

修士学位論文

高輝度 LHC-ATLAS 実験に向けた 深層学習を応用したトリガーシステムの提案と 性能評価

令和4年2月4日

専攻名 物理学専攻

学籍番号 205S101S

氏名 安部 草太

神戸大学大学院理学研究科博士課程前期課程

概要

欧州素粒子原子核研究機構 (CERN) で行われている LHC-ATLAS 実験では、標準模型の精密検証や標準模型を超える物理の探索が行われている。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おらず、2029 年からは LHC 加速器の高輝度化アップグレードにより高い統計量を実現し、さらなる探索が進められる予定である。

LHC 加速器の高輝度化アップグレードに伴いルミノシティが向上し、一度のバンチ交差における背景事象数が大きく増加する。そのため、物理的に興味のある事象のみを選別して保存する「トリガー」がより重要な役割を担うようになる。さらにルミノシティ向上に伴いデータの蓄積速度が上昇するため、データの処理や保存に必要な計算機資源量が大きく増加する。現在の試算では計算機資源の増設がデータ量の増加に間に合わない見込みとなっており、ATLAS 実験では必要となる計算機資源量の削減が課題となっている。

また高輝度 LHC-ATLAS 実験におけるもう一つの課題として、長期に渡る実験期間中のデータ取得のさらなる安定化が挙げられる。一度の運転期間が数年と長期に渡る ATLAS 実験では、実験期間中に検出器の状態変化が発生し、トリガー効率の低下などの問題が発生する。実際に、LHC-ATLAS 実験 Run 2 の TGC 検出器においては実験期間の経過に伴い動作しない検出器が増加し、トリガー効率の低下が見られていた。本研究ではまず初めに、高輝度 LHC-ATLAS 実験で運用される予定のハードウェアトリガーのアルゴリズムにおいてデッドチェンバーの影響を調査し、現行のハードウェアトリガーと同様にデッドチェンバーによりトリガー効率が低下する事を示した。

本研究ではこれら 2 つの課題に対して、新たなトリガーシステムの開発というアプローチで解決策の探求を試みた。TGC 検出器におけるミュオン飛跡の特徴に着目し、畳み込みニューラルネットワークを用いてミュオンの角度情報を再構成するアルゴリズムを開発した。またこのアルゴリズムを用いてトリガー判定を行うことにより、デッドチェンバーが存在する場合においても高いトリガー効率を維持できる事を示した。特にデッドチェンバーが 2 層存在する場合においては、従来のトリガーアルゴリズムよりも最大で 20% 程度高いトリガー効率を達成した。

さらに、本研究で開発したトリガーアルゴリズムを核として、アクセラレータカードを利用する新たなトリガーシステムの提案を行った。提案したトリガーシステムでは、実験期間中に取得できる大量のデータを用いて、継続的に角度情報を再構成するモデルのアップデートを行う事ができ、実験期間中の検出器の状態変化に迅速に対応する事が可能である。また、実験期間中のアップデートによるトリガー性能の向上を通して、誤って取得される事象をさらに削減することを期待できる。

本研究はハードウェアトリガーに深層学習を導入することの利点について記述しており、今後の素粒子実験における課題解決の一助となる事が期待される。

目次

第 1 章	序論	4
第 2 章	LHC-ATLAS 実験	6
2.1	LHC 加速器	6
2.2	ATLAS 実験	8
2.2.1	ATLAS 検出器における座標系	8
2.2.2	内部飛跡検出器	10
2.2.3	カロリメータ	12
2.2.4	ミュオンスペクトロメータ	13
2.2.5	マグネットシステム	19
2.3	高輝度 LHC-ATLAS 実験に向けたアップグレード計画	21
2.3.1	LHC 加速器のアップグレード	21
2.3.2	ATLAS 検出器のアップグレード	22
2.3.3	バレル部への新ミュオン検出器の導入	22
第 3 章	初段ミュオントリガーシステム	25
3.1	ATLAS トリガーシステム概観	25
3.1.1	LHC-ATLAS 実験 Run 3 におけるトリガーシステム	25
3.1.2	高輝度 LHC-ATLAS 実験におけるトリガーシステム	27
3.2	初段ミュオントリガーシステム	30
3.2.1	LHC-ATLAS 実験 Run 3 における初段ミュオントリガーシステム	30
3.2.2	高輝度 LHC-ATLAS 実験における初段ミュオントリガーシステム	33
3.3	ミュオントリガーシステムにおける課題	36
3.3.1	実験規模の拡大によるコストの増大	36
3.3.2	長期間の実験におけるデータ取得の更なる安定化	36
3.4	本研究の目的	37
第 4 章	デッドチェンバー存在下におけるトリガーアルゴリズム性能評価	39
4.1	デッドチェンバー	39

4.2	デッドチェンバーがトリガー性能へ与える影響の評価方法	43
4.2.1	現行トリガーアルゴリズムの評価に用いるサンプルの作成	43
4.2.2	高輝度 LHC-ATLAS 実験におけるトリガーアルゴリズムの評価に用いる サンプルの作成	45
4.2.3	性能評価の方法	45
4.3	現行トリガーアルゴリズムにおける性能評価	47
4.4	高輝度 LHC-ATLAS 実験のトリガーアルゴリズムにおける性能評価	50
4.4.1	性能評価のまとめ	52
第 5 章	深層学習を用いたトリガーアルゴリズムの構築	53
5.1	トリガーシステムの設計	53
5.1.1	TGC 検出器における飛跡の特徴	53
5.1.2	トリガーシステムへの深層学習の導入	55
5.2	機械学習と深層学習	58
5.2.1	機械学習	58
5.2.2	深層学習	60
5.3	素粒子実験と深層学習	65
5.3.1	検出器シミュレーション	65
5.3.2	波形弁別	66
5.4	深層学習を用いた飛跡の再構成	67
5.4.1	入力画像の前処理	67
5.4.2	角度再構成モデルの設計とトレーニング	70
5.5	角度再構成モデルの性能評価	74
5.6	トリガー性能としての評価	80
5.6.1	シミュレーションサンプルの作成	80
5.6.2	性能評価の方法	80
5.6.3	トリガー性能の評価	81
5.7	ファインチューニングによる実験期間中の継続的最適化	86
5.7.1	ファインチューニング	86
5.7.2	継続的最適化により得られる恩恵	86
5.7.3	継続的最適化を実現するためのシステムの提案	87
5.7.4	提案したトリガーシステムの実現に向けて	90
第 6 章	結論と展望	91
付録 A	本研究の手法による Turn-on curve の一覧	93
謝辞		98

目次

3

参考文献

100

第 1 章

序論

我々の身の回りに存在する物質を構成する最小の単位は素粒子である。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して標準理論が知られており、図 1.1 に示す 17 種の素粒子により構成されている。これらの素粒子は 2012 年のヒッグス粒子の発見 [1] により存在が全て実験的に確認され、標準理論は現在までの実験結果と大部分で無矛盾である。一方で、ニュートリノ質量の問題やヒッグス粒子の質量階層性問題など、標準理論では説明することができない現象も存在している。

これらの問題を説明するため、標準理論の枠組みを超える理論である超対称性理論 (SUSY) が提唱されている。SUSY には様々なモデルが存在するが、例として最も単純なモデルである Minimal Supersymmetric Standard Model (MSSM) では、標準理論に含まれる全ての粒子について、スピン以外の物理量が同じであり、スピンは $\frac{1}{2}$ だけずれている超対称性粒子の存在を予言している。

現在、標準理論を構成する粒子の精密測定や超対称性粒子の探索など、様々なアプローチで我々の宇宙が従う理論の探求が行われている。このアプローチの 1 つとして、欧州素粒子原子核研究機




図 1.1: 標準理論を構成する素粒子の一覧 [2]。

構 (CERN) における大型ハドロン衝突型加速器 (LHC) を用いた高エネルギー粒子衝突実験が挙げられる。LHC の衝突点の 1 つに設置されている ATLAS 検出器を用いた LHC-ATLAS 実験では、主に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、標準理論を構成する素粒子の精密測定や超対称性粒子の探索が行われている。

ATLAS 検出器では 40 MHz の高頻度で陽子-陽子衝突を発生させるが、計算機リソースやデータ容量の制約から、全ての衝突事象を保存することは不可能である。そこで、膨大な衝突事象の中から物理的に興味のある事象のみを選び出して保存する事象選別 (トリガー) が重要な役割を担う。ATLAS 実験におけるトリガーシステムは、ハードウェアベースで高速な事象選別を行う初段トリガー、ソフトウェアベースでより詳細な事象選別を行う後段トリガーの 2 段階で構成されている。

現在、LHC-ATLAS 実験では一部を除いて標準理論を超える物理の兆候は得られておらず、さらなる統計量の増加による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。高輝度 LHC-ATLAS 実験では、実験の高輝度化により 1 度のバンチ衝突 (BX) における事象数が現行実験と比較して大幅に増加する事に伴い、トリガー処理に要する計算機資源量の増加が見込まれている。その一方で、ソフトウェアの改良などによる必要計算機資源量の削減を継続的行ったとしても、計算機資源の増設が間に合わない事が見込まれている [3]。従って高輝度 LHC-ATLAS 実験に向けて、トリガー性能を高く保った上で必要となる計算機資源量の削減を行うための技術開発が必要不可欠である。

また、LHC-ATLAS 実験のように実験期間が数年に及ぶような長期の実験では、時間経過による検出器の状態変化が問題となる。実際に 2015 年から 2018 年に行われた Run 2 運転においては、実験期間の経過に伴い動作しない検出器 (デッドチェンバー) が増加し、トリガー効率の低下が見られていた。従って長期に渡る安定的なデータ取得を目指す上で、時間の経過や故障による検出器の性能変化にも自動で対応する事ができるようなシステムが必要である。

本論文ではこれらの課題に対して、対応可能な新たなトリガーシステムの提案及び性能評価についてまとめている。

本論文は、第 2 章で LHC-ATLAS 実験の概要について、第 3 章では初段ミュオントリガーについて説明する。さらに、第 4 章ではデッドチェンバーが存在する場合のトリガー性能の評価について、第 5 章では新たなトリガーシステムの提案及び性能評価について述べ、第 6 章で今後の展望と共に本研究のまとめについて述べる。

第 2 章

LHC-ATLAS 実験

2.1 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 の世界最大の加速器である。LHC 加速器では陽子や鉛などの重イオンを加速する事ができ、陽子陽子衝突実験の他に重イオン同士の衝突実験、陽子-重イオンの衝突実験が行われている。LHC 加速器の円周上には 4 つの衝突点が設けられており、各衝突点では本論文で述べる ATLAS 実験の他に、イオン衝突に特化した ALICE 実験、フレーバー物理に特化した LHCb 実験、ATLAS 実験と同様に幅広い物理の探索を行う CMS 実験が行われている。

LHC 加速器は複数の前段加速器と共に運用されており、それらの配置を図 2.1 に示す。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、続いて 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 加速器に入射される [5]。

図 2.2 に、LHC-ATLAS 実験の運転計画を示す。LHC 加速器の重心系エネルギーの設計値は 14 TeV、ピークルミノシティの設計値は $1 \times 10^{34} \text{ cm}^{-2}\text{s}^{-1}$ であり [6]、2015 年から 2018 年にかけて行われた LHC-ATLAS 実験 Run 2 では重心系エネルギー 13 TeV、ピークルミノシティ $2 \times 10^{34} \text{ cm}^{-2}\text{s}^{-1}$ と、設計値を超えるルミノシティでの運転が行われた [7]。また、2022 年から 2025 年にかけて重心系エネルギー 13.6 TeV で Run 3 運転が行われ、さらにその後のアップグレードを経て 2029 年からは高輝度 LHC-ATLAS 実験の運転開始が予定されている。

LHC 加速器では、約 1.6×10^{11} 個の陽子をおよそ $16 \mu\text{m} \times 16 \mu\text{m} \times 6 \text{ cm}$ の大きさの塊 (バンチ) に整形し、このバンチを単位として陽子を加速する [8]。LHC リング 1 周あたりに 25 ns の間隔で 2808 個のバンチを蓄える事ができ、衝突点では約 40 MHz の頻度でバンチ衝突 (BX) が発生する。バンチ内には多数の陽子が含まれているため、1 度の BX において複数の陽子陽子衝突イベント (パイルアップ) が起こり得る。実際に、LHC-ATLAS 実験 Run 2 において観測された 1 度の BX あたりのパイルアップ数の分布は図 2.3 となっており、その平均は約 33.7 回である。

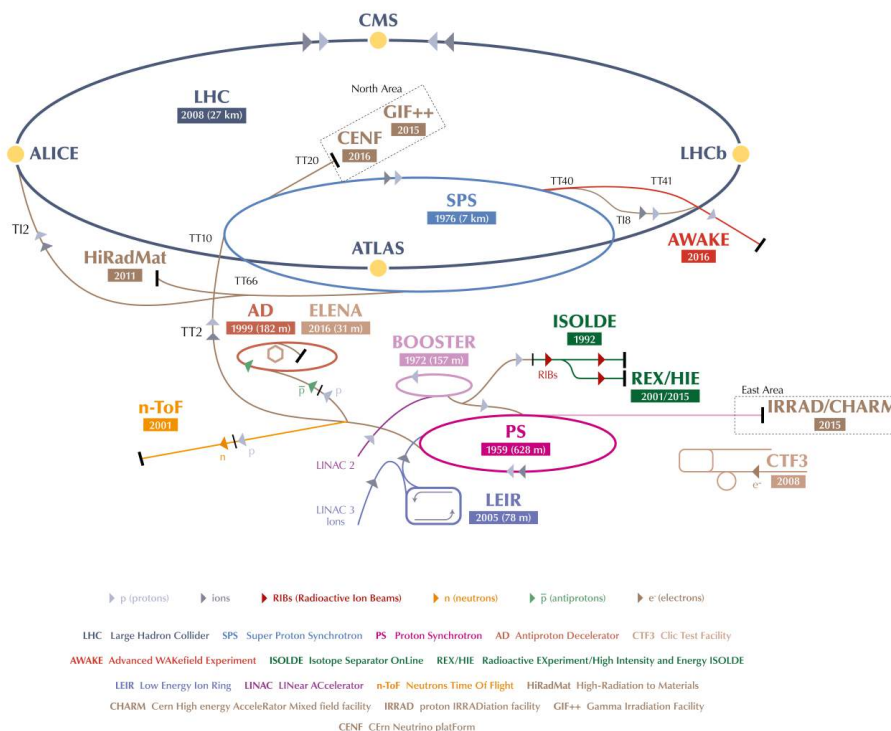


図 2.1: LHC 加速器とその前段加速器群 [4]。最も周長が大きいリングが LHC 加速器である。




図 2.2: LHC 加速器の運転スケジュール。2022 年から 2025 年まで Run 3 の運転が行われ、その後アップグレード期間を経て高輝度 LHC として運転が開始される予定である。

高輝度 LHC-ATLAS 実験においては、ルミノシティが $5 - 7.5 \times 10^{34} \text{ cm}^{-2}\text{s}^{-1}$ へと向上することに伴い、同時にパイルアップ数も増加する事となり、その値は 140 - 200 程度に達する。そのため、LHC 加速器の高輝度化アップグレードに対応するための ATLAS 検出器アップグレードが計画されており、現在アップグレードのための準備が進行中である。高輝度 LHC-ATLAS 実験に向けた LHC 加速器と ATLAS 検出器のアップグレード計画についての詳細は、2.3 節において述べる。




図 2.3: LHC-ATLAS 実験 Run 2 における BX あたりの陽子陽子衝突イベント数の分布 [9]。Run 2 全体における平均は 33.7 回となっている。

2.2 ATLAS 実験

ATLAS 実験は、LHC 加速器の衝突点の 1 つ (Point-1) に設置されている ATLAS 検出器を用いて、素粒子標準模型の精密測定や標準模型を超える新物理の探索を行う実験である [10]。ATLAS 検出器は直径 25 m、全長 44 m、総重量約 5,000 t の円筒形の大型汎用検出器であり、その全体像を図 2.4 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おり、大きく分け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おり、磁場によって曲げられた荷電粒子の曲率からその運動量を求めることができる。

本節では、ATLAS 検出器における座標系、各検出器システム及びマグネットシステムについて述べる。

2.2.1 ATLAS 検出器における座標系

ATLAS 検出器における座標系を図 2.5 に示す。まず、衝突点 (IP) を原点とし、ビームパイプに沿って z 軸を取る。便宜的に $z > 0$ の領域は A-side、 $z < 0$ の領域は C-side と呼ばれる。 z 軸と直交し、LHC 円周の中心に向かう方向に x 軸を取り、 $x-z$ 平面に垂直上向き方向に y 軸を取る。更に、 $x-y$ 平面において動径 $R = \sqrt{x^2 + y^2}$ を定義し、方位角を ϕ と定義する。また、 z 軸




図 2.4: ATLAS 検出器の全体像 [10]。複数の検出器システムを組み合わせて 1 つの大きな検出器を構成している。

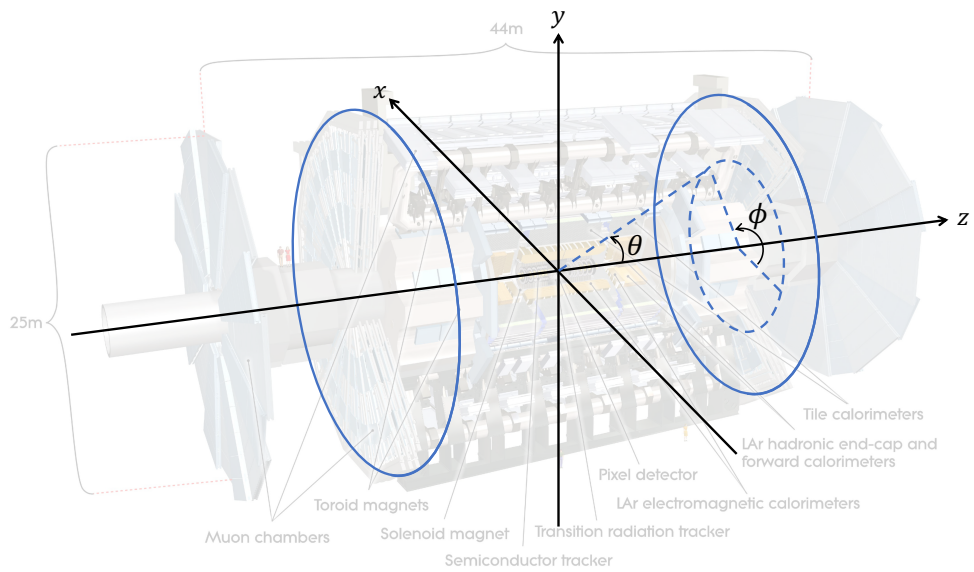


図 2.5: ATLAS 検出器で用いられる座標系。

からの天頂角を θ と定義し、この θ を用いた変数として、擬ラピディティ η を

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

と定義する。ATLAS 実験では、 $|\eta| < 1.05$ 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ぶ。




図 2.6: 内部飛跡検出器の全体像及び断面図。(a): 全体像 [10]、(b): バレル部の断面図 [11]。

陽子陽子衝突実験において、衝突の大部分は非弾性散乱であり、実際に衝突反応を起こすのは陽子を構成しているグルーオンやクォークなどのパートンである。それぞれのパートンが持つ運動量は一定ではなく、LHC 実験は非対称エネルギーの衝突実験として考える必要がある。そのため、衝突毎に係は z 軸方向にブーストされることとなり、ローレンツ不変量である擬ラピディティが導入されている。

2.2.2 内部飛跡検出器

内部飛跡検出器 (Inner Detector: ID) の全体像及び断面図を図 2.6 に示す。ID は ATLAS 検出器の最も内側に位置し、Pixel 検出器 (PIX)、Semi Conductor Tracker (SCT)、Transition Radiation Tracker (TRT) の 3 層から構成されている。これらの検出器は、荷電粒子の飛跡を精密に測定することを目的に設置されており、それぞれの検出器からの情報を組み合わせることで、陽子同士の衝突点及び二次粒子の崩壊点の位置を高い精度で求めることができる。ID には、超伝導ソレノイドコイルによる 2 T の磁場がビームパイプに平行な方向に印加されている。この磁場により荷電粒子は ϕ 方向に曲げられ、その飛跡から求めた曲率半径を用いて横方向運動量 (p_T) を算出することができる。

以下では、ID を構成する PIX、SCT、TRT について個別に述べる。

• Pixel 検出器 (PIX)

PIX は内部飛跡検出器の最も内側に位置し、 $|\eta| < 2.5$ の領域をカバーするシリコン検出器である。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それぞれ 3 層ずつ設置されている。1 ピクセルの大きさは $50 \times 400 \mu\text{m}^2$ であり、総ピクセル数は約 8000 万ピクセルに及ぶ。バレル部においては $R - \phi$ 平面で $10 \mu\text{m}$ 、 z 軸方向で $115 \mu\text{m}$ 、エンドキャップ部においては $R - \phi$ 平面で $10 \mu\text{m}$ 、 R 方向で $115 \mu\text{m}$ の高い

位置分解能を有する [10]。

LHC 実験 Run 2 からは、より高いルミノシティでの運転に向け、バレル部の最内層に Insertable B-Layer (IBL) が新たに設置された。IBL の 1 ピクセルの大きさは $50 \times 250 \mu\text{m}^2$ であり、総ピクセル数は約 1200 万ピクセルに及ぶ。IBL の導入による飛跡の測定点の増加に伴い、低 p_T 領域における飛跡頂点の測定精度が 40% 程度改善した [12]。

- Semi Conductor Tracker (SCT)

SCT は PIX の外側に位置し、 $|\eta| < 2.5$ の領域をカバーするシリコン検出器である。PIX と同様に、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おり、総チャンネル数は 630 万チャンネルに及ぶ。バレル部では、長さ 12.8 cm のストリップがビームパイプと平行に $80 \mu\text{m}$ 間隔で設置されており、もう 1 層を 40 mrad 傾けて設置することにより、 z 軸方向の測定が可能となっている。エンドキャップ部では、ストリップが放射状に $80 \mu\text{m}$ 間隔で設置されており、更にもう 1 層を 40 mrad 傾けて設置することにより、 R 方向の測定が可能となっている。バレル部においては $R - \phi$ 平面で $17 \mu\text{m}$ 、 z 軸方向で $580 \mu\text{m}$ 、エンドキャップ部においては $R - \phi$ 平面で $17 \mu\text{m}$ 、 R 方向で $580 \mu\text{m}$ の位置分解能を有する [10]。

- Transition Radiation Tracker (TRT)

TRT は内部飛跡検出器の最外層に位置する検出器であり、荷電粒子の遷移輻射を利用して電子/ π 中間子の識別を行う事ができる。TRT は約 30 万本のドリフトチューブから構成されており [13]、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いる。チューブ内部は $\text{Xe} : \text{CO}_2 : \text{O}_2 = 70 : 27 : 3$ の混合ガスで満たされており [14]、チューブ中心の直径 $30 \mu\text{m}$ の金メッキされたタングステンワイヤーから電荷の読み出しを行う。ただし、ガス漏れが多いチューブに対しては $\text{Ar} : \text{CO}_2 : \text{O}_2 = 70 : 27 : 3$ の混合ガスが用いられ、これらのチューブでは遷移輻射が起こらない。

$|\eta| < 1$ の範囲をカバーする TRT のバレル領域には、ビームパイプと並行に長さ 1.5 m のドリフトチューブが約 5 万本配置されている。また、 $1 < |\eta| < 2$ の範囲をカバーするエンドキャップ領域には、A-side、C-side それぞれに約 12 万本のドリフトチューブがビームパイプと垂直に配置されている。チューブ 1 本あたりの位置分解能は $120 \mu\text{m}$ 程度であるが、1 本のトラックあたりのヒット数の多さ及び検出器最内層から最外層までの距離の長さにより、より詳細な測定が可能である。さらに、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である。




図 2.7: カロリメータの全体像 [10]。

2.2.3 カロリメータ

カロリメータの全体像を図 2.7 に示す。カロリメータは内部飛跡検出器の外側に位置し、電子や光子の同定及び位置やエネルギーの測定を行うための検出器である。カロリメータは、電子や光子を測定対象とする電磁カロリメータとハドロンを測定対象とするハドロンカロリメータから構成されている。以下では、電磁カロリメータ及びハドロンカロリメータについて述べる。

・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、またそれらのエネルギーを精密に測定する。この検出器は、吸収層に鉛、検出層に 90 K の液体アルゴンを用いたサンプリングカロリメータであり、 $|\eta| < 1.5$ のバレル部と $1.4 < |\eta| < 3.2$ のエンドキャップ部から構成されている。吸収層において、電子及び光子から電磁シャワーを発生させ、検出層でそのエネルギーを測定することで、もとの電子及び光子のエネルギーを測定することができる。バレル部では約 22 放射長、エンドキャップ部では約 24 放射長の厚さを持つ。吸収層と検出層はアコーディオン状に重ねて配置され、 ϕ 方向についてはほぼ完全な対称性を有していることが特徴である。

・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位置し、強い相互作用をする粒子のエネルギーや方向を測定する。この検出器は、 $|\eta| < 1.7$ のバレル部、 $1.5 < |\eta| < 3.2$ のエンドキャップ部と $3.1 < |\eta| < 4.9$ のフォワード部から構成されており、それぞれ構造が異なる。




図 2.8: ミューオンスペクトロメータの配置 [15]。R-z 平面において 4 分割した形で示している。

バレル部は、吸収層に鉄、検出層にタイルシンチレータを用いたサンプリングカロリメータとなっており、 $\eta = 0$ では、9.7 相互作用長の厚さを持つ。

エンドキャップ部は、吸収層に銅、検出層に液体アルゴンを用いたサンプリングカロリメータとなっている。

フォワード部は約 10 相互作用長の厚さを持つサンプリングカロリメータであり、3 層から構成されている。最も内側の 1 層は電磁シャワーの測定に最適化され、吸収層に銅を用いている。残りの 2 層はハドロンシャワーの測定に最適化され、吸収層にタングステンを用いている。検出層はいずれも液体アルゴンである。

2.2.4 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の配置を図 2.8 に示す。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、ミューオンの飛跡から横方向運動量を測定することを目的とした検出器である。ミューオンは荷電レプトンであり、電子の約 200 倍の質量を持つ。そのため、物質の透過力が大きく、寿命も $2.2 \mu\text{s}$ と比較的長い。したがって、ミューオンは ID やカロリメータとほとんど相互作用することなくミューオンスペクトロメータまで到達することができる。

ニュートリノは弱い相互作用のみで物質と相互作用をするため、ミューオンと同様にミューオンスペクトロメータまで到達することができる。しかし、ニュートリノは電荷を持たないため検出器




図 2.9: MDT の構造図 [10]。ドリフトチューブが積層された構造であることがわかる。赤い線は、ATLAS 検出器のアライメントの狂いを補正するために用いられるレーザーを示している。

に信号を残さず、ミュオンの同定は比較的簡単に行うことができる。

ミュオンスペクトロメータは、Monitored Drift Tube (MDT)、New Small Wheel (NSW)、Resistive Plate Chambers (RPC)、Thin Gap Chambers (TGC) の 4 つの検出器から構成されている。

以下では、それぞれの検出器について個別に述べる。

• Monitored Drift Tube (MDT)

MDT は $|\eta| < 2.7$ の領域をカバーする、ミュオンの飛跡の精密測定を目的とした検出器である。MDT の構造図を図 2.9 に示す。

検出器は直径約 30 mm、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いる。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が封入されており、アノードワイヤーはタングステン-レニウム合金製である。アノードとカソードの間には 3080 V の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。

ドリフトチューブ 1 本での位置分解能はおよそ 80 μm であるが、複数のレイヤーを組み合わせることにより、最大 35 μm の位置分解能を実現する。




図 2.10: NSW の全体像と sTGC、MM の配置図 [16]。NSW の 1 セクターは、sTGC で MM2 層を挟む配置となっている。




図 2.11: small-strip TGC の構造図 [17]。

• New Small Wheel (NSW)

New Small Wheel (NSW) は、高レート環境下での飛跡測定精度の向上やミュオントリガーのアップグレードを目的として、ATLAS 実験 Run 3 から従来の TGC 検出器 Small Wheel と置き換えて設置される検出器である。その全体像を図 2.10 に示す。NSW は small-strip TGC (sTGC) と Micromegas (MM) の 2 種類の検出器から構成されており、それぞれの検出器は図 2.10 に示すように 2 枚の MM を sTGC で挟むように配置されている。NSW はエンドキャップ領域の磁場内部に設置され、 $1.3 < |\eta| < 2.7$ の領域と ϕ 方向の全領域をカバーする。

以下では、sTGC 及び MM の構造についてそれぞれ説明する。

sTGC は、TGC と同様に 2.8 mm のガスギャップを持つ MWPC である。その構造図を図 2.11 に示す。ガスギャップの中心には金メッキされたタングステンワイヤーが 1.8 mm 間隔で張られており、アノードワイヤーとして機能する。アノードワイヤーを挟むように、両側にパッド及びストリップの 2 種類のカソードが存在し、それぞれから電荷の読み出しを行う。sTGC では、TGC と異なりワイヤーで ϕ 方向、ストリップで η 方向の位置測定を行う。

パッドは長方形の電極であり、ストリップよりも粗い単位での電荷読み出しを行う。sTGC で




図 2.12: MM の構造図及び動作原理 [17]。ドリフト領域における電離により発生した電子が増幅領域で雪崩増幅を起こし、信号をストリップ電極から読み出す。

は、まず初めにパッドでの電荷情報を用いて大まかな位置情報を決定し、ストリップ及びワイヤーの信号を読み出す領域を限定する。

ストリップは 3.2 mm 間隔で電極が配置されており、TGC のストリップ間隔 15 mm よりも狭くなっている。ストリップに誘起される電荷情報の重心を計算する事でストリップ間隔よりも位置分解能を小さくする事が可能であり、50 – 200 μm の程度の位置分解能を有する [17]。

一方、MM はワイヤーを用いないガス検出器であり、図 2.12 のように 5 mm のドリフト領域と 128 μm の増幅領域をステンレス製のメッシュで隔てた構造となっている [17]。検出器内は $\text{Ar} : \text{CO}_2 = 93 : 7$ 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約 400 μm ピッチで配置されたストリップから読み出される。

増幅領域では電子と同時に陽イオンも生成されるが、MM の増幅領域は 128 μm と薄いため、発生した陽イオンが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においても陽イオンによる電場の歪みの影響を抑える事が可能であり、MM は比較的高いレート耐性を持つ。また、電荷情報に加えてドリフト時間の長さを利用した読み出し時間差の情報を用いる事で、90 μm 程度の位置分解能を実現する [17]。

• Resistive Plate Chambers (RPC)

RPC は $|\eta| < 1.05$ の領域をカバーし、主にバレル部のミュオントリガー判定に用いられるガス平行平板検出器である。RPC の構造を図 2.13 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、中には $\text{C}_2\text{H}_2\text{F}_4 \cdot \text{Iso} - \text{C}_4\text{H}_{10} \cdot \text{SF}_6$ の混合ガスが充填されている。抵抗板の外側にはグラファイト塗料が塗布されており、抵抗板間には約 4.9 kV/mm の電場が印加されている。この電場により、荷電粒子によってガスが電離されて発生した電子が、電子雪崩を起こしながらアノードへ引き寄せられる。これによって誘起された電荷が、ストリップから信号として読み出される。ストリップは抵抗板の外側に PET の層を挟んで配置され、それぞれの層のストリップは直交している。

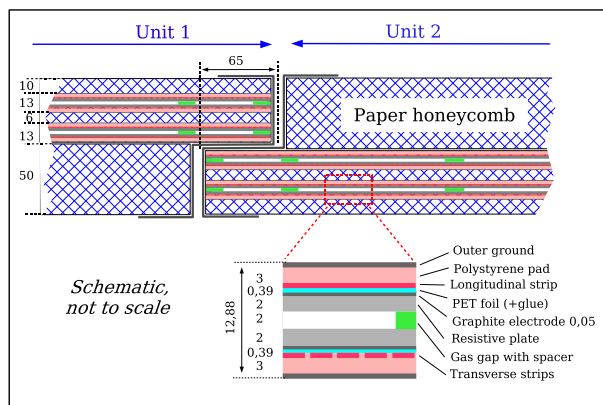


図 2.13: RPC の構造図 [10]。ワイヤーを用いない平行平板ガス検出器である。




図 2.14: TGC の構造図 [10]。金でコーティングされたタングステンのアノードワイヤーと、銅のストリップで構成された MWPC である。TGC は、必ず 2 層または 3 層を 1 組として設置される。

• Thin Gap Chambers (TGC)

TGC は $1.05 < |\eta| < 2.7$ の領域をカバーし、主にエンドキャップ部のミュオントリガー判定に用いられる検出器である。TGC の構造を図 2.14 に示す。TGC は MWPC の 1 種であり、幅 2.8 mm のガスギャップ中に 1.8 mm 間隔で直径 $50 \mu\text{m}$ のアノードワイヤーが張られている。カソード面にはアノードワイヤーと交差するようにストリップが配置され、 $R-\phi$ 方向の 2 次元での読み出しが可能となっている。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、ガスギャップ中の $\text{CO}_2 : n\text{-pentane} = 55 : 45$ 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、荷電粒子の通過位置を測定する。ATLAS 検出器では TGC を 2 層 1 組 (Doublet) または 3 層 1 組 (Triplet) として使い、各層とのコインシデンスを取ることで、フェイク信号を削減している。

TGC 検出器の配置図を図 2.15 に示す。一つの TGC チェンバーは台形であり、図 2.15(a) に示

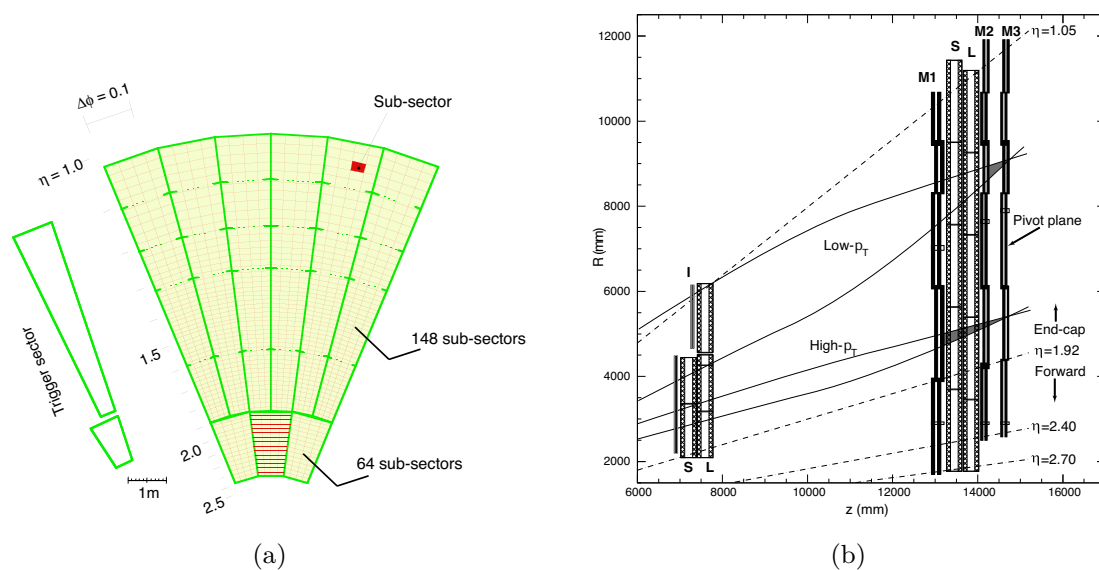


図 2.15: TGC 検出器の配置図 [10]。(a): $x - y$ 平面から見た配置、(b): $R - z$ 平面から見た配置。

表 2.1: TGC 検出器各チェンバーにおけるチャンネル数。

M1	Forward	-	E4	E3	E2	E1
Layer1 Wire	105	-	92	61	23	24
Layer1 Strip	32	-	32	32	32	32
Layer2 Wire	104	-	91	62	23	24
Layer3 Wire	105	-	91	62	23	24
Layer3 Strip	32	-	32	32	32	32
M2	Forward	E5	E4	E3	E2	E1
Layer1,2 Wire	125	110	103	32	32	32
Layer1,2 Strip	32	32	32	32	32	32
M3	Forward	E5	E4	E3	E2	E1
Layer1,2 Wire	122	96	106	32	30	31
Layer1,2 Strip	32	32	32	32	32	32

すように複数のチェンバーを組み合わせて $x - y$ 平面において円盤状の検出器を構成している。 $1.05 < |\eta| < 1.92$ の領域をエンドキャップ領域、 $1.92 < |\eta| < 2.4$ の領域をフォワード領域と呼び、それぞれのチェンバーは η が大きい方から Forward、E5、E4、E3、E2、E1 チェンバーと呼ばれる。各チェンバーはそれぞれチャンネル数が異なり、そのチャンネル数を表 2.1 にまとめた。

また、 $R - z$ 平面における TGC 検出器の配置を図 2.15(b) に示す。TGC 検出器ミドルステーションは $z \sim 14$ m 付近に位置し、M1、M2 及び M3 の 3 ステーションから構成されている。M1 ステーションは Triplet、M2 及び M3 ステーションは Doublet 構造となっている。




図 2.16: ATLAS 検出器で用いられている磁石 [10]。(a): 磁石の CG イメージ。カロリメータの周りに 8 回対称となるように設置されている。(b): ATLAS 検出器へインストールされる前のソレノイド磁石の写真。

2.2.5 マグネットシステム

ATLAS 検出器には、トロイド磁石とソレノイド磁石の 2 種類の超伝導電磁石が設置されている。それぞれの磁石の CG イメージ及び写真を図 2.16 に示す。以下に、それぞれの磁石について個別に述べる。

・ソレノイド磁石

ソレノイド磁石は ID 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、ID 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。この磁石はカロリメータの内側に設置されているため、粒子が磁石と相互作用を起こしてロスするエネルギーを小さくするように設計されており、ソレノイド磁石は 0.66 放射長となっている。

この磁石はビーム軸方向に約 2 T の磁場を提供しているが、トロイド磁石と同様に、完全に均一な磁場となっているわけではない。図 2.17 に、ソレノイド磁石による磁場の R 及び z に対する依存性を示す。これから、検出器の端へ近づくにつれ、 z 方向の磁場は小さく、 r 方向の磁場は大きくなる事が分かる。

・トロイド磁石

トロイド磁石はバレル部に 1 つ、エンドキャップ部に 2 つの計 3 つで構成されており、これらの電磁石が作り出す磁場によってミュオンを曲げ、その横方向運動量を測定するために設置されている。アルミニウム・銅・ニオブチタン合金の筒に、ニオブチタン製の導線を巻きつけた構造となっており、図 2.16(a) から分かるように、バレル部・エンドキャップ部のどちらも、磁場が ϕ 方向に 8 回対称となるようにコイルが配置されている。粒子が磁石と相互作用し、多重散乱が起こる




図 2.17: ソレノイド磁石による、 r 方向の磁場 (B_r) 及び z 方向の磁場 (B_z) の R 及び z に対する依存性 [10]。色の違いは、 R の違いを示している。

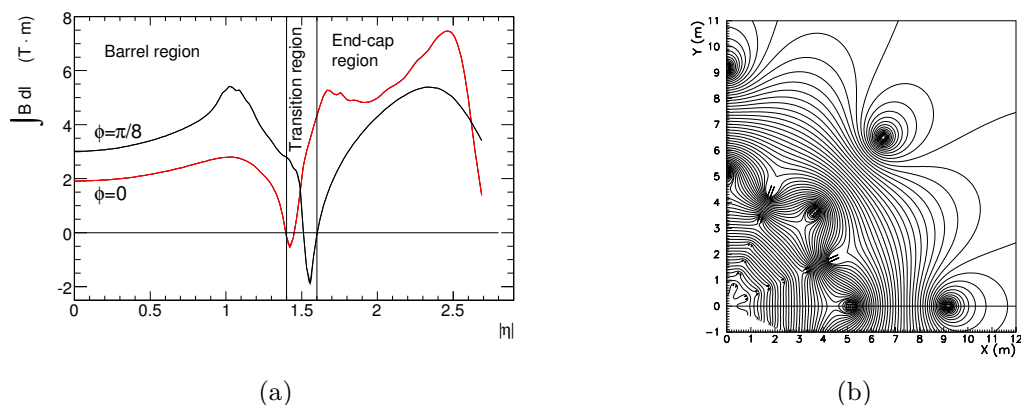


図 2.18: トロイド磁場の位置依存性。(a): 積分磁場強度の η 依存性 [10]。赤い線は $\phi = 0$ 、黒い線は $\phi = \pi/8$ に対応する。(b): $x - y$ 平面における、トロイド磁石が作る磁力線 [18]。

のを防ぐために、磁場が印加されている部分は中空となっている。この磁石により、バレル部では ϕ 方向に 0.5 T、エンドキャップ部では ϕ 方向に 1 T の磁場を印加している。

しかし、構造上の理由などから検出器内のどの位置でも同じ磁場構造が得られるわけではない。図 2.18(a) に、積分磁場強度の η 依存性を示す。これから分かるように、 $\eta = 1.5$ の周辺で磁場強度が落ち込んでいる。この領域をミュオンが通過すると、磁場による軌跡の変化が小さくなるため、横方向運動量の測定精度が低下する。また、図 2.18(b) に、 $x - y$ 平面におけるトロイド磁石が作る磁力線を示す。これから、 $x - y$ 平面においても磁場の不均一性が存在することが分かる。

2.3 高輝度 LHC-ATLAS 実験に向けたアップグレード計画

2.1 節で述べたように、LHC-ATLAS 実験 Run 3 が終了した後、アップグレード期間を経て 2029 年から高輝度 LHC が運転を開始する予定である。LHC 加速器の高輝度化アップグレードに対応するため ATLAS 検出器でもアップグレードが計画されており、現在アップグレードのための準備が進行中である。本節では、高輝度 LHC-ATLAS 実験に向けた LHC 加速器と ATLAS 検出器のアップグレード計画について述べる。

2.3.1 LHC 加速器のアップグレード

LHC-ATLAS 実験 Run 2 では最大瞬間ルミノシティ $2.0 \times 10^{34} \text{ cm}^{-2}\text{s}^{-1}$ での運転が行われていたが [19]、高輝度 LHC-ATLAS 実験においては瞬間ルミノシティを $5 - 7.5 \times 10^{34} \text{ cm}^{-2}\text{s}^{-1}$ 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 [20]。

LHC 加速器では、高ルミノシティを達成するため、前段加速器群のアップグレードによるビーム電流の増強、衝突点におけるビームサイズの絞り込み、クラブ空洞の導入によるバンチのクラブ衝突化などのアップグレードを行う。

前段加速器群のアップグレード

LHC 加速器には、図 2.1 に示すように複数の前段加速器が存在する。高輝度 LHC の要求に合わせ、ビーム電流の増強を行うためにこれらの前段加速器のアップグレードが行われる。入射加速器として、160 MeV での入射を行うことができる Linac4 が新たに建設され [21]、LHC 実験 Run 3 から高輝度 LHC 実験にかけて運転される予定である。また、Linac4 の後段加速器である PSB、PS、SPS においてもそれぞれ同様にアップグレードが計画されている [22]。

衝突点におけるビームサイズの絞り込み

現行の LHC 加速器においては、衝突点におけるビームの β 関数 (β^*) の設計値は 0.55 m となっている。高輝度 LHC 実験では、衝突点におけるビーム収束磁石の大口径化・高磁場化アップグレードを行い、 β^* を 0.15 m まで絞り込む [23]。

このアップグレードにより衝突点におけるビームサイズは約 1/3 以下に小さくなるが、収束系の衝突点から離れた位置におけるビームサイズが大きくなるというトレードオフが存在する。そのため、ビーム同士の干渉を避けるためにバンチ交差角を大きくする必要が生じ、高輝度化を達成する上で不利な状況となる。このバンチ交差角の増大による影響を補うため、次に述べるクラブ衝突の導入が予定されている。



図 2.19: 通常のバンチ衝突 (左) とクラブ衝突 (右) の概念図 [23]。通常のバンチ衝突と比較して、クラブ衝突では衝突時のバンチ同士の重なりが大きくなり、ルミノシティが向上する。

クラブ空洞の導入によるバンチのクラブ衝突化

高輝度 LHC 実験ではバンチ交差角の増大による影響を補うため、衝突点にクラブ空洞を導入し、バンチのクラブ衝突化を行う。通常のバンチ衝突とクラブ衝突の違いの概念図を図 2.19 に示す。クラブ衝突を導入することにより衝突時にバンチ同士が重なる面積が大きくなり、ルミノシティを向上させる事ができる。

クラブ衝突は既に高エネルギー加速器研究機構 (KEK) の Super KEKB 加速器において実用されており、2021 年 6 月には瞬間ルミノシティ $3.1 \times 10^{34} \text{ cm}^{-2}\text{s}^{-1}$ を達成して瞬間ルミノシティの世界記録を塗り替えた [24]。

2.3.2 ATLAS 検出器のアップグレード

高輝度 LHC による高ルミノシティ環境下では、パイルアップ数が 140 から 200 程度まで増加すると予測されている。パイルアップが増加するに従って内部飛跡検出器における飛跡の数が増加し、現行のままでは検出器の占有率が高くなってしまふ。またパイルアップの増加に伴い、現行の内部飛跡検出器の放射線耐性で耐え得る以上に放射線量が増加することとなる。内部飛跡検出器が高輝度 LHC-ATLAS 実験終了時までには受ける放射線量の見積りを図 2.20 に示す。

このため、高輝度 LHC-ATLAS 実験においては、内部飛跡検出器を従来の PIX, SCT, TRT の組み合わせから、全てシリコン検出器であるピクセル検出器とストリップ検出器を組み合わせた Inner Tracker (ITk) へと置き換えが行われる。現行の内部飛跡検出器と高輝度 LHC-ATLAS 実験における内部飛跡検出器の配置を図 2.21 に示す。この検出器の置き換えにより、内部飛跡検出器検出領域は現行の $\eta < 2.5$ から $\eta < 4.0$ へと拡張される。

2.3.3 バレル部への新ミュオン検出器の導入

2.2.4 節で述べたように、バレル部では MDT 及び RPC がミュオンスペクトロメータとして配置されている。高輝度 LHC-ATLAS 実験においては、アクセプタンス向上のため現在の Barrel Middle (BM)、Barrel Outer (BO) ステーションに加え、新たに Barrel Inner (BI) ステーションに 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。




図 2.20: 内部飛跡検出器が高輝度 LHC-ATLAS 実験終了時までには受ける放射線量の見積り [25]。線量は 1 MeV の中性子等量へと換算されている。

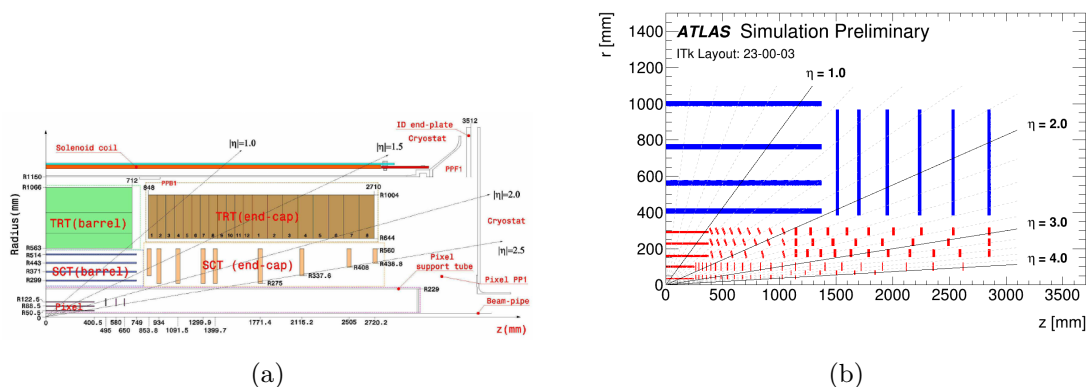


図 2.21: 現行と高輝度 LHC-ATLAS 実験における内部飛跡検出器の配置図の比較。(a): 現行の内部飛跡検出器の配置図 [26]。(b): 高輝度 LHC-ATLAS 実験における内部飛跡検出器の配置図 [27]。現行の内部飛跡検出器と比較して、検出領域が拡大している。

RPC BI が導入される位置を図 2.22 に示す。バレル部のミュオン検出器は、大きさにより Large Sector / Small Sector の 2 種類に分かれており、Large Sector 用の BI チェンバーは既存の MDT の外側に設置される。一方、Small Sector 用の BI チェンバーは MDT の内側に設置される。ただし、Small Sector では検出器を設置できる空間が限られるため、BI チェンバーの導入に合わせて既存の MDT はより薄型の small-diameter MDT (sMDT) へと置き換えられる。

RPC BI の導入によるバレル部のアクセプタンス向上の見積りを図 2.23 に示す。RPC BI 設置前 (図 2.23(a)) では、検出器の配置など構造的な要因によりアクセプタンスが大きく低下している箇所が見られるが、RPC BI 設置後 (図 2.23(b)) ではそのような箇所が減少し、アクセプタンスが大きく向上している事が見て取れる。

第 3 章

初段ミュオントリガーシステム

第 1 章で述べたように、計算機資源の制約により ATLAS 検出機で起こった衝突事象全てを保存することはできず、トリガーを用いた事象選別を行う必要がある。ATLAS 実験では、高エネルギーの電子、光子やミュオンなど、様々な物理オブジェクトを選択するトリガーが存在する。本章では、初めにトリガーシステム全体について述べ、その後本研究の対象である初段ミュオントリガーについて説明する。また、LHC-ATLAS 実験 Run 3 におけるトリガーシステムと高輝度 LHC-ATLAS 実験において運用される予定のトリガーシステムの変更点についても述べる。

3.1 ATLAS トリガーシステム概観

本節では、LHC-ATLAS 実験において運用されるトリガーシステムの概観について述べる。3.1.1 節では LHC-ATLAS 実験 Run 3 におけるトリガーシステム、3.1.2 節では高輝度 LHC-ATLAS 実験におけるトリガーシステムについて述べる。

3.1.1 LHC-ATLAS 実験 Run 3 におけるトリガーシステム

ATLAS 実験における陽子-陽子バンチ衝突頻度は 40 MHz である一方、計算機資源の制約などから実際にデータを保存できるレートは 1 kHz に制限されている。そのため、LHC-ATLAS 実験 Run 3 ではハードウェアベースの高速な事象選別システムである Level-1 Trigger (L1)、ソフトウェアベースでより詳細な事象選別を行う High-Level Trigger (HLT) の 2 段階のトリガーシステムを組み合わせて事象選別を行っている。40 MHz の頻度で発生するイベントは、まず初段トリガーである L1 によって 100 kHz までイベントレートが絞られ、さらに後段の HLT によって 1 kHz までレートを削減した上でストレージへとデータが保存される。

ATLAS 実験におけるトリガー・データ取得システムの概略を図 3.1 に示す。初段トリガーシステムでは、40 MHz の頻度で起こる陽子-陽子衝突データに対してトリガー処理を行い、 $2.5 \mu\text{s}$ 以内に 100 kHz までイベントレートを削減する事が要求される。このように高速なイベント選別を実現するため、初段トリガーシステムは Field Programmable Gate Array (FPGA) や Application

Specific Integrated Circuit (ASIC) を用いたハードウェアベースのシステムとして構成されている。

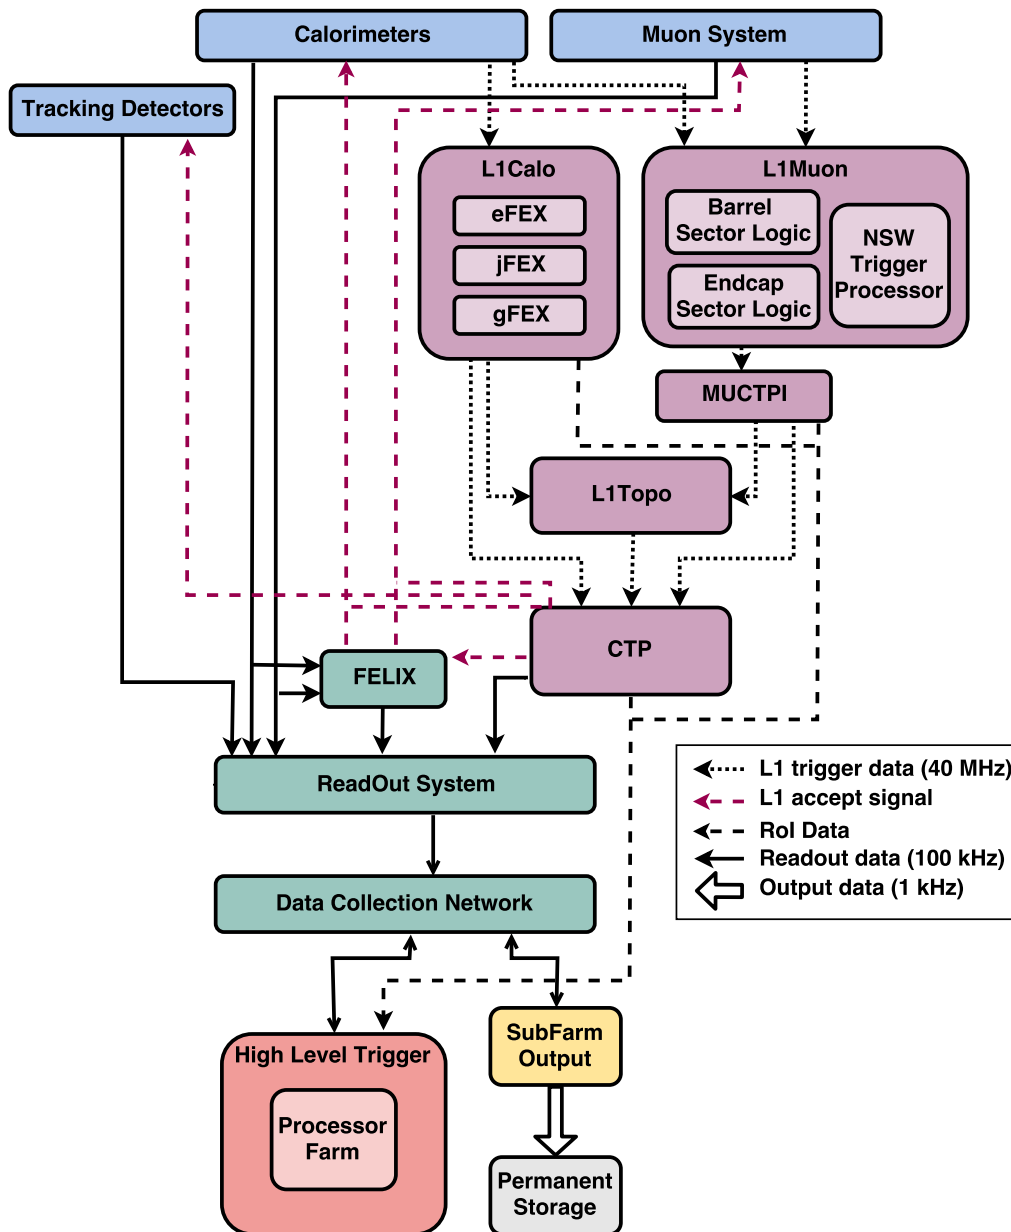


図 3.1: LHC-ATLAS 実験 Run 3 におけるトリガー・データ取得システムの概要 ([20] を編集)。L1 及び HLT の選別を通過したイベントのみがデータストレージへと保存される。

FPGA や ASIC は共に半導体集積回路 (IC) の一種であり、高速・低消費電力で特定の処理を行うように設計が可能であるという特長を持つ。FPGA はその名の通り、使用者が論理回路を設計して何度でも書き換えが可能な素子である。一方、ASIC は一度実装を行うと回路を修正する事は困難であるが、基本的に FPGA よりも高速に動作させることが可能である。

初段トリガーシステムは、図 3.1 に示すようにカロリメータの情報を用いてトリガー判定を行う Level-1 Calorimeter (L1Calo)、TGC 検出器などのミュオン検出器の情報を用いる Level-1 Muon (L1Muon)、またこれらのトリガー情報を組み合わせてトリガー判定を行う Central Trigger から構成されている。L1Calo、L1Muon はそれぞれの検出器からのトリガー判定用の情報を用いて独立にトリガー判定を行う。

L1Calo は電磁カロリメータ、ハドロンカロリメータの情報を用いてトリガー判定を行う。LHC-ATLAS 実験 Run 3 から LAr カロリメータがデジタル読み出しへと変更されることに伴い、L1Calo に FPGA ベースの処理機構である Feature Extractors (FEXs) が導入される [28]。カロリメータからの信号は electron FEX (eFEX)、jet FEX (jFEX) 及び global FEX (gFEX) へと送られ、それぞれ処理が行われる。eFEX は電子、光子やタウレプトンの判別を行い、jFEX はタウレプトンやジェットの判別、 E_T^{miss} の計算を行う。また gFEX は Large- R jet や E_T^{miss} の再構成を行う。

L1Muon は RPC の情報を用いるバレル部、TGC の情報を用いるエンドキャップ部においてそれぞれ独立にトリガー判定を行う。バレル部及びエンドキャップ部で判定された情報は、Muon to CTP Interface (MUCTPI) で統合され、Topology Processor (L1Topo) 及び Central Trigger Processor (CTP) へと送られる。L1Topo では、L1Calo 及び L1Muon からのオブジェクトの位置、個数などの情報を利用し、特定の物理解析に特化したトリガーの発行を可能にする [29]。

最終的に L1Calo、L1Muon、L1Topo のトリガー情報は CTP で統合され、トリガーレートが 100 kHz を超過しないよう、各トリガーチェーン毎にプリスケールファクターを掛けて Level-1 Accept (L1A) が発行される。

初段トリガーシステムがトリガー判定を行なっている間、各検出器で測定されたデータはフロントエンド回路上の Buffer (L1Buffer) に保持されており、L1A が発行された場合は L1Buffer に保存されたデータは ReadOut Driver (ROD) へと送られる。また、初段トリガーによって決定された Regions Of Interest (RoI) が HLT へと送られ、後段の HLT では RoI 情報を基により詳細なトリガー判定を行う。

3.1.2 高輝度 LHC-ATLAS 実験におけるトリガーシステム

高輝度 LHC-ATLAS 実験においては、ルミノシティの増加に伴う背景事象の増加に対応するためトリガーシステムのアップグレードを行い、Level-0 Trigger (L0) 及び Event Filter (EF) の 2 段階トリガーシステムが導入される予定である。高輝度 LHC-ATLAS 実験におけるトリガー・データ取得システムの概略を図 3.2 に示す。

高輝度 LHC-ATLAS 実験では背景事象の増加に伴いイベントレートも増加するため、L0 の許容

トリガーレートを現行の L1 と同様の 1 kHz に設定すると、トリガーの p_T 閾値を上げる事によってトリガーレートを抑制する必要がある。しかし、トリガーの p_T 閾値を上げることは物理のアクセプタンス低下に繋がる。そのため、L0 では許容トリガーレートを 1 MHz に設定することでトリガーの p_T 閾値を上げる事なくトリガーレートの増加に対応する。また、L1 では $2.5 \mu s$ であったトリガー判定時間が L0 では $10 \mu s$ に延長され、より複雑なトリガーアルゴリズムの導入によるトリガー性能の向上が可能となっている。

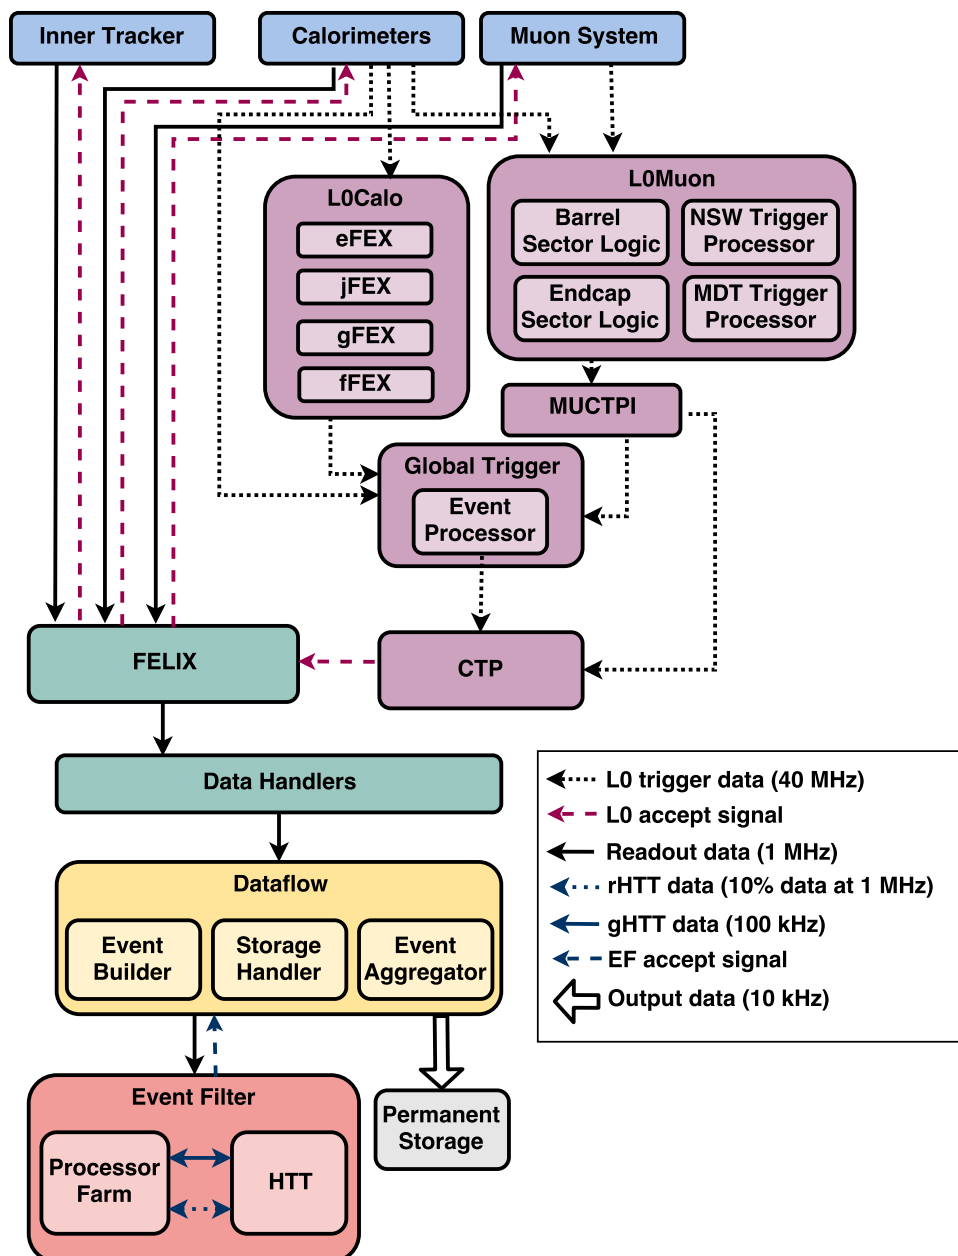


図 3.2: 高輝度 LHC-ATLAS 実験におけるトリガー・データ取得システムの概要 [20]。

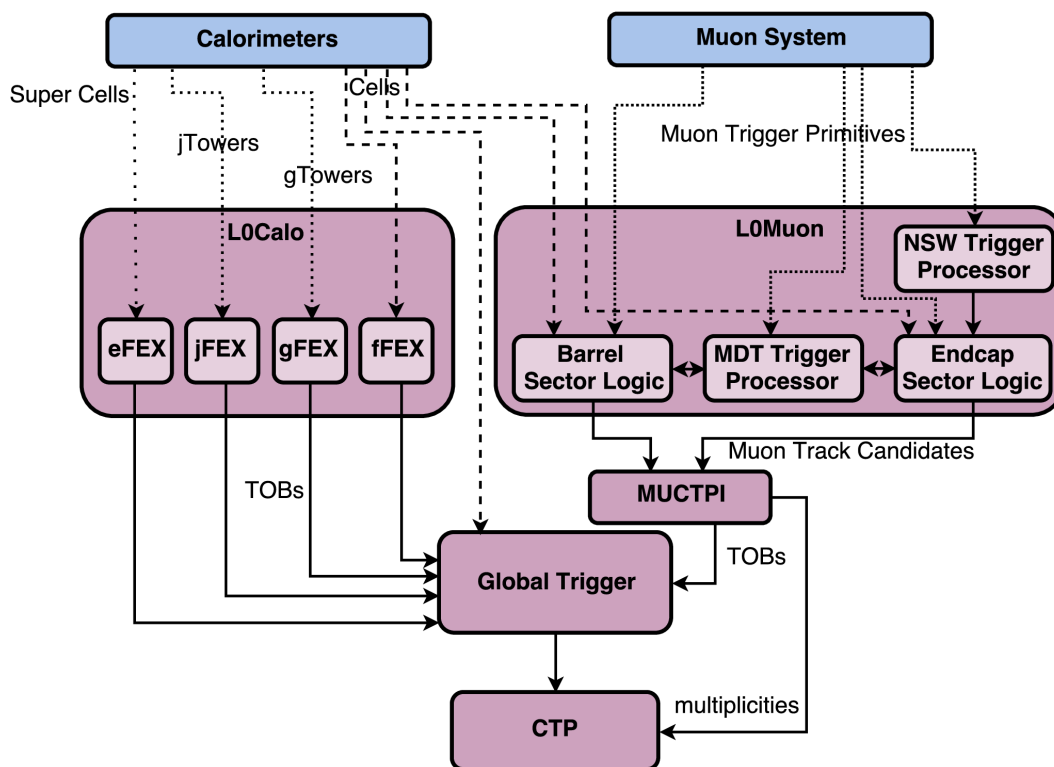


図 3.3: L0 の詳細なトリガーパス [20]。

高輝度 LHC-ATLAS 実験における初段トリガーシステム L0 では、FPGA や ASIC などを用いたハードウェアベースの高速な事象選別を行う。図 3.2 に示すように、L0 は Level-0 Calorimeter Trigger (L0Calo)、Level-0 Muon Trigger (L0Muon)、Global Trigger 及び Central Trigger Processor (CTP) から構成されている。図 3.3 に L0 の詳細なトリガーパスを示す。

L0Calo は Run 3 と同様に FPGA ベースの処理機構 (FEXs) から構成される。高輝度 LHC-ATLAS 実験から新たにタイルカロリメータもデジタル読み出しへと改良され、FEXs へと入力されるようになる。この改良により、より細かい単位での読み出しが可能となる。さらに eFEX、jFEX、eFEX に加えて新たにフォワード領域において電子、光子やジェットの判別を行う fFEX が導入される。FEXs によって処理されたデータは Global Trigger へと送信される。

L0Muon はミュオン検出器からの全てのヒット情報を用いてトリガー判定を行う。バレル領域及びエンドキャップ領域には、検出器からの情報を統合して処理する Sector Logic (SL) がそれぞれ存在する。バレル領域では、バンチ衝突毎に RPC からのヒット情報とタイルカロリメータからデジタル読み出しした情報を Barrel SL へと入力する。エンドキャップ領域では、バンチ衝突毎に TGC からのヒット情報、さらに NSW の情報やタイルカロリメータからデジタル読み出しした情報を付加して Endcap SL へと入力する。

さらに、L0 ではトリガーの精度を向上させるため、MDT からの情報も用いてトリガー判定を行う。バレル領域及びエンドキャップ領域のそれぞれの SL で処理されたミュオン候補は MDT

Trigger Processor (MDT-TP) へと送られる。MDT-TP では、Barrel SL 及び Endcap SL からのミュオン候補の情報を基により詳細な p_T 分解能でトリガー判定を行い、その結果を再び SL へと差し戻す。そして、最終的に選別されたミュオン候補は MUCTPI を介して Global Trigger 及び CTP へと送信される。

Global Trigger では、L0Calo からの詳細なエネルギー情報を用いてトポロジカルクラスタリング、詳細な電子や光子、タウレプトンの識別、カロリメータ情報を用いたパイルアップ抑制などを行う。さらに L0Muon からの情報も組み合わせ、L1Topo を置き換えるように特定のトリガーオブジェクトに特化したトポロジカルトリガーの提供も行う。

CTP では、Global Trigger や MUCTPI からの情報を用いて最終的な L0 Accept (L0A) を発行する。L0A 信号は Front-End Link eXchange (FELIX) へと送信され、各検出器からデータの読み出しが行われる。

3.2 初段ミュオントリガーシステム

3.1 節では ATLAS トリガーシステムの概観について述べたが、本節では特に初段ミュオントリガーシステムについて述べる。LHC-ATLAS 実験 Run 3、及び高輝度 LHC-ATLAS 実験における初段ミュオントリガーシステムについて、それぞれ 3.2.1 節、3.2.2 節で述べる。また、それぞれのトリガー性能についても述べる。

3.2.1 LHC-ATLAS 実験 Run 3 における初段ミュオントリガーシステム

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を図 3.4 に示す。衝突点で生成されたミュオンは内部飛跡検出器やカロリメータを通過した後、トロイド磁場領域へ到達する。トロイド磁場領域には ϕ 方向に磁場が印加されており、磁場内でミュオンは R 方向に曲げられる。

ただし、トロイド磁場領域の前にはソレノイド磁場が存在する事に加え、実際のトロイド磁石による磁場には ϕ 方向成分の他に R 方向の成分も含まれている。このため、ミュオンは実際には R 方向と同時に ϕ 方向へも曲げられる事となり、 ϕ 方向の曲がりも考慮したトリガースキームが運用されている。以下で、トリガースキームについて詳細に説明する。

トロイド磁場を通過したミュオンは TGC 検出器に到達し、M1、M2、M3 の各チェンバーにヒットを残す。次に、M3 におけるミュオンのヒット位置と衝突点を結んだ直線 (無限大運動量を持つミュオンの軌跡) を定義する。ここで、M1 において無限大運動量ミュオンの飛跡からの実際のミュオンのヒット位置のずれ (R 方向: ΔR 、 ϕ 方向: $\Delta\phi$) を計算し、あらかじめ準備した ΔR 、 $\Delta\phi$ と p_T の参照表 (Look-Up Table: LUT) に入力する事で p_T を出力する。

ΔR 、 $\Delta\phi$ と p_T の参照表は Coincidence Window (CW) と呼ばれており、その一例を図 3.5 に示す。図 3.5 における各ビンの色が異なる p_T 閾値に対応しており、各 p_T 閾値に付された符号はミュオンの電荷に対応している。検出器アライメントの誤差や磁場の不均一性により、ミュオンが飛来する場所毎に ΔR 、 $\Delta\phi$ と p_T の対応が異なるため、CW は各 RoI 毎にそれぞれ独立に定




図 3.4: 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 [30]。無限大の運動量を持つミュオンを仮定し、磁場によって曲げられたミュオンとの位置の差を用いて p_T を計算する。

義されている。

実際の運用においては CW は FPGA の LUT 上に実装されており、CW の書き換えにも対応しつつ高速なトリガー判定を可能にしている。この手法により、シングルミュオンシミュレーションサンプルに対して p_T 閾値を計算し、各閾値におけるトリガー効率を p_T の関数として表した結果を図 3.6 に示す。このようなプロットは Turn-on curve と呼ばれ、各 p_T 閾値の Turn-on curve の立ち上がりの鋭さやプラトー領域のトリガー効率を見ることにより、トリガー性能を知る事ができる。

Run 2 における p_T 閾値は 6 段階であったが、Run 3 においては 15 段階の p_T 閾値が設定可能であり、先行研究によってその閾値が決定されている [31]。それぞれの p_T 閾値において Turn-on curve が分離しており、 p_T 閾値を選択する事でそれぞれ異なる p_T のミュオンを取得できる事が分かる。また、Turn-on curve のプラトー領域におけるトリガー効率は 90 – 95% 程度であり、高いトリガー効率を達成できている事が分かる。

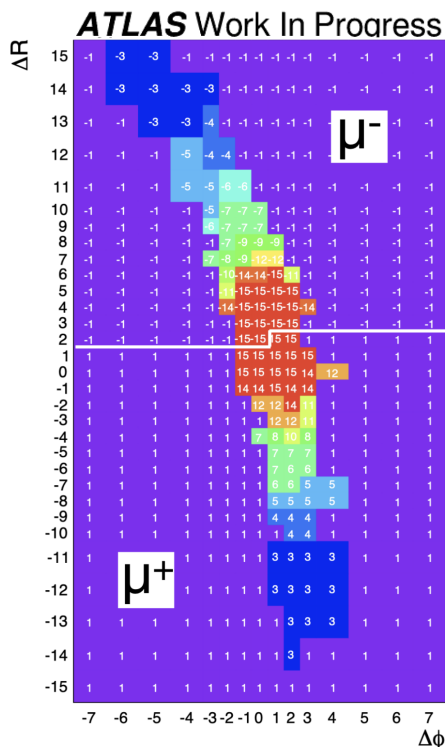


図 3.5: Run 3 における CW の一例 [31]。 ΔR 、 $\Delta\phi$ の入力に対して、ビンの値に対応した p_T 閾値が出力される。各 p_T 閾値に付された符号はミュオンの電荷に対応しており、白線よりも上側が μ^- 、下側が μ^+ へと対応している。




図 3.6: LHC-ATLAS 実験 Run 3 における Turn-on curve の例 [32]。シングルミュオンシミュレーションサンプルを用いて算出されている。マーカーの違いは p_T 閾値の違いに対応している。

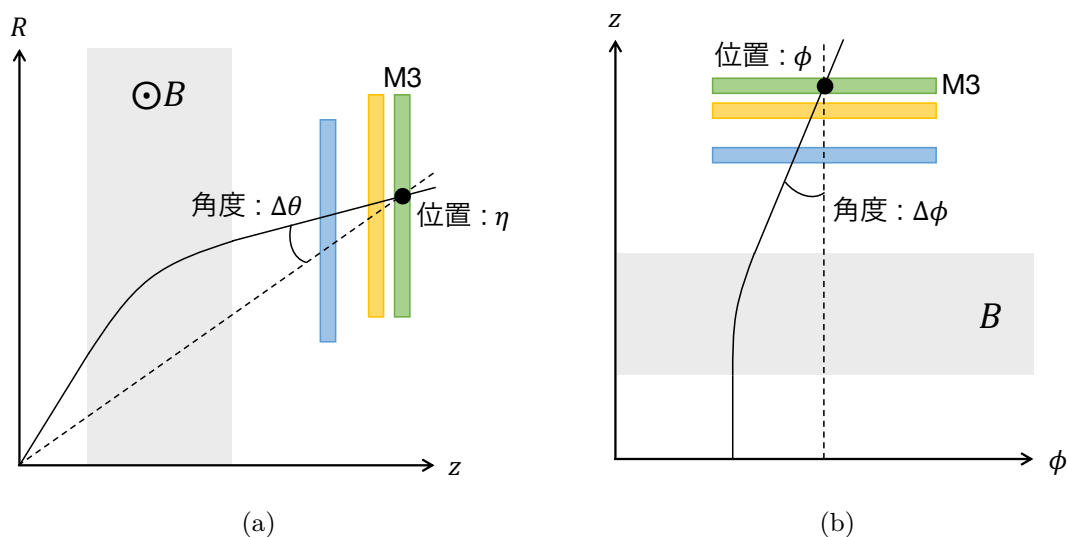


図 3.7: パターンリストに保存する位置・角度情報の詳細。黒の実線はミュオンの飛跡を表し、破線は衝突点と TGC M3 ステーションにおける飛跡の位置を結んだ直線である。(a): η 方向、(b): ϕ 方向。

3.2.2 高輝度 LHC-ATLAS 実験における初段ミュオントリガーシステム

高輝度 LHC-ATLAS 実験のエンドキャップ L0 ミュオントリガーでは、TGC のヒット情報を用いてパターンマッチングアルゴリズム [20] によりミュオン候補の再構成を行う。

パターンマッチングアルゴリズムでは、TGC のヒットパターンに対応した飛跡の位置・角度情報を予め計算してパターンリストを作成しておき、実際のヒットパターンとパターンリストを照合することでミュオン飛跡の位置・角度情報を測定する。パターンリストに保存する位置・角度情報の詳細を図 3.7 に示す。位置情報は TGC M3 ステーションにおける飛跡の位置 (η , ϕ) であり、角度情報は TGC M3 ステーションにおける飛跡の位置と衝突点を結ぶ直線とミュオン飛跡のなす角 ($\Delta\theta$, $\Delta\phi$) である。

ただし、TGC 検出器全チャンネル分のヒットパターンに対応するパターンリストのデータサイズは膨大となるため、Endcap SL に実装されている FPGA のメモリ上に保存する事ができない。そのため、TGC 検出器チャンネルのスタッガリング構造を利用し、パターンリストに保存するパターン数の削減を行う [33]。例として、ワイヤーチャンネルにおけるパターン数削減方法の概念図を図 3.8 に示す。M1、M2、M3 の各ステーションにおいて、ステーション内でチャンネルのコインシデンスを取る事により、各ステーションの代表点を定義する。このように代表点を用いてパターンリストを作成する事で、TGC 検出器 7 層分用意する必要があったパターンを代表点 3 層分まで削減する事ができる。さらに、代表点を用いる事でチャンネル幅よりも細かい単位でパターンを設定する事が可能となる。

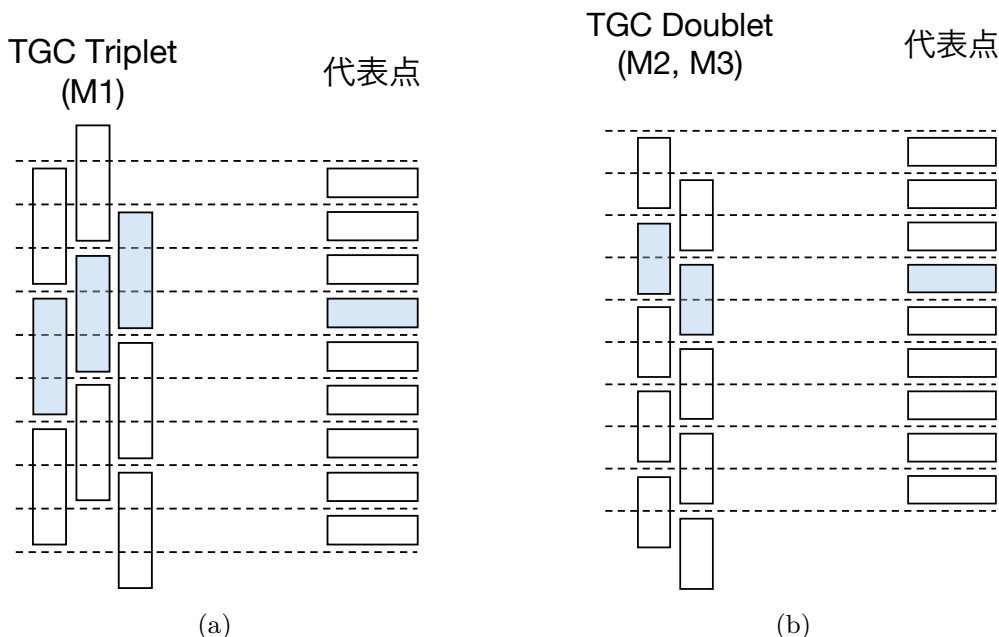


図 3.8: TGC 検出器ワイヤーチャンネルにおける代表点の決定方法。チャンネルのスタッガリング構造を利用する事で、チャンネル幅よりも小さな単位で代表点を決定する事ができる。(a): トリプレットチェンバー (M1) の場合、(b): ダブルレットチェンバー (M2, M3) の場合。

	M1	M2	M3	Output
⋮	⋮	⋮	⋮	⋮
pattern 57	6	7	9	$\Delta\theta_{57}, \eta_{57}$
pattern 58	6	8	9	$\Delta\theta_{58}, \eta_{58}$
pattern 59	6	9	9	$\Delta\theta_{59}, \eta_{59}$
⋮	⋮	⋮	⋮	⋮

(a)

	M1	M2	M3	Output
⋮	⋮	⋮	⋮	⋮
pattern 14	2	2	4	$\Delta\phi_{14}, \phi_{14}$
pattern 15	2	3	4	$\Delta\phi_{15}, \phi_{15}$
pattern 16	2	4	4	$\Delta\phi_{16}, \phi_{16}$
⋮	⋮	⋮	⋮	⋮

(b)

図 3.9: 代表点を用いたパターンリストの概念図。M1、M2、M3 の代表点に対応するパラメータを出力する。(a): ワイヤパターンリスト、(b): ストリップパターンリスト。

代表点を用いたパターンリストの概念図を図 3.9 に示す。ワイヤー・ストリップそれぞれに対してパターンリストが用意され、M1、M2、M3 の代表点の入力に対応する位置・角度情報の出力が行われる。最終的に、パターンリストからの η, ϕ の位置情報に対応した CW が選択され、その CW に角度情報 $\Delta\theta, \Delta\phi$ を入力する事で p_T 判定を行う。

LHC-ATLAS 実験 Run 2 と高輝度 LHC-ATLAS 実験におけるエンドキャップ領域の初段ミュオントリガー性能の比較を図 3.10 に示す。パターンマッチングアルゴリズムでは、Run 2 におけるトリガーアルゴリズムよりも TGC ステーション間のコインシデンスに関する条件が緩和さ




図 3.10: LHC-ATLAS 実験 Run 2 と高輝度 LHC-ATLAS 実験における Turn-on curve の比較 [34]。Run-2 アルゴリズムにおける結果は実データ、高輝度 LHC-ATLAS 実験のアルゴリズムにおける結果はシングルミュオンシミュレーションサンプルによる結果である。

れている。そのため、プラトー領域のトリガー効率に関して、高輝度 LHC-ATLAS 実験の結果では Run 2 の結果よりも 5% 程度向上している事が分かる。

また、パターンマッチングアルゴリズムによる飛跡再構成精度の向上により、高輝度 LHC-ATLAS 実験の Turn-on curve は Run 2 のものよりも立ち上がりが鋭くなっており、 p_T の分解能が向上している事が分かる。 p_T 分解能の向上は p_T 閾値以下のミュオンを取得する割合を減少させるため、トリガーレートの削減に繋がる。

3.3 ミュオントリガーシステムにおける課題

高輝度 LHC-ATLAS 実験や、さらに将来の素粒子実験を見越し、解決しなければならない様々な課題が存在する。更なる実験の高度化に向け、それらの課題に対してトリガーシステムからもアプローチを行っていく必要がある。本節では、トリガーシステムからアプローチが可能な課題として、以下の2点について述べる。

- 実験規模の拡大に伴うコストの増加への対応
- 長期間の実験におけるデータ取得の更なる安定化

3.3.1 実験規模の拡大によるコストの増大

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、その建設・運用コストが莫大である。更なる物理への理解のためには、高輝度 LHC-ATLAS 実験以後もさらにスケールを大きくした実験を行う事が不可欠であるが、スケールアップに伴い運用コストや環境への影響も更に大きくなる事が予測される。

LHC-ATLAS 実験において、年代毎に必要な計算機資源量の見積りを図 3.11 に示す。ベースラインの予測を見ると、高輝度 LHC-ATLAS 実験が開始する予定の 2027 年頃から、CPU・ディスクの必要リソースが共に急激に増加する事が見て取れる。また、高輝度 LHC-ATLAS 実験に向けて現行のシミュレーション手法をそのまま用いたり、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、CPU・ディスク共に必要となるリソースを賄う事ができない事が分かる。

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。例えば、誤って取得される事象を削減し、本当に取得したい事象のみを保存する事ができれば、データ保存量の削減及びデータ処理に用いる CPU リソースの削減を行う事ができる。そのためには、トリガーによる事象選別の更なる高性能化が必要である。

2015 年の国際連合サミットにおいて Sustainable Development Goals (SDGs : 持続可能な開発目標、図 3.12) が採択され、近年では日常生活においても様々な分野で取り組みがなされるようになってきている。素粒子実験においても、電力・計算効率の高い計算機を用いた消費電力の低減や、トリガーシステムの性能向上によって誤って取得される事象を減少させ、要求計算機資源量を低減するなど、地球環境への負荷を小さくして持続可能な形での実験へと変えていく努力が必要である。

3.3.2 長期間の実験におけるデータ取得の更なる安定化

LHC-ATLAS 実験は実験の性質上、一度のデータ取得期間が長期に渡り、検出器本体へとアクセスする事ができる期間が限られている。そのため、長期間に渡る安定的なデータ取得のためには




図 3.11: ATLAS 実験において、年代毎に必要な計算機資源量の見積もり [35]。(a): ディスク容量、(b): CPU リソース。図中のマーカーは、それぞれ丸のマーカーがベースライン、青の上三角のマーカーが技術開発の進展を保守的に見積もった場合、青の下三角のマーカーが技術開発が大きく進展した場合の必要量を表す。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時に賄う事ができる計算機資源量である。また、縦軸は HEP-SPEC06 (HS06) という指標を単位として表されている。HS06 とは、Worldwide LHC Computing Grid (WLCG) において CPU ベンチマーキングの指標として用いられている量であり、HEPiX Benchmarking Working Group [36] によって制定された。HEPiX Benchmarking Working Group の Web サイトには、様々なマシン構成における HS06 スコアが掲載されている。

検出器各システムの安定稼働が必要不可欠である。

エンドキャップ部ミュオントリガーに用いる TGC 検出器はガス検出器であり、運転のためには高電圧を印加する必要がある。後に 4.1 節で詳しく述べるが、長期に渡る実験期間中では、故障などの理由により高電圧を印加する事ができず、不感領域となる TGC チェンバー (デッドチェンバー) が発生する。実際に LHC-ATLAS 実験 Run 2 中にもデッドチェンバーが複数発生しており、トリガーシステム運用上の問題となっていた。

デッドチェンバーが存在すると当該領域のアクセプタンスが低下し、トリガー効率の低下を引き起こす。そのため、これまではデッドチェンバーに対して手動で処理を行い、トリガー効率の低下を最小限に抑えていた。しかし手動での取り扱いには限界があり、長期に渡ってより安定的なデータ取得を行うためには、デッドチェンバーの存在など、様々な検出器の状態に自動で対応可能なシステムが必要である。

3.4 本研究の目的

3.3 節で述べたように、高輝度 LHC-ATLAS 実験、またそれ以後の素粒子実験において、トリガーシステムから対応しなければならない課題が存在する。本研究では、3.3 節で述べた 2 つの課題



図 3.12: SDGs のロゴマーク [37]。持続可能な社会に向けて、17 の目標がアイコン化されている。

- 実験規模の拡大に伴うコスト増加への対応
- 長期間の実験におけるデータ取得の更なる安定化

に同時に対応可能な新たなトリガーシステムの探求を行う。

第4章では、シミュレーションを用いてデッドチェンバーがトリガー性能に与える影響を調査した結果について述べる。また、第5章では新たなトリガー判定アルゴリズムの開発を行い、その性能評価を行う。さらに、新たなアルゴリズムを組み込んだトリガーシステムの提案を行い、その展望について述べる。

第 4 章

デッドチェンバー存在下におけるトリガーアルゴリズム性能評価

第 3 章では、長期間の安定したデータ取得のためにはデッドチェンバーを始めとした検出器の状態変化に対応することが必要であると述べた。本章では、デッドチェンバーが存在する場合におけるトリガー性能への影響について、シミュレーションを用いて検証した結果を示す。4.1 節では、LHC-ATLAS 実験 Run 2 におけるデッドチェンバーの発生状況及びその対処についてまとめた。また、4.2 節では性能評価の方法について述べ、4.3 節では LHC-ATLAS 実験 Run 3 まで運用される現行のトリガーアルゴリズムにおける結果を、4.4 節では高輝度 LHC-ATLAS 実験で運用される予定のパターンマッチングアルゴリズムにおける結果を述べる。

4.1 デッドチェンバー

LHC-ATLAS 実験のように長期間に渡って運転が行われる素粒子実験では、経年劣化や故障などの理由により動作しなくなった検出器 (デッドチェンバー) が発生することがある。もちろん検出器は長期間の運用にも十分耐えられる放射線耐性を持つように設計がなされるが、様々な要因により検出器の故障が発生することは基本的に避けることができない。デッドチェンバーとなった検出器が存在する部分は不感領域となるため、その部分に飛来した粒子に対する検出効率が低下し、データ取得効率の低下に繋がる。実験の運転中には検出器にアクセスすることができず、故障した検出器の修理や交換を行うことができないため、長期に渡って安定的にデータ取得を行うためには、デッドチェンバーが存在しても粒子の検出効率の低下を低く抑えられるようなアルゴリズムの開発が不可欠である。

2015 年から 2018 年にかけて行われた LHC-ATLAS 実験 Run 2 において実際にデッドチェンバーが発生している。図 4.1 に Run 2 期間において TGC 検出器の高電圧が印加可能なチャンネルの割合の推移を示す。時間経過に伴って検出器の動作チャンネルの割合が低下している。また、Run 2 期間中の初段ミュオントリガー効率の推移を図 4.2 に示す。図 4.1 で示した高電圧印加可能チャンネルの割合低下に伴い、トリガー効率も徐々に低下している事が分かる。

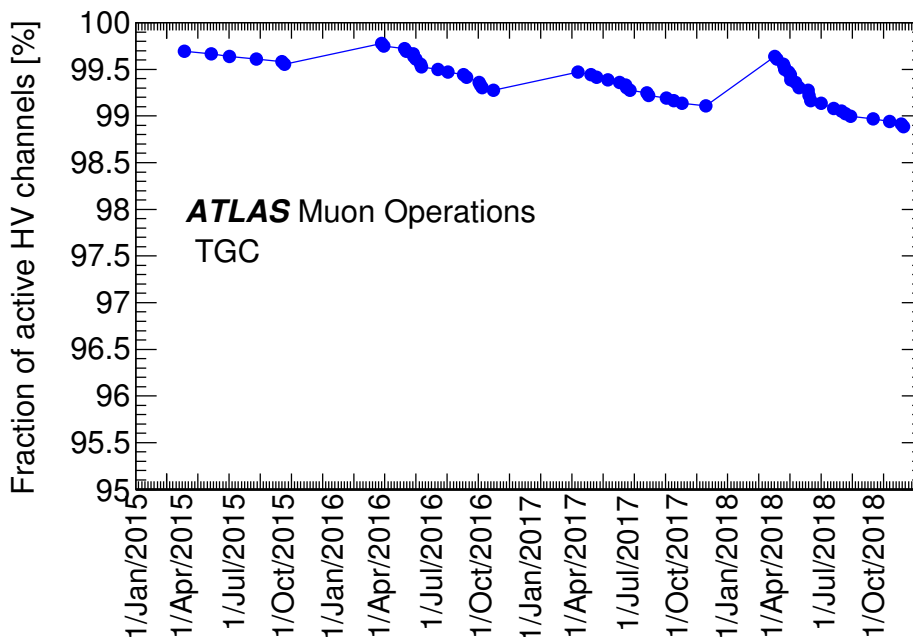


図 4.1: LHC-ATLAS 実験 Run 2 における、TGC 全チャンネルの内 HV が印加可能なチャンネルが占める割合の推移 [38]。冬季シャットダウン中に故障した検出器が交換されるため、年が変わる付近で割合が回復している。




図 4.2: LHC-ATLAS 実験 Run 2 におけるトリガー効率の推移 [38]。時間の経過と共にトリガー効率が低下している。




図 4.3: TGC 検出器ダブルットのワイヤーにおけるトリガー・データ読み出し経路の概略図 ([39] を編集)。(a): ダブルットのワイヤーにおけるトリガー・データ読み出し経路。上側がデータ読み出しの経路、下側がトリガーの経路である。赤色の網掛けで表されている部分で、トリガーの経路にのみ処理を行う。(b): トリプレットのワイヤーにおけるトリガー・データ読み出し経路。




図 4.4: LHC-ATLAS 実験 Run 2 において、TGC 検出器のデッドチェンバーに適用されていた処理のパターン。赤く塗ったチャンネルに強制的にヒットを埋めている。

デッドチェンバーに対しては毎年の冬季シャットダウン中に修理や交換の対応を行なっていたが、冬季シャットダウンまでの間は検出器へのアクセスができないため、トリガー処理の際に特別な処理によって対応していた。

TGC 検出器のトリガー・データ読み出し経路の概略図は図 4.3 のようになっており、検出器からのデータをトリガー処理に送る前に、任意のチャンネルに特定のヒットパターンを適用することができる機能 (mask2) が存在する。Run 2 においては、図 4.4 に示すように

1. デッドチェンバーにおいてもノイズによりチャンネルにヒットが生じる場合があるため、2 層のデッドチェンバーの内 1 層のチャンネルを全て OFF にする。
2. もう一方のデッドチェンバーのチャンネルを 1 チャンネルごとに ON にする。

という手順でヒットパターンを適用し、デッドチェンバーによるトリガー効率の低下を抑えていた。

例として、TGC 検出器トリプレットのワイヤーにおいてデッドチェンバーが 2 層存在する場合を考える。このとき、ヒットパターンの処理がない場合は、ミュオンによるヒットがあっても 3 層の内 1 層のチャンネルのみが ON となり、コインシデンス条件を満たさない。一方ヒットパター

ンの処理がある場合は、図 4.5 に示すようにコインシデンス条件を満たしデッドチェンバーによるミューオンの取得効率低下を抑えることができる。

しかし、デッドチェンバーの位置の記録やヒットパターンの処理作業は現在手動で行われているため、デッドチェンバーの数が増加すると手作業での処理が限界を迎え、長期間の安定したデータ取得への障害となる可能性がある。このように検出器オペレーションの観点からも、様々な検出器の状態に自動で対応可能なアルゴリズムの開発が望まれている。

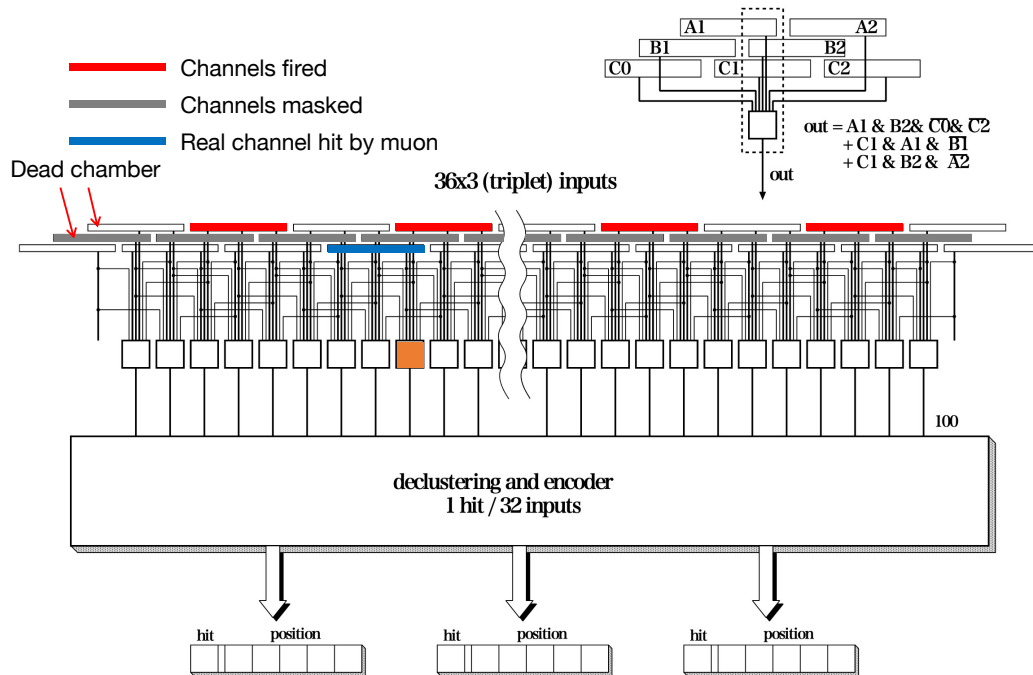


図 4.5: TGC 検出器トリプレットのワイヤーにおいてデッドチェンバーが2層存在する場合に対して、mask2 によってヒットパターンを適用した際のコインシデンス概要図 ([39] を編集)。ヒットパターンの適用があることでコインシデンス条件を満たし、出力 (橙色) がなされる。

表 4.1: シミュレーションサンプル作成の際に発生させたデッドチェンバーのパターン一覧。

パターン	1	2	3	4	5	6	7
1層	M1 Lyr1	M1 Lyr2	M1 Lyr3	M2 Lyr1	M2 Lyr2	M3 Lyr1	M3 Lyr2
2層	M1 Lyr1	M1 Lyr1	M1 Lyr1	M1 Lyr1	M1 Lyr1	M1 Lyr1	M1 Lyr1
	M1 Lyr2	M1 Lyr3	M2 Lyr1	M2 Lyr2	M3 Lyr1	M3 Lyr2	

4.2 デッドチェンバーがトリガー性能へ与える影響の評価方法

3.4節で述べた通り、LHC-ATLAS 実験 Run 2 において実際にデッドチェンバーが発生しており、トリガー性能への影響が懸念されている。本研究では、シミュレーションによって様々なパターンのデッドチェンバーが存在する状況を再現し、それぞれの場合についてトリガー性能の評価を行った。また、実際に LHC-ATLAS 実験 Run 2 においてデッドチェンバーに対して適用されていた処理を適用した場合のトリガー性能についても同時に評価を行った。

本節では、デッドチェンバーが存在する場合におけるトリガー性能評価の方法について述べる。

4.2.1 現行トリガーアルゴリズムの評価に用いるサンプルの作成

本研究では、TGC 検出器フォワード領域において、デッドチェンバーが存在する場合のトリガー性能の評価を行った。性能評価に用いるシミュレーションサンプル作成の際には、TGC 検出器の構造及びトロイド磁場の 8 回対称性を利用した。

図 4.6 に示すように、対称な 1/8 領域 (オクタント) 毎に 1 ~ 8 の番号を割り当て、それぞれの領域毎に異なるデッドチェンバーのパターンを発生させてシミュレーションを行った。表 4.1 にシミュレーションサンプル作成の際に発生させたデッドチェンバーのパターン一覧をまとめた。

また、図 4.7 及び図 4.8 はそれぞれデッドチェンバーが 1 層及び 2 層の場合に、表 4.1 にまとめたパターンを TGC 検出器の展開図に図示している。表 4.1 中のパターン番号は、図 4.6 のオクタントに割り振った番号に対応している。

このデッドチェンバーの設定で、ミューオンの p_T を 1~100 GeV、 η を $1.05 < |\eta| < 2.4$ 、 ϕ についても一様に分布する条件でシミュレーションサンプルの生成を行った。

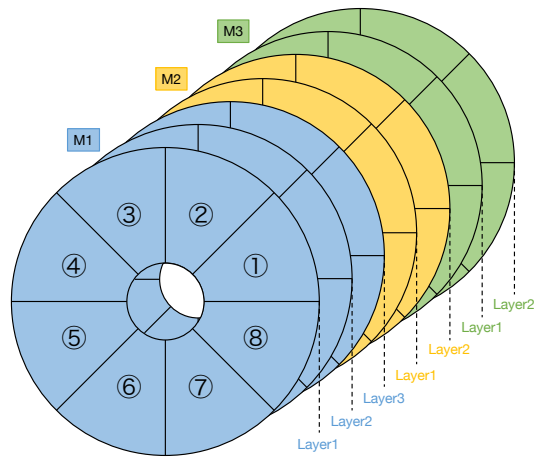


図 4.6: 性能評価に用いるサンプルを作成する際の領域分けの方法。

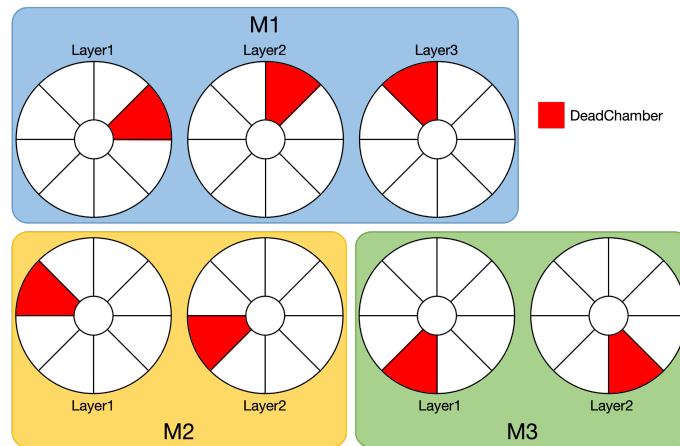


図 4.7: デッドチェンバーが1層のサンプルを作成する際に、オクタント毎にデッドチェンバーを発生させた位置のまとめ。




図 4.8: デッドチェンバーが2層のサンプルを作成する際に、オクタント毎にデッドチェンバーを発生させた位置のまとめ。




図 4.9: シミュレーションサンプルを作成する際に、デッドチェンバーを発生させたチェンバーのまとめ。灰色で表した位置のチェンバーがデッドチェンバーとなっている。

4.2.2 高輝度 LHC-ATLAS 実験におけるトリガーアルゴリズムの評価に用いるサンプルの作成

TGC 検出器フォワード領域において、デッドチェンバーが存在する場合のトリガー性能の評価を行った。性能評価にはシミュレーションサンプルを用い、様々なパターンのデッドチェンバーを発生させる事でデッドチェンバーに対するパターンマッチングアルゴリズムのトリガー性能を評価した。

4.2.1 節でサンプルを作成した際のようにオクタンツ毎にデッドチェンバーのパターンを振り分けるのではなく、1つのパターンに対して全オクタンツをデッドチェンバーとし、パターン数分新たにサンプルを作成した。デッドチェンバーを発生させたパターンは図 4.9 に示す通りであり、デッドチェンバーが 1 層及び 2 層のパターンについて性能評価を行った。ミューオンの p_T を $1 \sim 100$ GeV、 η を $1.05 < |\eta| < 2.4$ 、 ϕ についても一様に分布する条件でシミュレーションサンプルの生成を行った。

4.2.3 性能評価の方法

4.2.1 節及び 4.2.2 節で作成したシミュレーションサンプルについて、トリガー性能の評価を行った。性能評価のために、全オフラインミューオンの内、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 (4.1) 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。フィッティングを行った Turn-on curve の一例を図 4.10 に示す。

$$f(p_T) = \frac{p_0}{\exp\left(\frac{p_T - p_1}{p_2}\right) + 1} \quad (4.1)$$

本研究では、トリガー性能を表す指標として

- Plateau efficiency
- Effective threshold
- Resolution

の 3 つのパラメータを用いる。これらのパラメータはそれぞれ式 (4.1) 中のフィッティングパラメータ p_0 、 p_1 、 p_2 に対応しており、図 4.10 中にそれぞれのパラメータの概念を図示している。以下に、3 つのパラメータについてそれぞれ詳細な説明を述べる。

p_0 : Plateau efficiency

Turn-on curve が立ち上がった後のトリガー効率を表す。トリガー閾値以上の p_T を持つミューオンに対するトリガー効率を表すため、その値が 1 に近い方が高性能である。

p_1 : Effective threshold

あるトリガー閾値における実効的な p_T の閾値を表す。トリガー効率が Plateau efficiency の半分となる p_T の値である。

p_2 : Resolution

あるトリガー閾値における運動量の分解能を表し、Turn-on curve の立ち上がりの鋭さに対応する。Resolution の値が大きくなると Turn-on curve の立ち上がりが緩くなり、Effective threshold 以下の p_T を持つミューオンの取得効率が上昇してしまうため、 p_T の分解能が悪くなる。式 (4.1) は $p_2 \rightarrow 0$ でステップ関数となるため、Resolution の値が小さいほど高性能である。




図 4.10: 式 (4.1) によってフィッティングを行った Turn-on curve の一例。

4.3 現行トリガーアルゴリズムにおける性能評価

本節では、現行のトリガーアルゴリズムにおいて、デッドチェンバーが存在する場合の性能評価を行う。初めに、デッドチェンバーのパターンに対する Plateau efficiency の比較を図 4.11 に示す。デッドチェンバーが1層の場合は、最大で15%程度トリガー効率が低下する事が見て取れる。M1ステーションにデッドチェンバーが存在する場合、M2、M3ステーションにデッドチェンバーが存在する場合よりもトリガー効率の低下が小さく抑えられている。これは、M1ステーションがM2、M3ステーションとは異なり Triplet 構造であるため、1層がデッドチェンバーとなってもコインシデンス条件を満たす事ができるイベントの割合が大きいためであると考えられる。

また、図 4.11 で示したデッドチェンバーが2層存在するパターンにおいては、アルゴリズムの設計上現行のトリガーアルゴリズムではトリガーを発行する事ができない。これらのパターンに対して、2層のデッドチェンバーの内1層にヒット埋め処理を行なった場合、多くのパターンにおいて80%程度までトリガー効率が回復する事が見て取れる。一方、パターンによっては30%や70%程度しかトリガー効率が回復していない事が分かる。




図 4.11: デッドチェンバーのパターンに対する Plateau efficiency の比較。赤線はデッドチェンバーがない場合の Plateau efficiency を示す。上三角のマーカは、赤文字で示したチェンバーにダミーヒットを埋める処理を行なった場合の結果を示す。




図 4.12: デッドチェンバーのパターンに対する Effective threshold の比較。赤線はデッドチェンバーがない場合の Effective threshold を示す。上三角のマーカは、赤文字で示したチェンバーにダミーヒットを埋める処理を行なった場合の結果を示す。




図 4.13: デッドチェンバーのパターンに対する Resolution の比較。赤線はデッドチェンバーがない場合の Resolution を示す。上三角のマーカは、赤文字で示したチェンバーにダミーヒットを埋める処理を行なった場合の結果を示す。

次に、デッドチェンバーのパターンに対する Effective threshold の比較を図 4.12 に示す。デッドチェンバーが1層の場合は、デッドチェンバーが存在しない場合と比較して Effective threshold の値は大きく変化しない事が見て取れる。

また、デッドチェンバーが2層存在し、内1層にダミーヒットを埋める処理を行なった場合、ほとんどのパターンではデッドチェンバーが存在しない場合の Effective threshold と同程度の値となっている。一方、M3ステーションにデッドチェンバーが2層存在するパターンでは、他のパターンと比較して1 GeV程度 Effective threshold が低い事が分かる。3.2.2節で述べたように、現行トリガーアルゴリズムではM3ステーションのヒット位置を基準としてトリガー判定を行うため、このような場合でトリガー性能の回復が小さいと考えられる。

さらに、デッドチェンバーのパターンに対する Resolution の比較を図 4.13 に示す。デッドチェンバーが1層の場合は、デッドチェンバーが存在しない場合と比較して Resolution の値は大きく変化しない事が分かる。一方、デッドチェンバーが2層存在し、内1層にダミーヒットを埋める処理を行なった場合、パターンによっては若干 Resolution が悪化していることが分かる。

4.4 高輝度 LHC-ATLAS 実験のトリガーアルゴリズムにおける性能評価

本節では、高輝度 LHC-ATLAS 実験のトリガーアルゴリズムにおいて、デッドチェンバーが存在する場合の性能評価を行う。初めに、デッドチェンバーのパターンに対する Plateau efficiency の比較を図 4.14 に示す。デッドチェンバーが 1 層の場合は、最大で 5% 程度トリガー効率が低下する事が見て取れる。M1 ステーションにデッドチェンバーが存在する場合、M2、M3 ステーションにデッドチェンバーが存在する場合よりもトリガー効率の低下が小さく抑えられている。これは、M1 ステーションが M2、M3 ステーションとは異なり Triplet 構造であるため、1 層がデッドチェンバーとなってもコインシデンス条件を満たす事ができるイベントの割合が大きいためであると考えられる。

一方、デッドチェンバーが 2 層存在する場合、デッドチェンバーが 1 層の場合よりもトリガー効率の低下が大きく、30% 程度のトリガー効率低下が見て取れる。また、2 層のデッドチェンバーの内 1 層に Run2 と同様のダミーヒットを埋める処理を行なった場合、パターンによっては 90% 近くまでトリガー効率が回復している事が分かる。しかし、ダミーヒットを埋める処理を行なってもトリガー効率の回復が 5% 程度に留まるパターンも存在し、4.3 節で示した現行トリガーアルゴリ




図 4.14: デッドチェンバーのパターンに対する Plateau efficiency の比較。赤線はデッドチェンバーがない場合の Plateau efficiency を示す。上三角のマーカは、赤文字で示したチェンバーにダミーヒットを埋める処理を行なった場合の結果を示す。




図 4.15: デッドチェンバーのパターンに対する Effective threshold の比較。赤線はデッドチェンバーがない場合の Effective threshold を示す。上三角のマーカは、赤文字で示したチェンバーにダミーヒットを埋める処理を行なった場合の結果を示す。




図 4.16: デッドチェンバーのパターンに対する Resolution の比較。赤線はデッドチェンバーがない場合の Resolution を示す。上三角のマーカは、赤文字で示したチェンバーにダミーヒットを埋める処理を行なった場合の結果を示す。

ズムの場合と同様に、ダミーヒットを埋める処理が全ての場合に対して有効という事ではないと分かる。

次に、デッドチェンバーのパターンに対する Effective threshold の比較を図 4.15 に示す。デッドチェンバーが1層の場合は、デッドチェンバーが存在しない場合と比較して Effective threshold の値は大きく変化しない事が見て取れる。

一方、デッドチェンバーが2層存在する場合は若干 Effective threshold が低下する傾向があることが分かる。また、デッドチェンバー2層の内1層に Run 2 と同様のダミーヒットを埋める処理を行なった場合、パターンに依らずデッドチェンバーが存在しない場合と同程度まで Effective threshold が回復している事が見て取れる。

さらに、デッドチェンバーのパターンに対する Resolution の比較を図 4.16 に示す。デッドチェンバーが1層の場合は、デッドチェンバーが存在しない場合と比較して Resolution の値は大きく変化しない事が見て取れる。

一方、デッドチェンバーが2層存在する場合は若干 Resolution が悪化することが分かる。また、デッドチェンバー2層の内1層に Run 2 と同様のダミーヒットを埋める処理を行なった場合、パターンに依らず Resolution がさらに悪化している事が分かる。

4.4.1 性能評価のまとめ

4.3 節及び 4.4 節では、現行のトリガーアルゴリズム及び高輝度 LHC-ATLAS 実験において用いられる予定のパターンマッチングアルゴリズムのそれぞれで、デッドチェンバーが存在する場合のトリガー性能の評価を行なった。

デッドチェンバーが1層の場合、パターンマッチングアルゴリズムでは現行のトリガーアルゴリズムと比較してトリガー効率の低下を 5% 程度小さく抑えられている。

一方、デッドチェンバーが2層の場合では、ダミーヒットを埋める処理を行なったとしても、どちらのトリガーアルゴリズムもトリガー効率の回復量はパターンによって大きく異なっている。特に、パターンマッチングアルゴリズムでは 5% 程度しかトリガー効率が回復しないパターンが存在する事に加え、ダミーヒットを埋める処理により Resolution が悪化する事が分かった。

以上のように、デッドチェンバーが複数層存在する場合、パターンマッチングアルゴリズムでは LHC-ATLAS 実験 Run 2 において行われていたダミーヒットを埋める処理を行ったとしても、トリガー効率の回復が限定的となる場合がある。また、従来のダミーヒットを埋める処理は故障が発覚したチェンバーに対して、手動で処理を行なう必要があった。長期間に渡る実験期間においてより安定的なトリガー運用を行うためには、デッドチェンバーに対して自動で対応でき、同時にできるだけトリガー効率を高く保つ事が必要である。これらの2つの課題に同時に応えるためには、従来のダミーヒットを埋める処理とは異なる対応方法の検討が必要であり、第5章において述べていく。

第 5 章

深層学習を用いたトリガーアルゴリズムの構築

第 4 章ではデッドチェンバーが存在する場合にトリガー性能が低下し、新たな対処法を開発する必要があると示した。本章では、初めに本研究で提案するトリガーシステムの設計について述べる。また、近年アルゴリズムの発展が著しい種々の深層学習手法についての概説や、深層学習が素粒子実験で応用されている例を挙げ、深層学習を用いたトリガーアルゴリズムの構築及びその性能評価について述べる。

5.1 トリガーシステムの設計

本節では、TGC 検出器におけるミュオン飛跡の特徴や高輝度 LHC-ATLAS 実験で想定されているミュオントリガーバスを基に新たなトリガーシステムの提案を行う。

5.1.1 TGC 検出器における飛跡の特徴

第 3 章で述べたように、TGC 検出器ではミュオン飛跡情報を用いて横方向運動量 (p_T) を概算し、トリガー判定を行う。ミュオンはトロイド磁場領域を通過し、ミュオン検出器に到達する前に曲げられる。図 5.1 に示すように、高い運動量のミュオンはあまり曲げられることなく TGC 検出器まで到達する一方、低い運動量のミュオンは大きく曲げられる。

ミュオン飛跡を η に対する曲がり方という観点で考えると、図 5.1 から分かるように、高い運動量のミュオンは低い運動量のミュオンよりも η に沿ってより直線的な飛跡を残す事が分かる。従って、TGC 検出器におけるミュオンヒットパターンを図 5.2 のように 2 次元の画像として表すと、 p_T の違いによるミュオン飛跡パターンの特徴の違いがよく分かる。

また、第 4 章で問題にしたデッドチェンバーが存在する場合の飛跡パターンについても考える。図 5.3 に、デッドチェンバーが存在する場合の典型的な飛跡パターンの概念図を示す。人間の目で図 5.3 を見ると、デッドチェンバーが 2 層程度存在する場合であっても、最左端の元の飛跡を推測

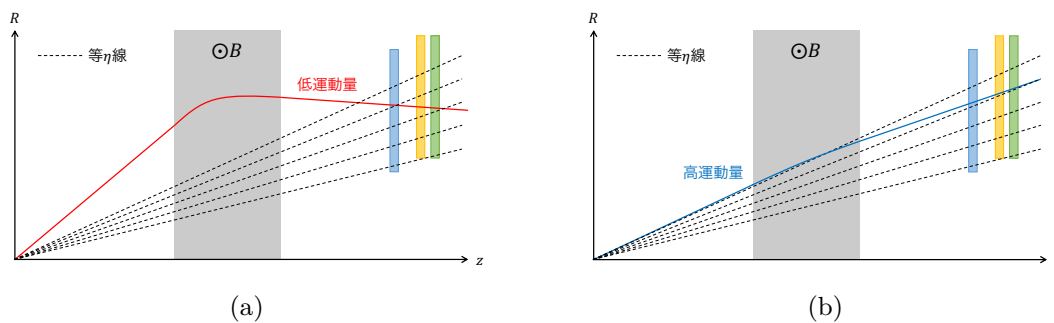


図 5.1: 横方向運動量 p_T の違いによるミュオンの曲がり方の違い。(a): 低運動量の場合、(b): 高運動量の場合。




図 5.2: TGC 検出器ワイヤーチャンネルにおける典型的な飛跡パターンの概念図。高運動量ミュオンの方が、より直線的な飛跡パターンを示す。

することが可能である。一方、第 4 章で示したように、現行のトリガーアルゴリズムは、デザイン上このようなデッドチェンバーが存在する場合の飛跡に対して弱く、トリガー効率が大きく低下する。

そこで、以上の TGC 検出器におけるミュオンの飛跡パターンの特徴

- 高い運動量のミュオンは η に沿ってより直線的な飛跡を残す
- デッドチェンバーが存在しても、人間の目ではある程度飛跡パターンが補完できる

を有効に利用することができる手法として、パターン認識に強く、近年発展の著しい深層学習を検討する。深層学習技術の中でも、特に画像処理分野でよく用いられている畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) はその層構造により特にパターン認識に強く、本研究でトリガーシステムに新たに導入する技術として非常に適している。これらの深層学習技術については、5.2 節で述べる。




図 5.3: TGC 検出器ワイヤーチャンネルにおける、デッドチェンバーが存在する場合の典型的な飛跡パターン概念図。最左端の飛跡パターンに対して、右側にデッドチェンバーが存在する場合の飛跡パターンを示している。

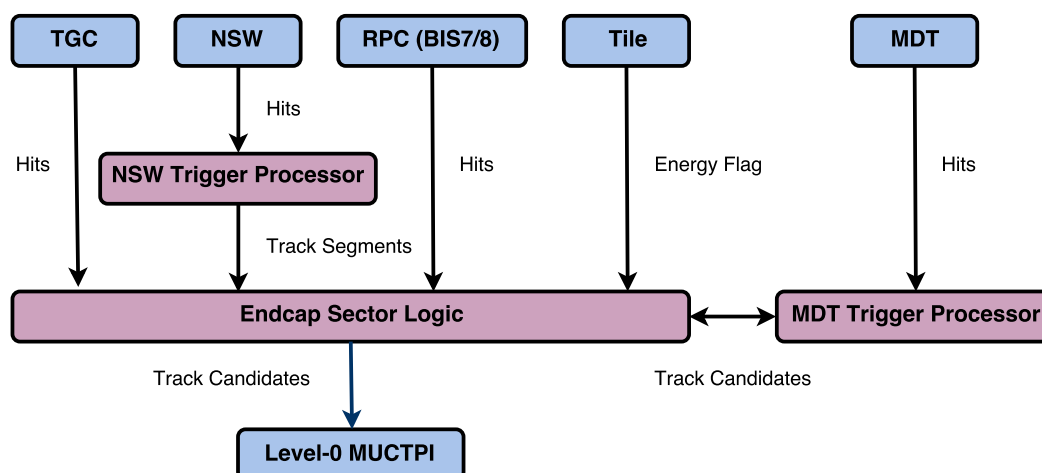


図 5.4: 高輝度 LHC-ATLAS 実験におけるエンドキャップ部ミューオントリガー情報の流れ [20]。

また、トリガーと深層学習はトリガーの運用という面においても親和性が高い。トリガーシステムに深層学習を導入すると、実験期間中に取得される大量のデータを用いて、実験期間中に随時深層学習モデルを再トレーニングさせることが可能となり、トリガー性能のさらなる向上を見込むことができるなどの利点が考えられる。この点に関して本研究で提案するトリガーシステムの構成については 5.6 節に後述する。

5.1.2 トリガーシステムへの深層学習の導入

図 5.4 に、高輝度 LHC-ATLAS 実験におけるエンドキャップ部ミューオントリガー情報の流れを示す。初めに、Sector Logic (SL) において TGC 検出器のヒット情報を用いてミューオン候補が

選別される。さらに、選別されたミュオン候補に対して、タイルカロリメータなど他の検出器の情報との照合が行われる。また、SL からの情報は MDT-TP へと送られ、MDT のヒット情報を用いてより詳細なトリガー判定を行う。

この時重要な事は、SL におけるミュオン候補の選別時にミュオン候補を取り逃がさず、デッドチェンバーが存在してもトリガー効率を落とさない事である。SL の時点でミュオン候補が残っていれば、たとえその時点で p_T の分解能が悪くとも後段の MDT-TP の情報を用いて p_T 測定の精度を回復させることが可能である。従って、本研究では TGC 検出器におけるミュオン候補選別のロジックに深層学習を取り入れ、デッドチェンバーに対するトリガー効率の向上などの性能向上を一番の目標とする。

図 5.5 に、SL におけるミュオン候補選別の概念図を示す。TGC 検出器のワイヤー・ストリップ情報は、信号のタイミング調整のための Delay ブロック、4.1 節で述べた処理などの機能を持つ Mask ブロックを通過し、それぞれ独立にミュオンの ϕ 方向、 η 方向の再構成に用いられる。

本研究では、比較的磁場の歪みが少なく、ミュオンの ϕ 方向への曲がり小さいフォワード領域 ($1.9 < |\eta| < 2.4$) を対象として検証を行う。そのため、ミュオンのトリガー判定には η 方向の

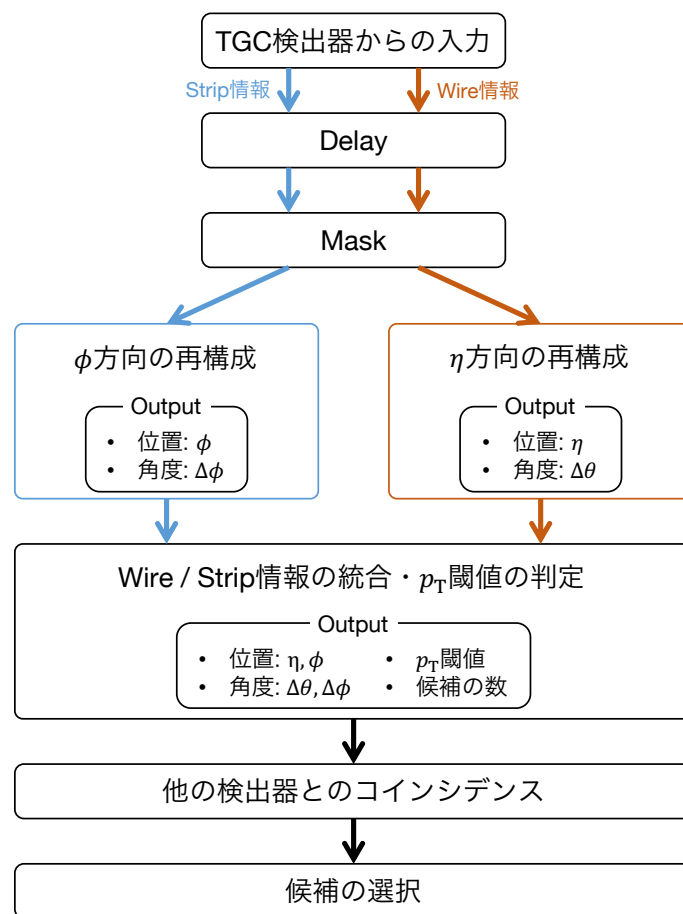


図 5.5: Sector Logic におけるミュオン候補選別の概念図。

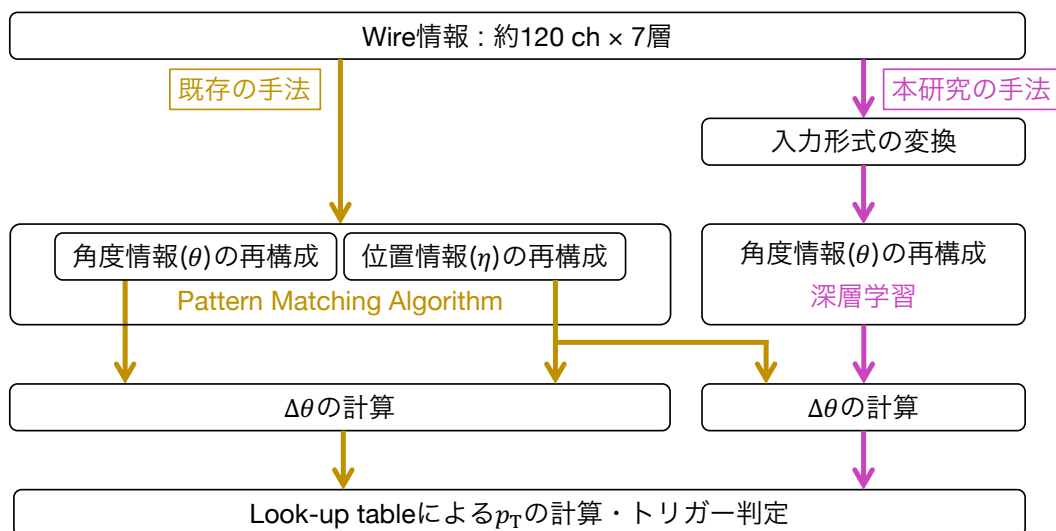


図 5.6: 既存の手法および本研究の手法によるトリガー判定の概念図。

情報の再構成がより大きな影響を与える。そこで、本研究では η 方向の情報の内、ミューオン飛跡の角度情報の再構成に深層学習を導入する。

本研究で開発したトリガーシステムの概念図を図 5.6 に示す。既存のシステムでは、ワイヤーの情報から 3.2.2 節で述べた Pattern Matching Algorithm によってミューオン飛跡の位置情報・角度情報の再構成を行う。一方、本研究で開発したシステムでは深層学習を用いてミューオン飛跡の角度情報を再構成する。初めに、入力のワイヤー情報を深層学習モデルへの入力に適した形式へと変換を行う。この変換については、5.4.1 節で詳しく述べる。続いて、5.4.2 節で述べる深層学習モデルを用いて飛跡の角度情報の再構成を行う。飛跡の位置情報の再構成には既存のパターンマッチングアルゴリズムを用いて、深層学習によって再構成した角度情報と併せて角度差 $\Delta\theta$ の計算を行う。

最終的に、パターンマッチングアルゴリズムと同じ Look-up table へと計算した角度情報を入力し、トリガー判定を行う。5.5 節では深層学習を用いた角度情報再構成の性能について述べ、実際に上述したシステムを用いてトリガー判定を行った場合のトリガー性能の評価を 5.6 節で行う。

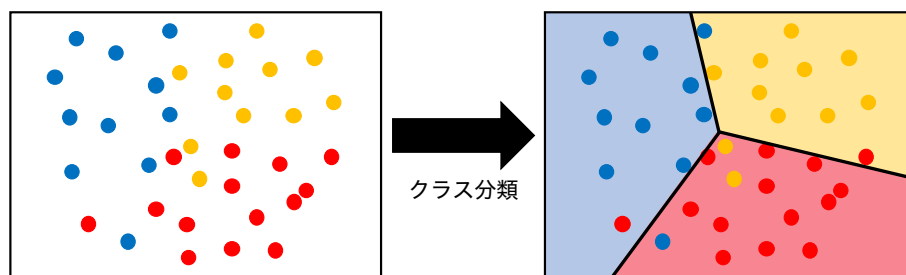


図 5.7: クラス分類の概念図。この図では、赤、青、黄の 3 色のデータを直線によってクラス分けしている。

5.2 機械学習と深層学習

深層学習とは機械学習手法の 1 種であり、近年の計算機の性能向上に伴って従来の機械学習よりも深い層構造を持つモデルを用いて学習を行う手法である。深層学習は従来の機械学習と同様にクラス分類や回帰などのタスクに対応することができるが、その深い層構造を活かしてより高い汎化性能を獲得することができる。

本節では、種々の深層学習手法についての概説及び素粒子実験において深層学習が応用されている例について述べる。

5.2.1 機械学習

機械学習とは、コンピュータを用いてデータの中から特徴的なパターンを見つけ出し (学習)、その結果を用いて未知のデータに対する分類や値の推測を行う解析手法である。機械学習の特徴は、コンピュータプログラムに知的な作業をさせたいときに、作業のこなし方を明示的に指示するプログラムは必要がないということである [40]。

現在では様々な機械学習アルゴリズムが開発されており、素粒子実験分野でよく使用されている手法として Boosted Decision Tree [41] や Multi Layer Perceptron [42] が挙げられる。各アルゴリズムは、データ間の相関の有無などによって得意・不得意があるため、入力データを考慮して用いるアルゴリズムを選択する必要がある。

機械学習を用いて解くことができるタスクは大きく分けてクラス分類と回帰に分ける事ができ、以下ではそれぞれについて簡単に説明する。

クラス分類

クラス分類とは、入力されたデータを複数のカテゴリーに分類する問題である。図 5.7 に示すように、線形または非線形な関数を用いて、パラメータ空間内のデータ群に境界線を引くことでカテゴリー分けを行う。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




図 5.8: 回帰分析の概念図。入力変数 (青い点) と目的変数 (黒い線) の間の関係 (関数) を求める。

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 [43]。特にクラス分類を用いて様々な粒子同定アルゴリズムの開発が行われており、LHC-ATLAS 実験における b ジェットの識別 [44]、CMS 実験のデータを用いたブーストされたトップクォークの識別 [45] などの例が挙げられる。

また、ATLAS 実験においては超対称性粒子の探索 [46] や標準理論粒子の精密測定 [47] など、様々な解析において機械学習を用いたシグナル及びバックグラウンドの分離が用いられている。

回帰分析

回帰分析とは、目的変数と説明変数 (目的変数の特徴を表す変数) との間の関係を求める問題である。図 5.8 にその概念図を示す。1次元もしくは多次元の説明変数を用いて目的変数を表すような関数を作成する。例として、最小二乗法を用いた1次元のフィッティングも回帰分析の一種と言える。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説明変数とし、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。例として、CMS 実験では、光子のエネルギー補正に回帰分析が用いられている [48]。

5.2.2 深層学習

深層学習とは、5.2.1 節で述べたタスクのために、データの中からそのデータの特徴づける表現 (特徴量) を学習する手法であると言える。図 5.9 に深層学習による表現学習の概念図を示す。深層学習アルゴリズムは様々な役割を持つ「層」を用いて構成されており、多数の層を用いてデータから表現を学習し、タスクの解決に用いる。図 5.9 では、猫の顔を構成するパーツを各層が学習し、猫の特徴を捉える様子を表す。

深層学習手法には、大きく分けて教師データ (正解データ) を用いて学習を行う「教師あり学習」、教師データを用いずに学習を行う「教師なし学習」の 2 種類が存在する。本節では、本論文において用いる手法である教師あり学習について取り扱う。

図 5.10 に、教師あり深層学習の流れの概念図を示す。深層学習モデルは一般的に複数の層から構成されており、それぞれの層は重みパラメータを有している。単純なニューラルネットワークモデルの場合を例にすると、各層では入力 \vec{I} 、重み \vec{w} 及びバイアス b を用いて計算した値

$$\vec{I} \cdot \vec{w} + b \quad (5.1)$$

を活性化関数に入力し、出力値を得る。活性化関数としてよく用いられる関数としては双曲線正接関数や ReLU 関数があり、その概形を図 5.11 に示す。ReLU 関数は

$$\text{ReLU}(x) = \max(0, x) \quad (5.2)$$

と定義される関数であり、表式がシンプルであるため計算速度が速い、スパース性により神経構造

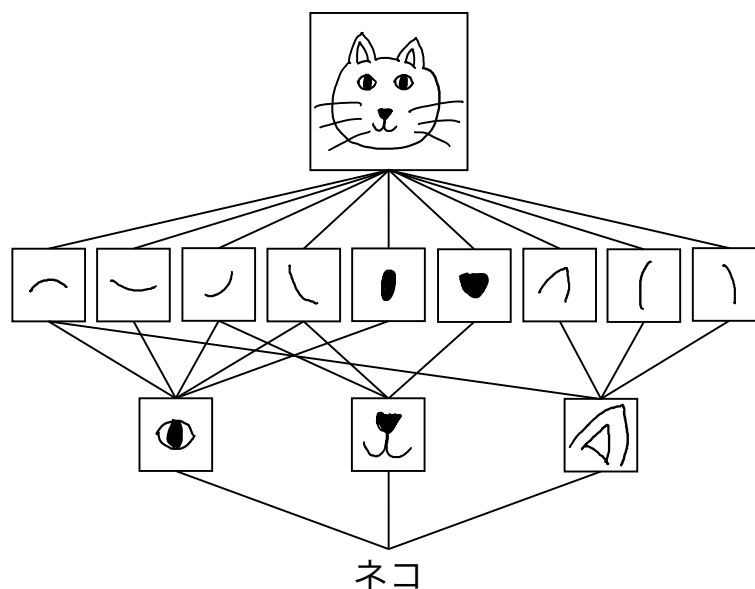


図 5.9: 深層学習による表現学習の概念図。多数の層を用いてデータの特徴づける表現を学習し、タスクの解決に用いる。

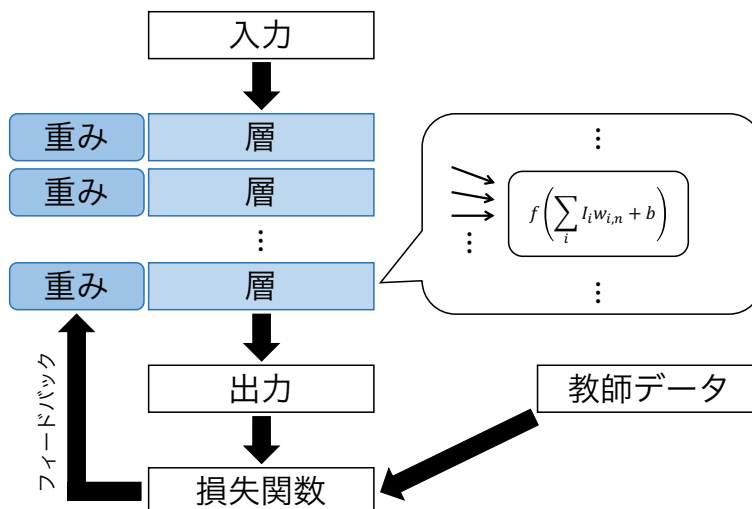


図 5.10: 教師あり深層学習の流れの概念図。




図 5.11: 活性化関数としてよく用いられる関数の例。(a): 双曲線正接関数、(b): ReLU 関数。

に近いネットワーク構造を実現でき、性能向上を見込むことができるなどの利点を持つ [49]。

最終的にネットワークから出力された値は、損失関数 (Loss function) により正解値 (教師データ) との誤差の評価が行われる。損失関数としてよく用いられる関数として、平均二乗誤差 (Mean Squared Error) や多クラス交差エントロピー (Categorical Cross Entropy) が挙げられる [50]。平均二乗誤差はサンプル数 N 、教師データの値 y_n 及びネットワークの出力値 \hat{y}_n を用いて式 (5.3) で与えられ、主に回帰問題の損失関数として用いられる。

$$E = \frac{1}{N} \sum_{n=1}^N (\hat{y}_n - y_n) \tag{5.3}$$

一方、多クラス交差エントロピーはサンプル数 N 、分類クラス数 C 、教師データのラベル y_c 、

ネットワークの出力ラベル \hat{y}_c を用いて式 (5.4) で与えられ、主に分類問題の損失関数として用いられる。

$$E = - \sum_{n=1}^N \sum_{c=1}^C y_c \log \hat{y}_c \quad (5.4)$$

損失関数は教師データとネットワークの出力値の誤差が小さいほど小さな値を出力するため、損失関数の値を最小化するように重みの更新が行われ、学習が進められる。学習の中で重みの更新を行う回数をエポックと呼び、一度の重み更新で変更する重みの大きさを調節する学習率 (Learning rate) などと合わせてハイパーパラメータとして扱う。ハイパーパラメータは学習において決定するのではなく、ネットワークの構造やデータの性質によって人間が予め設定する必要がある。

最終的な学習の結果、ネットワークが学習に用いたデータに過剰に適合し、汎化性能が低くなってしまう過剰適合 (Overfitting) や、ネットワークが十分にデータに適合できていない状態である学習不足 (Underfitting) などが生じる場合がある。このような状態は、汎化性能の獲得を目的とする深層学習においては望ましくない。そのため、学習率などハイパーパラメータの調整、データ構造やネットワーク構造の見直しなどを行い、汎化性能の高いネットワークを学習させる必要がある。

近年のコンピュータの高性能化に伴い、従来の単純なニューラルネットワークよりも複雑な構造を持つ深層学習モデルを運用することが可能となり、様々な学習アルゴリズムが開発されるようになった。中でも、画像認識分野では畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) [51, 52] が高い性能を発揮しており、様々な応用がなされている。CNN の特徴は、その名の通り「畳み込み層」を用いて表現の学習を行う点である。畳み込み層を用いることで、画像中の局所的なパターンを学習することが可能となる。

本研究では、検出器からの情報を2次元の画像として表現し、ミューオンの情報を再構成する手法を提案している。以下では、CNN に用いられる層やパラメータについて述べる。

畳み込み層

畳み込み層の概念図を図 5.12 に示す。畳み込み層では、入力データに対して複数のフィルタを畳み込み演算して表現の抽出を行う。各フィルタはそれぞれ異なる表現を抽出するために用いられ、入力データに対して任意のピクセル数毎に移動 (ストライド) させながら畳み込み演算を行う。

例として、2次元、1チャンネルの入力データ ($W \times W$ ピクセル) に対して、 $H \times H$ ($H < W$) ピクセルのフィルタをストライド 1 で畳み込む場合について考える。フィルタの (p, q) ピクセル目の値を $h_{p,q}$ 、入力データの (x, y) ピクセル目のピクセル値を $z_{x,y}$ とすると、畳み込み演算後の画像における座標 (i, j) のピクセル $u_{i,j}$ は

$$u_{i,j} = \sum_{p=0}^{H-1} \sum_{q=0}^{H-1} h_{p,q} \cdot z_{i+p,j+q} \quad (5.5)$$

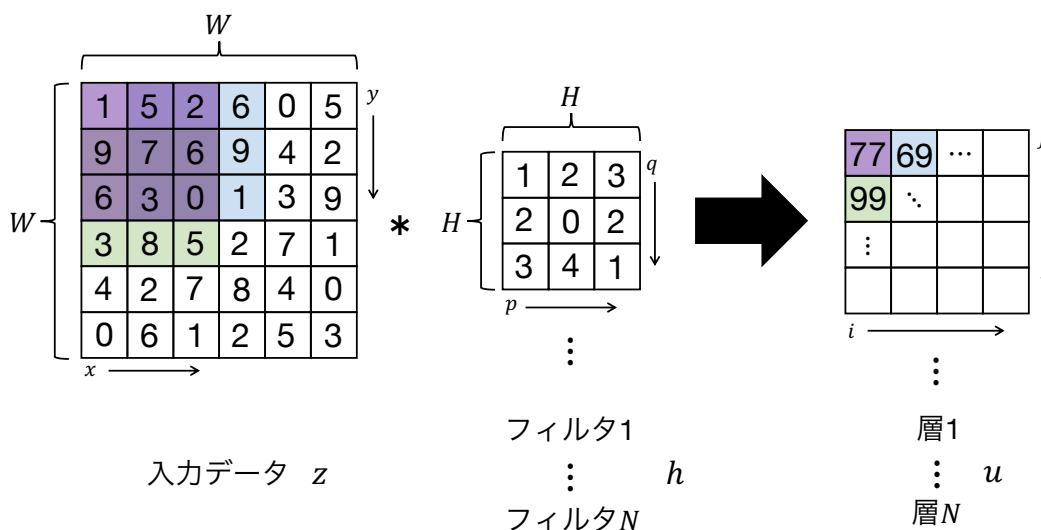


図 5.12: 畳み込み層の概念図。フィルタを複数用意し、入力データと畳み込み演算を行う事で各フィルタに対応した表現の抽出を行う。

と表される。この演算を入力データ全体に渡って行い、最終的に畳み込み後の画像サイズは

$$(W - H + 1) \times (W - H + 1) \tag{5.6}$$

ピクセルとなる。

畳み込み層においては、フィルタがネットワークにおける重みとして理解され、学習を通じて表現を抽出するために適したフィルタを獲得する。

全結合層

全結合層 (Dense) は、入力に対して各ノードが全て結合している最も基本的な層である。全結合層の概念図を図 5.13 に示す。丸い図形で表されたノードが、それぞれ入力に対して全結合していることが分かる。各ノードでは、活性化関数 $f(x)$ 、入力 \vec{I} 、ノード間の結合重み \vec{w} 及びバイアス b を用いて

$$h = f(\vec{I} \cdot \vec{w} + b) \tag{5.7}$$

を計算し、後段のノードへの出力とする。

学習を通じて結合重み \vec{w} が調整され、タスク解決のためにより重要な表現に対応するノード間の重みが大きくなる。




図 5.13: 全結合層の概念図。 I_n は全結合層への入力を表す。




図 5.14: 平滑化層の概念図。

平滑化層

平滑化層 (Flatten) は、図 5.14 に示すように入力されたテンソルを平滑化し 1 次元へと次元数の削減を行う層である。通常、畳み込み層の出力テンソル形式は

$$(\text{フィルター数}) \times (\text{行数}) \times (\text{列数}) \quad (5.8)$$

となるため、後段の全結合層に入力するために平滑化層を用いて 1 次元テンソルへの変形を行う必要がある。

5.3 素粒子実験と深層学習

現在では、様々な学問分野において深層学習技術を応用した研究が数多く行われている。本節では特に素粒子実験分野に焦点を当て、ATLAS 実験のような加速器素粒子実験や地下素粒子実験において、深層学習技術を応用した研究を行なっている例について述べる。

5.3.1 検出器シミュレーション

現在の ATLAS 実験における CPU リソースの 70% はシミュレーションサンプルの作成に用いられており [35]、中でも Geant4 [53–55] を用いた検出器のシミュレーションには多量の CPU リソースが消費されている。3.3.1 節で述べたように、高輝度 LHC-ATLAS 実験においてはデータ蓄積速度の上昇に伴い、シミュレーションサンプルの作成量も同様に増加させる必要があり、より計算リソースの消費が少ないシミュレーション手法の開発が望まれている。

ATLAS 実験の検出器シミュレーションには、Geant4 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 [56] の 2 種類が存在する。フルシミュレーションは精度が高い一方で、計算コストや計算にかかる時間も長い。一方、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、性能に限界がある。

近年、ファストシミュレーションの精度向上へのアプローチとして、Generative Adversarial Network (GAN) を用いた手法の開発が行われている [57, 58]。GAN を用いて電磁カロリメータの




図 5.15: 電磁シャワーに対するカロリメータの応答シミュレーションの結果 [57]。Geant4(左) と GAN(右) のエネルギーデポジットはよく一致している。

応答シミュレーション手法の開発を行った研究 [57] では、図 5.15 に示すように、GAN を用いて Geant4 のエネルギーデポジットを良く再現することができている。

5.3.2 波形弁別

CANDLES 実験 [59] によるニュートリノを伴わない 2 重 β 崩壊 ($0\nu\beta\beta$) 探索など、低バックグラウンド環境における稀事象探索実験では、探索対象となる信号事象とその背景事象の弁別が鍵を握る。信号事象と背景事象の弁別には、事象における波形情報を用いて粒子の識別を行う波形弁別 (Pulse Shape Discrimination: PSD) が有用であり、CANDLES 実験を始め様々な実験で用いられてきた。これまで、PSD の手法として電荷情報を用いる手法 [60] や周波数情報を用いる手法 [61] などが開発されてきたが、更に実験の感度を向上させるためにはより高性能な PSD 手法の開発が必要である。

近年、新たな PSD 手法として深層学習を用いた手法の開発が行われており、従来の PSD 手法と比較して性能の向上を達成している [62, 63]。 ${}^6\text{LiF}:\text{ZnS}(\text{Ag})$ シンチレータを用いた中性子/ γ 線識別手法開発の例では、従来の電荷情報を用いた PSD 手法を抑え、1 次元 CNN を用いた PSD 手法が最も高い正答率 0.996 ± 0.003 を達成している [62]。

また、 $\text{Ca}(\text{Br}, \text{I})_2$ 結晶を用いた α 線/ γ 線識別手法開発の例においても、1 次元 CNN を用いた PSD 手法が最も高い正答率を達成しており、図 5.16 に示した分布からも CNN を用いた手法の分離能力の高さが見て取れる [63]。




図 5.16: 従来手法及び CNN を用いた手法による、識別能力のエネルギー依存性 [63]。(a): 従来手法 (Double Gate method)、(b): CNN を用いた手法。従来手法と比較し、 α 線/ β 線の分離が良い事が見て取れる。

表 5.1: TGC 検出器フォワード領域のチェンバー各層におけるワイヤーチャンネルの数。

層	M1			M2		M3	
	1	2	3	1	2	1	2
ワイヤーチャンネル数	105	104	105	125	125	122	122

情報の変換を行った後、画像化を行った。

本研究では、図 5.18 に示すように TGC 検出器フォワード領域 ($1.9 < |\eta| < 2.4$) を $d\eta = 0.005$ 刻みで計 140 の領域に分割し、それぞれの領域内に位置するワイヤーチャンネルを新たに 1 つの η index として振り分けた。

ワイヤーチャンネルから η -index へと変換を行う事によるワイヤーチャンネルのヒット情報画像の変化を図 5.19 に示す。図 5.19 では、実際に本研究で用いたシミュレーションデータの中から高運動量 ($p_T = 19$ GeV) 及び低運動量 ($p_T = 6.3$ GeV) の飛跡を選択し、 η -index への変換を行う前後におけるヒットマップを示している。 η -index 変換前のヒットマップでは、TGC 検出器 M1 と M2 間の間隔が広がっている事に起因して 3 層目と 4 層目のヒットの間に大きなギャップが生じている。一方で、 η -index 変換後のヒットマップではこの影響が緩和され、3 層目と 4 層目のヒットの間のギャップが小さくなっていることが見て取れる。

また、 η -index 変換後の高運動量飛跡と低運動量飛跡を比較すると、高運動量飛跡ではヒットが




図 5.18: η -index の割り振り方の概略図。TGC 検出器フォワード領域 ($1.9 < |\eta| < 2.4$) に対して、 $d\eta = 0.005$ 毎に区切った領域に存在するワイヤーチャンネルを同一の η -index として定義する。

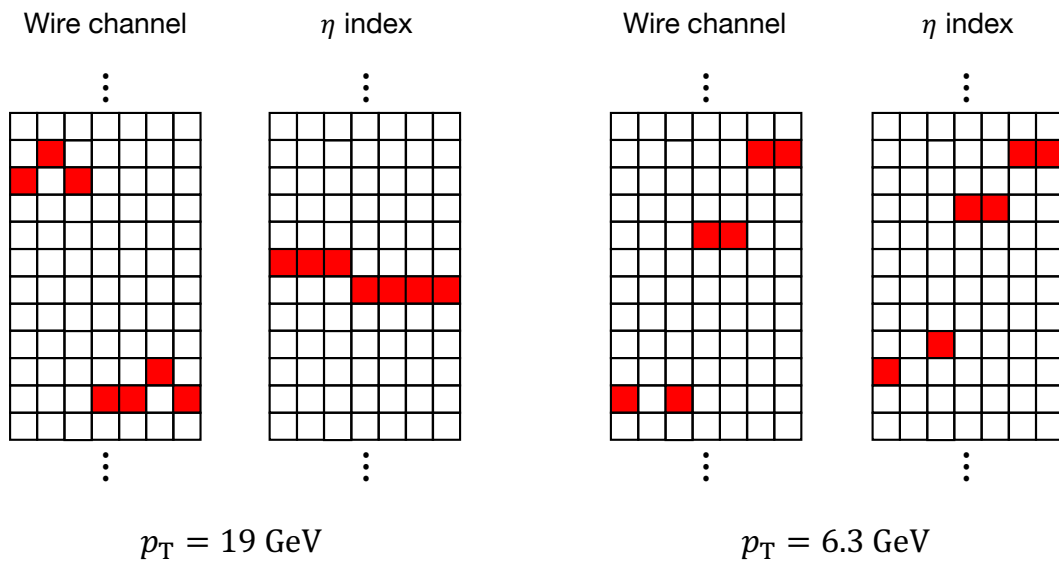


図 5.19: ワイヤチャンネルから η -index に変換する事によるチャンネルヒットマップの変化。高い運動量の飛跡 (左) では、低い運動量の飛跡 (右) と比較して、ヒットの並びがより直線的になっている。

より直線的に分布するようになるのに対し、低運動量飛跡ではヒットの分布がばらついたままと なっていることが見て取れる。このようにワイヤチャンネルから η -index への変換を行う事によ り、高運動量飛跡と低運動量飛跡間のヒットマップの特徴の違いが強調され、深層学習における識 別性能の向上にも寄与することが期待できる。

5.4.2 角度再構成モデルの設計とトレーニング

モデルの設計

本節では、TGC 検出器ワイヤーチャンネルのヒット情報からミューオンの角度情報を再構成する深層学習モデルの設計について述べる。

本研究において、深層学習モデルの構築には Google によって開発されたオープンソースの深層学習ライブラリである TensorFlow [65] を用いた。

角度情報の再構成を行う深層学習モデルの設計において、基本的なコンセプトはパターン認識に強いモデルを設計する事である。また、第3章で述べたように、本研究が想定している初段ミューオントリガーはハードウェアベースのシステムであるため、運用の際には設計したモデルを FPGA などの電子回路上で実行する必要がある。さらに、高輝度 LHC-ATLAS 実験における初段ミューオントリガーは $10 \mu\text{s}$ 以内にトリガー判定を行う必要があり、深層学習モデルを用いて角度情報の推論を行う際に必要な時間 (レイテンシ) をこれより小さく抑える必要がある。

FPGA などの電子回路にモデルを搭載して推論を行う場合、モデルの大きさ (パラメータ数や層の深さ) や識別能力とレイテンシはトレードオフの関係にあることが知られており [66–68]、初段ミューオントリガーの制約上無闇に層数の多いモデルを用いる事はできない。

先行研究により、畳み込み層が3層の深層学習モデルにおいてレイテンシが $10 \mu\text{s}$ 以内に収まる事が示されているため [64]、本研究ではたたみ込み層が1層、2層及び3層の深層学習モデルを作成し、パラメータ数と角度再構成性能の観点から最適なモデルを選択する。

図 5.20、図 5.21 及び図 5.22 に本研究で設計した角度再構成モデルを示す。3つのモデルについて、畳み込み層の数以外の設計は基本的に共通である。初めに、モデルは 5.4.1 節で述べた前処理を行った TGC 検出器のワイヤー情報を入力として受け取る。続いてデータは畳み込み層へ入力され、特徴量の抽出を行う。畳み込み層1層のモデルでは (5×7) サイズのフィルター 32 枚、畳み込み層2層及び3層のモデルでは後段に (5×1) サイズのフィルターを 16 枚及び 8 枚それぞれ追加し、パラメータ数の削減を行う。その後、全結合層へと入力するために畳み込み層の出力を平滑化層で1次元に変形する。最終的に、全結合層を通して角度情報の出力を行う。




図 5.20: 畳み込み層が 1 層の角度再構成モデルの構成。




図 5.21: 畳み込み層が 2 層の角度再構成モデルの構成。

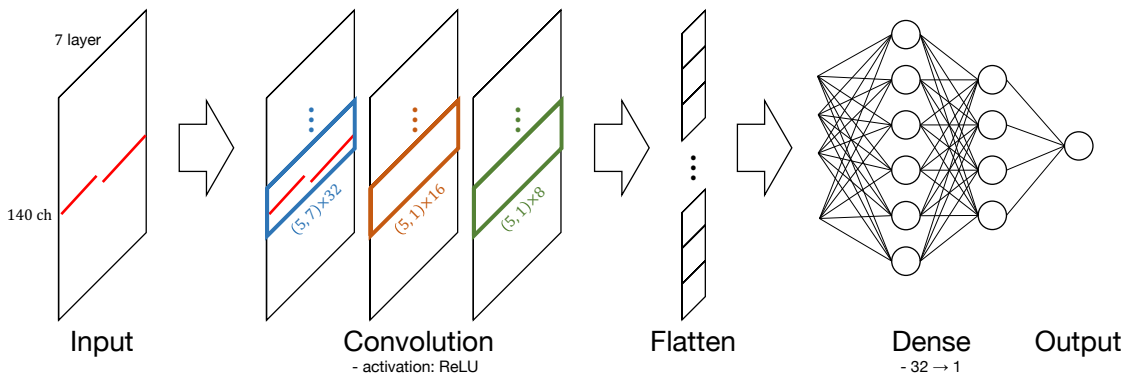


図 5.22: 畳み込み層が 3 層の角度再構成モデルの構成。

モデルのトレーニング

深層学習モデルのトレーニングには、1 イベントにミュオンが1 個存在するシミュレーションサンプル (シングルミュオンサンプル) を使用する。これらのイベントの内、TGC 検出器フォワード領域 ($1.9 < |\eta| < 2.4$) で再構成されたミュオンが存在し、TGC 検出器ワイヤー7 層の内、少なくとも2 層以上にヒットがあるイベントを選別した。また、これらのイベントの内、MDT ミドルステーションにおける真の飛跡角度情報が存在するのイベントのみをトレーニングデータとして用いた。トレーニングデータとして用いたミュオンサンプルの p_T 、 η 及び ϕ 分布をそれぞれ図 5.23、図 5.24(a) 及び図 5.24(b) に示す。

角度情報の教師データとしては MDT ミドルステーションにおけるミュオンの飛跡角度の真の情報を利用し、トレーニングデータの総数は 100 万イベントである。また、トレーニングに際して




図 5.23: 深層学習モデルのトレーニングに用いたミュオンサンプルの p_T 分布。高 p_T 領域のサンプル数がやや少なくなっているが、概ね一様に分布している。




図 5.24: 深層学習モデルのトレーニングに用いたミュオンサンプルの η 、 ϕ 分布。(a): η 分布。MDT 検出器の構造により、 $\eta = 2.2$ 付近のイベントがやや少なくなっている。(b): ϕ 分布。ほぼ一様に分布している。

表 5.2: トレーニングに際して設定したハイパーパラメータの一覧。

パラメータ名	説明	値
epochs	学習を繰り返す回数	200
batch_size	トレーニングデータを分割したサブセットに入るイベント数	128
validation_split	epoch 毎に validation に用いるイベント数の割合	0.1
learning_rate	1 回の epoch で更新する重みの大きさ	1e-5

設定したハイパーパラメータの一覧を表 5.2 にまとめた。

図 5.25 及び図 5.26 に、深層学習モデルをトレーニングした際の epoch に対する出力と教師データの平均二乗誤差の推移を示す。全てのモデルにおいて validation データの平均二乗誤差は十分に収束している事が見て取れる。






図 5.25: 畳み込み層が 3 層のモデルをトレーニングした際の epoch に対する平均二乗誤差の推移。



(a)



(b)

図 5.26: 畳み込み層が 1 層及び 2 層のモデルをトレーニングした際の epoch に対する平均二乗誤差の推移。(a): 畳み込み層が 1 層の場合、(b): 畳み込み層が 2 層の場合。

5.5 角度再構成モデルの性能評価

本節では、5.4.2 節で設計及びトレーニングを行ったミュオン飛跡の角度情報再構成モデルの性能評価を行う。

初めに、畳み込み層の数による角度再構成性能の違いを評価するため、畳み込み層 1 層、2 層及び 3 層のモデルにそれぞれ同じシングルミュオンサンプルを 10 万イベント入力し、角度情報の予測値 (θ_{pred}) と正解値 (θ_{true}) の残差分布の比較を行った。図 5.27 に、畳み込み層の層数毎に残差分布を描いたプロットを示す。これらの分布に対して、ガウス関数

$$f(\theta) = A \exp\left(-\frac{(\theta - \mu)^2}{2\sigma^2}\right) \quad (5.9)$$

を用いてフィッティングを行い、フィッティングパラメータの値と共に深層学習モデルのパラメータ数を表 5.3 にまとめた。ここで、 A は分布のスケール、 μ は分布の中央値、 σ は分布の標準偏差を表す。

表 5.3 から、畳み込み層の数を増やすにつれて σ の値が小さくなっている事が見て取れる。また、モデルのパラメータ数は畳み込み層 3 層の場合が最も小さくなっている。畳み込み層が 2 層及び 3 層の場合ではあまり性能に差は見られないが、深層学習モデルを電子回路へ搭載するという観点から考え、本研究ではパラメータ数がより少ない畳み込み層 3 層のモデルを採用する事とし、以降ではこのモデルについて更に性能評価を行う。




図 5.27: 畳み込み層の層数を変化させた場合の角度の予測値 (θ_{pred}) と角度の正解値 (θ_{true}) の残差の比較。畳み込み層 3 層のモデルの標準偏差が最も小さい事が分かる。

図 5.28 に、畳み込み層 3 層の場合の θ_{true} に対する θ_{pred} の分布を示す。 θ_{true} の全域に渡って、深層学習の予測値である θ_{pred} は概ね直線的に分布しており、角度情報の再構成が行えている事が見て取れる。さらに図 5.28 の分布において、ある θ_{true} における θ_{pred} の分布をガウス関数でフィッティングした際の μ の分布を図 5.29 に示す。この分布に対して直線フィッティングを行うと

$$\mu = (0.9798 \pm 0.0011)\theta_{\text{true}} + (0.0069 \pm 0.0003) \quad (5.10)$$

という関係が得られ、 θ_{true} に対して深層学習の予測値はほぼ線形である事が見て取れる。

また、同様にある θ_{true} における θ_{pred} の分布をガウス関数でフィッティングした際の σ の分布を図 5.30 に示す。 σ の値は $0.15 < \theta_{\text{true}} < 0.3$ の範囲では 3 ~ 5 mrad 程度であるのに対し、それよりも外側の θ_{true} に対しては σ の値は大きくなっている事が分かる。

表 5.3: 図 5.27 の分布をフィットした結果と各モデルのパラメータ数のまとめ。

畳み込み層の数	μ [mrad]	σ [mrad]	モデルのパラメータ数
1	-0.10 ± 0.02	3.14 ± 0.01	1,004,737
2	-0.07 ± 0.01	3.03 ± 0.01	505,553
3	0.04 ± 0.01	3.00 ± 0.01	255,321




図 5.28: 畳み込み層 3 層の場合の θ_{true} に対する θ_{pred} の分布。




図 5.29: ある θ_{true} に対して、 θ_{pred} の分布をガウシアンフィットした場合の μ の分布。図中の赤線は 1 次関数によるフィッティング直線を示す。 $\theta_{\text{true}} > 0.35$ では、イベント数が少ないためフィットする事ができなかった。




図 5.30: ある θ_{true} に対して、 θ_{pred} の分布をガウシアンフィットした場合の σ の分布。 $\theta_{\text{true}} > 0.35$ では、イベント数が少ないためフィットする事ができなかった。

この理由を探るため、さらにミュオンの p_T に対する角度再構成性能の評価を行った。図 5.31 に、ミュオンの p_T に対する $\theta_{\text{true}} - \theta_{\text{pred}}$ の分布を示す。また、図 5.31 の横軸を 5 GeV 毎に区切り、各ビン内のイベントによる $\theta_{\text{true}} - \theta_{\text{pred}}$ 分布を作成し、それぞれガウス関数を用いてフィットを行った。この時のミュオンの p_T に対するフィッティングパラメータ μ 及び σ の分布を図 5.32(a) 及び図 5.32(b) に示す。 μ の分布は 0 - 5 GeV のビンを除いてほぼ 0 付近に分布しており、 σ の分布も 0 - 5 GeV、5 - 10 GeV のビンを除いて概ね 3 - 4 mrad の範囲に収まっている事が分かる。従って角度再構成性能に p_T 依存性があり、低 p_T 領域において角度再構成性能が低下している事が分かる。図 5.33 に、図 5.28 をミュオンの p_T により分割した分布を示す。図 5.33(a)


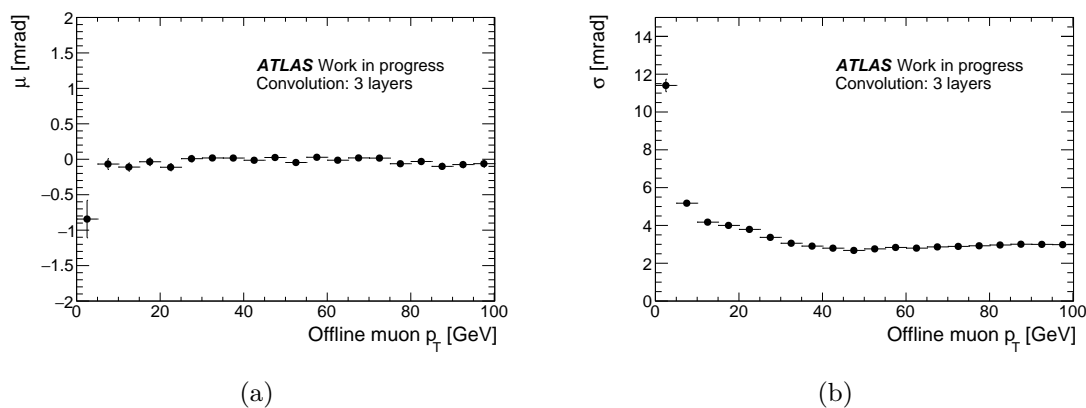


図 5.31: ミュオンの p_T に対する $\theta_{\text{true}} - \theta_{\text{pred}}$ の分布。



(a)

(b)

図 5.32: ミュオンの p_T に対して、 $\theta_{\text{true}} - \theta_{\text{pred}}$ の分布をガウスフィットした場合のパラメータの分布。(a): μ の分布、(b): σ の分布。

から、図 5.30 において σ の値が大きくなっていた領域は $p_T < 5$ GeV 以下のミュオンが占めている事が分かる。

また、図 5.33(b) から高 p_T のミュオンは $\theta_{\text{true}} = 0.25$ を中心として分布する事が分かる。本研究で開発した深層学習モデルの角度再構成性能に p_T 依存性が生じた理由は、 p_T により θ_{true} 分布の傾向が異なる事を考慮せずにトレーニングを行なったためであると考えられる。

本研究では、5.4.2 節で述べたようにミュオンの p_T 分布が一様なサンプルを用いて深層学習モデルのトレーニング行なった。この場合、 θ_{true} が 0.25 付近となるイベントの数が多くなってしまうため、結果的に θ_{true} の分布が 0.25 付近から離れている低 p_T イベントに対する学習が十分に行われていなかった可能性がある。

今後、トレーニングを行う際に $1/p_T$ で重みをつけるなどの対策を行う事で、このような角度再構成性能の p_T 依存性を小さく抑えることができる可能性がある。

最後に、畳み込み層が 3 層のモデルについて、デッドチェンバーが存在する場合の角度情報再構成性能の比較を行った。様々なデッドチェンバーのパターンに対して $\theta_{\text{true}} - \theta_{\text{pred}}$ の分布を計算し、それぞれの分布に対してガウシアンフィットを行ってフィットパラメータ μ 及び σ の比較を行った。図 5.34(a) に、フィットパラメータ μ の比較を示す。

デッドチェンバーが存在する場合でも、ほとんどのパターンにおいて μ は 0 付近の値を取っている事が見て取れる。ただし、M3 ステーションの 1 層目、2 層目がデッドチェンバーの場合など、最外層付近でデッドチェンバーが 2 層存在する場合は最大で 0.7 mrad 程度のずれが生じている事が分かる。また、図 5.34(b) にフィットパラメータ σ の比較を示す。デッドチェンバーが存在しない場合の σ が 3 mrad 程度であるのに対し、デッドチェンバーが 1 層存在する場合は 3 – 4 mrad、

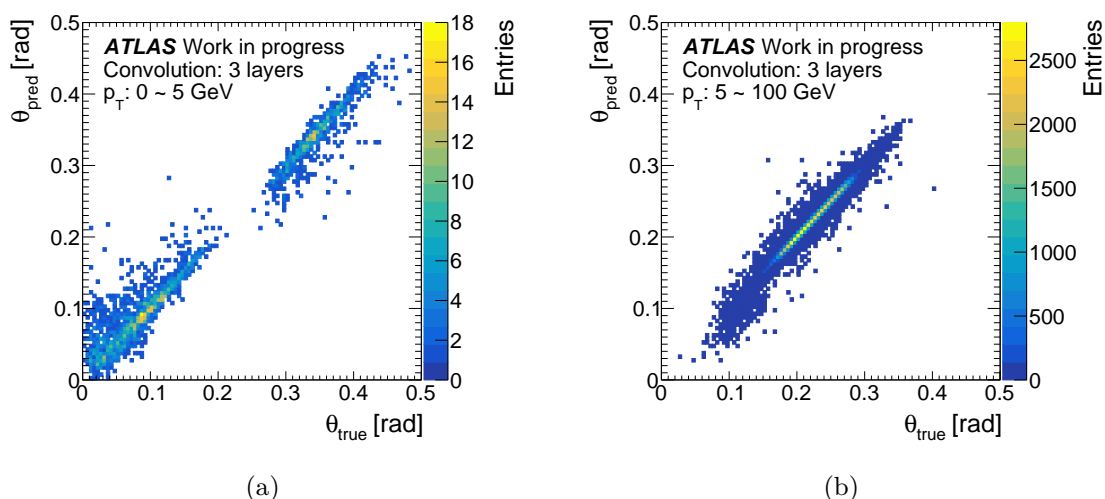


図 5.33: 図 5.28 をミュオンの p_T によって分割した分布。(a): $p_T < 5$ GeV 以下の分布、(b): $p_T > 5$ GeV 以上の分布。低 p_T ミュオンは $0.2 < \theta_{\text{true}}$ 、 $\theta_{\text{true}} > 0.3$ に分布している事が分かる。

デッドチェンバーが 2 層存在する場合でも 4 – 5 mrad 程度の性能を保っている事が分かる。 μ の場合と同様に、M3 ステーションの 1 層目、2 層目がデッドチェンバーの場合など、最外層付近でデッドチェンバーが 2 層存在する場合に性能が悪化する傾向がある事が分かる。この理由として、図 5.35 に示すように、最外層付近でデッドチェンバーが 2 層存在する場合、中間層でデッドチェンバーが 2 層存在する場合よりもヒットから飛跡を再構成する際の不定性が大きい事が影響している可能性がある。

これらのパラメータの違いは、最終的に Plateau efficiency や Resolution などトリガー性能の違いとして現れる。5.6 節では、本節で性能評価を行ったモデルによって再構成した角度情報を用いてトリガー判定を行い、パターンマッチングアルゴリズムによるトリガー性能との比較を行う。

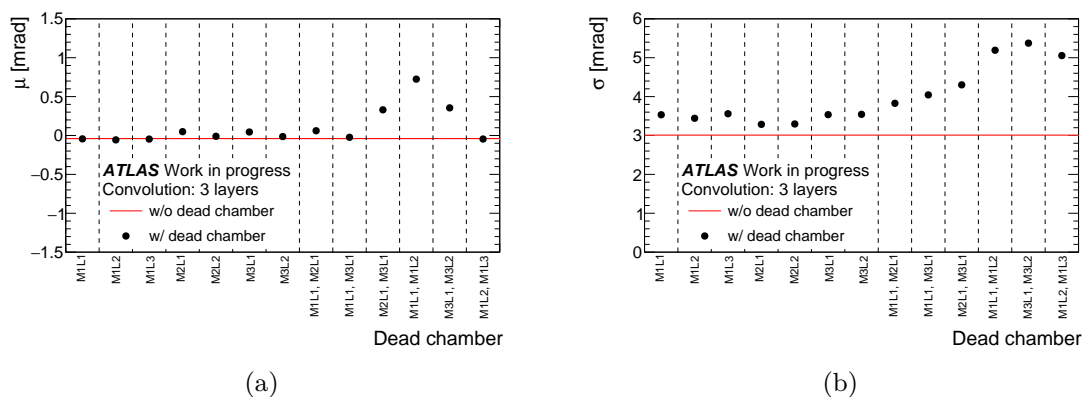


図 5.34: 様々なパターンのデッドチェンバーに対して、 $\theta_{\text{true}} - \theta_{\text{pred}}$ 分布のガウシアンフィットを行なった場合のパラメータの比較。赤の直線は、デッドチェンバーが存在しない場合のパラメータの値を示す。(a): μ の分布、(b): σ の分布。




図 5.35: デッドチェンバーが中間層及び最外層に 2 層存在する場合の違いの例。最外層にデッドチェンバーが 2 層存在する場合、飛跡の不定性が大きい。

5.6 トリガー性能としての評価

本節では、5.5 節で性能評価を行った角度再構成手法によって再構成した角度を用いてトリガー処理を行い、パターンマッチングアルゴリズムによるトリガー性能との比較を行った。

5.6.1 シミュレーションサンプルの作成

TGC 検出器フォワード領域において、デッドチェンバーが存在する場合のトリガー性能の評価を行った。性能評価にはシミュレーションサンプルを用い、様々なパターンのデッドチェンバーを発生させる事でデッドチェンバーに対するパターンマッチングアルゴリズムのトリガー性能を評価した。デッドチェンバーを発生させたパターンは図 5.36 に示す通りであり、デッドチェンバーが 1 層及び 2 層のパターンについて性能評価を行った。

5.6.2 性能評価の方法

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 (5.11) 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。

$$f(p_T) = \frac{p_0}{\exp\left(\frac{p_T - p_1}{p_2}\right) + 1} \tag{5.11}$$

性能の比較を行うパラメータは Plateau efficiency、Effective threshold 及び Resolution である。




図 5.36: シミュレーションサンプルを作成する際に、デッドチェンバーを発生させたチェンバーのまとめ。灰色で表した位置のチェンバーがデッドチェンバーとなっている。

5.6.3 トリガー性能の評価

初めに、Turn-on curve の比較を行う。図 5.37 に、デッドチェンバーが存在しない場合における、パターンマッチングアルゴリズムと本研究の手法による Turn-on curve の比較を示す。デッドチェンバーが存在しない場合では、異なる p_T 閾値それぞれにおいて、本研究の手法による Turn-on curve はパターンマッチングアルゴリズムの場合とほぼ同様の結果を得られている事が見て取れる。また、M1 ステーションにデッドチェンバーが2層存在する場合の Turn-on curve の比較を図 5.38 に示す。この場合パターンマッチングアルゴリズムによる Turn-on curve はプラトー領域のトリ

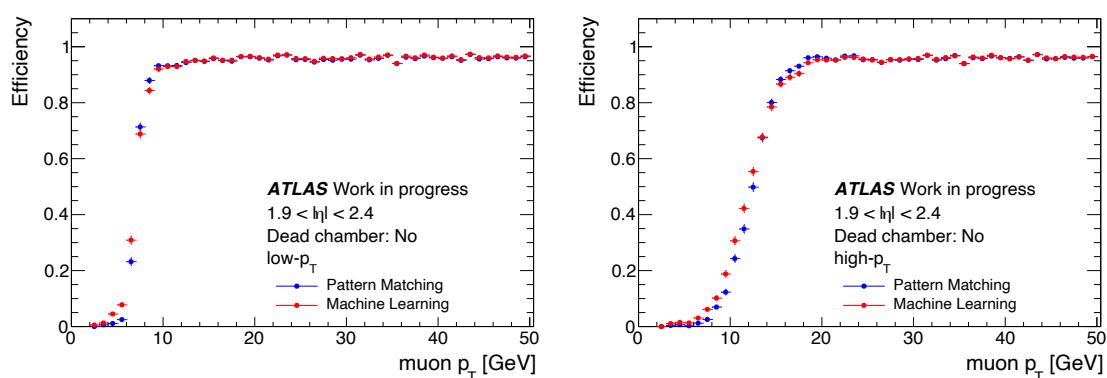


図 5.37: 深層学習によって再構成した角度情報を用いた場合とパターンマッチングアルゴリズムを用いた場合の Turn-on curve の比較。青のマーカがパターンマッチングアルゴリズム、赤のマーカが本研究の手法による結果に対応する。2 枚のプロットは、それぞれ異なる p_T 閾値に対応している。

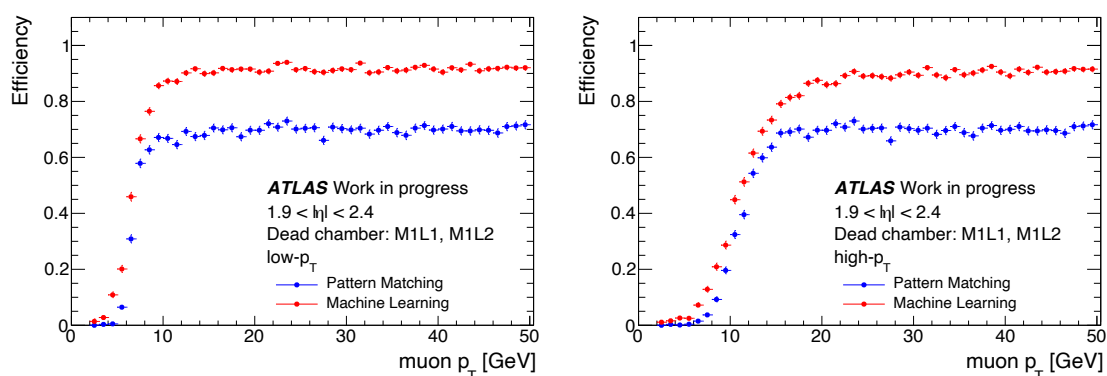


図 5.38: 深層学習によって再構成した角度情報を用いた場合とパターンマッチングアルゴリズムを用いた場合の Turn-on curve の比較。M1 ステーション内にデッドチェンバーが2層存在する場合の結果を示している。青のマーカがパターンマッチングアルゴリズム、赤のマーカが本研究の手法による結果に対応する。2 枚のプロットは、それぞれ異なる p_T 閾値に対応している。

ガー効率が大きく低下しているのに対し、本研究の手法による Turn-on curve では高いトリガー効率を維持している事が見て取れる。

さらに、図 5.36 に示したパターンのそれぞれについて、Turn-on curve のフィッティングパラメータを用いた性能の比較を行う。図 5.39 に、デッドチェンバーのパターンに対するパターンマッチングアルゴリズム及び本研究の手法による Plateau efficiency の比較を示す。また表 5.4 及び表 5.5 に各パターンにおける Relative efficiency の値をまとめた。本研究の手法では、デッドチェンバーが 1 層及び 2 層の場合に対しても、デッドチェンバーが存在しない場合に対するトリガー効率の低下を最大でも 10% 程度に抑えられている事が分かる。また、パターンマッチングアルゴリズムでは特にトリガー効率の低下が大きかったデッドチェンバーが 2 層存在する場合でも、本研究の手法では従来のヒット埋め手法を適用せずとも高いトリガー効率を維持する事ができている。

図 5.40 に、デッドチェンバーのパターンに対するパターンマッチングアルゴリズム及び本研究の手法による Effective threshold の比較を示す。パターンマッチングアルゴリズム及び本研究の手法による結果のどちらも、デッドチェンバーが 1 層または 2 層に関わらず低い p_T 閾値では 7 GeV 程度、高い p_T 閾値では 11 ~ 12 GeV 程度の Effective threshold であり、同じトリガー閾値において本研究の手法はパターンマッチングアルゴリズムと同程度の Effective threshold を維持する




図 5.39: 各デッドチェンバーパターンにおける、plateau efficiency の比較。縦軸は、デッドチェンバーが存在しない場合の plateau efficiency に対する Relative efficiency として表示している。青のマーカはパターンマッチングアルゴリズム、赤のマーカは本研究の手法による結果を示す。同じマーカは、同じ p_T 閾値の結果を表している。

表 5.4: デッドチェンバーが 1 層の場合の Plateau efficiency の比較。値はデッドチェンバーが存在しない場合の plateau efficiency に対する Relative efficiency として表示している。

Dead chamber		M1L1	M1L2	M1L3	M2L1	M2L2	M3L1	M3L2
low- p_T	ML	0.998(1)	0.999(1)	0.998(2)	0.936(2)	0.943(1)	0.946(2)	0.936(2)
	PM	0.975(2)	0.972(2)	0.974(2)	0.930(2)	0.938(1)	0.942(1)	0.932(1)
high- p_T	ML	0.997(2)	0.998(2)	0.996(2)	0.935(2)	0.942(2)	0.946(2)	0.937(2)
	PM	0.975(2)	0.971(2)	0.974(2)	0.931(2)	0.939(2)	0.942(2)	0.933(2)

表 5.5: デッドチェンバーが 2 層の場合の Plateau efficiency の比較。値はデッドチェンバーが存在しない場合の plateau efficiency に対する Relative efficiency として表示している。

Dead chamber		M1L1	M1L1	M2L1	M1L1	M1L1
		M2L1	M3L1	M3L1	M1L2	M1L3
low- p_T	ML	0.934(2)	0.944(2)	0.883(2)	0.953(2)	0.943(2)
	PM	0.836(2)	0.847(2)	0.877(2)	0.727(3)	0.718(3)
high- p_T	ML	0.930(2)	0.942(2)	0.881(2)	0.938(2)	0.931(2)
	PM	0.836(3)	0.847(3)	0.878(2)	0.729(3)	0.718(3)

事ができている。

さらに、図 5.41 にデッドチェンバーのパターンに対するパターンマッチングアルゴリズム及び本研究の手法による Resolution の比較を示す。また表 5.6 及び表 5.7 に各パターンにおける Resolution の値をまとめた。デッドチェンバーが 1 層及び 2 層のどちらの場合も、本研究の手法はほとんどのパターンで同じトリガー閾値において Resolution は一定の値を維持している。一方で、本研究の手法では全体的にパターンマッチングアルゴリズムと比較して Resolution の値が大きくなっており、低い p_T 閾値においては 0.3 GeV、高い p_T 閾値では 0.5 GeV 程度の悪化が見られる。特に、M1 ステーション内にデッドチェンバーが 2 層存在するパターンでは、低い p_T 閾値においては 0.5 GeV、高い p_T 閾値では 1 GeV 程度の Resolution 悪化が見られ、他のパターンよりも若干性能の低下が大きい。この一因として、5.5 節の図 5.34 で示した通り、M1 ステーションでデッドチェンバーが 2 層存在する場合、他のパターンと比較して深層学習による角度再構成の性能が少し悪く、 σ が大きくなっている事が挙げられる。

ただし、高輝度 LHC-ATLAS 実験のエンドキャップミュオントリガーでは、5.1.2 節で述べたように MDT など他の検出機の情報を付加して Resolution を改善する事ができる。また、本研究の手法を用いて TGC 検出器におけるトリガー判定を行うことにより、デッドチェンバーが存在する場合でもミュオン候補を取り逃がす割合が減少する。従って、デッドチェンバー存在下においても従来よりも高いトリガー効率を維持する事が可能となり、全体としてトリガー性能の向上を見込む事ができる。

表 5.6: デッドチェンバーが 1 層の場合の Resolution の比較。

Dead chamber		No	M1L1	M1L2	M1L3	M2L1	M2L2	M3L1	M3L2
low- p_T	ML	0.74(2)	0.79(3)	0.79(3)	0.80(3)	0.80(3)	0.75(3)	0.79(3)	0.75(3)
	PM	0.52(2)	0.52(2)	0.51(2)	0.52(2)	0.51(2)	0.49(2)	0.51(2)	0.53(2)
high- p_T	ML	1.69(3)	1.79(3)	1.75(3)	1.77(3)	1.79(4)	1.75(4)	1.76(4)	1.79(4)
	PM	1.41(3)	1.37(3)	1.38(3)	1.38(3)	1.39(3)	1.37(3)	1.42(3)	1.36(3)

表 5.7: デッドチェンバーが 2 層の場合の Resolution の比較。

Dead chamber		M1L1	M1L1	M2L1	M1L1	M1L1
		M2L1	M3L1	M3L1	M1L2	M1L3
low- p_T	ML	0.89(3)	0.84(3)	0.84(3)	1.02(3)	1.03(3)
	PM	0.52(2)	0.50(2)	0.52(2)	0.52(3)	0.52(3)
high- p_T	ML	1.93(4)	1.90(4)	1.77(4)	2.04(4)	2.12(5)
	PM	1.34(4)	1.35(4)	1.40(3)	1.26(4)	1.31(4)

5.7 ファインチューニングによる実験期間中の継続的最適化

5.6 節では、本研究で提案したトリガーシステムを用いる事で、デッドチェンバーが存在する場合でも高いトリガー効率を維持できる事を示した。本節では、実際に本トリガーシステムを導入する場合に、更なるメリットとなるファインチューニングによる継続的最適化について述べる。

5.7.1 ファインチューニング

ファインチューニングとは、あるタスクの解決を行う既存の深層学習モデルを基に学習を行い、新たなタスクの解決を行う深層学習モデルを構築する手法である。転移学習では既存のモデルを再利用する部分の重みパラメータを固定するのに対し、ファインチューニングでは既存のモデルの重みパラメータを初期値として追加学習を行い、新たなタスクに対応する。

ファインチューニングは、一般的に

- 既にある程度汎化性能の高い深層学習モデルを基にすることで、比較的少ないサンプル数で学習する事ができる
- 既存の深層学習モデルの構造を再利用することにより、学習時間を短縮する事ができる

等の特徴を有する。そのため、5.6.3 節で示したように様々なパターンのデッドチェンバーに強く、比較的汎化性能の高い本研究の深層学習モデルはファインチューニングに適していると言える。また、学習時間の短縮は計算機資源の使用量を低く抑える上で重要であり、この点も LHC-ATLAS 実験の環境とよく合致している。

5.7.2 継続的最適化により得られる恩恵

本研究において開発した深層学習モデルは、TGC 検出器フォワード領域全体に対してヒットパターンを学習させている。しかし、実際の TGC 検出器では場所により磁場構造の不均一性が存在するため、TGC 検出器内の位置ごとにミューオン飛跡の特徴などが微妙に異なる。従って、TGC 検出器の位置ごとにアルゴリズムの最適化を行う必要があるが、本研究の手法では深層学習モデルのファインチューニングを用いてこの最適化を行う事が可能である。ベースラインの深層学習モデルとして 5.4.2 節で設計したモデルを用い、実験期間中に取得される大量の実データを用いて位置ごとにモデルのファインチューニングを行う事で、TGC 検出器の位置毎に特化した深層学習モデルを常にアップデートし続ける事ができる。そのため、継続的に最適化を続ける事で、実験期間中には 5.6.3 節で示した性能よりも高いトリガー性能を見込む事ができる。

さらに、ファインチューニングを用いたモデルのアップデートを行う事で、TGC 検出器アライメントのずれに対しても自動で最適化が可能である。実際の TGC 検出器の各チェンバーは図 5.42 のように理想位置からのずれがあり、このアライメントのずれを考慮せずにアルゴリズムを構築すると、トリガー効率の低下などの弊害が生じる。実際に、先行研究においてアライメントのずれに

よる影響の評価や最適化が行われている [69, 70]。

一方で、本研究で提案するトリガーアルゴリズムにおいては、ファインチューニングによるモデルのアップデートの際にアライメントのずれによる影響も織り込みが可能であるため、特定の最適化作業を行う必要がない。また、何らかの理由で運転期間中に新たにアライメントのずれが生じたとしても、継続的最適化によって迅速な対応が可能である。

また、継続的最適化のさらなる応用例としてノイズが多いチャンネルの検出・対処が考えられる。TGC 検出器では何らかの理由によりノイズが多いチャンネルが発生する事があり、このようなチャンネルは偽のヒット判定を産み、トリガー性能へ影響を与える事がある。トリガーシステムによりヒットの分布を記録し、ファインチューニングの際に異常な割合でヒットが起こるチャンネルの重みを小さくする機構を構築する事で、このようなノイズによるトリガー性能への影響も軽減する事ができる可能性がある。

5.7.3 継続的最適化を実現するためのシステムの提案

本研究で開発したトリガーアルゴリズムを実装し、かつ 5.7.2 節で述べた継続的最適化を実現するためのトリガーシステムについて考える。3.2.2 節で述べたように、初段ミュオントリガーシステムはハードウェアベースであるため、5.4.2 節で設計した角度情報再構成モデルを FPGA などハードウェア上で実行する必要がある。TensorFlow で開発をおこなった深層学習モデルは HLS4ML [71] を用いて C++ コードに変換を行った後、Vivado HLS [72] により高位合成を行なって VHDL へと変換し、FPGA に実装する事ができる。

高輝度 LHC-ATLAS 実験の SL には、Xilinx UltraScale+ アーキテクチャ [73] の FPGA XCVU13P [74] が搭載される予定であり、XCVU13P の FPGA リソースを表 5.8 に示す。本研究で提案するトリガーシステムでは、5.4.2 節で設計した角度再構成モデルを SL 上の FPGA に搭載する。

また、5.7.2 節で述べた継続的最適化を行うために、FPGA を搭載し、深層学習のトレーニングを高速化できるアクセラレータとしての機能を持つハードウェアが必要である。この条件を満たすハードウェアとして、Xilinx 社により販売されている Alveo アクセラレータカードが挙げられる。




図 5.42: TGC 検出器 A-side M3 ステーションにおけるアライメントのずれの $x - y$ 平面図 [69]。ステーション全体が z 方向に対して傾いている事が分かる。

表 5.8: SL に搭載される FPGA(XCVU13P) の主なリソース量。

LUT	レジスタ	DSP	UltraRAM
1,728k	3,456k	12,288	360 Mb

表 5.9: Alveo U250 の主な仕様。

インタフェース・メモリ			FPGA リソース			
ネットワーク	PCI Express	メモリ	LUT	レジスタ	DSP	UltraRAM
2 × QSFP28	Gen3 × 16	DDR4 64 GB	1,728k	3,456k	12,288	360 Mb

例として、本研究において使用を提案する Alveo U250 を図 5.43 に示す。また、Alveo U250 の主な仕様を表 5.9 に示す。

Alveo U250 は Xilinx UltraScale+ アーキテクチャの FPGA を搭載したアクセラレータカードであり、さらに畳み込みニューラルネットなどの深層学習処理に特化したコア (xDNN) も搭載している。また、Xilinx の FPGA では Multi-Gigabit Transceiver (MGT) や Xilinx Virtual Cable (XVC) 機能を用いて FPGA の書き換えを行う事ができる。

本研究では、Alveo U250 のこれらの特徴を利用したトリガーシステムを提案する。本研究で提案するトリガーシステムの概念図を図 5.44 に示し、以下でトリガーシステムの流れについて説明する。

TGC からのヒットデータは Endcap SL へと入力され、5.4.2 節で設計した角度再構成モデルを



図 5.43: Alveo U250 アクセラレータカード [75]。

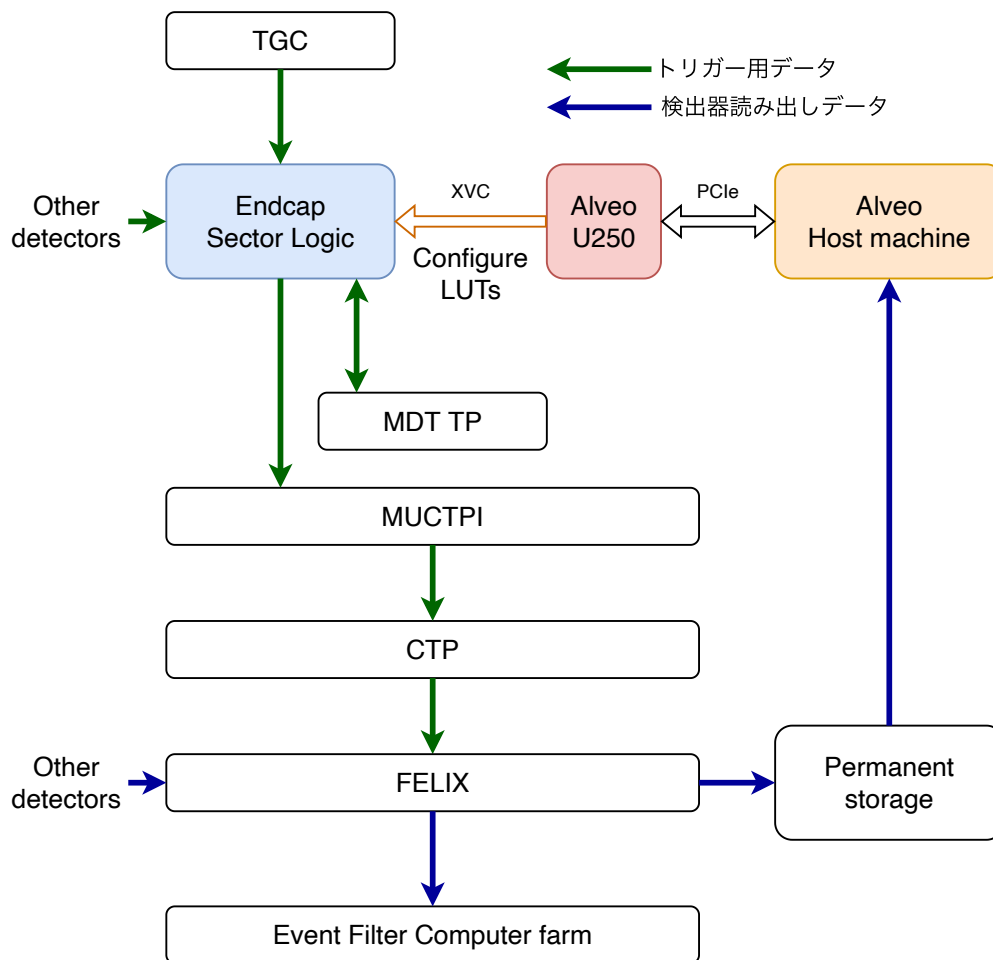


図 5.44: 本研究で提案するトリガーシステムの概念図。SL に飛跡再構成のための深層学習モデルを搭載し、アクセラレータによる FPGA 書き換えを用いて継続的最適化を可能にする。

利用してミューオン候補の選別を行う。SL によって選別されたミューオン候補は MDT-TP の情報を付加して MUCTPI へと送られ、より後段のトリガーシステムへと送信される。

さらに、ホストマシンはイベントストレージからモデルのファインチューニングに用いるイベントデータを取得する。このデータを PCIe レーンを介して Alveo U250 の DDR4 メモリへと書き込み、U250 の FPGA 上に搭載した角度再構成モデルのファインチューニングを行う。

最終的にファインチューニングによって更新されたモデルのパラメータを QSFP ポートを介して Endcap SL の FPGA へと書き込みを行う。ATLAS 実験の 1 ランは十数時間であり、一度ランが終了すると次のランが始まるまで数十分のインターバルがある。そのため、前ラン分のデータを用いてモデルのファインチューニングを行い、インターバル中に FPGA の書き換えを行うことで継続的にモデルの更新を行う事が可能となる。

5.7.4 提案したトリガーシステムの実現に向けて

本研究では、ミューオンの角度情報再構成を行う深層学習モデルを構築し、さらにこのモデルを用いたトリガーアルゴリズムにより、デッドチェンバーが存在する場合に対しても高いトリガー効率を維持できる事を示した。5.7.3 節で提案したトリガーシステムを実現するためには、更に

- Alveo U250 への深層学習モデルの実装
- Endcap SL やイベントストレージと本システムの連携のためのパスの確立及びソフトウェア開発

などの開発が必要であり、将来的にこれらの事項の開発が望まれる。

第 6 章

結論と展望

LHC 加速器の高輝度化アップグレードに伴いルミノシティが向上し、一度のバンチ交差におけるパイルアップ数が増加する。そのため、物理的に興味のある事象のみを選別して保存する「トリガー」がより重要な役割を担うようになる。さらに、ルミノシティ向上に伴いデータの蓄積速度が上昇するため、データの処理や保存に必要となる計算機資源量が大きく増加する。現在の試算では、データ量の増加に対し計算機資源の増設が間に合わない見込みとなっており、ATLAS 実験では効率良い計算機資源の利用が喫緊の課題となっている。

また高輝度 LHC-ATLAS 実験におけるもう一つの課題として、長期に渡る実験期間中のデータ取得のさらなる安定化が挙げられる。一度の運転期間が数年と長期に渡る ATLAS 実験では、実験期間中に検出器の状態変化が発生し、トリガー効率の低下などの問題が発生する。実際に、LHC-ATLAS 実験 Run 2 においては実験期間の経過に伴いデッドチェンバーが増加し、トリガー効率の低下が見られた。本研究では、まず初めに高輝度 LHC-ATLAS 実験で運用される予定のトリガーアルゴリズムにおいてデッドチェンバーの影響を調査し、現行のトリガーアルゴリズムと同様にデッドチェンバーによりトリガー効率が低下する事を示した。特に、デッドチェンバーが 2 層存在する場合は、トリガー効率が約 30% 低下すると共に、運動量分解能も低下することが明らかとなった。さらに 2 層のデッドチェンバーの内 1 層にダミーヒットを埋める処理を行ってもトリガー効率の回復が 5% 程度に留まる場合があり、この処理が全ての場合に対して有効という訳ではなく、新たな対処の考案が必要であると示した。

本研究ではこれら 2 つの課題に対して、新たなトリガーアルゴリズムの導入というアプローチで解決策の探求を試みた。TGC 検出器におけるミュオン飛跡の特徴に着目し、畳み込みニューラルネットワークを用いてミュオンの角度情報を再構成するアルゴリズムを開発した。また、このアルゴリズムを用いてトリガー判定を行うことにより、デッドチェンバーが存在する場合でも、ヒット埋め処理を行うことなく高いトリガー効率を維持する事ができると示した。特に、デッドチェンバーが 2 層存在する場合、現在予定されているアルゴリズムではデッドチェンバーが存在しない場合に対して最大で 30% 程度トリガー効率が低下していたのに対し、本研究の手法では 5% 程度のトリガー効率低下に抑える事が可能であることを示した。

近年では特定の処理に特化したプロセッサを組み合わせ、より電力・計算効率に優れたコン

ピューティングを行う「ヘテロジニアス・コンピューティング」が発展している。本論文では、新たに開発したトリガーアルゴリズムを核として、Xilinx 社の Alveo のようなアクセラレータカードを利用する新たなトリガーシステムの提案を行った。提案したトリガーシステムでは、実験期間中に取得する大量のデータを用いて継続的に深層学習モデルのアップデートを行う事ができ、実験期間中の検出器の状態変化に迅速に対応する事が可能である。さらに、TGC 検出器内の位置による磁場構造の違いや検出器アライメントのずれを自動で織り込んでモデルの学習を行う事ができるため、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もなくなると期待される。このように、本研究で提案するトリガーシステムでは、実験期間中のアップデートによるトリガー性能の向上を通して、誤って取得されるミュオンをさらに削減することが期待される。

また、ヘテロジニアス・コンピューティングの特性をより活かした次のステップとして、Xilinx 社が新たに商品名「Versal」として発表した Adaptive Compute Acceleration Platform (ACAP) を利用できる可能性がある。ACAP は CPU、FPGA 及び AI 処理に特化した Vector Processor を搭載したプロセッサであり、深層学習の推論や学習を効率的に行う事ができる。将来的には、アクセラレータカードを ACAP へと置き換える事で、より電力・計算効率に優れたトリガーシステムを構築できる可能性がある。

本論文では、以上のように新たなトリガーアルゴリズムの開発、及び新技術を用いた革新的なトリガーシステムの提案を行い、将来の素粒子実験に向けたトリガーシステムの新たな道を示した。

付録 A

本研究の手法による Turn-on curve の
一覧

5.6.3 節で示した結果を算出した際の Turn-on curve を図 A.1-図 A.12 に掲載する。

デッドチェンバーが 1 層の場合

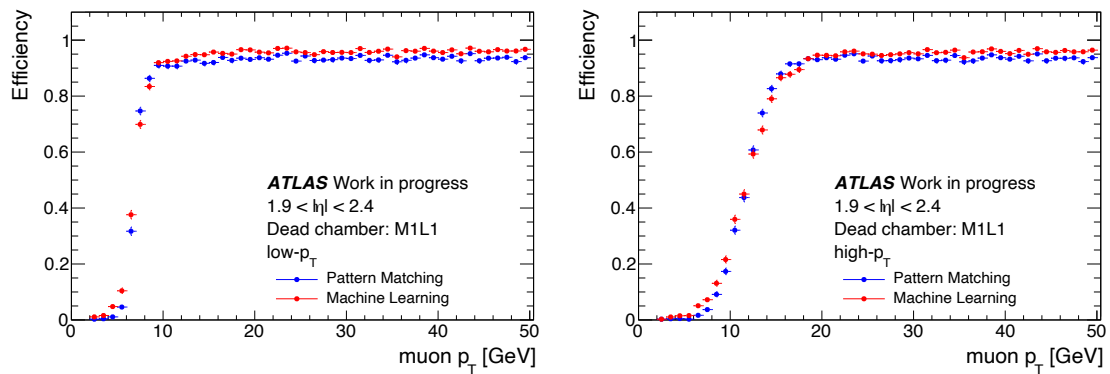


図 A.1: デッドチェンバーが M1 Layer1 の場合の Turn-on curve 比較。

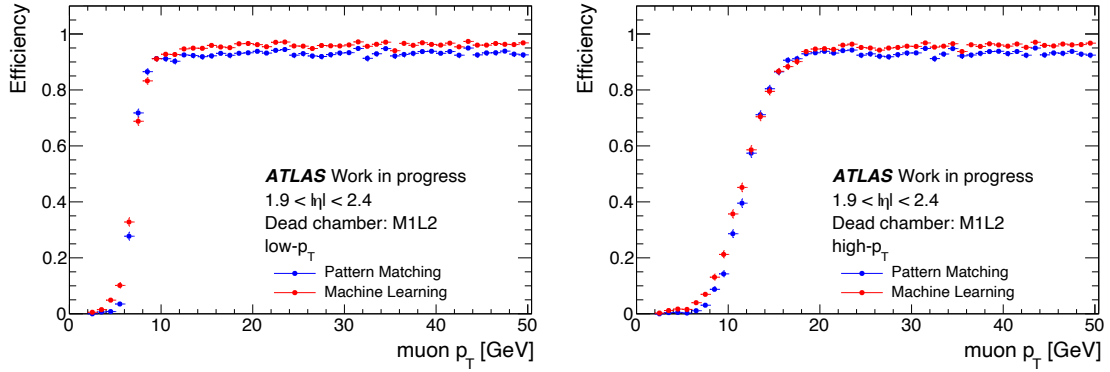


図 A.2: デッドチェンバーが M1 Layer2 の場合の Turn-on curve 比較。

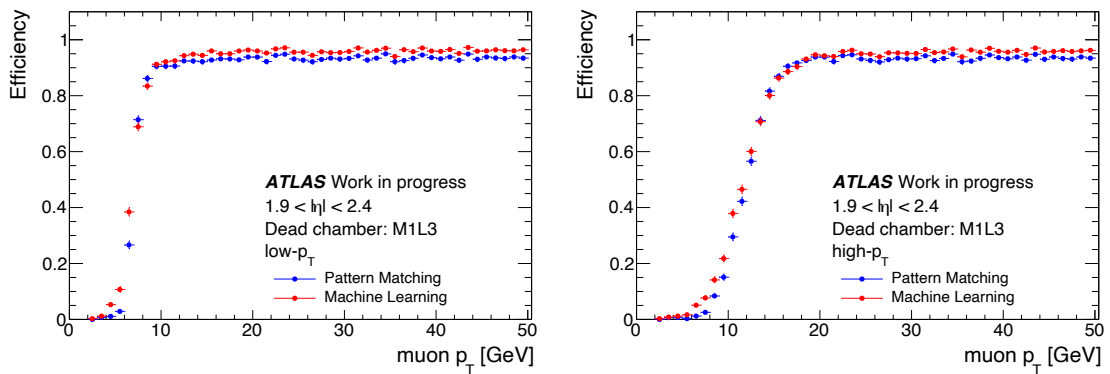


図 A.3: デッドチェンバーが M1 Layer3 の場合の Turn-on curve 比較。

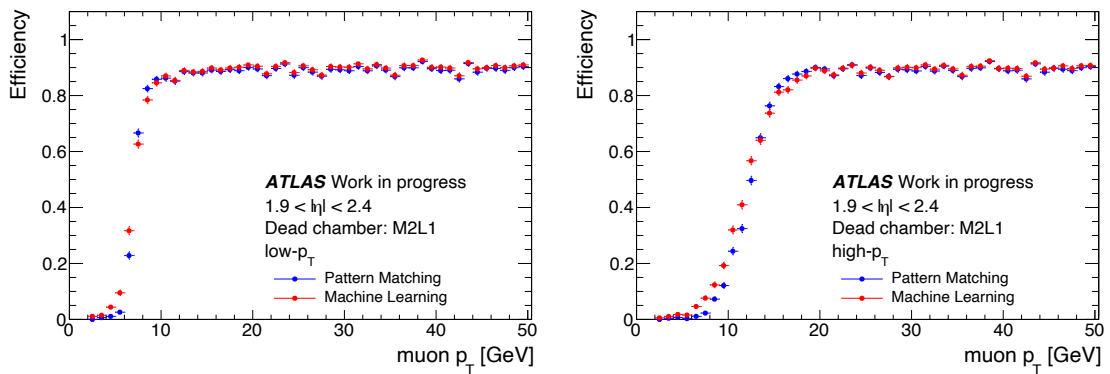


図 A.4: デッドチェンバーが M2 Layer1 の場合の Turn-on curve 比較。

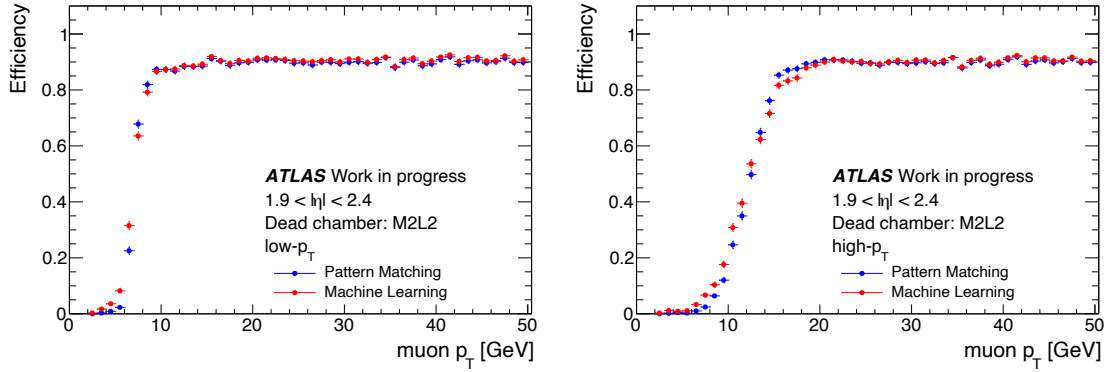


図 A.5: デッドチェンバーが M2 Layer2 の場合の Turn-on curve 比較。

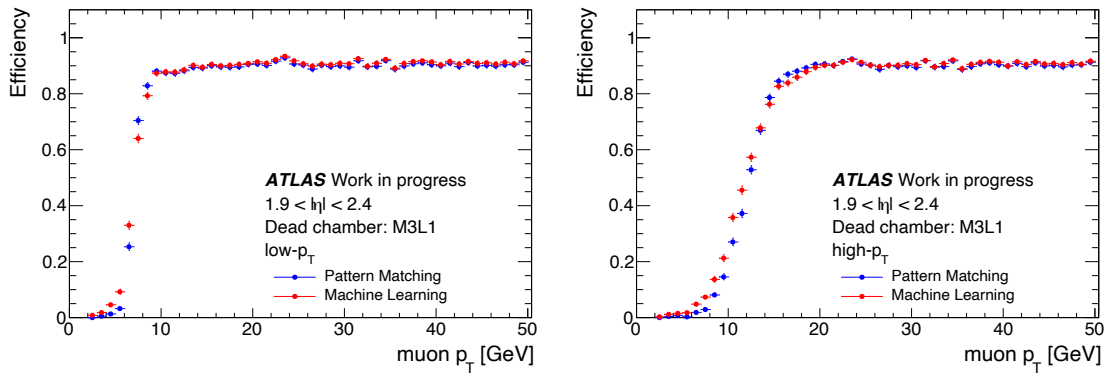


図 A.6: デッドチェンバーが M3 Layer2 の場合の Turn-on curve 比較。

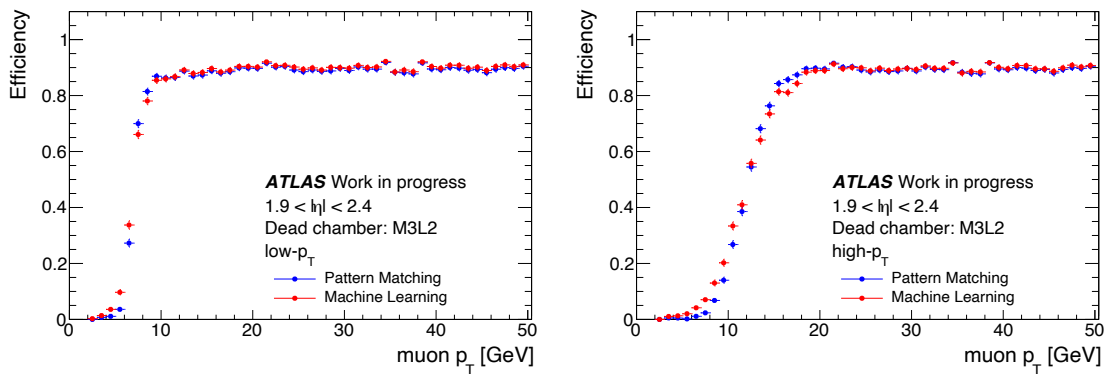


図 A.7: デッドチェンバーが M3 Layer2 の場合の Turn-on curve 比較。

デッドチェンバーが 2 層の場合

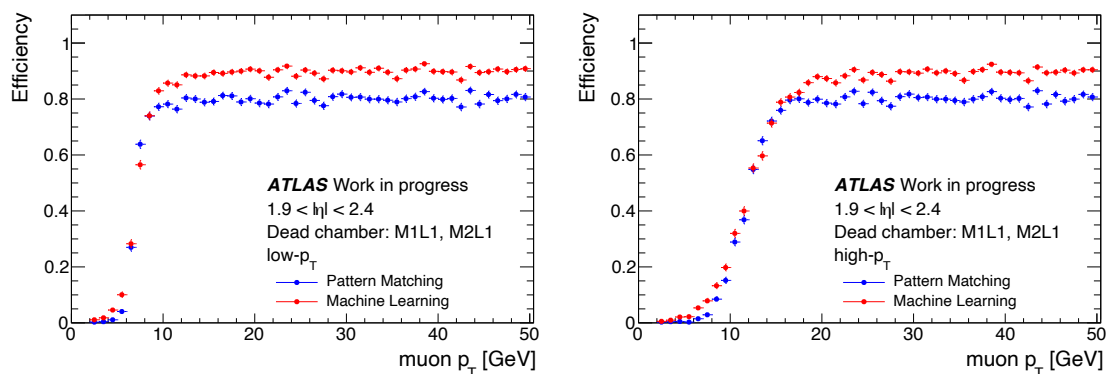


図 A.8: デッドチェンバーが M1 Layer1, M2 Layer1 の場合の Turn-on curve 比較。

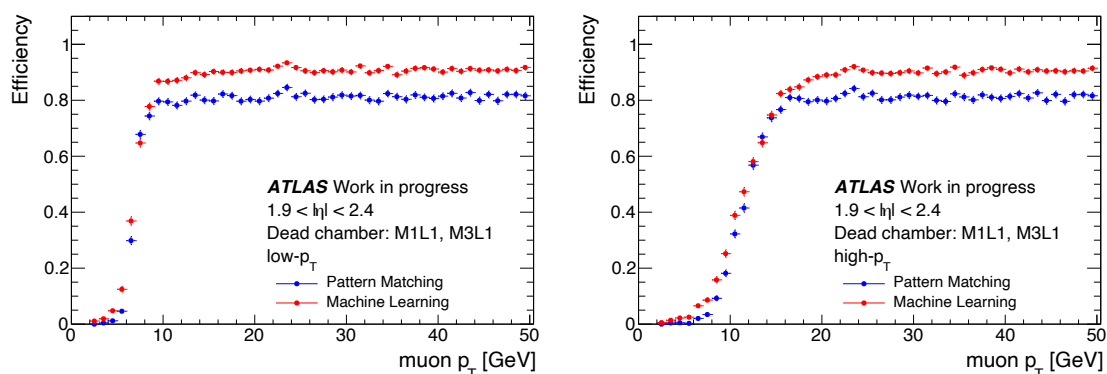


図 A.9: デッドチェンバーが M1 Layer1, M3 Layer1 の場合の Turn-on curve 比較。

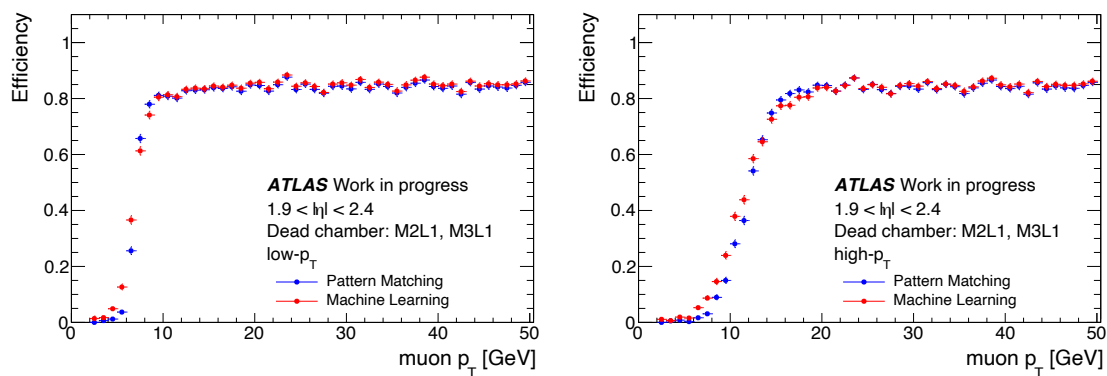


図 A.10: デッドチェンバーが M2 Layer1, M3 Layer1 の場合の Turn-on curve 比較。

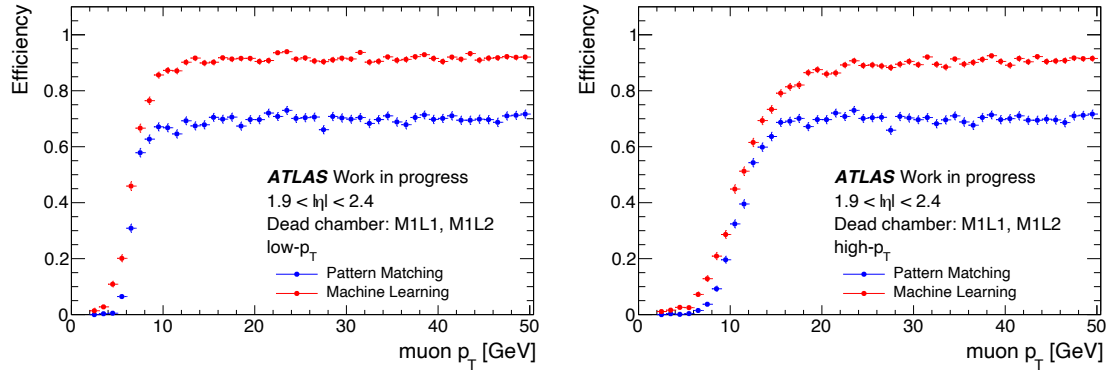


図 A.11: デッドチェンバーが M1 Layer1, Layer2 の場合の Turn-on curve 比較。

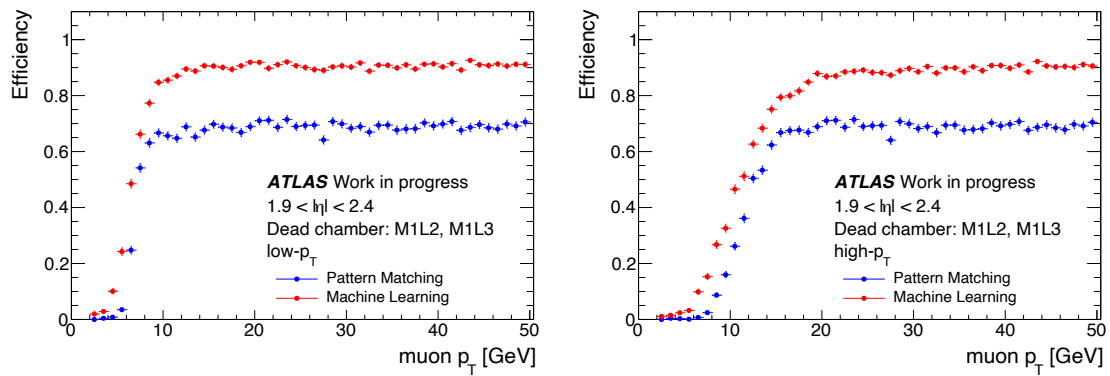


図 A.12: デッドチェンバーが M1 Layer2, Layer3 の場合の Turn-on curve 比較。

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。まず初めに、外部からの大学院進学にも関わらず私を暖かく迎え入れて下さった神戸大学 粒子物理学研究室の皆様感謝いたします。

指導教員である前田順平先生には、研究をする上で基礎となる ATLAS 実験に関する一般的な事柄から細かな技術・知識に至るまで、大変多くのことをご教示頂きました。また、私が研究で行き詰まった際にはいつもの確かなアドバイスを下さり、精神的に辛い時にも暖かく見守りながら研究の指導をして下さったことで、どうにか研究を続ける事ができました。さらに、ATLAS 実験の研究以外にも KEK におけるテストビームライン建設に携わるという大変貴重な経験をさせて頂き、非常に多くのことを学ぶ事ができました。前田先生のご指導により、2年間の修士生活は私にとって大変実りのあるものになりました。本当にありがとうございました。

神戸 ATLAS グループの蔵重久弥先生、山崎祐司先生、越智敦彦先生には、毎週のミーティングにおけるご指導に加え、研究室における日常的なコミュニケーションを通して様々なことをご教示頂きました。また、竹内康雄先生、鈴木州先生、中野佑樹先生、身内賢太郎先生、東野聡先生には、コロキウムや研究室生活において様々なご指導・お力添えを頂きました。特に、中野佑樹先生には修士課程入学後から ATLAS の研究が始まるまでの間に別の研究テーマを与えて頂いたり、ヘッドホンなどのオーディオグッズを貸して頂くなど大変お世話になりました。貸して頂いたヘッドホンのノイズキャンセリング機能は、修士論文執筆時に大変役に立ちました。ありがとうございました。

神戸 ATLAS グループの先輩である日比宏明さんには、研究の技術的な部分だけではなく、SUSY についての講義をして頂くなど理論面からも多くのことをご教示頂きました。日比さんは私が信州大学に在籍していた時からの先輩であり、日比さんの研究や飲み会に対する姿勢にはいつも刺激を受けていました。日比さんがいて下さったおかげで、不安なく研究室を移る事ができました。本当にありがとうございました。また、塩見崇宏さん、谷口浩平さん、角源一郎さん、末田皓介さんにも大変お世話になりました。修士課程に進学してすぐの右も左も分からない私に、優しく研究の指導をして下さりありがとうございました。研究面以外でも、先輩方との普段の何気ない会話や一緒にボードゲームで遊んだことなど、楽しかった思い出が尽きません。

他グループの先輩方にも大変お世話になりました。水越慧太さんは、ハードウェア・ソフトウェアに関わらず、私が質問したことについていつも分かりやすく教えて下さいました。水越さんに買って頂いた Raspberry Pi は、テストビームライン建設でのソフトウェア開発に大変役立ちまし

た。石浦宏尚さんとは趣味などについていつも楽しくお話をさせて頂きました。研究室に移ってきたばかりの私にも気さくに声をかけて頂き、とても嬉しかったです。今度一緒に登山に行きましょう。

研究室同期の寺村七都君、池森隆太郎君、野口健太君、窪田諒君、前田剛志君、谷口大悟君、長崎大智君、尾崎博紀君、Kotsor Yuri 君、外部から進学してきた私を暖かく迎え入れてくれてありがとうございました。研究室を移ってきたばかりの私に対しても分け隔てなく接して下さり、勝手の分からない事があればいつも優しく教えて下さいました。皆様のおかげでとても楽しく、非常に充実した修士生活を送る事ができました。本当にありがとうございました。

KEK 出張の際には、東京大学の松下凌大君、名古屋大学の古市亜門君、総合研究大学院大学の中島樹利菜さんに何度も食事に連れて行って頂きました。皆様のおかげで、KEK での QOL が劇的に向上しました。

高エネルギー加速器研究機構の花垣和則先生、池上陽一先生、中村勇先生、外川学先生、満田史織先生、森隆志先生を始め、PF-AR テストビームライングループの皆様には電磁石リモートコントロールシステムの開発にあたり沢山のお力添えを頂きました。テストビームラインの立ち上げに携わるという貴重な経験をさせて頂くとともに、毎回のミーティングでの的確なご助言を頂くなど大変お世話になりました。皆様のお力添えによりなんとか電磁石リモートコントロールシステムを確立させる事ができました。ありがとうございました。

また、ATLAS Japan グループの皆様には大変お世話になりました。名古屋大学の堀井泰之先生、戸本誠先生、中島拓海君には機械学習トリガーミーティングでの議論を通して研究へのご助言を頂きました。Milestone week の際には KEK の青木雅人先生、東京大学の斉藤智之先生、増渕達也先生及び先輩方に大変お世話になりました。私に研究を行う上での基礎を教えて下さり、神戸大学へ進学する私を快く送り出して下さった信州大学の竹下徹先生、長谷川庸司先生、川出健太郎先生に感謝いたします。

最後に、大学院へ進学したいという私の我儘を快く受け入れて下さり、何不自由のない学生生活を送る事ができるようにサポートをして下さった両親に感謝いたします。本当にありがとうございました。

参考文献

- [1] 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-but-flawed-theory/>, Accessed on 11/11/2021.
- [3] ATLAS Collaboration, ATLAS HL-LHC Computing Conceptual Design Report, CERN-LHCC-2020-015, LHCC-G-178, 2020.
- [4] CERN, The CERN accelerator complex Complexe des accélérateurs du CERN, <http://cds.cern.ch/record/2197559/?ln=ja>, Accessed on 01/12/2019.
- [5] O. Brüning *et al.*, Challenges and Goals for Accelerators in the XXI Century, *WORLD SCIENTIFIC*, 2016.
- [6] O. Brüning *et al.*, LHC Design Report, CERN-2004-003-V-1, 2004.
- [7] ATLAS Collaboration, Luminosity determination in pp collisions at $\sqrt{s} = 13$ TeV using the ATLAS detector at the LHC, ATLAS-CONF-2019-021, 2019.
- [8] 浅井祥仁, LHC の物理 - ヒッグス粒子発見とその後の展開 -, 共立出版, 2016.
- [9] ATLAS Collaboration, ATLAS Experiment Public Results - Luminosity Public Results Run2, <https://twiki.cern.ch/twiki/bin/view/AtlasPublic/LuminosityPublicResultsRun2>, Accessed on 05/12/2021.
- [10] ATLAS Collaboration, The ATLAS Experiment at the CERN Large Hadron Collider, *JINST*, Vol. 3, p. S08003, 2008.
- [11] ATLAS Collaboration, Experiment Briefing: Keeping the ATLAS Inner Detector in perfect alignment, ATLAS-PHOTO-2020-018, 2020.
- [12] ATLAS Collaboration, ATLAS IBL operational experience, *PoS*, Vol. Vertex2016, p. 004, 2017.
- [13] ATLAS Collaboration, ATLAS Transition Radiation Tracker (TRT): Straw Tube Gaseous Detectors at High Rates, ATLAS-INDET-PROC-2013-005, 2013.

-
- [14] ATLAS Collaboration, Performance of the ATLAS Transition Radiation Tracker in Run 1 of the LHC: tracker properties, JINST, Vol. 12, p. P05002, 2017.
- [15] ATLAS Collaboration, Technical Design Report for the Phase-II Upgrade of the ATLAS Muon Spectrometer, CERN-LHCC-2017-017 ; ATLAS-TDR-026, 2017.
- [16] ATLAS Collaboration, Small-strip thin gap chambers for the muon spectrometer upgrade of the ATLAS experiment, JINST, Vol. 15, p. C09064, 2020.
- [17] ATLAS Collaboration, New Small Wheel Technical Design Report, CERN-LHCC-2013-006 ; ATLAS-TDR-020, 2013.
- [18] ATLAS Collaboration, ATLAS Magnetic Field, <http://atlas.web.cern.ch/Atlas/GROUPS/MUON/magfield/>, Accessed on 29/1/2022.
- [19] ATLAS Collaboration, Operation of the ATLAS trigger system in Run 2, JINST, Vol. 15, pp. P10004–P10004, 2020.
- [20] ATLAS Collaboration, Technical Design Report for the Phase-II Upgrade of the ATLAS TDAQ System, CERN-LHCC-2017-020 ; ATLAS-TDR-029, 2017.
- [21] M. Vretenar *et al.*, Linac4 design report, CERN-2020-006, 2020.
- [22] H. Damerau *et al.*, Upgrade Plans for the LHC injector complex, CERN-ATS-2012-111, 2012.
- [23] O. Aberle *et al.*, High-Luminosity Large Hadron Collider (HL-LHC): Technical design report, CERN-2020-010, 2020.
- [24] KEK, Belle II 実験公式 twitter, <https://twitter.com/belle2japan/status/1407921488145965056>, Accessed on 30/1/2022.
- [25] ATLAS Collaboration, Technical Design Report for the ATLAS Inner Tracker Pixel Detector, CERN-LHCC-2017-021 ; ATLAS-TDR-030, 2017.
- [26] ATLAS Collaboration, Combined performance tests before installation of the ATLAS Semiconductor and Transition Radiation Tracking Detectors, JINST, Vol. 3, p. P8003, 2008.
- [27] 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.
- [28] ATLAS Collaboration, The Phase-I upgrade of the ATLAS Level-1 calorimeter trigger, JINST, Vol. 15, p. C06040, 2020.
- [29] ATLAS Collaboration, The ATLAS Level-1 Topological Processor: from design to routine usage in Run-2, 2018 IEEE NSS/MIC Proceedings, pp. 1–4, 2018.
- [30] 赤塚駿一, LHC-ATLAS 実験 Run-3 に向けたミュオントリガーの改良, 京都大学 修士学位論文, 2017.
- [31] 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.
- [32] ATLAS Collaboration, ATLAS Experiment Public Results - L1 Muon Trigger Public Results,
<https://twiki.cern.ch/twiki/bin/view/AtlasPublic/L1MuonTriggerPublicResults>, Accessed on 30/1/2022.
- [33] 三野裕哉, 高輝度 LHC ATLAS 実験に向けた初段ミュオントリガーアルゴリズムの開発およびハードウェアへの実装, 京都大学 修士学位論文, 2020.
- [34] ATLAS Collaboration, ATLAS Experiment Public Results - L0 Muon Trigger Public Results,
<https://twiki.cern.ch/twiki/bin/view/AtlasPublic/L0MuonTriggerPublicResults>, Accessed on 31/1/2022.
- [35] ATLAS Collaboration, ATLAS HL-LHC Computing Conceptual Design Report, CERN-LHCC-2020-015 ; LHCC-G-178, 2020.
- [36] HEPiX, Benchmarking Working Group,
<https://w3.hepix.org/benchmarking.html>, Accessed on 1/1/2022.
- [37] 国際連合広報センター, 2030 アジェンダ,
https://www.unic.or.jp/activities/economic_social_development/sustainable_development/2030agenda/, Accessed on 4/1/2022.
- [38] ATLAS Collaboration, ATLAS Experiment Public Results - TGC operation performance plots in Run2,
<http://atlas.web.cern.ch/Atlas/GROUPS/MUON/PLOTS/MUON-2019-007/>, Accessed on 20/12/2021.
- [39] ATLAS Collaboration, ATLAS level-1 trigger: Technical Design Report, CERN-LHCC-98-014 ; ATLAS-TDR-12, 1998.
- [40] 瀧雅人, これならわかる深層学習入門 = Introduction to deep learning, 講談社, 2017.
- [41] J. H. Friedman, Greedy Function Approximation: A gradient boosting machine, *Ann. Statist.*, Vol. 29, pp. 1189–1232, 2001.
- [42] E. Rumelhart *et al.*, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: Foundations*, MIT Press, 1987.
- [43] Particle Data Group, Review of Particle Physics, *PTEP*, Vol. 2020, p. 083C01, 2020.
- [44] ATLAS Collaboration, ATLAS b-jet identification performance and efficiency measurement with $t\bar{t}$ events in pp collisions at $\sqrt{s} = 13$ TeV, *Eur. Phys. J. C*, Vol. 79, p. 970, 2019.
- [45] M. Andrews *et al.*, End-to-End Jet Classification of Boosted Top Quarks with the CMS Open Data, arXiv:2104.14659, 2022.
- [46] ATLAS Collaboration, Search for chargino–neutralino pair production in final states with three leptons and missing transverse momentum in $\sqrt{s} = 13$ TeV pp collisions with the

- ATLAS detector, Eur. Phys. J. C, Vol. 81, p. 1118, 2021.
- [47] ATLAS Collaboration, Measurement of Higgs boson decay into b -quarks in associated production with a top-quark pair in pp collisions at $\sqrt{s} = 13$ TeV with the ATLAS detector, arXiv:2111.06712, 2021.
- [48] CMS Collaboration, Electron and photon reconstruction and identification with the CMS experiment at the CERN LHC, JINST, Vol. 16, p. P05014, 2021.
- [49] X. Glorot *et al.*, Deep Sparse Rectifier Neural Networks, Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, pp. 315–323, 2011.
- [50] S. Kullback, Information theory and statistics, Wiley, 1959.
- [51] Y. LeCun *et al.*, The Handbook of Brain Theory and Neural Networks, MIT Press, 1998.
- [52] K. Fukushima, Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, Biol. Cybern., Vol. 36, pp. 193–202, 1980.
- [53] GEANT4 Collaboration, GEANT4—a simulation toolkit, Nucl. Instrum. Meth. A, Vol. 506, pp. 250–303, 2003.
- [54] GEANT4 Collaboration, Geant4 developments and applications, IEEE Trans. Nucl. Sci., Vol. 53, pp. 270–278, 2006.
- [55] GEANT4 Collaboration, Recent developments in Geant4, Nucl. Instrum. Meth. A, Vol. 835, pp. 186–225, 2016.
- [56] ATLAS Collaboration, ATLFAST 2.0 a fast simulation package for ATLAS, ATL-PHYS-98-131, 1998.
- [57] G. Khattak *et al.*, Fast Simulation of a High Granularity Calorimeter by Generative Adversarial Networks, arXiv:2109.07388, 2021.
- [58] S. Vallecorsa *et al.*, 3D convolutional GAN for fast simulation, Eur. Phys. J. Web Conf., Vol. 214, p. 02010, 2019.
- [59] CANDLES Collaboration, The CANDLES experiment for the study of Ca-48 double beta decay, Nuclear and Particle Physics Proceedings, Vol. 273-275, pp. 2633–2635, 2016.
- [60] E. Legler *et al.*, Pulse Shape Discrimination System for $6\text{LiF}(\text{ZnS})$ Scintillation Counters, Rev. Sci. Instrum., Vol. 36, pp. 1167–1169, 1965.
- [61] S. Yousefi *et al.*, Digital discrimination of neutrons and gamma-rays in liquid scintillators using wavelets, Nucl. Instrum. Meth. A, Vol. 598, pp. 551–555, 2009.
- [62] J. Griffiths *et al.*, Pulse shape discrimination and exploration of scintillation signals using convolutional neural networks, Mach. Learn.: Sci. Technol., Vol. 1, No. 4, p. 045022, 2020.
- [63] M. Yoshino *et al.*, Comparative pulse shape discrimination study for $\text{Ca}(\text{Br}, \text{I})_2$ scintillators using machine learning and conventional methods, arXiv:2110.01992, 2021.
- [64] 中島 拓海 他, 高輝度 LHC-ATLAS 実験の TGC 検出器トリガーにおける機械学習を用いた飛跡再構成手法の開発 (14aT3-9), 日本物理学会 2021 年次大会, 2021.

- [65] M. Abadi *et al.*, TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems, arXiv:1603.04467, 2016.
- [66] M. Cho *et al.*, FPGA-Based Convolutional Neural Network Accelerator with Resource-Optimized Approximate Multiply-Accumulate Unit, *Electronics*, Vol. 10, p. 2859, 2021.
- [67] R. Kuramochi *et al.*, A Low-Latency Inference of Randomly Wired Convolutional Neural Networks on an FPGA, *IEICE Transactions on Information and Systems*, Vol. E104.D, pp. 2068–2077, 2021.
- [68] A. Canziani *et al.*, An Analysis of Deep Neural Network Models for Practical Applications, arXiv:1605.07678, 2017.
- [69] 小林蓮, 高輝度 LHC ATLAS 実験に向けた初段ミュオントリガーアルゴリズムの改良とハードウェアへの実装, 京都大学 修士学位論文, 2021.
- [70] 山内克弥, LHC-ATLAS 実験ミュオン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.
- [71] F. Farah *et al.*, hls4ml: An Open-Source Codesign Workflow to Empower Scientific Low-Power Machine Learning Devices, arXiv:2103.05579, 2021.
- [72] Xilinx, Vivado Design Suite User Guide: High-Level Synthesis, https://www.xilinx.com/support/documentation/sw_manuals/xilinx2018_3/ug902-vivado-high-level-synthesis.pdf, Accessed on 27/1/2022.
- [73] Xilinx, VIRTEX UltraSCALE+, <https://japan.xilinx.com/products/silicon-devices/fpga/virtex-ultrascale-plus.html>, Accessed on 31/1/2022.
- [74] Xilinx, Ultrascale アーキテクチャおよび製品データシート: 概要, https://japan.xilinx.com/content/dam/xilinx/support/documentation/data_sheets/j_ds890-ultrascale-overview.pdf, Accessed on 2/2/2022.
- [75] Xilinx, Alveo U250 データセンター アクセラレータ カード, <https://japan.xilinx.com/products/boards-and-kits/alveo/u250.html>, Accessed on 27/1/2022.