を行った。プライマリートリガーである p_T 閾値 14 GeV のトリ ガーレートは、本研究の手法で作成した CW_{Data} では約 15 kHz、2022 年度 Run-2 で使用された CW₂₀₂₂ では約 16 kHz となり、トリガーレートの削減が確認できた。また、 p_T 閾値 7 GeV 以上 のトリガーにおいて、CW_{Data} のトリガーレートの値は CW₂₀₂₂ と同等であることが見て取れる。 しかし、 p_T 閾値 6 GeV 以下のトリガーにおいてはトリガーレートの増加がみられた。これはシ ミュレーションでは表現しきれないような多重散乱したミューオンの影響によるものだと考えら れる。

以上より、本研究の手法である機械学習を用いた手法は、従来の手法と同様に 15 段階の閾値を 持った CW の作成を可能とし、さらに検出器アライメントに対する補正を自動的に行えることが 確認できた。本研究の手法では将来、検出器やシステムのアップグレードが行われた際に本研究の 手法が有効である。

第6章

結論と展望

2022 年より LHC 第三期運転 (Run-3) が開始され、第二期運転 (Run-2) に比べて重心系エネ ルギーとルミノシティが増加したことに伴ってイベント数が増加する。これらに対応すべく、 ATLAS 実験のトリガーシステムを改良する必要がある。

トリガーシステムの中でも初段トリガーに分類される初段ミューオントリガーは、ミューオンの ヒット情報をもとに Coincidence Window (CW)を参照することで、短時間でミューオンの横方 向運動量 *p*_T を算出している。そこで、LHC 及び ATLAS 検出器のアップグレードに伴って、CW を Run-3 に対応したものに作り直す必要がある。

従来の手法では、CW はシングルミューオンのシミュレーションデータから作成しており、実際 の検出器のズレや歪みが考慮されていない。そのため、実際の測定にこの CW を適用するとトリ ガー性能が低下してしまう。そこで、検出器のズレや歪みに対する補正を行うことで CW を最適 化し、トリガー性能を向上させる手法が先行研究によって確立された。しかし、この手法では検出 器の位置ごとに手動で最適化を行うため、作業量が膨大であることが問題となり、従来の手法に代 わる効率的な CW の作成及び最適化手法が求められた。そこで、本研究ではエンドキャプ部の初 段ミューオントリガーにおいて、トリガー判定の際に使用されている CW を効率よく作成及び最 適化する手法の開発を行った。

本論文では近年急速に発展している機械学習に注目し、機械学習を CW の作成に用いること作 成及び最適化する作業の効率化を図った。多層パーセプトロンの機械学習モデルを構築し、シミュ レーションデータをトレーニングに使用することで、従来の手法で作成した CW と同様の性能を 持つ CW の作成が可能であることを示した。また、実際のデータをトレーニングに使用すること で、CW に対して検出器のズレの補正ができることを証明した。機械学習で作成した CW を用い た際のトリガー性能についての評価を行い、代表的な閾値として *p*T 閾値が 14 GeV のトリガーに 関して、2022 年度 Run-3 で使用されている CW よりも運動量分解能が向上し、トリガー効率が約 1% 向上したことを確認した。本研究で開発した手法では実際のデータをトレーニングに用いるこ とで、従来の手法と同等以上の性能の CW を作成できるモデルを学習できるだけでなく、TGC 検 出器の位置による磁場構造の違いや検出器アライメントのズレを自動で織り込んでモデルの学習を 行う事ができることを示した。そのため、本研究の手法では、従来のような検出器の位置ごとに手 動で最適化を行う必要が無くなるといった利点がある。さらに機械学習のトレーニングに Run-3 のデータを使用し、CW を作成することで新たな検出器のズレに対応することができるため、トリ ガー性能の向上が期待される。また、本研究で提案した作成手法では、機械学習を用いることで従 来の手法よりも CW を効率よく短時間で作成することができ、さらに、本研究の開発した機械学 習モデルは *p*T 閾値の変更に対して柔軟な対応が可能であるため、実験期間中に迅速に CW のアッ プデートが可能となり、今後のアップグレードやトリガーシステムに対する要求の変更に対して も、即座に対応が可能であると期待される。

本研究では検出器の設置位置のズレを機械学習を用いることで補正を自動的に行い、性能を向上 させることが可能であることを示した。したがって他の理由による検出器の状態変化や、補正値の 測定が難しい別の検出器にも対応できる可能性があり、実験上の様々な性能改善に応用できること が期待される。

謝辞

本論文の作成にあたり、多くの方々にご指導ご鞭撻を賜りました。

指導教員である前田順平先生には、非常にお世話になりました。深く御礼申し上げます。何もわ からなかった私に ATLAS 実験のことや、ソフトウェア、機械学習といった最新技術などの知識 を、根気よく指導いただいたおかげで研究を進めていくことができました。また、CERN に行く 機会をいただき、心から感謝しております。実際に CERN に行き、ATLAS 検出器を目にするこ とができたことはとても良い経験になりました。学会等の発表準備の際には何度も指導や添削をし て頂き、本当にありがとうございました。修士課程の2年間で大変多くの知識と技術を得ることが できたのは前田先生のおかげです。

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、神大内部のミーティ ングや日常の研究生活において様々な助言をいただきましたこと、大変感謝しております。また、 竹内康雄先生、身内賢太朗先生、鈴木州先生に、東野聡先生には研究室ミーティングのコロキウム で様々なことをご指導いただきました。お礼申し上げます。

神戸大学 ATLAS グループの先輩である日比宏明さん、安部草太さん、寺村七都さん、池森隆太郎さん、野口健太さんには多くのことで手助けをしていただきました。研究の技術的な部分の質問にも懇切丁寧にご教示頂いたことで、本研究をやり遂げることができました。本当にありがとうございました。研究以外の面でも多くの面倒を見ていただいたことは心の大きな支えでした。色々とお世話になりました。ありがとうございます。

研究室の同期である丸元星弥君、金崎奎君、中山郁香さん、山下翼君、高橋真斗君、みんなと切 磋琢磨し、互いに励ましあったことで、ここまで研究をやり遂げることができました。みんなのお かげでとても充実した研究生活を送ることができました。丸元君、何度も研究室で徹夜しました ね。今となってはいい思い出です。金崎君、一緒に帰宅しながらいろんな相談に乗ってくれてあり がとう。中山さん、卒業研究では色々お世話になりました。とても助かりました。山下君、よく雑 な絡み方をして困らせてしまいましたが、私の相手をしてくれてありがとう。高橋君、研究の相談 から日常の雑談まで多くのことをこの2年間語り合いましたね。君との雑談の時間はとても良い気 分転換になり、研究生活の心の支えでした。ありがとう。博士課程でも頑張ってください。後輩の 田路君、山下さん、森本君、先輩としてあまり大層なことはできなかったですが、君たちのより一 層の活躍を願っています。

また、ATLAS Japan グループの皆様には大変お世話になりました。KEK の青木雅人先生、東

京大学の斉藤智之先生、名古屋大学の堀井泰之先生及び ATLAS Japan の TGC グループに所属し ている先輩方には日頃よりお世話になりました。ミーティングでは多くの助言を頂き、CERN 滞 在中には気にかけていただきありがとうございました。

最後に、これまで何不自由のなく育て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

- ATLAS Collaboration, Observation of a new particle in the search for the Standard Model Higgs boson with the ATLAS detector at the LHC, Phys. Lett. B, Vol. 716, pp. 1–29, 2012.
- [2] Quantum Diaries, The Standard Model: a beautiful but flawed theory, https: //www.quantumdiaries.org/2014/03/14/the-standard-model-a-beautiful-, Accessed on 01/06/2023.
- [3] CERN, CERN: Home https://www.home.cern/.
- [4] CERN, The Large Hadron Collider https://home.cern/science/accelerators/large-hadron-collider.
- [5] ATLAS Collaboration, The ATLAS Experiment at the CERN Large Hadron Collider, JINST, Vol. 3, p. S0800, 2008.
- [6] ATLAS Collaboration, Technical Design Report for the Phase-I Upgrade of the ATLAS TDAQ System, CERN-LHCC-2013-018, ATLAS-TDR-023, 2013.
- [7] CERN, CMS Experiment https://cms.cern/.
- [8] CERN, LHCb Experiment http://lhcb-public.web.cern.ch/WelcomeGGG.html.
- [9] CERN, ALICE Experiment https://alice-collaboration.web.cern.ch/.
- [10] P. Mouche, Overall view of the LHC, Vue d'ensemble du LHC, OPEN-PHO-ACCEL-2014-001, 2014.
- [11] O. Brüning et al., LHC Design Report, CERN-2004-003-V-1, 2004.
- [12] E. Mobs, The CERN accelerator complex Complexe des accélérateurs du CERN, OPEN-PHO-ACCEL-2016-009, 2016.
- [13] CERN, Linear accelerator 4 https://home.cern/science/accelerators/linear-accelerator-4.
- [14] CERN, The Proton Synchrotron Booster https://home.cern/science/accelerators/proton-synchrotron-booster.

- [15] CERN, The Proton Synchrotron https://home.cern/science/accelerators/proton-synchrotron.
- [16] CERN, The Super Proton Synchrotron https://home.cern/science/accelerators/super-proton-synchrotron.
- [17] ATLAS Collaboration, ATLAS Magnetic Field http://atlas.web.cern.ch/Atlas/GROUPS/MUON/magfield/.
- [18] ATLAS Collaboration, Experiment Briefing: Keeping the ATLAS Inner Detector in perfect alignment, ATLAS-PHOTO-2020-018, 2020.
- [19] ATLAS Collaboration, Technical Design Report for the Phase-II Upgrade of the ATLAS Muon Spectrometer, CERN-LHCC-2017-017, ATLAS-TDR-026, 2017.
- [20] D. Lellouch and L. Levinson and K. Hasuko, Naming and numbering scheme for the Endcap muon trigger system, ATL-MUON-2001-002, 2000.
- [21] ATLAS Collaboration, New Small Wheel Technical Design Report, CERN-LHCC-2013-006, ATLAS-TDR-020, 2013.
- [22] ATLAS Collaboration, Small-Strip Thin Gap Chambers for the Muon Spectrometer Upgrade of the ATLAS Experiment, ATL-MUON-PROC-2020-008, 2020.
- [23] ATLAS Collaboration, Performance of the ATLAS Trigger System in 2015, CERN-EP-2016-241, 2017.
- [24] A. Ruiz-Martinez et al., Run 3 trigger menu design, ATL-COM-DAQ-2019-116, 2019.
- [25] 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.
- [26] S. Akatsuka *et al.*, Plots for approval: Performance estimation of the Level-1 Endcap muon at Run 3, ATL-COM-DAQ-2018-033, 2018.
- [27] ATLAS Level-1 Endcap Muon Trigger group, Full Design Report of the ATLAS Level-1 Endcap Muon Trigger in the Phase-I upgrade, AT1-DA-AR-0001, EDMS Id 1915231, 2018.
- [28] 岡崎 佑太, LHC-ATLAS 実験 Run-3 に向けたミューオントリガーの改良とハードウェアへの実装, 京都大学 修士学位論文, 2018.
- [29] 佐野 裕太, TGC positon measurement based on Run 2 data, Muon Combined Performance meeting on 15th Feb, 2017.
- [30] 山内 克弥, LHC-ATLAS 実験ミュー粒子検出器の精密アライメントによるトリガー効率の改善, 名古屋大学 修士学位論文, 2013.
- [31] 木戸 将吾, ATLAS 実験 Run2 におけるレベル 1 ミューオントリガーの性能評価及び最適化 の研究, 神戸大学 修士学位論文, 2016.
- [32] 岡野原 大輔, ディープラーニングを支える技術 「正解」を導くメカニズム 技術基礎, 株式会 社技術評論社, 2022.
- [33] CMS Collaboration, Electron and photon reconstruction and identification with the

CMS experiment at the CERN LHC, JINST, Vol. 16, p. P05014, 2021.

- [34] M. Abadi et al., TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems, 2015. https://www.tensorflow.org/, Accessed on 31/1/2023.
- [35] François Chollet et al., Keras. https://keras.io, Accessed on 31/1/2023.
- [36] Akiba et al., Optuna: A Next-generation Hyperparameter Optimization Framework, 2019. https://optuna.org/, Accessed on 31/1/2023.