



車載向けエッジ機器の高性能化と社会実装に関する研究

北山, 晃

(Degree)

博士 (工学)

(Date of Degree)

2024-03-25

(Date of Publication)

2025-03-01

(Resource Type)

doctoral thesis

(Report Number)

甲第8943号

(URL)

<https://hdl.handle.net/20.500.14094/0100490168>

※ 当コンテンツは神戸大学の学術成果です。無断複製・不正使用等を禁じます。著作権法で認められている範囲内で、適切にご利用ください。



博士論文

車載向けエッジ機器の高性能化と 社会実装に関する研究

2024年1月

神戸大学大学院 システム情報学研究科

北山 晃

目次

第1章 序論	8
1.1. 現代社会における車載エッジ機器の進化と潮流	8
1.2. 車両エッジ機器の社会実装に向けた研究方針	12
1.3. ミリ波レーダ小型化の研究方針	15
1.4. CNN の低消費電力化実装の研究方針	18
1.5. 物体認識 AI の更新時における検証効率化の研究方針	20
1.6. 本論文の構成	22
第2章 遠距離ミリ波レーダにおける RF フロントエンドの高効率実装技術	24
2.1. 緒言	24
2.2. RF フロントエンドの高密度実装技術	24
2.3. プロトタイプ LRR の試作	33
2.4. プロトタイプ LRR の評価結果	37
2.5. 結言	43
第3章 CNN の低電力実装に関する研究	46
3.1. 緒言	46
3.2. 提案する CNN の低消費電力実装技術	46
3.3. 提案のゼロスキップ回路の実装	53
3.4. 提案のゼロスキップ手法の評価結果	56
3.5. 結論	58
第4章 物体検出 AI の実機検証効率化 に関する研究	60
4.1. 緒言	60
4.2. 車両における物体検出 AI の検証方法	60
4.3. 提案の AI 検証手法	63
4.4. TOED の設計	65
4.5. TOED の評価結果	69
4.6. TOED の性能改善の検討	75
4.7. 結論	78
第5章 結論	81
5.1. 本研究で明らかにされた事項	81
5.2. 今後の展望	83

謝辭.....	87
參考文獻	88
1 章參考文獻.....	88
2 章參考文獻.....	91
3 章參考文獻.....	93
4 章參考文獻.....	93
研究成果一覽	96

目次

図 1.1 車載エッジ機器の構成と要求課題.....	9
図 1.2 エッジ AI 向けの演算デバイスの演算性能と消費電力の関係.....	10
図 1.3 エッジ向けデバイスの市場規模予測.....	11
図 1.4 自動運転レベルごとの生産台数の市場予測.....	12
図 1.5 ミリ波レーダにおける性能仕様のイメージ.....	15
図 1.6 Level 1~2ADAS 向けの LRR における構成.....	16
図 1.7 高レベルの ADAS, AD 向けの LRR における構成.....	17
図 1.8 CNN の全体構成と畳込み演算のブロック図.....	18
図 1.9 CNN の演算量・消費電力削減技術.....	19
図 1.10 車両ソフトウェアにおける開発プロセスの例.....	20
図 1.11 本研究の全体像と構成.....	22
図 2.1 LRR におけるハードウェア構成の例.....	25
図 2.2 ホーンレンズアンテナの構成.....	27
図 2.3 平面アンテナとホーンレンズアンテナの特性比較結果.....	28
図 2.4 3Tx4Rx のアンテナ, MSL, MMIC および周辺部品の実装パタンの例.....	30
図 2.5 MMIC ごとの RF フロントエンドの面積.....	31
図 2.6 各アンテナのシミュレーションモデル(2ch のケース).....	32
図 2.7 アンテナ間ギャップごとのチャネル間アイソレーションの.....	32
図 2.8 プロトタイプ LRR のアーキテクチャ(1 Tx & 4 Rx).....	34
図 2.9 ファストチャープ変調における各パラメータの定義.....	35
図 2.10 プロトタイプ LRR の構成.....	36
図 2.11 プロトタイプ LRR の基本性能測定系.....	37
図 2.12 試作 LRR の 2-way アンテナ利得特性測定結果.....	38
図 2.13 レーダにおける角度推定方式.....	38
図 2.14 プロトタイプ LRR のアンテナ特性測定結果.....	39
図 2.15 プロトタイプ LRR を車両のバンパ内に実装した写真.....	40
図 2.16 プロトタイプ LRR の検出性能評価系.....	40
図 2.17 車両に実装したプロトタイプ LRR の検出性能評価結果.....	41
図 2.18 ターゲット車両に対する DoA 推定誤差の評価結果.....	42
図 3.1 MAC 演算回路向けゼロスキップを用いたクロックゲーティング回路の構成.....	47
図 3.2 SSD500 における各層のゼロデータの割合 (Data set: 500 cityscape images).....	49
図 3.3 SSD500 における各層のゼロ重みの割合(Training data set: 3,000 cityscape images)	

.....	49
図 3.4 提案する MAC 演算向けゼロスキップの構成.....	50
図 3.5 SSD500 の各層の入力における 0,1 データの割合(Data set: 500 cityscape images).....	51
図 3.6 提案するアクティブデータスキップ手法の構成.....	52
図 3.7 本研究の検討用に FPGA に SSD500 を実装した構成	53
図 3.8 畳込み回路におけるデータフロー.....	54
図 3.9 提案のゲーティングロジック回路を適用した畳込み演算回路の構成	55
図 3.10 ゲーティング閾値に対する消費電力および認識精度の関係	56
図 3.11 ゲーティング閾値と LUT 回路のオーバヘッドの関係	57
図 4.1 ソフトウェアの実機検証方法.....	60
図 4.2 ユーザ車両を用いた更新版ソフトウェアの検証方式.....	61
図 4.3 運用版と更新版ソフトウェアの比較検証方式.....	62
図 4.4 提案の検証方式.....	64
図 4.5 TOED の学習データと評価データセットの例	65
図 4.6 TOED の学習データと評価データセットの例	66
図 4.7 TOED(Target Object Existence Detector)の構成.....	67
図 4.8 TOED の推論確信度に対する物体有無判定結果	70
図 4.9 推論不確実度に対する特徴スコアと confidence 値のイメージ.....	71
図 4.10 物体存在の特徴量スコアを用いた物体有無判定結果.....	71
図 4.11 推論差分のモードの例とその発生割合の例	72
図 4.12 2 つの AI モデルの推論差分の例（上側：運用版 AI，下側：更新版 AI）	73
図 4.13 運用版と更新版 AI の推論差分に対する TOED の物体有無検出結果	74
図 4.14 TOED をクラスごとに実装した構成	75
図 4.15 各クラスに対する TOED の判定精度評価結果	76
図 4.16 複数の TOED を用いた判定精度向上手法	77

表目次

表 1.1 周辺認識センサの特徴と設計課題.....	14
表 2.1 LRR の構造ごとのハードウェア構成・サイズの特徴	26
表 2.2 アンテナ構造と性能比較結果.....	28
表 2.3 RF フロントエンドの面積算出結果 (3Tx 4Rx)	31
表 2.4 プロトタイプ LRR の目標性能.....	33
表 2.5 プロトタイプ LRR の変調条件設定値	35
表 2.6 RF フロントエンド各領域における実装面積.....	37
表 2.7 LRR における基本性能のベンチマーク	43
表 3.1 Xilinx ZU9 における PL 部の使用状況(ゲーティング回路は含まず).....	54
表 3.2 Xilinx ZU9 における消費電力の詳細(ゲーティング回路は含まず).....	55
表 4.1 更新 AI の性能改善/劣化の判定ルール	64
表 4.2 TOED のデータセットにおける物体有無の詳細	67
表 4.3 TOED の畳込み層の各パラメータ詳細	68
表 4.4 更新版 SW の各検証手法における性能劣化検出精度の比較.....	78

第1章 序論

1.1. 現代社会における車載エッジ機器の進化と潮流

近年、超高齢化社会の到来による労働人口の減少や環境破壊・エネルギー枯渇問題、未曾有の自然災害、犯罪・事件の悪質化など、多様で複雑な社会課題への対応が強く求められている。これに対する手段の一つとして、エッジ機器を活用したサービス、ソリューションの開発が盛んになっている[1-1]。本論文では「エッジ機器」を、生活空間や市街地、職場や生産現場などのフィジカル空間において、周辺物体や機器の状態をセンサ等で取得し、その場で処理した結果を用いて何らかの価値を提供する機器、と定義する。センサモジュールや携帯電話、スマートフォン、PC、生産現場の装置、ロボット、車両など、幅広いハードウェアがエッジ機器として定義できる。

2000年代後半から2010年代にかけては、シンプルなセンサと通信機能を備えたいわゆるIoT（Internet of Things）機器を用いたサービスやソリューションが幅広く普及した[1-2]。例えば、インフラ設備や工場内の装置にエッジ機器を設置し、装置状態の見える化や故障予兆を検出するシステムを提供するなど、産業基盤を下支えするシステムとして既に多くのケースで社会実装されてきた。2010年代後半から現在に至るまでは、センサの高度化や小型化、低コスト化が進んだことと、AI技術の進化・普及によって、エッジ機器が提供できる価値が一層高まってきた。特に自動車分野においては、増え続ける高齢者や限界集落における交通弱者への対応、交通事故による死亡事故ゼロ化などの実現に向けて、ADAS（Advanced Driver Assistance System）やAD（Autonomous driving）などの自動運転車両や、それを用いたMaaS（Mobility as a Service）に関する技術開発が活発に行なわれ、自動運転レベル2までの運転アシスト機能については実用化が進んでいる状況である[1-3]。また、人々の暮らしの安全・安心と快適性・利便性の実現に向けた都市・街の人流モニタリングシステム、スマートシティ、スマート物流、商品の生産性や信頼性を担保するための製造ラインにおける外観検査システムなど、高度なアプリケーションを実現するためのエッジ機器とそれを用いたシステムが国内外を問わず活発に開発が進められている。

以上のように、これまで実用化されてきた様々な社会課題を解決するためのアプリケーションやシステムの根幹にはエッジ機器があると言える。この中で自動運転アプリケーションを搭載した車両は、前述したような多くの社会課題を解決し、より安全・安心な暮らしと移動の利便性・快適性を実現する重要なエッジ機器の一つである。また、現在に至るまでの多くのエッジ機器に関する技術は、まず自動車分野を中心に研究開発と実用化に向けた技術開発が進められ、完成した高性能・高信頼な技術を他のエッジ機器に展開・応用する歴

史的な背景もあると言える。このことから、本研究では自動運転車両をターゲットとするエッジ機器として想定し、その中でも最重要の機能である周辺認識アプリケーションにフォーカスして以下の議論を進めることとする。

車載エッジ機器では、機器状態の振動や温度などをセンシングするようなシンプルなエッジ機器とは違い、検出対象物体の正確な位置情報の推定や、外観から予測される状態（向き、停車中、等）の推定、歩行者の行動の種類や次の動きの予測など、より複雑で高難易度なセンシングと認識処理の性能が要求される。また、衝突防止などを目的としたアプリケーションの性質上、車両エッジ機器で取得したデータはその場でリアルタイムに処理し、即座に制御へフィードバックすることが求められる。例えば、車両の経路上における物体検出時に緊急停止や回避のための即時判断・制御処理を実現するにはミリ秒単位のリアルタイム性が要求される。また、車両エッジ機器は低コスト化への要求が厳しいために、サーバ等で使うプロセッサに比べて貧弱な性能の演算デバイスを搭載しなければならず、限られた演算リソースで高速なデータ処理を実行する必要がある。更に、車両エッジ機器ではバッテリー駆動が必要のため低消費電力化や、機器サイズの小型化も求められる。以上のように、認識性能、処理のリアルタイム性、消費電力、機器サイズ、コストは車両エッジ機器における代表的な要求項目として挙げられる。

図 1.1 に車両エッジ機器の構成と要求を示す。ハードウェアの主な構成部品としては、電源や通信 I/F、それに付随する細かな部品・配線や筐体・基板等を除いて、周辺の物体情報（種類や位置、大きさ等）を取得する「センサ部」と、センサデータを処理する「演算デバイス部」の 2 つに分けられる。周辺認識アプリケーションにおいて、運転者の「目」の代替とな




図 1.1 車載エッジ機器の構成と要求課題

るための「センサ部」にはカメラやレーダ、LiDAR などが用いられている。しかし、現状では自動運転レベル 2 までの運転アシスト機能の実現にとどまっており、レベル 3 以上の高度な自動運転の実用化に向けてはより高い検出性能とセンサの小型化・低コスト化が必要で、現状では一部の高級車から段階的に実用化が進んでいる状況である。また、これらのセンサで取得される情報量はシンプルなセンサに比べて圧倒的に多く、更新頻度（フレームレート）も 20~30 fps が求められるため、「演算デバイス部」の処理能力向上に関する技術開発も重要となる。

従来の車載エッジ機器向けの演算デバイスは、比較的シンプルな信号処理や制御プログラムの実行のためのマイコンが初期のエッジ機器向けに活用され、高性能な自動運転向けにはプロセッサ、メモリ、ネットワーク、セキュリティ等の機能を統合した SoC (System on Chip) が適用され、低消費電力かつ高性能な処理が可能となった。また、2012 年頃に登場した深層ニューラルネットワーク (DNN: Deep Neural Network) が登場したことにより、画像を始めとする様々なセンサデータに対する処理性能が格段に向上し、AI の認識能力は人を超えたと言われている。AI の処理を車載エッジ機器で実行することを目的に、図 1.2 に示す組み込み向けの GPU (Graphics Processing Unit) や AI アクセラレータを搭載した SoC, FPGA (Field Programmable Gate Array) 等の処理デバイスが登場し、エッジ機器の性能が大幅に高性能化した。また、図 1.3 に示すように、これらのエッジ向けデバイスの市場規模は右肩上がりであり、2025 年にはエンタープライズ向けのデバイスの 3 倍以上になると予想されており、今後車載エッジ機器をはじめとしたエッジ活用のシステムやソリューションの社会実装がますます進み、人々の暮らしに寄り添った存在になっていくことが予想される。




図 1.2 エッジ AI 向けの演算デバイスの演算性能と消費電力の関係




図 1.3 エッジ向けデバイスの市場規模予測

次に、演算デバイス部で実行される処理アルゴリズム・機能について述べる。大きくは「認識」、「判断」、「制御」の3機能に分類される。自動運転向けの車両エッジ機器では、周辺の物体や道路形状などを「認識」し、それが自分の走行経路に対して危険であると「判断」されればブレーキやハンドル操作で回避する「制御」を行なう一連の処理が車両制御ソフトウェアとして実装される。これらの処理機能を実現するためのアルゴリズムは、明確に仕様が定義できるルールベースが用いられてきた。一方、近年適用が進んでいる AI 技術においては、学習に用いたデータの特徴を AI が学習して推論するために、設計者が意図しない推論ミスが起こり得る。また、それらの推論根拠や性能の定義、原理の説明が難しく、ブラックボックスのアルゴリズムとも呼ばれる性質があることから、AI を搭載した製品の社会実装や実用化に向けては、安全性や信頼性を証明するためのテスト・検証が特に重要な位置付けとなる。

以上で述べたように、時代とともに進化したハードウェアと処理アルゴリズムを活用して、車載エッジ機器の高性能化と社会実装に向けた研究開発が活発に行なわれている。課題としては図 1.1 に示した通り、「センサ部」では検出性能に対してトレードオフとなる消費電力、センササイズ、コストの解決が必要となる。「演算デバイス部」では実装される処理アルゴリズムの規模・性能に対して、処理のリアルタイム性、低消費電力化、低コスト化を実現する必要がある。また、ハードウェア、ソフトウェア両視点での安全性、信頼性も要求されることから、検証のための工数や時間が増大することも課題となる。次節では、車両エッジ機器のアプリケーションと課題の詳細、及びそれに対する本研究の方針について述べる。

1.2. 車両エッジ機器の社会実装に向けた研究方針

自動運転向け車両エッジ機器は、2000 年代前半から高級車を中心に運転アシストの分野で実用化が始まり、2010 年代から徐々に一般大衆車に普及が進み始めた。現在も自動運転レベル 2 までに対応した車両の市場投入が続いており[1-4]、国内の動向としては、2021 年 11 月以降に新たに市場に投入される国産の新型車は衝突被害軽減ブレーキ（自動ブレーキ）の搭載を義務化する法律が施行されている（輸入車は 2024 年 7 月以降）[1-5]。また、近年では完全自動駐車のアプリケーションが搭載される車両の普及や[1-6][1-7]、自動運転レベル 3 以上の自動運転を搭載した車両も限定的ではあるが徐々に市場投入が始まっている状況である。

国内では本田技研工業が 2021 年にリース限定での市販を開始し、それ以降もレベル 3 の車両が海外を含めて各社から相次いで発表されている。しかし、搭載されるセンシングデバイスが高コストであるため、しばらくは高級車を中心とした市場展開になると予想され、レベル 3 以上の本格的な普及は 2030 年代になると予想されている（図 1.4）。また、運転責任がシステム側となるため、法整備や事故時の責任問題やルール化も解決すべき課題の一つである。また、ロボットタクシーや無人バスなどの商用車における自動運転も一部で実用化が始まっており、米国、中国においては成長市場として位置付けられている。しかし、いかなる場所・環境においても高安全・高信頼を保证するには技術的なハードルと、インフラ側の整備もクリアしていく必要があるため、本格的な普及には時間がかかる見通しである。このように、レベル 3 以上の自動運転アプリケーションが一般大衆車にまで普及するにはセンシングデバイスのコスト、性能や信頼性は勿論、法整備やインフラ、更には自動運転車に対する社会的な理解・受容性の向上などの様々な課題を解決する必要がある。




図 1.4 自動運転レベルごとの生産台数の市場予測

自動運転向け周辺認識アプリケーションに用いられる代表的なセンサとして、カメラ、ミリ波レーダ、LiDAR、ソナーが挙げられる。それぞれのセンサは検出性能に一長一短の特性を持っており、単独のセンサだけでは高信頼な周辺認識アプリケーションの実現は難しい。そのため、実現したい性能・要件に最適なセンサを組み合わせることで検出の信頼性を担保する構成を取ることが一般的である。例えば、カメラとLiDARは光学系を用いたセンサのため逆光や粉塵、霧などの環境条件によっては認識性能が低下する短所があるが、電波を用いたミリ波レーダは環境条件に対して頑健でロバストな認識性能を持つため、この2つを組み合わせることで環境条件に対するロバスト性を担保することが出来る。また、カメラでは奥行方向の距離検出精度が低いために、前方車両との衝突を正確に回避するためには奥行方向の距離検出精度が高いミリ波レーダやLiDARと組み合わせることで検出性能の精度や信頼性を担保している。カメラとミリ波レーダを組合せた事例としては、ACC (Auto Cruise Control) や AEB (Autonomous Emergency Braking) などの自動運転レベル 1~2 向けアプリケーションがあり、いずれも既に実用化されている[1-8]-[1-11]。一方で、ミリ波レーダは検出した物体の種類・形状の認識や、色の識別や文字の認識は不向きであるため、歩行者や車両の行動予測や、信号認識、標識認識などのより高レベルな機能を実現するにはカメラと組み合わせることが必須となる。また、LiDARは検出の位置精度が非常に高いため、SLAM (Simultaneous Localization and Mapping) 技術による自己位置推定や周辺地図作成が可能で、より安全な自動運転の実現に向けたセンサデバイスとして 2010 年中盤頃から期待が高まっている。また、自動駐車アプリケーションのように数 cm オーダの超至近距離の衝突防止（近接車両や壁等との接触防止）が要求される場合は、カメラ、ミリ波レーダ、LiDAR の検出範囲外となるために、安価で複数設置可能かつ近距離検出が得意なソナーとの組合せで実現・実用化されている。このように、複数種類のセンサを組み合わせることで互いの得意・不得意を補完し、周辺認識アプリケーションの性能と信頼性を担保する必要がある[1-12]-[1-17]。

表 1.1 に上記で挙げた 4 つの周辺認識センサと、車両前方監視向けアプリケーションの用途における技術課題を示す。カメラの認識・識別性能、ミリ波レーダの検出距離・耐環境ロバスト性、LiDAR の検出物体との距離精度などが上記で述べた各センサにおける利点である。アプリケーションの安定性・信頼性の観点では少なくとも環境ロバスト性に優れたミリ波レーダの実装は不可避であり、逆にミリ波レーダの検出特性（方位推定性能と物体識別機能）を補うためにカメラの実装も必須である。このことから、これら 2 つのセンサは信頼性の高い自動運転の実現に向けて必須の組合せと言える。

カメラとミリ波レーダに注目したとき、カメラのデータ量と環境ロバスト性、ミリ波レーダの物体識別機能などの短所はセンサの原理的な問題であるため改善は難しいが、技術的なアプローチで改善可能な項目がいくつか挙げられる。例えば、ミリ波レーダの方位検出精度を高めるためにはアンテナ数とその送受信利得、およびアンテナ間のアイソレーション特性を改善することである程度の改善が可能となる。しかしこれらの性能はアンテナ面積とのトレードオフであるために、センサ小型化との両立が課題となる。そのため、面積効率

表 1.1 周辺認識センサの特徴と設計課題

センサ	センサ特性				前方監視における技術課題		
	クラス分類	距離精度	環境ロバスト性	データ量	検出距離	方位精度	消費電力
カメラ	○	低	低(雨,霧,粉塵,逆光,夜)	大	～100m	高	大
レーダ	×	高	高	小	～250m	低	小
LiDAR	△	高	低(雨,霧,粉塵,逆光)	中	～70m	高	中
ソナー	×	高	低(雨,霧,風)	小	～10m	低	小

が高くアイソレーション特性の良いアンテナ技術が必要となる。

また、他センサよりも単位時間あたりの取得データ量が多いカメラにおける課題としては、画像処理性能の向上、演算デバイスにおけるリアルタイム処理や消費電力の抑制、センサの小型化や低コスト化が挙げられる。この中でも画像処理アルゴリズムは近年、CNN を用いたものが主流となっており、大規模な並列積和演算が必要となるために演算デバイスにおける消費電力がより一層の課題となる。更に、CNN などの AI 処理はルールベースで設計されたものではなく、大量のデータセットから物体の特徴を学習したものであるために、設計者の意図しない性能となることが多い。すなわち、AI を適用したことにより AI の更新が頻繁に必要なと考えられる。しかし、更新版 AI を含むソフトウェアのリリース前には様々なテストパターンでの検証と実車による走行試験をクリアする必要があるために、時間と人的リソースが必要となる。このことから、車載エッジ機器に AI を適用したことにより AI の更新頻度が上がり、それに伴う検証時間とコストの増大が大きな課題になると考えられる。

以上のことから本研究では前節でも結論付けた通り、車載エッジ機器の高性能化と社会実装に向けて、自動運転向け周辺認識アプリケーションを想定して検討を行なう。このうち、本節で述べた通り様々な周辺認識センサにおける課題の中でも特に優先度の高い①ミリ波レーダの方位推定精度の向上と小型化の両立、②大規模な CNN 演算における低消費電力化、③AI の検証効率化、の3つに対する技術開発を目的とする。

1.3. ミリ波レーダ小型化の研究方針

車載用のレーダは 24GHz 帯の準ミリ波と呼ばれる帯域と、77GHz 帯、79GHz 帯のミリ波帯域を用いて周辺物体を検出するものが市場投入されている。このうち 24GHz 帯は電波法の規制から将来的に使用できなくなる可能性があることと、使える帯域幅がミリ波帯に比べて狭いために、現在では 77GHz、79GHz 帯を中心にミリ波レーダの開発が行なわれている[1-18]。ミリ波レーダの用途としては前方監視用の LRR（Long Range Radar）と周辺監視用の MRR（Middle Range Radar）、SRR（Short Range Radar）に分けられる。いずれも自動運転を実現するためには必須の機能であるが、LRR は交通事故の中で最も多発している前方の追突事故を回避するための基本的かつ重要な位置付けである。また、自動運転の適用先シナリオとしては高速道路などの自動車専用道路から着手される傾向にあるため、より遠距離の物体を早期に検知することが要求される。以上のことから、本研究では LRR の高性能化について検討を進めることとする。

高速道路において 100km/h 以上の速度で走行する場合は、例えば図 1.5(a)のように視野角（FoV : Field of View）18 度で 200m 以上の距離にある車両を車線位置まで含めて正確に検出することが要求され、後述する高レベルの自動運転向け LRR では更に広い検出範囲が求められる。検出対象の物体までの距離が遠くなる程に伝搬する電波は減衰するため、遠距離化に向けてはアンテナの高利得化が求められる。更に、図 1.5(b)のように先行車両の位置が自車線か隣車線かを見極めるための方位推定性能や、図 1.5(c)のように直線距離が同一で方位が異なる 2 車両を分離検出するための方位分解能も要求される。




図 1.5 ミリ波レーダにおける性能仕様のイメージ

図 1.6 は現在市場投入されている ADAS 向けの標準的な LRR のハードウェア構成を示したもので、後述する高レベル自動運転向けレーダに比べるとシンプルな RF フロントエンドを有する。本研究では RF フロントエンドを次のように定義する。すなわち、ミリ波帯の変調信号の生成と送信・受信およびベースバンド信号への変換を行なう MMIC

(Monolithic Microwave Integrated Circuits), 送信 (Tx)・受信 (Rx) アンテナ, MMIC と各アンテナを接続する MSL (Micro Strip Line), MMIC を動作させるための周辺部品から成る構成を RF フロントエンドと定義する。RF フロントエンドはミリ波帯の超高周波信号を扱う部分であるために実装難易度が高い。具体的には, MSL やアンテナにおいて周辺の回路パターンや部品との電磁的結合やインピーダンスミスマッチによって信号劣化が起こりやすく, これらの周辺には十分な物理的スペースも必要となる。これらのことから, RF フロントエンド部はレーダモジュールのサイズに対してインパクトが大きく, 効率的な実装技術が求められる。

一方で, より高度な自動運転レベル向けの LRR では, 遠方の歩行者や落下物の検知, 道路端の検知, 悪天候下での長距離検知など, 様々なユースケースにおいて高い検出性能が求められる。これらの要求を満たすための性能仕様の一例として, FoV 30 度, 検出距離 300m 程度の性能が要求される。ミリ波レーダにおいては, 検出距離と方位推定精度を向上させる要件は次の通りであることが知られている。

- (a) 受信信号の SNR (Signal to Noise Ratio) の改善
- (b) Tx-Rx 間および Rx 間のアイソレーションの改善
- (c) Tx, Rx チャンネル数の増加

(a) の SNR を改善するための手段として, MMIC の出力電力やノイズ性能を向上させることや[1-19]-[1-23], 受信電力 P_r を大きくすることが挙げられる。レーダ方程式によると, P_r は以下のように求められる。

$$P_r = \frac{P_t G_t G_r \sigma \lambda^2}{(4\pi)^3 R^4} \quad (1.1)$$




図 1.6 Level 1~2ADAS 向けの LRR における構成

ここで、 P_t はTx アンテナに供給される電力、 P_r はRx アンテナで受信する電力、 G_t はTx アンテナの利得、 G_r はRx アンテナの利得、 λ は自由空間における波長、 σ は検出ターゲットのレーダ断面積、 R はターゲットまでの距離である。レーダの動作パラメータや検出ターゲットを変更することなく、検出距離を 200m から 300m に改善するためには、アンテナ利得（ G_t と G_r ）を合計で約 7.0dB 増加させる必要がある。これは、アンテナの有効面積を 5.1 倍に増加させることに相当し、レーダモジュールのサイズに対して大きなインパクトがあると言える。

(b)のアイソレーションを改善するためには各チャネルのアンテナを隣接チャネルから物理的に離す必要があるために、RF フロントエンドの面積増大の一因となる。更に、(c)のTx, Rx のチャネル数を増やす場合は、それらに接続される MMIC の数も増やす必要があるために、図 1.7 に示すように、複数の RF フロントエンドのセットを並べる構成となる。従って、(b)(c)もまた RF フロントエンドの面積増大を引き起こすこととなる。つまり、高性能な LRR は単純な ADAS 用の LRR よりも大きなサイズになる傾向があると言える。これに対して、LRR のサイズは車両のバンパ内に収める必要があるために、高性能化しながらも RF フロントエンドを高密度かつコンパクトに実装することが必須となる。

本研究では、これらの要求を満たすために、ホーンアンテナとレンズアンテナを組合わせたホーンレンズアンテナに注目した[1-24]-[1-26]。このアンテナは一般的な LRR で用いられている平面アンテナに対して高さ方向にアンテナ領域が必要である一方で、高利得、高アイソレーションである特徴を備えている。本研究ではこのホーンレンズアンテナの物理的な特徴を生かし、LRR の小型実装技術について検討する。




図 1.7 高レベルの ADAS, AD 向けの LRR における構成

1.4. CNN の低消費電力化実装の研究方針

本節では CNN の低消費電力化実装の研究方針について述べる。既に述べた通り，CNN を用いた画像認識技術は，従来のルールベースのアルゴリズムに比べて認識精度が飛躍的に向上することが知られている。CNN に関する技術は自動運转向け車載エッジ機器だけでなく，医療機器，産業用ロボット，監視システムなど，様々なエッジ機器への実装が進んでいる。その中でも特に画像分類，物体検出，セグメンテーションに広く使用される CNN のモデルはこれまでに数多く提案されている[1-27]-[1-32]。図 1.8 は一般的な CNN の構成と演算ブロック構成を示す図である。CNN の畳込み層では， n 番目の入力データ D_n と $F = f \times f$ のサイズのフィルタにおける m 番目の重み W_m が乗算されたのち， F 個の乗算結果が加算される。その後，ビットシフト処理を行ない，バイアス係数を加算し，最後に活性化関数の一つである ReLU (Rectified Linear Unit) の処理を行なう。ReLU 処理により負の値の入力データはゼロとして出力され，次の層の入力データにおけるゼロの割合が増加する。CNN は層構造が深くなる程に認識精度が向上する一方で演算量は増大し，一般的に 1 枚の画像に対して 10～100 GOP (Giga OPerations) 程度の積和演算が必要となる。そのため，リアルタイム




図 1.8 CNN の全体構成と畳込み演算のブロック図

処理と低消費電力化を実現するには、CNN の膨大な演算を効率良く実行する技術が必要となる。

CNN を構成する演算は殆どが積和演算から成る畳込み演算であり、これを効率良く実装する技術としては、図 1.9(a)に示す枝刈り技術や(b)量子化(低ビット化)技術など、認識精度への影響を抑えながら演算量を削減するモデル圧縮技術[1-33]-[1-35]や、高速処理・低消費電力に対応したの AI アクセラレータも報告されている[1-36]-[1-38]。また、図 1.9(c)のゼロスキップ技術では畳込み演算のフィルタ単位で入力データまたは重みがゼロの場合に積和演算を停止することで消費電力を削減する。また、FPGA 回路[1-39][1-40]や専用のハードウェアアクセラレータ[1-41]-[1-44]を用いて、ゼロスキップ技術による畳込み演算を高速化した研究がいくつか報告されている。これらの技術は、各層の出力、すなわち次の層の入力データにゼロが多く含まれるという CNN の計算の特徴をうまく利用しており、計算速度の向上と消費電力の低減に有効である。しかし、ゼロスキップ技術では積和演算を停止させるために、入力データや重みがゼロかどうかを監視するロジック回路の追加が必要があるため、監視回路のオーバーヘッドが課題となる。また、エッジデバイスに実装するために圧縮された CNN モデルは、圧縮前よりも重みゼロの比率が低くなっているために、ゼロスキップ技術による低消費電力化の効果が低下する課題がある。これは、計算されない重み（つまり重みの値がゼロ）が優先的に枝刈りされるためである。本研究では、入力データのみを監視する小規模なゲーティング論理回路を用いて積和演算器を細かく停止する技術と、入力データが認識精度に影響を与えない小さな値の場合に計算を停止させるアクティブスキップ技術




図 1.9 CNN の演算量・消費電力削減技術

の2つの手法を提案し、それらの低消費電力化の検討結果について述べる。

1.5. 物体認識 AI の更新時における検証効率化の研究方針

本節では、車載向け周辺認識として最も普及している物体認識 AI の更新版をリリースする際に必要な実車検証の効率化を目的とした技術開発の方針について述べる。一般に、様々な製品に搭載されるソフトウェアは、顧客が使用する前に十分に検証されることが必要である。製品に求められる安全性、信頼性、品質が高いほどに検証の重要性は増し、検証に必要な時間やコストは増大する。自動車のシステムを支える車両制御ソフトウェアにおいては、運転者、歩行者、車両、ひいては社会の安全・安心を担保する必要があるために、極めて厳格な検証が要求される[1-45]-[1-48]。

図 1.10 では、バージョン N でソフトウェアの不具合や修正が必要な項目が見つかった場合、あるいは機能追加などのアップデートをする場合に、バージョン N+1 のリリースに向けた開発プロセスを示している。設計者がプログラムの修正を実施して、バージョン N+1 の検証を行なうにあたり、まずは開発環境で様々なテストパターンを用いて網羅的に検証する。さらに、実世界の実験車両で様々な場所を実際に走行して、不具合が無いことを最終検証することが行われる。自動車メーカーはあらゆる状況下で車両の安全性を保証する責任と義務があるために、実験車両を使った検証では様々な走行条件を想定することが求められる。仮に実験車両を使った検証で不具合が見つかった場合は、開発環境でデバッグを行ない、修正したソフトウェアを用いて再び実験車両で検証しなければならない。実験車両を使っ




図 1.10 車両ソフトウェアにおける開発プロセスの例

た検証は、超長距離・多岐に渡るテストパターン走行と、取得した膨大なデータの解析に人的リソースと時間がかかるため、ソフトウェアの更新時の大きな課題と言える。

検証時における工数低減のための技術開発は様々に行なわれており、例えば実際の走行環境をシミュレーションや高精細な CG などで再現し、それをテストパターンとする方法が提案されている[1-49]-[1-51]。また、生成したテストパターンがなるべく重複しないよう、網羅的にテストパターンを生成するなどの技術なども提案されている[1-52][1-53]。このような技術によって、開発環境で自動的かつ高品質な検証を行なう取り組みは行われているが、発生可能性のあるシナリオは無限に存在するために、誰も知り得ない未知のエッジケースに対するテストパターンを作ることは難しい。また、いかに開発環境において効率的に検証を行なったとしても、自動車という製品の性質上、品質保証・信頼性担保などの観点から、従来の製品で実施していた実走行検証のプロセスを省略することは出来ないジレンマがある。ただ、現実的には検証にかけられる時間とコストは有限であるため、例えば経験ベースで決めた所定のテストシナリオでの検証や、一定の走行時間と走行距離で不具合が出なければ検証をパスしてソフトをリリースする運用となっている。

更に、前節でも述べた通り、近年では ADAS や AD に求められる機能の高度化が進み、車両制御ソフトウェアへの AI の適用が急速に進んでいる。ルールベースで記述されたソフトウェアとは異なり、AI の性能は学習データ、学習パラメータ、学習方法によって決まる。そのため、AI の更新によって設計者が意図しない性能向上や性能劣化が起こることが知られている。そのため、ルールベースで記述されたソフトウェア以上に性能不足や不具合が見つかることが多く、上記で述べた更新・開発プロセスを実行する頻度が増加すると予想される。AI の検証の難しさと重要性、そしてどのように検証すべきかについては多くの研究と検討が進められている[1-54][1-55]。

以上で述べたように、今後の自動運転ソフトウェアに必ず搭載される AI は、更新時の検証コストが大きな課題となる。本研究では、自動運转向けの周辺認識として最も普及が進んでいる物体検出 AI を対象に、更新時の実車検証を効率化する技術について検討した。更新版と現状版 AI の推論結果を比較し、その差分を軽量な AI で判定する方式を開発し、その検証精度について検討を行なった結果について述べる。

1.6. 本論文の構成

本研究では、前節までに述べた方針に従って、車載エッジ機器の高性能化と社会実装に向けた課題を解決する技術を開発する。本論文の構成は図 1.11 に示す通りで、以下の内容である。

第 1 章では、本研究の背景および目的を説明した。エッジ機器のうち設計・実装難易度が高く、社会的なインパクトの高い自動運转向けアプリケーションを想定し、①カメラの不得意領域を補間するミリ波レーダの小型化、②カメラで取得した画像データを AI で処理する際の消費電力増大、③AI モデルを製品化あるいはモデル更新の際に必要な検証の工数、の 3 テーマを本研究において解くべき課題に設定した。

第 2 章ではミリ波レーダの性能を改善するために必要なアンテナ利得とアイソレーション特性に対するアンテナサイズ増大のトレードオフを解消するために、ホーンレンズアンテナを用いた小型実装技術について述べる。

第 3 章では幾層にも繰り返される CNN の演算において、出力されるデータに応じて演算を停止することで低消費電力を実現するための技術開発について述べる。

第 4 章では AI の更新時に課題となる実車検証に要する時間と人的リソースを解消するための検証自動化技術について述べる。

最後に第 5 章では本研究を総括し、車載エッジ機器の高性能化と社会実装に向けた今後の展望と取り組むべき課題について述べる。




図 1.11 本研究の全体像と構成

第2章 遠距離ミリ波レーダにおける RF フロントエンドの高効率実装技術

2.1. 緒言

前章では自動運転の前方監視における中心的センサの一つである遠距離ミリ波レーダの特徴と要求、アーキテクチャの概要について述べた。本章では、現在普及しているミリ波レーダより高いレベルの ADAS, AD における要求の詳細を整理する。その上で、ミリ波レーダの重要課題である検出距離の遠距離化と方位推定精度の向上のためのアンテナ面積増大を解決する実装技術について検討する。本研究では、アンテナ効率の高いホーンレンズアンテナとその実装柔軟性を活用して、RF フロントエンドと筐体全体を含めた高効率実装技術について述べ、試作した LRR の特性について議論する。

2.2. RF フロントエンドの高密度実装技術

本節では現行世代における自動運転レベル 2 までに対応した LRR に対して、次世代におけるレベル 3 以上の LRR への要求性能と、それを実現するためのレーダモジュールのハードウェア実装技術について述べる。

レベル 3 以上の自動運転における LRR では、運転の安全性を更に向上させるために前方の車両や歩行者の検知だけでなく、路上の落下物や道路標識などの高さ情報の検出、物体の大きさの検出など、フリースペース検出をサポートする機能や、高速走行を想定した 300 m 以上の超長距離検出なども要求される。落下物の検出に関して具体例を挙げると、100 m 先に高さ 50 cm 程度の落下物がある場合、路面と分離して検出するには高さ方向の分解能 0.3 度以下が必要となる。また、走行時に設定できる自動運転の最高速度はブレーキ時の制動距離の関係上、最大検出距離に依存するため、現行世代の最大検出距離 200 m 程度に対して 300 m 以上の検出距離（晴天時）の実現が求められている。

これらの機能を実現する LRR のハードウェア構成としては、検出物体の位置を高さ情報も含めて認識するためにアンテナを 2 次元アレイ状に配置（垂直、水平方向それぞれに複数のアンテナを配置）する必要がある。また、垂直・水平方向の位置情報を正確に検出するためには前章で述べた通りアンテナ数の増加と、受信信号の SNR を向上させるためにアンテナ面積を増加させる必要がある。アンテナ数を物理的に増やすのはレーダモジュールのサイズとコスト増加につながるために、アンテナ数を仮想的に増加させる MIMO (Multi-Input Multi-Output) 技術や、方位推定精度を向上させるための信号処理技術が古くから開発され

ている[2-1]-[2-7]。しかし、いずれにしてもレベル 3 以上の LRR に対する要求を満たすには、ベースとなるハードウェア性能の向上が必要で、アンテナサイズと数を現行世代のものよりも増加させる必要がある。

次に、レベル 3 以上の LRR のハードウェア構成について、現行世代の LRR と比較しながら説明する。図 2.1(a)に現行世代の ADAS 向け LRR の構造の一例を示す。上側が電波を放射する方向であり、LRR においては車両の進行方向に相当する。一般的に 2 枚のプリント基板(PCB)から構成されていることが多く、RF フロントエンドは電波を放射するアンテナや信号を伝達する高周波伝送線路 (MSL) を含むため、上側の PCB1 に実装される。PCB1 の基板材料は送受信信号の損失をなるべく抑制するために、77 GHz の高周波帯域で低損失となるものを用いる必要があるが、FR4 等の汎用基板材料に比べて高コストである。また、PCB1 においてはアンテナと MSL は PCB1 の上面側に、MMIC はアンテナや MSL との相互干渉を抑制するために PCB1 の裏面に実装されることが多い。一方で、レーダ信号処理を行なう演算デバイスである MCU (Micro Control Unit)、電源 IC、インタフェース (I/F) コネクタは、FR4 などの低コスト材料を使用した PCB2 に実装される。この構成では 2 枚のプリント基板を用いるために高さ方向に厚みが増大する。また、アンテナ面はレドーム (カバー) との結合によるインピーダンス不整合を回避するために、数 mm 程度の距離を確保しなければならないため、モジュールの厚みとしては 30 mm 程度のものが一般的である。

次に、次世代の高性能向け LRR の構造を図 2.1 (b)に示す。図 1.7 でも述べた通り、LRR




図 2.1 LRR におけるハードウェア構成の例

の方位推定性能を高めるためにアンテナ数が多くなる。これによってモジュールの厚みは図 2.1(a)と同じ約 30 mm程度であるものの縦横のサイズが大きくなる。また、アンテナと接続される MMIC の数も増加することや、MMIC で受信したデータ量が増加することによる演算デバイス(MCU)の高性能化、およびこれらの半導体デバイスを駆動するための電源 IC も大容量化することが想定される。

これに対して図 2.1(c)のように PCB を 1 枚構成にすることで基板間を接続するコネクタが不要となることで、基板のコストや基板間の接続信頼性の観点で有利となるハードウェア構成も考えられる。この構成では PCB 上面はアンテナ面積に加えて MMIC や MSL, 周辺部品の面積が増えることになるため、縦横のサイズが図 2.1(b)よりも大きくなり、結果としてモジュール面積が大型化することが懸念される。この構成は MRR で採用されており、LRR ほど方位分解能や最大検出距離が要求されないために RF フロントエンドの面積がもともと小さいために成立することによるものである。

以上で述べたハードウェア構成ごとの特徴を表 2.1 にまとめた。本研究では、図 2.1(b)と(c)の構成における短所・課題を解決するために、ホーンレンズアンテナを効率良く実装することで、LRR モジュールの厚みを現行の 30 mmに保ちつつ、縦と横のサイズをコンパクトにして、プリント基板を 1 枚にすることでコストダウンや信頼性担保をねらう方針とした。

ホーンレンズアンテナの概要については、過去の論文[1-24]-[1-26]に詳述されているため、ここではその構造と原理を簡単に説明する。ホーンレンズアンテナは高周波基板上に配置された 1 パッチアンテナと、逆ピラミッド型のホーン、誘電体レンズから構成される。図 2.2(a)は 1 パッチアンテナ周辺の上面図であり、1 パッチアンテナ（縦横サイズ： $W_A \times L_A$ ）と、その周辺に基準 GND のパターン（GND の内側のサイズ： $W_G \times L_G$ ）を配置され、この基準 GND に対して、ホーンアンテナの入力開口部（縦横サイズ： $W_i \times L_i$ ）が接続される。1 パッチアンテナの形状は MSL との特性インピーダンスと整合を取って反射損失を低減するために、一部でスリットを入れて設計される。図の形状のパッチアンテナでは、上下方向（垂

表 2.1 LRR の構造ごとのハードウェア構成・サイズの特徴

	図2.1(b)	図2.1(c)	提案
アンテナ構造	平面アンテナ	平面アンテナ	ホーンレンズアンテナ
基板枚数	2枚	1枚	1枚
モジュール高さ(厚み)	30 mm程度	15 mm程度	30 mm程度
モジュール面積(縦横サイズ)	10×10 cm ² 程度	15×15 cm ² 程度	10×10 cm ² 程度
長所・利点	縦横サイズが比較的コンパクト	1枚基板のためコネクタ接続が無く信頼性が高、薄型化	縦横サイズをコンパクトに抑えつつ1枚基板で信頼性が高
短所・課題	コネクタ接続の信頼性 部品点数増加, コスト増加	縦横サイズが増加, 大型化	ホーンレンズアンテナを含めた RFフロントエンドの高密度実装




図 2.2 ホーンレンズアンテナの構成

直方向) の電気長が 77 GHz の半波長となるよう設計され、この方向で電界が振れるモード (垂直偏波) で共振が起こることで効率良く電波を放射する構造となっている。垂直偏波で電波を送受信するため、送受いずれのアンテナともに同じ方向でパッチアンテナを配置する必要がある。図 2.2 (b) はホーンアンテナ全体の上面図であり、ホーンの出人口部 (サイズ: $W_o \times L_o$) の面積がアンテナ利得を決定するパラメータの一つとなる。この開口部に対して図 2.2 (c)(d) の側面図に示すように、誘電体レンズを組込むことで 1 パッチアンテナから球面状に放射される電波を平面波に変換する。レンズの内側の形状は、1 パッチアンテナ部を焦点距離とするように曲率を設計することで、ホーンレンズアンテナの放射特性をある程度任意に設計することが出来る。図の例では垂直方向にのみ曲率を指定しているために垂直方向の放射特性は狭く絞られ、水平方向は広く電波が広がる構成となっている。

以上がホーンレンズアンテナのハードウェア的な構成であり、次に電気的な特性について述べる。ホーンレンズアンテナはシリーズフェッドアンテナ等のようにプリント基板上

に配線される一般的な平面型アンテナ[2-9]-[2-14]よりも誘電体損失やアンテナ間カップリングが小さくなる。そのため、放射効率（アンテナ利得）とチャネル間アイソレーション特性が良好となる特徴がある。47×19 mmのシリーズフェッドアンテナ（図 2.3(a)）と開口部が45×18 mmのホーンレンズアンテナ（図 2.3(b)）を試作し、その放射特性を評価した結果を図 2.3 (c)と表 2.2 に示す。ホーンレンズアンテナにおける開口面積の方が狭いにもかかわらずアンテナ利得は 1.2 dB 良好であり、これを下記で示すアンテナ効率 η で比較すると、ホーンレンズアンテナはシリーズフェッドアンテナの約 1.6 倍となることが分かる。

$$\eta = \frac{4\pi G_A}{S_A \lambda^2} \quad (2.1)$$

ここで、 G_A はアンテナ利得、 S_A はアンテナ開口面積である。従って、シリーズフェッドアンテナと同等の性能を得るためのホーンレンズアンテナの開口面積は約 60 %で実現できることとなる。




図 2.3 平面アンテナとホーンレンズアンテナの特性比較結果

表 2.2 アンテナ構造と性能比較結果

アンテナ方式	アンテナ利得	アンテナ開口面積	アンテナ効率
ホーンレンズ	23.5 dBi	18x45 mm ²	32.3 %
シリーズフェッド	22.3 dBi	19x47 mm ²	19.4 %

以下では、これまでに述べた特徴を持つホーンレンズアンテナを適用したときの RF フロントエンドの面積と、本研究で提案する高効率実装技術について説明する。アンテナ、RF フロントエンド、PCB の面積は以下の通りである。

$$A_{\text{ANT}} = n(A_{\text{ANT_EFF}} + A_{\text{ANT_GAP}}) \quad (2.2)$$

$$A_{\text{RF}} = nA_{\text{ANT}} + mA_{\text{Part}} \quad (2.3)$$

$$A_{\text{PCB}} = A_{\text{RF}} + A_{\text{other}} \quad (2.4)$$

ここで n はアンテナ数、 m は MMIC の数、 $A_{\text{ANT_EFF}}$ はアンテナの実効面積、 $A_{\text{ANT_GAP}}$ は各アンテナ間のギャップの面積である。 A_{Part} は MMIC、MSL、および MMIC を動作させるための周辺部品(抵抗、コンデンサ、水晶振動子など)の実装に必要な面積である。 A_{other} はプリント基板を筐体に固定するためのネジの領域、GND パターン、I/F コネクタの領域等を合算した面積である。図 2.4(a)(b)に示すアンテナ配置は、各アンテナとのアイソレーションを確保するための $A_{\text{ANT_GAP}}$ を設けている[2-15][2-16]。一方で、ホーンアンテナの給電点となる 1 パッチアンテナは周辺が導電体であるホーンで空間的に遮断されているために、隣接するチャンネルとのアイソレーション特性が高い。また、ホーンの出カ開口部においても PCB 基板上のような電磁カップリングは起こりにくいことから、平面アンテナよりもアイソレーション特性が高い特性がある。本研究ではこれらの特徴に注目し、第一のアンテナ実装技術として図 2.4(c)に示す隙間の無いゼロギャップのアンテナ配置 $A_{\text{ANT_GAP}} = 0$ を提案する。これにより、平面アンテナで RF フロントエンドを構成するよりもアンテナ間に設けたギャップの分だけ面積小型化が可能となる。更に、RF フロントエンドの周辺部品や基板端とのギャップも不要となる効果が期待出来る。

本研究で提案する第二のアンテナ実装技術として、ホーンレンズアンテナの入カ開口部から出力開口部にかけてテーパ状に面積が増加する構造(四角錐を逆さにした構造)のため、これを複数並べることによって、入力開口部側(基板側)に空間的なスペースが出来る。これを利用して、ホーンレンズアンテナの出力開口部を図 2.4 (d)のように各構成要素(MMIC、MSL 等)とオーバーラップするように配置する。従って、PCB 上のアンテナ面積 A_{ANT} は $A_{\text{ANT_HO}} (W_o \times L_o)$ から、 $A_{\text{ANT_HI}} (W_i \times L_i)$ に削減することが出来、RF フロントエンドの面積 A_{RF} は次のように表される。

$$A_{\text{RF}} = \begin{cases} nA_{\text{ANT_HO}} & (nA_{\text{ANT_HO}} > nA_{\text{ANT_HI}} + mA_{\text{Part}}) \\ nA_{\text{ANT_HI}} + mA_{\text{Part}} & (\text{otherwise}) \end{cases} \quad (2.5)$$

次に、ホーンレンズアンテナを用いた高密度実装技術の効果について説明する。議論を簡略化するために、アンテナ面積は先行研究[1-26]で用いられた値を前提とした。それぞれの

パラメータは、ホーンの出力開口面積 $W_o \times L_o = 22 \times 9 \text{ mm}^2$ ，入力開口面積 $W_i \times L_i = 2 \times 4 \text{ mm}^2$ ，チャンネルごとのMSLの面積は $5 \times 10 \text{ mm}^2$ である。MMICの面積は $10 \times 10 \text{ mm}^2$ ，周辺部品の面積は $20 \times 10 \text{ mm}^2$ である。1つのMMICは3つの送信チャンネルと4つの受信チャンネルを持つ構成が一般的であるので，例えば8つの受信チャンネルが必要な場合は2つのMMICが必要となる。図 2.5 は，上記の仮定と式(2.4)(2.5)を用いて各アンテナ方式におけるPCB面積を見積もった結果である。




図 2.4 3Tx4Rx のアンテナ，MSL，MMIC および周辺部品の実装パタンの例





図 2.5 MMIC ごとの RF フロントエンドの面積

表 2.3 RF フロントエンドの面積算出結果 (3Tx 4Rx)

Item	Unit	シリーズフェッドアンテナ	ホーンレンズアンテナ [本研究]
$A_{\text{ANT_EFF}}$	mm^2	330.7×7	198×7
A_{gap}	mm^2	66.1×7	0
A_{part}	mm^2	650	650
A_{RF}	mm^2	3423	1386

更に、シリーズフェッドアンテナを用いた RF フロントエンドの面積 A_{RF} も、式(2.2)(2.3)を用いて表 2.3 のように見積もった。RF フロントエンドの面積 A_{RF} に関するパラメータの値は次のように決定した。 $A_{\text{ANT_EFF}}$ は $22 \times 9 \times 1.67 = 330.7 \text{ mm}^2$ であり、これは先ほど述べた通りシリーズフェッドアンテナの開口効率がホーンレンズアンテナの 60 % (同じ利得を得るには 1.67 倍の面積が必要) であることが反映されている。実際の平面アンテナの面積と利得の関係は、面積を増やすほどに基板の誘電体損失による影響を受けるためにリニアな関係になることはないが、今回の面積見積もりではこの仮定で議論を進める。また、アンテナ間ギャップ $A_{\text{ANT_GAP}}$ の 66.1 mm^2 は、 $A_{\text{ANT_EFF}}$ の 0.2 倍であると仮定した値であり、これらが送受合計 7 チャンネル分の面積を要することとなる。

MMIC1 個の場合、高密度実装技術を適用したホーンレンズアンテナの場合は、シリーズフェッドアンテナと比較して、RF フロントエンド A_{RF} の面積が 46.8 %削減されることとなる。ADAS/AD 向けのより高性能な LRR では SNR を向上させるために、MMIC の数は 2~4 個、すなわちアンテナの数は 8~10 個以上にまで増加すると予想される。このとき、本技術



(a) シリーズフェッドアンテナ (b) ホーンレンズアンテナ(上面, 側面図)

図 2.6 各アンテナのシミュレーションモデル(アンテナ 2 個の場合)




図 2.7 アンテナ間ギャップごとのチャネル間アイソレーションのシミュレーション結果

を用いることにより、アンテナ面積の増加を抑制することが可能な見通しが得られた。

最後に、ANSYS 社の HFSS™を用いた電磁界シミュレーションにより、ギャップとアイソレーションの関係を計算した。図 2.6 に示すアンテナの 3D モデルの物理特性パラメータは先行研究[1-26]を参考にし、隣接アンテナとのギャップ g は 0 mm から 2 mm の間で感度解析を行なった。図 2.7 のシミュレーション結果では、シリーズフェッドアンテナのアイソレーション特性は、アンテナ間のギャップを大きくすることで改善されるが、一般的なレーダで要求される 30 dB のアイソレーションを得るためには 1.5 mm のギャップが必要となるために、RF フロントエンドの面積へのインパクトが大きくなる。

一方、ホーンレンズアンテナのアイソレーション特性はギャップに関係なく 40 dB 以上となることが確認でき、シリーズフェッドアンテナよりも良好な特性であることが分かる。また、図 2.4(d)に示すように縦横に送信-受信、受信-受信の各アンテナが隣接している構成においても同等のアイソレーション特性が得られることを確認した。

以上で述べたように、本検討で提案した 2 つの高密度実装技術を適用したホーンレンズアンテナは、アンテナ数とアンテナ面積が増大する高レベル自動運転向けの LRR モジュールとして、従来の平面アンテナよりも高性能化と小型化の両立に適したアンテナ方式の一つであると言える。

2.3. プロトタイプ LRR の試作

本節ではホーンレンズアンテナを適用したプロトタイプ LRR の設計について述べる。表 2.4 は試作したレーダの目標性能である。アンテナ利得は前方 300 m の車両（10 dBsm を想定）を検知できる性能とし、FoV は水平・垂直それぞれ 18 度、5 度とした。また、水平・垂直方向の角度推定誤差は、300 m 先の車両が自車線か隣車線かを判定するために ± 1.5 m の精度を目標として ± 0.3 度とした。目標とするアンテナ利得については、使用する MMIC の雑音特性や PCB の誘電体損失、採用する信号処理アルゴリズムや変調設定など様々なパラメータで許容される値が変わるが、本研究ではこれまでの経験上 200 m の検知に必要な送信・受信アンテナ利得の合計値はおおよそ 34 dBi であったことをベースに考えることとし、式(2.1)のレーダ方程式を用いて 300 m の検知に必要なアンテナ利得（送信アンテナと受信アンテナ利得の合計値）を 41 dBi と設定した。今回の試作で最も重視したポイントはモジュールサイズであり、表 2.4 の性能を実現するための必要最小限の構成とした。また、Tx アンテナは 1 チャンネルとし、Rx アンテナは 2×2 のアレイ状に 4 チャンネルを配置することで水平・垂直方向の角度推定を実現する構成とした。

表 2.4 プロトタイプ LRR の目標性能

項目	目標性能
最大検出距離（車両 10 dBsm を想定）	> 300 m
到来方向推定誤差	< ± 0.3 deg
水平方向 FoV	> 18 deg
垂直方向 FoV	> 5 deg
モジュールサイズ（コネクタを含まず）	$40 \times 60 \times 30$ mm ³
送信・受信アンテナ数	1 Tx, 4 Rx
送受アンテナ利得（Gt + Gr）	> 41 dBi

図 2.8 に試作した LRR のアーキテクチャを示す。変調信号を生成する PLL (Phase Locked Loop) 回路とトランシーバ回路, ADC (Analog Digital Converter) 回路を備えた 1 チップの MMIC と, MMIC を制御する機能と受信信号を信号処理する機能を備えた MCU, およびこれらの IC を駆動する電源, 外部へのデータ出力やデバッグのための I/F コネクタを備えている。今回使用した MMIC の Tx と Rx は差動出力のために, PCB 上で Rx アンテナと MMIC の間で差動-シングル変換のバランを実装している。また, 詳細は後述するが, Tx アンテナは利得向上のために開口面積を大きくする必要があるが, 焦点距離の関係からレンズが厚くなりすぎてしまい製造時の信頼性が担保できない課題があるために, 差動のアンテナで 2 つに分割することで実装上の課題を解決している[1-26]。これらアンテナと伝送路, MMIC




図 2.8 プロトタイプ LRR のアーキテクチャ (1 Tx & 4 Rx)

とその周辺部品は PCB 上面側に実装され、MCU や電源、通信系のドライバは PCB 裏側に実装される。本研究で用いた MMIC における変調方式は図 2.9 に示すファストチャープ変調（FCM : Fast Chirp Modulation）に対応しており、本研究で設定した変調パラメータを表 2.5 に示す。50 μs オーダの超短時間に 76.5 GHz を中心に 500MHz 程度的高速変調を行なった信号を生成する。この 1 変調信号を「チャープ」と呼び、1 フレームで 128 回のチャープを繰り返して送信する。変調帯域が広いほどに距離の分解能が向上するが、変調の線形リニアリティすなわち SNR とのトレードオフとなることと、LRR では遠方の距離分解能は重視されないことから、今回は 512 MHz（距離分解能：50cm）で設定している。

次に、ホーンレンズアンテナの設計について述べる。アンテナの開口面積は次のように表せる：




図 2.9 ファストチャープ変調における各パラメータの定義

表 2.5 プロトタイプ LRR の変調条件設定値

項目	性能
変調方式	ファストチャープ変調方式
変調周波数(中心)	76.5 GHz
実効変調帯域	512 MHz
チャープあたりのサンプリング数	1024 sample/chirp
1 フレームあたりのチャープ数	128 chirp
サンプリングレート	20 Msample/sec
チャープ周期	60 μs
フレームレート	50 msec

$$A_{\text{ANT}} = L_o \times W_o = \frac{G\lambda^2}{4\pi\eta} \quad (2.6)$$

ここで、 η は開口効率、 G はアンテナ利得である。前節でも述べた通り、ホーンレンズアンテナの η は 32.3 % で (表 2.2), $G_t + G_r$ を 41dB 以上とするために送信と受信のホーンアンテナにおける開口サイズはそれぞれ $44 \times 18 \text{ mm}^2$ と $22 \times 9 \text{ mm}^2$ とした。また、入力側 (PCB との接続面) のサイズ $L_i \times W_i$ は $2 \times 4 \text{ mm}^2$ とした。更に、モジュールの厚み 30 mm に対してホーンアンテナの高さを 15 mm 以下にするには焦点距離の関係からレンズの設計が出来ないために、送信アンテナを $22 \times 18 \text{ mm}^2$ のサイズに 2 等分して、それぞれのアンテナに対して MMIC の差動出力端子を接続する低背化技術[1-26]を用いた。各受信チャンネルにおける 1 パッチアンテナは、バランを介して MMIC の差動入力端子に接続される。1 パッチアンテナの大きさ $L_A \times W_A$ と GND パタンの面積 $L_G \times W_G$ はそれぞれ $1.06 \times 1.38 \text{ mm}^2$, $1.5 \times 3 \text{ mm}^2$ とした。レンズの直径は 22 mm, 焦点距離は 16 mm である。ホーンアンテナとレンズにおける材料はそれぞれアルミニウムと PPS (polyphenylene sulfide) を用いた。PPS の誘電率は 4.2, $\tan\delta$ は 0.01 とした。

試作したレーダの全体構成を図 2.10 に示す。(a)はレンズ, (b)はモジュール筐体つきホーン, (c)は PCB 上面, (d)は PCB 下, (e)は LRR の斜視図である。PCB のサイズは $37 \times 51.2 \text{ mm}^2$




図 2.10 プロトタイプ LRR の構成

表 2.6 RF フロントエンド各領域における実装面積

項目	単位	値
チャンネル構成	--	1Tx, 4Rx (2×2 array)
アンテナ面積	mm ²	PCB: 288, horn: 1584
周辺部品面積	mm ²	564
他面積 (固定用ネジ,コネクタ,等.)	mm ²	1042
PCB 全体面積	mm ²	1894

で、上面には MMIC, MSL, 1 パッチアンテナ, 周辺部品, ネジ, I/F コネクタが実装されている。下面側には, MCU, 電源 IC とその他周辺部品が実装される。PCB の上面側の層は, ミリ波帯で低損失な材料である Rogers RO3003 を用いている。77 GHz における誘電率は 3.2, $\tan\delta$ は 0.004 とした。

最後に, RF フロントエンドの実装結果について述べる。ホーンレンズアンテナの特性を生かしつつコンパクトに実装するために, 図 2.10 (b)のように送信と受信アンテナ間のギャップ, および受信と受信アンテナ間のギャップをゼロにして配置した。また, ホーンレンズアンテナの開口部が完全に PCB の上面にオーバーラップしており, 図 2.10 (c)に示すように, RF フロントエンドの各要素がホーンの谷間に無駄なく配置出来ており, 狙い通りに効率的に実装出来ていることも確認できる。表 2.6 に各部品の実装面積を示す。以上で説明した通り, ホーンレンズアンテナに対して本研究の高効率実装技術を適用することで, LRR の小型化に貢献出来ていると言える。次に, 試作した LRR の基本的な検出性能を評価する。

2.4. プロトタイプ LRR の評価結果

本節では試作した LRR の基本性能評価結果について述べる。まずはアンテナの基本的な特性を評価するための測定系を図 2.11 に示すように構築した。LRR から 10 m の距離に 20 dBsm のリフレクタを設置し, LRR を動作させたときの受信信号データを信号処理する。信





図 2.11 LRR の基本性能測定系

号処理は各受信チャンネルの信号をFFT処理することにより10mの距離における反射信号電力を算出し、この信号電力値を用いて式(2.1)のレーダ方程式から送受合計のアンテナ利得を間接的に求めた。アンテナ特性の角度依存性を評価するために、回転台を制御してLRRを1度ずつ回転させて行ない、垂直特性を測定する際にはLRRを90度回転させてアンテナ利得の評価を行なった。水平、垂直方向の送受信(2-way)のアンテナ利得評価結果を図2.12に示す。送受信アンテナ利得の最大値は43.7dBiであり、電力半値幅は水平方向が18度、垂直方向が5度であった。試作したLRRのアンテナ特性は表2.4に示した目標性能を満足することを確認した。

次に、到来方向推定精度の評価結果について述べる。到来方向 θ は図2.13に示すように、2チャンネルの受信信号の位相差 φ から以下の式で推定するモノパルス方式で算出した。



©IEICE [2-18]

図 2.12 試作 LRR の 2-way アンテナ利得特性測定結果






図 2.13 レーダにおける角度推定方式

$$\theta = \arcsin\left(\frac{\lambda\varphi}{2\pi d}\right) \quad (2.7)$$

図 2.14 (a)(b)に水平, 垂直方向の到来方向推定結果を示す。推定誤差は ± 0.2 度以下であり, チャンネルごとの配線長や信号強度ばらつき, RF フロントエンドのアイソレーション特性など, 到来方向推定に影響を与える要素は無視できるほど小さいことが確認できた。更に, 各測定を 3 回行ったときのばらつきは ± 0.03 度以下であり, 今回実施した測定系における再現



(a) 水平方向の到来方向推定精度



(b) 垂直方向の到来方向推定精度

©IEICE]

図 2.14 試作 LRR のアンテナ特性測定結果

性を確認できた。以上の結果より、ホーンレンズアンテナを用いたプロトタイプ LRR の基本的なアンテナ性能および RF フロントエンドの実装結果は、表 2.4 に示すハイエンド向け ADAS/AD に適した性能であることを確認した。

次に、試作した LRR を車両に実装して走行中の車両に対する検出性能について評価を行った。図 2.15 は試作した LRR を車両のフロントバンパに取り付けた写真である。今回は LRR を安定して取り付けるために、実験用車両に対して追加で固定用フレームを取り付けてある。評価条件は図 2.16 に示すように、レーダを実装した車両を時速 20 km で直進させ、ターゲット車両を時速 50 km で直進させた。評価は 500 m 以上の直線が確保できるテストコース(この速度で 30 秒以上直線が続く環境)で行なった。また、ターゲット車両と観測車両の相対的な位置（レーダの正解値）は GPS で RTK(Real Time Kinematic)方式により ± 5 cm 以内の精度で計測している。測定ばらつきを確認するため、同じ測定を 3 回繰り返した。これは、実験を重ねるごとにターゲット車両と観測車両の位置関係や相対的な姿勢がドリフトする可能性があるためである。




図 2.15 試作 LRR を車両のバンパ内に実装した写真





図 2.16 試作 LRR の検出性能評価系

以上で述べた実験条件で検出性能を評価した結果を図 2.17 に示す。横軸は実験開始からの経過時間であり、縦軸は(a)が前方距離 YR, (b)が水平距離 XR, (c)が高さを示す。検出性能について図 2.17(a)を用いて説明する。表 2.5 に示した変調条件では 300 m を超える距離ではアンビギュイティ（折り返し）が発生するため、34 秒付近で検出限界を超えてしまっているが、それを考慮すると 320 m までは目標車両を見失うことなく検出出来ていることが確認できる。図 2.17 (b), (c)に示す到来方向推定精度は、いずれも車両幅 2.0 m や車両高さ 1.5 m の範囲内ではばらついているのみで、それを逸脱する推定結果は出ていないことか




©IEICE[2-18]


図 2.17 車両に実装したプロトタイプ LRR の検出性能評価結果

ら、十分に高精度に検出出来ていると言える。図 2.18 は DoA 推定結果（図 2.17 (b), (c)）と GPS 検出位置との差を示している。測定結果に示すように、100 m までは水平方向の DoA 推定誤差が 0.5 度以上となっている。これは先ほども述べた通りターゲット車両の幅が 2 m 程度あるためで、100 m において ± 0.5 度に相当するためと考えられる。また、車両からの反射は図 2.11 の測定系で用いたリフレクタのように、理想的な点反射ではなく凹凸面からの反射であるために、ターゲット車両との位置関係や車両の傾きによって最大反射点の位置が変化するため、結果がばらついたと考えられる。280 m 以上では車両の幅が ± 0.2 度以下となり、測定結果のばらつきは車幅程度に収まっており、表 2.4 の目標 DoA 推定誤差性能を満足することを確認した。

最後に、試作した LRR における小型化の効果について、市場投入されている LRR と比較



(a) Horizontal direction



(b) Vertical direction

©IEICE[2-18]

図 2.18 ターゲット車両に対する DoA 推定誤差の評価結果

して評価する。表 2.7 は LRR の基本性能とハードウェア仕様をまとめたものである。LRR ごとに性能・機能が異なるために、単純かつ公平に比較することはできない。例えば、試作した LRR はモノパルスの角度推定方式を採用しているために、同距離で角度が異なる複数の物体を分離して検出することが出来ない。一方で、最小構成で 300 m 以上の検出距離を達成し、 ± 0.2 度以内の DoA 推定精度を持つことは特筆すべき結果と言える。これは、2.2 節で述べたように、より高性能な LRR を実現するためには、2~4 個の MMIC と 10 本以上のアンテナが必要になることと強く関係する。例えば、MMIC とアンテナの数を試作 LRR の 4 倍にしてモジュールサイズも 4 倍にすると体積は 324 cm^3 となるが、これは現行世代の高性能 LRR と同等の体積相当となる。従って、アンテナ面積が大きく、アンテナ数が増えることが予想される次世代の高性能 LRR において、ホーンレンズアンテナを使用し、本論で述べた高効率高密度実装を適用することが小型化を両立するための最適な対策の一つであると言える。

表 2.7 LRR における基本性能のベンチマーク

Item	Bosch LRR4 [2-17]	Continental ARS4 [2-17]	本研究試作 LRR
最大検出距離	250 m	250 m	320 m
モジュール寸法	$78 \times 81 \times 62 \text{ mm}^3$	$137 \times 91 \times 31 \text{ mm}^3$	$45 \times 60 \times 30 \text{ mm}^3$
モジュール体積	391.7 cm^3	386.5 cm^3	81 cm^3
PCB の数	2	2	1
角度推定精度	0.3 deg	0.1 deg	0.2 deg *
角度推定分離分解能	4 deg	1.6 deg	--- *

* モノパルス方式で角度推定

2.5. 結言

本章では、高度な ADAS/AD における LRR の性能向上と小型化の両立をめざして、RF フロントエンドの高密度実装について検討した。RF フロントエンドで最も面積へのインパクトが大きいアンテナ方式について、単位面積あたりの放射効率とアンテナ間のアイソレーション特性、および周辺部品実装との互換性が高いホーンレンズアンテナに着目した。本研究ではホーンレンズアンテナの実装について、2 つの高密度実装技術を提案し、これを適用したプロトタイプの LRR を試作、評価した。

1 つ目の技術はホーンレンズアンテナの高いアイソレーション特性を利用して、送信と受信アンテナおよび、受信と受信アンテナ間のギャップをゼロにする実装方法を提案した。これにより従来の平面アンテナよりも面積利用効率が向上する効果が得られた。もう一つの

技術は、ホーンレンズアンテナの領域を MSL, MMIC, および周辺部品の領域と重なるように配置する方法を提案した。これにより、複数の MMIC を使用する次世代の LRR で課題となる部品実装部とアンテナ部の面積をオーバーラップさせ、効率的な実装を可能とした。提案した実装技術を適用した LRR は、送信アンテナは 1 チャンネルでアンテナ面積は $44 \times 18 \text{ mm}^2$, 受信アンテナは 4 チャンネルで 2×2 のアレイ状に配置され、各アンテナの面積は $22 \times 9 \text{ mm}^2$, PCB のサイズは $37 \times 51.2 \text{ mm}^2$ で、レーダモジュールの体積は $45 \times 60 \times 30 \text{ mm}^3$ であり、市場投入されている LRR と比較すると最小サイズである。

LRR のレーダ基本特性を評価した結果、送受信アンテナ利得のアンテナビーム幅は水平 18 度、垂直 5 度、角度推定精度は ± 0.2 度となった。試作した LRR を車両に搭載し、先行車検知性能を評価した結果、最大検知距離は 320 m、角度推定精度は 100 m までは ± 0.5 度、280 m 以上で ± 0.2 度となることを確認した。上記の議論と測定結果は、より遠方の検出性能と、角度推定精度、および小さなモジュールサイズを実現するためのホーンレンズアンテナの高密度実装技術の有用性を示している。今後は、より高度な ADAS/AD を実現するため、アンテナ数を増やした LRR を試作し、検出性能を評価する予定である。

第3章 CNN の低電力実装に関する研究

3.1. 緒言

2章ではフロントセンシングのキーデバイスの一つである LRR の小型化と高性能化を両立するハードウェア実装技術について述べた。本章では、フロントセンシングだけでなく車載の周辺認識において汎用性の高いカメラの処理技術に注目し、カメラ画像を CNN で処理する際に課題となる消費電力を低減する技術について述べる。本研究では、消費電力低減のためにゼロスキップ法を更に効率化する技術を開発した。本章では、3.2 節で提案する高精度ゼロスキップ法とアクティブデータスキップ法のコンセプトとアーキテクチャについて述べる。3.3 節では FPGA 上に CNN を実装し、各手法における認識精度、消費電力、回路オーバーヘッドの評価を示す。最後に 3.4 節で本章の結論を述べる。

3.2. 提案する CNN の低消費電力実装技術

本節ではまず、CNN における消費電力を低減するためのゼロスキップ機能の実装について説明する。この技術を実装する方法の一つとして、クロックゲーティングを使用して演算回路の動作を停止させることが挙げられる。クロックゲーティングによるゼロスキップを用いた回路構成を図 3.1 に示す。図 1.8 で説明した CNN への入力データ D_n と重み W_m のビット幅を K ビットとしたとき、記憶装置から読み出された入力データと重みは、 K ビット NOR 回路によってゼロか否かが判定される。本論文では、NOR 回路のようなクロックゲーティングに関連する判定ロジックを GL (Gating Logic) 回路と呼ぶこととする。 n 番目の入力データ D_n に対する GL 回路を GL_{dn} 、 m 番目の重み W_m に対する GL 回路を GL_{wm} とし、それらの出力をそれぞれ Z_{dn} 、 Z_{wm} とする。 Z_{dn} と Z_{wm} の条件式は次の通りである。

$$Z_{dn} = \begin{cases} \text{true} : D_n = 0 \\ \text{false} : D_n \neq 0 \end{cases} \quad (3.1)$$

$$Z_{wm} = \begin{cases} \text{true} : W_m = 0 \\ \text{false} : W_m \neq 0 \end{cases} \quad (3.2)$$

Z_{dn} と Z_{wm} の NOR 回路が全ての積和演算器 (MAC : Multiply ACcumulate) 単位で True にな




図 3.1 MAC 演算回路向けゼロスキップを用いたクロックゲーティング回路の構成

ると、積和演算器へのクロック供給を停止する。 q 番目の MAC 演算のクロック供給を決定する論理回路は GL_{Mq} で表される。 GL_{Mq} の判定式は次の通りである。

$$Z_{Mq} = (Z_{d(n+1)} \text{ OR } Z_{w1}) \text{ AND } (Z_{d(n+2)} \text{ OR } Z_{w2}) \text{ AND } \dots \text{ AND } (Z_{d(n+F)} \text{ OR } Z_{wF}) \quad (3.3)$$

この構成により、積和演算器の FF (Flip-Flop) 回路のクロック遷移と、データと重みの信号遷移が起こらなくなることから、消費電力を削減することが出来る。ただし、この構成でゼロスキップ技術を使用する場合は、(1)MAC 演算の停止が頻繁に起こらない (電力削減の効果が低い)、(2)GL 回路のオーバーヘッドが大きい (演算リソース・消費電力の増加)、という課題が生じる。

GL 回路は各入力データと重みデータに対する K ビットの NOR 回路、各乗算器に対する

2 ビットの OR 回路，各加算器に対する F ビットの AND 回路で構成される。 F は図 1.8 に示すフィルタサイズである。GL 回路はデバイスに実装可能な MAC 演算器の並列数に応じて規模が増大する。GL 回路を追加することによる積和演算の回路オーバーヘッドは 5 %程度となり，限られた回路リソースで高効率な実装・設計をする上で非常に大きなインパクトとなる。MAC 演算器の並列数を P としたときの GL 回路の入力ビット数 (AND, OR など) は以下の式で表される。

$$\begin{aligned} B_{GL_{total}} &= P(B_{GL_d} + B_{GL_W} + B_{GL_M}) \\ &= P\{K + K + (2F + F)\} \\ &= P(2K + 3F) \end{aligned} \quad (3.4)$$

ここで， B_{GL_d} ， B_{GL_W} ， B_{GL_M} はそれぞれ， GL_{dn} ， GL_{wm} ， GL_{Mq} の入力ビット数であり， $B_{GL_{total}}$ は図 3.1 のゼロスキップ回路を適用したときの回路オーバーヘッドである。GL 回路を追加することは消費電力の削減と背反することから，更なる消費電力削減のためには積和演算の停止頻度を高めて，回路オーバーヘッドの小さいクロックゲーティング機構を実装する必要がある。

以下ではこの要求を満たすために，本研究で開発したゼロスキップ技術について実際の CNN を用いた AI モデルを例に説明する。検討に用いた AI モデルは，画像内に映っている物体を検出する SSD500 (Single shot multi-box detector 500) であり [3-1]，演算リソースに限られる ECU 等のエッジデバイスに実装するために，図 1.9 に示したブルーニング技術と 8 ビット量子化技術を適用して 88 %の演算を削減・圧縮した [3-2]-[3-4]。この圧縮済みモデルに対して本研究では，オープンソースのデータセットである Cityscape [3-5] の 3000 枚の学習画像を用いて学習したモデルを用いて検討した。

図 3.2 は Cityscape データセットの評価用画像 500 枚を SSD500 で処理したとき，SSD を構成する CNN の各層における入力データが 0 である比率を示したものである。「乗算器ごとの 0 の比率」は，各乗算器における入力データが 0 である比率であり，「MAC ごとの 0 の比率」は各積和演算器に対する入力データ (図 3.1 の $D_{n+1} \sim D_{n+F}$) が全てゼロとなる比率である。ゼロスキップでは，入力データと重みの乗算結果が全て 0 になった時点で積和演算を停止する。図 1.8 で説明したように，CNN の 1 層あたりの演算は，積和演算，バイアス加算，ReLU で構成され，このうち最後の ReLU は負の値を 0 に丸める処理であるために，出力が 0 となる確率が高くなる。しかし，図 3.2 に示すように，入力データあたりの 0 の割合が 50~60 % (青線) であるにもかかわらず，積和演算器の平均停止率は 30 % (赤線) に留まっていることが確認できる。このため従来のゼロスキップでは，積和演算が停止される頻度が入力データ 0 となる確率の割に低くなっている状況である。

一方，図 3.3 は SSD500 の各層の重みがゼロの比率を示したものであり，重みが 0 の比率

の平均はわずか 5 %程度であり（青線）、積和演算の入力重みが全て 0 になる組合せは無かった。これは、前述したモデルサイズの削減・圧縮技術を適用したことにより、計算されない（つまり値が 0 の）重みが優先的に削除されているためと考えられる。このことから、重みデータを用いたゼロスキップによる消費電力削減効果は、データを用いたものよりも効果・効率が低い傾向にあると言える。

従来のゼロスキップ方式では(3.3)式に示すように、データのゼロ判定結果 Z_{dn} と重みのゼロ判定結果 Z_{wm} のどちらか一方がゼロであることを監視するために、多くの OR 回路が必要となる。その一方で、この OR 回路を削除してデータのゼロ判定結果 Z_{dn} のみを使用した場




図 3.2 SSD500 における各層のゼロデータの割合 (Data set: 500 cityscape images)




図 3.3 SSD500 における各層のゼロ重みの割合(Training data set: 3,000 cityscape images)

合は図 3.3 の結果から、 F ビットの AND 回路への入力信号がゼロとなる確率はわずか 5 % 程度の影響しか出ないことが分かる。本研究で提案するゼロスキップの方針は、積和演算器単位で完全に停止させるのではなく、図 3.4 に示すようにデータゼロ判定 Z_{dn} のみを用いてデータがゼロとなるときに乗算器を停止させる。これにより乗算器の停止率を約 60 % まで高められることが期待できる。また、積和演算器後段の加算器はトーナメント式に構成し、これらの加算器を正確に停止させるために、1 段目の加算器単位で入力データが全てゼロの場合に停止する論理回路を配置した。1 段目の加算器を全て停止させれば、2 段目の加算器も停止させることが出来る。

以上のように入力データのみで演算停止を判断することで、重みのゼロ判定回路 GL_{wm} が削除可能となり GL_{Mq} の回路オーバーヘッドを削減した。また、これにより従来のゼロスキップよりも細かく演算器を停止させることが出来る。入力データがゼロの乗算器は全て停止




図 3.4 提案する MAC 演算向けゼロスキップの構成

され、加算器単位で入力データがゼロの場合は加算器も停止される。これらの技術を用いて CNN を実装することで、消費電力と回路オーバーヘッドを大幅に削減することが出来る。そのため、GL 回路の入力ビット数は以下ようになる。

$$\begin{aligned}
 B_{\text{GLtotal}} &= P(B_{\text{GLd}} + B_{\text{GLM}}) \\
 &= P\{K + (F + F)\} \\
 &= P(K + 2F)
 \end{aligned} \tag{3.4}$$

例えば、入力データのビット数 K が 8、フィルタサイズ F が 9 の場合、(3.3)式と(3.4)式により、GL 入力ビット数 B_{GLtotal} は、従来のゼロスキップでは $P \times (2 \times 8 + 3 \times 9) = 43P$ ビットであったのに対して提案の方式では $P \times (8 + 2 \times 9) = 26P$ ビットとなり、追加の回路オーバーヘッドを約 40 %削減できる。

更に消費電力を削減するために、認識精度に殆ど影響を与えないような小さい値のときにも演算を停止する方式を提案する。例えば入力データが 1 となる比率は図 3.5 の緑線に示す傾向となっており、平均で 10 %程度となっている。すなわち、入力データが 1 以下のときに演算を停止することで、ゼロスキップよりも更なる低消費電力化が期待できる。この構成を実現するために、図 3.6 に示すように K ビットの入力データの上位 k ビットのみを





図 3.5 SSD500 の各層の入力における 0,1 データの割合 (Data set: 500 cityscape images)



監視する論理回路を追加する。この構成を便宜上、アクティブデータスキップ手法と呼称する。これにより GL_{dn} 回路のオーバーヘッドと消費電力は、全ビットを監視する方式に比べて k/K に削減される。入力データが閾値 D_{th} 以下のときに乗算器は停止され、加算器単位での入力データが閾値 D_{th} 以下であればその加算器も停止する動作となる。 D_{th} は GL 回路追加のオーバーヘッドの観点から、以下のように定義される値であることが望ましい。

$$D_{th} = 2^{K-k} - 1 \quad (0 \leq k \leq K) \quad (3.5)$$

また、 D_{th} を設定した後、計算誤差の影響を緩和するために CNN モデルの再学習を行なうことが望ましいが、それでも計算誤差の影響が残留することが懸念される。この対応策として、図 3.5 に示したように、そもそも入力データ量が少なく 0 のデータが少ない層（例えば 11～21 層目）では、消費電力の削減効果が期待出来ないため、図 3.6 のようにゲーティング有効化判定の機能を追加し、 EN_{Layer} 信号によりクロックゲーティングを無効化する構成も考えられる。

以上で述べた 2 つの技術が本研究で提案するゼロスキップ方式である。1 つは積和演算器単位でのゼロスキップではなく、データだけに注目した乗算器単位のゼロスキップであり、もう一つが演算結果に対して影響が小さい値も含めてクロックゲーティングする方式となる。次節ではこれらの技術の実装について述べる。

3.3. 提案のゼロスキップ回路の実装

本節では CNN の実装条件と提案技術を用いた積和演算器の構成について述べる。本研究では CNN の演算処理を実装するエッジデバイスとして Xilinx 社の XU9 FPGA[3-6]を選択した。物体検出用 CNN モデルとして SSD500 を用い、ZU9 の回路リソースに実装するために畳込み演算の 88 %を削除した。また、入力データと重みを浮動小数点から 8 ビットの整数 ($K=8$)に量子化することで、計算量を 182 GOP から 22 GOP に圧縮した。モデルの学習には Cityscapes データセットから 3000 枚の画像を使用し、認識精度の評価には 500 枚のテスト画像を使用した。

図 3.7 に ZU9 に実装した SSD500 のアーキテクチャを示す。高速処理が要求される畳込み処理は PL (Programmable Logic) に実装し、入力データ、演算結果データ、重みデータを外部 RAM とやり取りするトランスミッタ (Tx) とレシーバ (Rx), 回路動作の管理のためのスケジューラもここに実装した。SSD500 が入力画像の物体位置を推論して出力する情報




図 3.7 本研究の検討用に FPGA に SSD500 を実装した構成

(bbox : bounding box) は、PS 部の CPU で処理される。CNN は大規模な演算であるために、全ての畳込み演算回路を PL 部に実装することはできない。このため、積和演算器の並列数は 512 個とし、図 3.8 に示すように重みとバイアスのデータを層ごと、あるいはチャンネルごとに読み出し、画像データを 612 画素ごとに読み出すようにした。重みデータは 3×3 でストライドは 1 の例であるため、出力データは 512 データが出力されることとなる。図の赤枠部の処理が終わると次の領域の 612 画素を読み出す。このように入力データの範囲を選択的にスライドさせていくことで、画像全体の畳込み演算を所定の時間内に処理する構成としている。

ゲーティングロジックを含まずに ZU9 の PL 部に実装した SSD500 の DSP (Digital Signal Processor) と、LUT (Look up Table), FF の各回路使用率を表 3.1 に示す。DSP のほとんどは畳込み処理における乗算器に使用されていることが分かる。ZU9 の DSP には 2 つの乗算




図 3.8 畳込み回路におけるデータフロー

表 3.1 Xilinx ZU9 における PL 部の使用状況(ゲーティング回路は含まず)

回路カテゴリ	DSP	LUT	FF
制御回路*	0 (0%)	18354 (6.7%)	62801 (11.5%)
BRAM	0 (0%)	784 (0.3%)	5472 (1.0%)
畳込み演算回路	2304 (91%)	165223 (60.3%)	103905 (19.0%)
Blank (未使用)	216 (9%)	89719 (32.7%)	375982 (68.6%)

* 制御回路 : Tx, Rx, Scheduler

器が含まれていることから、2304 個の DSP には 4608 個の乗算器があり、これは 512 個の積和演算器に相当する。また、LUT や FF のリソース使用率はそれぞれ 67.3 %、31.4 %だが、このうち畳込み演算回路には両者とも約 90 %以上が割り当てられている。つまり、FPGA の消費電力の大半は畳込み演算が占めていることとなる。表 3.2 に示すように、畳込み演算の消費電力は 9.2 W（FPGA 全体の 54 %）であった。

図 3.9 は提案する GL 回路を積和演算器に実装した回路図の概要を示したものである。積和演算と FF の動作タイミングを合わせるために、GL にも FF を設置している。各回路のクロックゲーティングは、GL からの論理出力を用いて CB（Clock Buffer）を停止させる構成とした。ZU9 の動作クロック周波数は 300 MHz、フレームレートは 110 fps であり、SSD500 の処理速度は 2420 GOPs であった。畳込み回路の消費電力あたりの演算性能は 263.0 GOPS/W となる。

表 3.2 Xilinx ZU9 おける消費電力の詳細(ゲーティング回路は含まず)

回路カテゴリ		消費電力 [W]	割合 [%]
PL	制御回路*	1.8	10.7
	BRAM	2.8	16.5
	畳込み演算回路	9.2	54.4
PS		3.1	18.4
Total		16.9	---

* 制御回路 : Tx, Rx, Scheduler






図 3.9 提案のゲーティングロジック回路を適用した畳込み演算回路の構成

3.4. 提案のゼロスキップ手法の評価結果

図 3.10 にクロックゲーティングの対象となる入力データの閾値と消費電力，および認識精度との関係を示す。消費電力は ZU9 の評価ボード上の論理回路システムの電源電流を測定した結果である。論理回路における畳込み回路の消費電力の比率は，FPGA 設計ツール Vivado™を用いて算出し，測定した電流の 80 %を畳込み回路が占めるとした。例えば[3-7]と同等のゼロスキップ回路を適用した畳込み演算回路の消費電力は 6.4 W であり，2.8 W の



(a) 畳込み演算回路の消費電力測定結果



(b) 認識精度の性能劣化シミュレーション結果

図 3.10 ゲーティング閾値に対する消費電力および認識精度の関係




図 3.11 ゲーティング閾値と LUT 回路のオーバーヘッドの関係

電力削減効果が得られた。一方で，図 3.11 は GL 回路追加による回路オーバーヘッドを示しており，LUT は 8426 でありオーバーヘッドは 5.1 %であった。

提案したゼロスキップ方式において，入力データが 0 の時に乗算回路を細かく停止することで，図 3.10(a)の $D_{th} = 0$ に示すように畳込み演算回路の消費電力は 5.1 W に低減することが確認でき，従来のゼロスキップ方式よりも電力削減効果が高いことを確認した。また，図 3.11 に示すように回路オーバーヘッドは 2.9 %であり，従来の回路オーバーヘッドよりも 43.1 %削減できることを確認した。このように，データ閾値 $D_{th} = 0$ の設定でも従来のゼロスキップ方式に比べて消費電力と回路オーバーヘッドの低減に有効であることを確認した。

次に， $D_{th} \geq 0$ のアクティブデータスキップ方式を適用した結果について述べる。 D_{th} が 1 と 3 の場合，認識精度の劣化はそれぞれ 0.59 %と 2.91 %，畳込み計算回路の消費電力はそれぞれ 4.1 W と 3.6 W であり， D_{th} が大きいほどに消費電力削減効果が高く，認識精度劣化も大きくなることが確認出来る。この結果は全層の処理に対して $D_{th} \geq 0$ を満たすときにクロックゲーティングされるものであり，図 3.10 の①太線に相当する。次に，全層の 0 データのうち，②各層における 0 データの割合(R.Z. : Ratio of zero)が 5 %以上，③10 %以上の層，すなわち 1～7 層目，1～4 層目にそれぞれ本手法を適用した。 D_{th} が 1 で 1～4 層目に適用した場合の精度低下は 0.29 %，畳込み計算回路の消費電力は 4.4 W (-52.3 %)となった。更に，図 3.11 に示すように，従来のゼロスキップ回路を用いた場合と比較して回路オーバーヘッドを 2.7%に削減した。このときの畳込み回路の消費電力あたりの演算性能は 550.0 GOPS/W である。

以上から，今回用いた SSD モデルの条件においては， $D_{th} = 1$ で 1～4 層目に対してアクティブデータスキップ方式を適用し，それ以外の層には $D_{th} = 0$ とすることで精度低下を抑制しながら消費電力低減効果が得られることを確認した。

3.5. 結論

本章では、大規模な演算リソースが必要な CNN を処理するエッジデバイスにおいて課題となる消費電力を削減するために、より電力削減効果が高く回路オーバーヘッドの小さいゼロスキップ方式を提案した。本研究では CNN を処理する演算デバイスとして、ADAS や AD などの自動運転を想定アプリの一つとしている Xilinx ZU9 FPGA を選択し、物体検出 AI モデルの一つである SSD500 の畳込み演算のうち 88 %を圧縮・削減したモデルを実装した。これに対して提案したゼロスキップ方式を適用することで、従来のゼロスキップ方式と比較して、-0.29 %の認識精度劣化で消費電力の削減効率 52.3 %、回路オーバーヘッドの削減 (-45.9 %)を確認した。

今後、更なる認識精度の向上と多様な機能への適用が期待される CNN は、畳込み演算の規模がますます増大すると予想される[3-8]-[3-11]。このような AI モデルを車載エッジ機器に実装する中で、消費電力は大きな課題となる。本研究で提案したゼロスキップ方式を適用することにより、高精度な AI モデルの実用化に貢献できることが期待される。

第4章 物体検出 AI の実機検証効率化に関する研究

4.1. 緒言

前章では画像処理 CNN の低消費電力化に関する技術について述べた。本章では, CNN をベースとする画像処理アルゴリズムの中でも, 車載向けに最も普及している物体検出 AI を更新する際の検証の効率化技術について述べる。1 章でも述べた通り, ルールベースで開発されたソフトウェアに対して, AI は更新の際に設計者の意図しない性能変化が起こるために, 多様なテストパターンでの検証が必要となる。また, 図 1.10 にも示した通り, 自動運転のように極めて高い信頼性, 安全性が求められるアプリケーションにおいては, 実車両での走行試験の実施が更新版のリリース要件になっていることも少なくない。本章では, 画像分類やセグメンテーションと並んで最も普及している物体検出について[4-1]-[4-6], その AI モデルの更新時の実機検証の効率化する新たな手法について述べる。4.2 節では, 検証効率化の既存手法と課題について述べ, 4.3 節では既存手法の課題を解決するための新しい手法について説明する。4.4, 4.5 節では提案手法の設計結果とその有効性について実験結果を交えて説明し, 4.6 節では結論を述べる。

4.2. 車両における物体検出 AI の検証方法

本節では, 実験車両を用いた検証コストの問題を解決するための一つの提案手法について述べる。現状の実車検証は図 4.1(a)に示すように, n 台 (数台~数十台オーダ) の実験車両を用いて様々なテストシナリオを走行し, そこで取得されたデータをオフラインでソ




図 4.1 ソフトウェアの実機検証方法

ソフトウェア開発者が検証・解析し、想定外の不具合や異常が無いかどうかを最終確認することが求められる。テストシナリオは非常に多岐にわたり、要求される走行距離も長いために時間とコストが深刻な課題となることは1.5節でも述べた通りである。これを解決するための1手段として、図4.1(b)に示すように一般ユーザが所有する車両(N 台, $N \gg n$ とする)を検証車両として用いることで、検証効率を N/n 倍にする方法が考えられる。この方法を実現するには一般ユーザの運転者に影響を与えることなく、開発者が意図した検証を自動的実行する仕組みが必要となる。

図4.2は自動検証を実現するための方式の一つで、車両メーカーが既に市場投入して実用されている方式である[4-7][4-8]。手動運転モードのときに運転者の操作(ハンドル、アクセル、ブレーキ等)を正解値として、検証対象の車両制御ソフトウェアをバックグラウンドで実行し、出力される制御信号と運転者操作とを常時比較する。制御結果に差分がある場合、その時点での車両センサからの情報(周辺認識情報、車両情報等)がサーバに送信され、開発者がオフライン解析を行なう。検証対象のソフトウェア出力は(検証未完了のため)車の制御系には接続されず、検証は手動操作時のみ行われる。この方法は、運転者の運転操作が正しいという前提であるために、運転者の判断ミスや操作ミスがあった場合に正しい検証が出来ない課題はあるが、従来の実験車両を使った検証よりもはるかに多くの車両を用いることが出来るため、検証の効率化に貢献できる方法と言える。

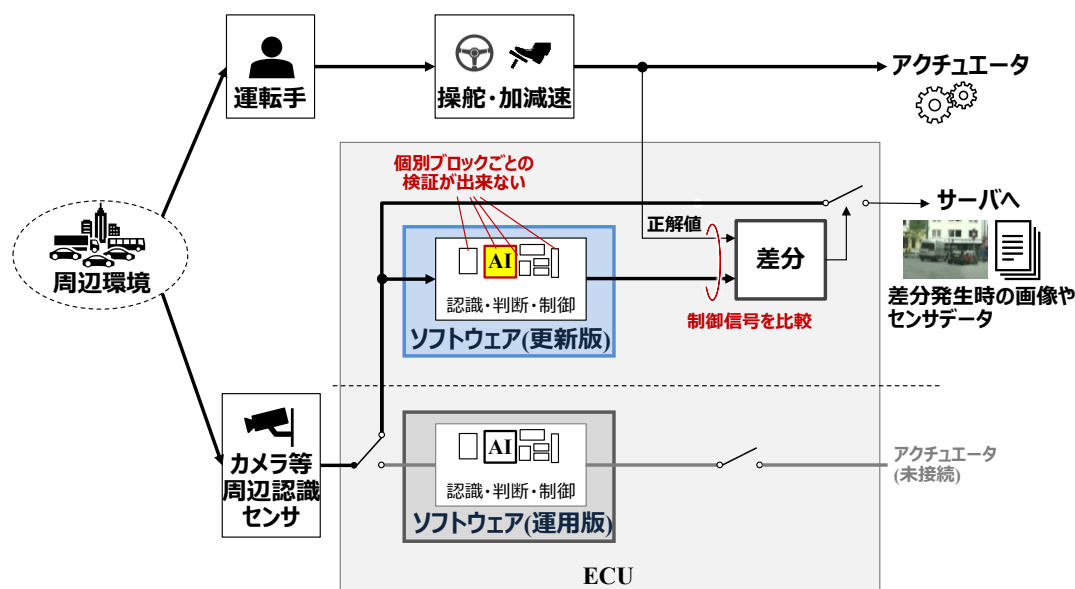


図 4.2 ユーザ車両を用いた更新版ソフトウェアの検証方式

図 4.2 の方法では検証時に参照できる正解値が運転者の操作情報，すなわちハンドル，アクセル，ブレーキ等の制御情報のみであるため，ソフトウェアを構成する各機能ブロックや各 AI 単体に対して細かく検証することは難しい。1.6 節でも述べた通り，学習データに依存して性能が決まる AI の性質上，意図しない不具合が常に潜在するため，AI の更新頻度はルールベースのソフトウェアよりも多くなるため，AI 単体での検証が必要になると考えられる。また，手動運転時にしか検証出来ないため，検証シナリオの網羅性や偏りなどが懸念される。

これらの課題を解決するための方法の一つとして図 4.3 に示すように運用中の AI モデルと，検証対象の更新版 AI における推論結果を比較する検証方法が考えられる。これにより，AI 単体の検証と常時検証が可能となる。この方式における運用版 AI はリリースの際に十分に検証済みであり実用に耐えると判断されている前提である。すなわち，更新版 AI が運用版 AI に比べて少なくとも性能が劣化していないことを示せばよい。しかし，この方式には次の課題があり，実用に向けた解決手段の開発が必要である。

(i) 車両単独では正解値を持っていない：

運用版 AI と更新版 AI における推論結果の差分が，性能改善または性能劣化によるものかが判断できない

(ii) 検証の網羅性：

任意の時間と場所で多数のユーザ車両が走行するため，テストシナリオの重複や不足が発生する可能性がある




図 4.3 運用版と更新版ソフトウェアの比較検証方式

(iii) ハードウェアリソースの増加：

運用版 AI と更新版 AI の両モデルを実行するには 2 倍のリソースを要するため、効率的な実装や実効タイミング・トリガの設計が必須となる

(iv) 収集データの管理：

従来方式の実験車両よりもはるかに多くのユーザ車両を用いるため、集約された大量のデータをどのように運用・管理するかの方針の検討が必要となる

本研究では、図 4.3 の実車検証方式において最も本質的な課題となる(i)について、車両内（エッジ機器）だけで推論差分の正しさを判定し、検証を成立するための新たな手法を提案した。

4.3. 提案の AI 検証手法

正解データが無い車載エッジ機器において、更新版 AI を現状版 AI における推論結果と比較して検証を成立させるには、推論差分の妥当性を何らかの方法で判定する必要がある。判定手段は少なくとも更新版と現状版 AI よりも性能が高い必要がある。しかし、もともと高性能な周辺認識 AI を実装するために、計算コストが非常に大きく、それよりも高性能な AI モデルを実装するのは現実的ではない。また、そもそもその高性能な AI を実装できるのであれば、検証をせずともその AI モデルを利用すれば良いことになる。

これに対して本研究では、シンプルな構成で検証を実現するための新たな手法を提案する。物体検出 AI はカメラで取得した画像全体の中から、物体が存在する位置座標とその物体の種類（クラス）情報を出力する。このことから、更新版 AI と運用版 AI の推論差分となった画像領域に、検出すべきクラスの物体が存在するか否かが判断出来れば、性能改善または劣化を判断することが出来ると考えられる。すなわち、この方式のポイントは、画像全体から認識対象の位置とクラスを予測する“物体検出タスク”の検証を、2 つの AI モデルの推論差分となった画像領域に検出対象の物体が存在するかどうかを予測する“二値分類タスク”に問題を単純化するところである。一方、この方法では、運用版 AI と更新版 AI の両方の推論結果が間違っている場合には推論差分が出ないために性能劣化を検出することができない課題がある。この課題については今後も検討を続ける必要があるが、本研究では車両における更新版 AI モデルの検証を以下のように定義する。

- ・第一ステップ：開発環境で網羅的なテストパターンやシミュレーション技術を用いて検証を実施


- ・最終ステップ：安全運転に重大な影響がないことを確認。最終検証の位置付けであり、運用版 AI モデルから重大な劣化が無いことを確認

よって以下の議論では、運用版 AI に対する性能劣化が無い限り、実車検証は有効であると

考えて議論を進める。

図 4.4 に提案手法の構成を示す。この図ではまず(a)の入力画像に車両が 2 台，自転車が 1 台映っている例で説明する。入力画像は運用版 AI と更新版 AI に入力され，それぞれの推論結果(b)(c)として物体の位置情報 bbox とクラスが出力される。運用版 AI では車両 2 台が検出された一方で自転車は未検出であり，更新版 AI では車両 1 台と自転車が検出された一方で奥側の車両が未検出となっている。これらの推論結果の差分となった画素を算出したものが(d)である。差分の判定は(b)(c)の bbox それぞれに対する IoU (Intersection over Union) を計算し，例えば 0.8 以下になった bbox を推論差分として扱う。IoU の計算は次の式で定義される：

$$IoU = \frac{\text{Area of Intersection}}{\text{Area of Union}} \quad \cdot \cdot \cdot (4.1)$$



*TOED : Target Object Existence Detector

図 4.4 提案の検証方式

表 4.1 更新 AI の性能改善/劣化の判定ルール

	検出対象物体の有無	
	物体有り	物体無し
更新版モデルで検出	性能改善	性能劣化
更新版モデルで未検出	性能劣化	性能改善

Intersection は比較対象となる bbox の重なり合った面積（共通部分）、Union は比較対象となる bbox の和集合である。この推論差分に対して検出すべき対象となるクラスの物体が存在するかどうかを判定する二値分類器 TOED（Target Object Existence Detector）によって判定(e)する。TOED の詳細は次節で述べる。物体有無情報(e)と、推論差分 bbox が更新版 AI によって領域が検出されたかどうかの情報(f)を用いて、表 4.1 に示すルールに従って更新版 AI の性能改善・劣化を判定する。例えば、更新版 AI では奥側の自動車が検出されておらず(c)、運用版 AI では検出(b)されていることから、推論差分となった領域(d)に対して TOED で「検出すべき物体が存在する」と判定された場合(e)は、更新版 AI は性能が劣化したと判定される(g)。

以上が提案する実機検証方式の概要である。次節ではこの検証方式の肝である TOED の設計について述べる。

4.4. TOED の設計

本節では、TOED の設計について学習データセットとアーキテクチャの観点から述べる。TOED の学習データセットは、物体検出 AI の検出対象物体が存在することを示す「Object」ラベルと、検出対象の物体が存在しないことを示す「None」ラベルのいずれかが付与された画像から構成される。それぞれのラベルは例えば図 4.5 に示すように、検出対象（車、自転




図 4.5 TOED の学習データと評価データセットの例

※検出対象物体あり（Object ラベル）を青い四角，物体無し（None ラベル）を赤い四角で囲った例

車，歩行者等）の青色矩形領域を「object」ラベルとし，それ以外（背景，路面，建物，樹木，標識等）の赤色矩形領域を「None」ラベルとして切出し，図 4.6 (a)(b)のようにデータセットを作成した。詳細は後ほど説明するが，TOED への入力画像サイズは固定にしなければならないため，切出した画像は $64 \times 64 \text{ pixel}^2$ の領域に収まるように短辺長辺いずれかに合わせてリサイズされ，余った領域はゼロパディングされている。

TOED の学習データセットと評価データセットには Cityscapes のデータセットから抽出し，検出対象のクラスは “car”, “bike”, “person” の 3 クラスとした。表 4.2 に示すように，検出対象の物体が存在する「Object」ラベルは，学習用に 5000 枚，評価用に 2000 枚とし，検



(a) 検出対象の物体有り画像（Object ラベル）の例（車両，自転車，歩行者クラス）



(b) 検出対象の物体無し画像（None ラベル）の例（背景，路面，看板 等）

図 4.6 TOED の学習データと評価データセットの例

表 4.2 TOED のデータセットにおける物体有無の詳細

データセット	“Object” 画像	“None” 画像	元画像
学習データセット	5000	10000	Cityscapes training data (3000 枚)
評価データセット	2000	2000	Cityscapes validation data (500 枚)




図 4.7 TOED (Target Object Existence Detector)の構成

出対象の物体が存在しない「None」ラベルは学習用に 10000 枚、評価用に 2000 枚の画像が含まれる。None ラベルの画像は検出対象以外の背景が対象であり非常に多様であることから、Object ラベルよりも多くの画像を抽出した。以下では、物体検出 AI 自体の学習データセットと分けて表現するために、便宜上これらのデータセットを「物体有無データセット」と呼ぶ。なお、物体のサイズが小さすぎたり、物体の一部しか含まれていなかったりすると、物体有無の判定が難しくなる。そのため、画像の面積が 1024 pixel^2 ($32 \times 32 \text{ pixel}^2$ 相当) 以下の bbox や、複数のクラスの物体が映っている bbox、オクルージョン状態および見切れ状態の bbox は物体有無データセットから除外した。

次に、本研究における二値分類器（TOED : Target Object Existence Detector）の構成について述べる。エッジ機器での実行を想定しているため、なるべくシンプルで軽量の構成となるように設計した。図 4.7 に示すように、入力は 64×64 の RGB 画像であり、4 層の畳み込み層と、2 層の全結合層、ソフトマックス処理によって算出された推論の確信度スコアから、検証対象の物体有無（二値分類）を実現する。畳み込みの各層と全結合層における出力データサイズと重みパラメータ数を表 4.3 に示す。

畳み込み層と全結合層における積和演算は 0.5 GFLOPs であり、SSD500[4-6]やYOLOv5[4-14]などの物体検出モデルの演算規模の 0.05% 以下である。これらの AI モデルが車載 ECU な

表 4.3 TOED の畳込み層の各パラメータ詳細

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(64, 64, 32)	896
activation_1 (Activation)	(64, 64, 32)	0
conv2d_2 (Conv2D)	(62, 62, 32)	9248
activation_2 (Activation)	(62, 62, 32)	0
max_pooling2d_1 (MaxPooling2	(31, 31, 32)	0
dropout_1 (Dropout)	(31, 31, 32)	0
conv2d_3 (Conv2D)	(31, 31, 64)	18496
activation_3 (Activation)	(31, 31, 64)	0
conv2d_4 (Conv2D)	(29, 29, 64)	36928
activation_4 (Activation)	(29, 29, 64)	0
max_pooling2d_2 (MaxPooling2	(14, 14, 64)	0
dropout_2 (Dropout)	(14, 14, 64)	0
flatten_1 (Flatten)	(12544)	0
dense_1 (Dense)	(512)	6423040
activation_5 (Activation)	(512)	0
dropout_3 (Dropout)	(512)	0
dense_2 (Dense)	(2)	1026
activation_6 (Activation)	(2)	0
Total params: 6,489,634		
Trainable params: 6,489,634		
Non-trainable params: 0		

どのエッジ演算デバイスに実装される場合は、デバイスの演算性能と要求フレームレートにも拠るが、モデル圧縮技術[4-18]-[4-20]によって 80～90 %以上の演算を削除するのが一般的である。今回設計した TOED はこれらを考慮しても、検証対象の AI モデルの演算量に対して 0.5 %以下であるため、追加の演算コストや実装のインパクトは小さいと言える。

最後に、提案手法の検証精度に大きく関わる TOED の目標性能について述べる。ここで検証精度とは、更新版 AI モデルが運用版 AI モデルに対して性能劣化していることを漏れなく検出する性能を指す。検証のための入力画像(a)は毎秒数十フレームで連続的に入力されるため、数フレームにわたる検証結果の連続性と揺らぎを利用することで、検証結果の妥当性を担保することを想定する。例えば、判定性能 95 %の二値分類器が 3 フレーム連続で同じ判定結果を出した場合、その判定精度は 99.9 %となる。これは確率論的な概念で

あり，全ての条件下で成立するわけではないが，本研究では TOED の判定精度を 95 %に設定した。

4.5. TOED の評価結果

本節では前節で作成した物体有無データセットに対する TOED の性能評価結果について述べる。TOED の判定性能 A_{total} は以下の式で定義する。

$$I_{\text{obj}} = J_{\text{oo}} + J_{\text{on}}, \quad \dots (4.2)$$

$$I_{\text{none}} = J_{\text{nn}} + J_{\text{no}}, \quad \dots (4.3)$$

$$A_{\text{obj}} = \frac{J_{\text{oo}}}{J_{\text{oo}} + J_{\text{no}}} \times 100, \quad \dots (4.4)$$


$$A_{\text{none}} = \frac{J_{\text{nn}}}{J_{\text{nn}} + J_{\text{on}}} \times 100, \quad \dots (4.5)$$

$$A_{\text{total}} = \frac{J_{\text{oo}} + J_{\text{nn}}}{I_{\text{obj}} + I_{\text{none}}} \times 100. \quad \dots (4.6)$$


ここで， I_{obj} と I_{none} は検出対象の物体が存在する画像と存在しない画像の数を示し， J_{oo} は Object ラベルの画像を“物体有り”と判定した数(正解数)， J_{on} は Object ラベルの画像を“物体無し”と判定した数(不正解数)， J_{no} は None ラベルの画像を“物体有り”と判定した数(不正解数)， J_{nn} は None ラベルの画像を“物体無し”と判定した数(正解数)を示す。これらの判定結果を用いて， A_{obj} は Object ラベルの画像に対する判定精度， A_{none} は None ラベルの画像に対する判定精度， A_{total} は物体有無データセット全体に対する判定精度を示す。

図 4.8 (a)は物体有無データセットに対する TOED の性能を評価したヒストグラムである。横軸は TOED が推論した物体有無の確信度を示す値で，50 %を閾値として物体有無を判定している。判定性能 A_{obj} は 92.1 %， A_{none} は 98.3 %， A_{total} は 94.8 %となり，Object ラベルおよびトータル性能で目標の 95 %を満足しない結果となった。

図 4.8(b)に(a)の縦軸を拡大したヒストグラムを示す。信頼度が高いにもかかわらず誤って判定されたケースが多いことが分かる。考えられる理由の一つは，TOED の最終段で全ての結合層が出力した特徴量(x_1, x_2)が，ソフトマックス処理によって予測信頼度(y_1, y_2)が 0 と 1 の間に圧縮され，特徴量の絶対値が失われていることである。ソフトマックス処理は以下



(a) 物体有無データセットに対する推論確信度のヒストグラム



(b) (a)の拡大図

図 4.8 TOED の推論確信度に対する物体有無判定結果

の式で定義され、 x_1 は物体が存在するスコア、 y_1 は物体が存在する信頼度（図 4.8 の横軸）である。

$$\begin{cases} y_1 = \frac{\exp(x_1)}{\exp(x_1) + \exp(x_2)} \\ y_2 = \frac{\exp(x_2)}{\exp(x_1) + \exp(x_2)} \end{cases} \quad \dots (4.7)$$

例えば、図 4.9(a)の画像は明らかに車両に見えるため、抽出された特徴量スコア x_1 の値は高く、ソフトマックス処理後の推論信頼度も高い値となる ($y_1=0.9$)。一方で、図 4.9 (b)の画像は不鮮明な背景画像か、もしくは車両のようにも見える画像であり、抽出された特徴量（以下では物体存在スコアと呼ぶ）は x_1 、 x_2 ともに低い値であるが、ソフトマックス処理によりこれらの値の比率によっては図 4.9 (a)と同じ推論信頼度 ($y_1=0.9$) が得られる可能性がある。そのため、推論のための特徴量がうまく抽出出来ていない場合でも自信を持って推論してしまうことがあると同時に、確信度が閾値周辺であってもその推論が不確実であるとは限らない。

そこで、物体存在スコア(x_1 , x_2)を用いることにより判定性能を向上させるとともに、少なくとも「性能劣化の見逃し」は許容しないという設計指針とした。すなわち、図 4.9 (b)の画像のように、物体存在スコアが小さい（特徴をうまく抽出出来ていない）不確実な推論結果は、物体が有るか無いか不明瞭のため「グレーゾーン」に属すると判断する。グレーゾーンと判定された画像は、性能劣化と判断された画像と同様に「性能劣化の疑いあり」としてサーバに送信される。

図 4.10 は、この手法で得られた物体存在スコアのヒストグラムである。特徴量が1以下




図 4.9 推論不確実度に対する特徴スコアと confidence 値のイメージ

(a) 入力画像が明らかに車両, (b)入力画像が不明瞭




図 4.10 物体存在の特徴量スコアを用いた物体有無判定結果

の場合、 A_{none} は 99.0 %，特徴量が 5 以上の場合は A_{exist} が 99.4 %であった。一方，物体存在スコアが 1 から 5 までのグレーゾーン区間に属する画像は物体有無データセット全体の 10.5 %を占める。グレーゾーン区間に属する画像の割合 R_{gz} は以下の式で定義される。

$$R_{\text{gz}} = \frac{J_{\text{gz}}}{I_{\text{obj}} + I_{\text{none}}} \times 100. \quad \dots (7)$$

ここで、 J_{gz} は TOED がグレーゾーンと判定した画像の数を示す。つまり，この特徴量の範囲は，物体の存在を判断出来ないグレーゾーンに当たる。しかし，このような性能劣化を疑わせるデータも含めて検出することで，このデータセットでは判定精度 A_{total} が 99.2 %（グレーゾーン 10.5 %）で性能劣化の検出ができることを確認した。

以上が物体有無データセットに対する TOED の評価結果であり，次に図 4.4 に示す構成を用いて TOED の性能を評価した。運用版 AI は YOLOv5 [4-14] の L モデル，更新版 AI は YOLOv5 の X モデルとし，意図的に認識性能に差が出るようにしている。入力画像は Cityscapes の評価画像 500 枚とした。異なる AI 同士の推論差分に対して TOED で物体有無を判定しようとする，もともと想定していた図 4.11 (a)の不検出や(b)の背景(検出対象クラス以外)の過検出の他に，(c)部分検出，(d)二重検出，(e)超過検出(背景と物体の両方を含む)，などが多く発生することが分かった。この傾向は特に物体検出 AI の推論確信度が低い時に顕著であり，検出された全ての bbox における比率(f)では 32 %が(c)~(e)のパターンで

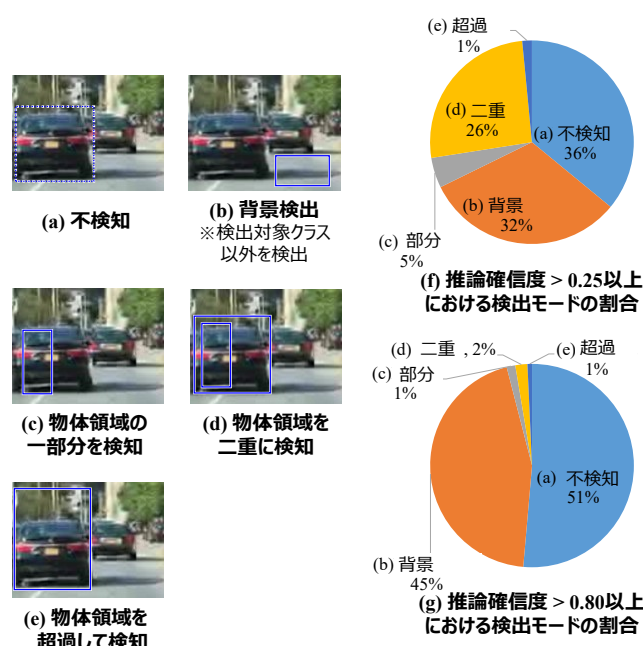


図 4.11 推論差分のモードの例とその発生割合の例

あることに対し、確信度が 0.8 以上であればこれらは 4 %に留まることが分かる。例えば、運用版 AI の推論結果が図 4.11 (d) のようになり（外側の bbox が正しく、内側の bbox が間違っている）、更新版 AI は外側の bbox のみを推論した場合を考える。この場合、更新版 AI は内部の bbox を検出しないので市恵能が向上したと言える。一方、内側の bbox は車両の一部を示しているため、高い確率で物体有りと判定される。従って、表 4.1 のルールに従い、内側の bbox を検出しない更新版 AI は“性能劣化”と判定される。このような複雑な検出パターンに対しては単純な推論差分だけでは検証を成立させることは難しい。本研究ではまず、フレーム間で連続して発生する確率の高い(a)(b)のケースに対して TOED の性能を評価するために、推論確信度が 0.8 以上となる推論差分に対してのみ TOED による判定を行なった。

図 4.12 に運用版 AI と更新版 AI で得られた推論結果とその推論差分の一例を示す。推論差分のある部分が図の下側でピンク色に塗りつぶされている。枠がある推論差分は更新版 AI のみで予測された bbox であり、枠が無い推論差分は運用版 AI のみで推論された bbox である。




図 4.12 2 つの AI モデルの推論差分の例（上側：運用版 AI，下側：更新版 AI）




図 4.13 運用版と更新版 AI の推論差分に対する TOED の物体有無検出結果

物体検出 AI における推論確信度が 0.8 以上となる bbox を対象に推論差分を抽出し、その差分画像に対して TOED で物体有無を判定した結果を図 4.13 に示す。判定精度は、検証対象の物体有りと判定したときの精度 A_{obj} は 94.6 %、「物体無し」と判定した精度 A_{none} が 98.3 %であった。トータルの判定精度 A_{total} が 95 %以上となる見通しを得られたものの、グレーゾーン判定となった画像が全体の 23.3 %となった。物体有無データセットを用いた判定結果（図 4.10、グレーゾーン 10.3 %）よりもグレーゾーンが広がる結果となった理由の一つとしては、推論差分となる画像の判定難易度にあると考えられる。すなわち、物体有無データセットは、Cityscapes の正解ラベルの中からランダムに選んだ物体、および背景画像から成るため、認識難易度が簡単なものから難しいものまで含まれる一方で、2 つの AI モデルの推論差分から抽出される画像は、基本的に認識難易度が高くなる。そのため、TOED も間違った判断を下しやすいと考えられる。この問題に対処するためには TOED のネットワーク構造の変更や、学習データセットの見直しなどが必要になると考えられるが、次節ではこれに対する対応手段について述べる。

4.6. TOED の性能改善の検討

TOED の判定精度を更に向上するには、一般には(1)CNN の層数やチャンネル数を増加するなどモデルの規模を増大、(2)更に多様なデータを用いて学習、などのエンジニアリング領域での試行錯誤が必要となる。一方で、AI の更新時に新しいクラスを追加する場合は TOED の再学習と再設計が必要となるために、実用・運用に向けた課題となる。そこで本節では、運用上の課題を考慮しながら物体有無の判定精度を向上させるために、図 4.14 に示すようにクラスごとに TOED を実装し、物体検出 AI の推論したクラス情報に応じて TOED を選択する方式を提案する。この方式ではクラスごとに TOED を設計・追加する思想であることから、検証対象となる新クラスが追加されても、他クラスの分類器の判定性能とは独立して考えることが出来る。

クラスごとの TOED の CNN は図 4.7 と同じ構造とし、例えば自動車クラスの TOED の学習データには、自動車クラスの bbox の切り出し画像を”object”ラベルとし、他のクラスの画像（自転車、歩行者、背景等）を”none”ラベルとした。自転車や歩行者クラスの存在有無判定の学習データセットも同様に構成した。






図 4.14 TOED をクラスごとに実装した構成


各クラスの TOED の性能評価結果を図 4.15 に示す。判定困難なグレーゾーンの割合は、自動車、自転車、歩行者でそれぞれ 0 %, 9.5 %, 7.8 %であり、1 つの TOED で判定する場合 (23.3 %) に比べて減少しており、クラスごとに TOED を実装するメリットが確認された。また、グレーゾーンを除く部分のトータルの判定精度は 98 %であり、良好な



(a) 車両存在有無スコアของ Histogram



(b) 二輪車存在有無スコアของ Histogram




(c) 歩行者存在有無スコアของ Histogram


図 4.15 各クラスに対する TOED の判定精度評価結果

結果と言えるが、1～2 %の性能劣化見逃しや、性能改善を間違って性能劣化と判定ミスすることがあるため、可能な限り判定精度を向上させる必要がある。

判定精度を更に向上させるための手段の一つとして、図 4.16 に示す構成と処理フローを提案する。この方法は、図 4.14 で設置したクラスごとの TOED を全て使用し、その結果を組み合わせる方法である。図 4.16(b)のフローチャートに示すように、本体の物体検出 AI における推論結果のクラスに対応する TOED の結果が“物体有り”であり、その他のクラスの TOED の結果も“物体有り”であると判定された場合、推論されたクラスが間違っている可能性があるため、“グレーゾーン”と判定する。これにより、TOED が“物体有り”と判



(a) 検証部の構成



(b) フローチャート

図 4.16 複数の TOED を用いた判定精度向上手法

表 4.4 更新版 SW の各検証手法における性能劣化検出精度の比較

AI 向け自動検証手法	検証精度[%]	グレースケール[%]	追加演算量 [GFLOPs]
運用版 AI と更新版 AI の単純比較方式 (図 4.3)	50.0 (判定不可)	---	---
アンサンブルした物体検出 AI の多数決方式	99.2	---	147.0*
TOED (本研究, 図 4.4)	96.5	23.3	0.5**
クラスごとの TOED (本研究, 図 4.14)	98.6	8.4	0.5**
全てのクラスごとの TOED を使用 (本研究, 図 4.16)	99.3	8.4	1.5***

* YOLOv5 M モデルを 3 アンサンブル, 並列動作, ** 4 層畳込み, 2 層全結合の構成, *** 3 つの TOED を使用

定した結果の中から誤りの可能性があるものを発見することが出来, 検証の精度を向上させることが出来る。本方式を適用することにより, TOED の判定精度は自動車は 99.8 %, 自転車は 98.1 %, 歩行者は 99.0 % となり, 合計で 99.5 % に向上した。

最後に, 提案手法の検証精度 (図 4.4) と, 運用版と更新版 AI を単純比較するだけの標準的な検証手法 (図 4.3), および物体検出 AI を追加したモデルアンサンブルを用いた検証精度と比較した。アンサンブルベースの物体検出 AI は Cityscapes データセットに対してランダムな初期パラメータで学習させた 3 つの YOLOv5 M モデル (49.0GFLOPs/モデル) を用いた。3 つのモデルの推論結果に対する多数決によって, 更新版 AI における性能劣化を検出する構成とした。表 4.4 に各手法の検証精度と, 追加の演算コストを示す。この結果から, 本手法がほとんど追加の演算コストをかけずに高い検証を達成できることが確認できた。

4.7 結論

本章では, 車両 ECU などの極めて高い信頼性が求められるエッジ機器において, 更新版 AI の検証コストを削減するために, ADAS や AD などの自動運転分野で最も普及している物体検出 AI の新たな検証手法を提案した。本手法では運用版 AI と更新版 AI の予測結果を比較し, 推論差分が発生した画像領域に検出対象の物体が存在するか否かを判定する二値分類器 (TOED : Target Object Existence Detector) を用いる。この TOED の判定結果と推論差分の情報を用いて, 更新版 AI の自動検証システムを構築した。その結果, 正解デ

ータを持たない車載エッジ機器においても、更新版 AI の性能向上と性能劣化を判別することが可能となった。TOED を用いて、Cityscapes データセットにおける YOLOv5 の L モデルと X モデルの推論差分に対して性能劣化・改善の判定精度は 96.5 % となった。また、各クラス専用の TOED を導入することで、グレーゾーンの割合が 22.3 % から 8.6 % に減少し、判定精度が 98.6 % に向上することを確認した。また、各クラスに導入した全クラスの TOED の結果を活用することで、判定精度が 99.5 % まで向上することが確認され、提案した検証手法の実用性が確認された。今後は、TOED の更なる精度向上とハードウェアリソースの利用効率向上をめざす。また、検証の網羅性を保証するシステムについても検討していく。

第5章 結論

5.1. 本研究で明らかにされた事項

本論文では、自動運转向け車載エッジ機器における周辺認識アプリケーションの高性能化と社会実装に向けた代表的な課題として、ミリ波レーダのハードウェア高効率実装、カメラ画像の CNN 認識処理の低消費電力化、および更新時の実機検証効率化について注目し、それぞれの開発技術について述べた。

第2章 遠距離ミリ波レーダにおける RF フロントエンドの高効率実装に関する研究

本章では自動運転レベル 3 以上の高度な ADAS/AD で適用される遠距離ミリ波レーダ (LRR) において、検出距離と方位推定性能の向上に伴ってアンテナ数・アンテナサイズが増大する課題について取り組んだ。アンテナの単位面積あたりの放射効率とアンテナ間のアイソレーション特性が高いホーンレンズアンテナに注目し、アンテナを含む RF フロントエンドの実装に関して 2 つの高密度実装技術を開発した。

1 つ目の実装技術では、ホーンレンズアンテナを使用して送信と受信アンテナ間、および受信と受信アンテナ間のギャップとアイソレーション特性の関係を明らかにし、ゼロギャップで配置した。もう一つの実装技術では、ホーンレンズアンテナの開口領域の直下にテーパ状の空間があることを利用し、MSL, MMIC, および周辺部品の実装領域にアンテナ開口領域をオーバーラップするように配置した。これら 2 つの実装技術を適用することで、現行世代の LRR で標準的に採用されている平面アンテナ方式に比べて、RF フロントエンドの面積を 46.8%削減出来る見通しを得た。開発技術を適用した LRR を試作した結果、PCB のサイズは $37 \times 51.2 \text{ mm}^2$ で、レーダモジュールの体積は $45 \times 60 \times 30 \text{ mm}^3$ となり、同等のレーダに対して大幅に小型化できることを確認した。

また、試作した LRR のレーダ基本特性を評価した結果、送受信アンテナ利得のアンテナビーム幅は水平 18 度、垂直 5 度、角度推定精度は ± 0.2 度であり、要求される基本性能を満たすことを確認した。また、先行車検知性能を評価した結果では、最大検知距離は 320 m、角度推定精度は 100 m までは ± 0.5 度、280 m 以上で ± 0.2 度であり、実車試験においても実用出来る性能であることを確認した。

以上の検討結果から、検出距離と方位推定精度の高性能化に対してトレードオフとなるモジュールサイズの小型化を実現するための手段の一つとして、ホーンレンズアンテナを採用し、本研究で開発した高密度実装技術を適用することにより、実用的なモジュールサイズで LRR を実現出来る見通しを示した。

第3章 CNNの低電力実装に関する研究

本章では自動運转向けの周辺認識において、最も重要な機能の一つである画像認識の性能を飛躍的に向上するCNNの消費電力を低減する技術について述べた。CNNはルールベースのソフトウェアよりも遥かに演算量が大きく、リアルタイム性と消費電力が課題となる。従来のプルーニングや量子化などの既存のモデル圧縮技術に加えて、本研究ではCNNの各層に入力されるデータと重みが0のときに積和演算回路を停止するゼロスキップ技術に注目した。

一般的なCNNモデルでは各層の入力データと重みの両者が0になる頻度が高い一方で、エッジ機器への実装時はプルーニングや量子化により重みが0になる頻度が低くなる傾向に注目し、入力データのみを監視する論理回路と、認識精度に影響を与えない小さな値であれば演算停止する論理回路で構成されるゲーティングロジックを考案し、CNNにおける積和演算器を高頻度に停止する方針とした。開発技術の効果を確認するために、Xilinx ZU9 FPGAに88%の演算を圧縮・削減したSSD500を実装した結果、従来のゼロスキップ方式と比較して、-0.29%の認識精度劣化で消費電力の削減効率52.3%、回路オーバーヘッドの削減(-45.9%)を確認した。

本章の取組みにより、演算リソースや消費電力に大きな制約のあるエッジ機器において、提案のゼロスキップ手法を適用することで回路オーバーヘッドを抑制しながらCNNの演算処理の低消費電力化が実現できる有用な手法である見通しが得られた。

第4章 物体検出AIの実車検証効率化に関する研究

本章では、車載ECUなどの極めて高い信頼性が求められるエッジ機器におけるAIモデルの更新時の実車検証コストを削減する技術について述べた。AIモデルはルールベースのソフトウェアに比べて意図しない性能改善や劣化が起こるために、より高い頻度での更新が必要となるため、実車検証コストを効率化する技術開発が急務である。本研究では、ADASやADなどの自動運転分野で最も普及している物体検出AIについて、実車検証を自動化する新たな検証手法を開発した。本手法では、運用版AIと更新版AIの推論結果を比較し、推論差分が発生した画像領域に検出対象の物体が存在するか否かを判定する二値分類器（TOED: Target Object Existence Detector）を用いた。このTOEDの判定結果と推論差分の情報を用いて、更新版AIの自動検証システムを構築した。その結果、正解データを持たないエッジ機器内においても、更新版AIの性能向上と性能劣化を判別することが可能となった。TOEDを用いて、CityscapesデータセットにおけるYOLOv5のLモデルとXモデルの推論差分に対して性能劣化・改善の判定精度は96.5%となった。また、各クラス専用のTOEDを導入することで、グレーゾーンの割合が22.3%から8.6%に減少し、判定精度が98.6%に向上することを確認した。また、各クラスに導入した全クラスのTOEDの結果を活用することで、判定精度が99.5%まで向上することを確認した。

本章の取組みにより，AI モデルの更新時に課題となる実車検証コストについて，提案した検証手法の有用性が確認された。一方で，運用版 AI と更新版 AI の 2 つを動作させる必要があるために，ハードウェア実装や検証タイミング，収集された性能劣化シーンのデータ管理・再学習向け活用方法など，設計・運用の両面で実用化に向けた技術開発が更に必要となる。

5.2. 今後の展望

本論文では，エッジ機器の社会実装に向けた課題について，自動運転における周辺認識アプリケーションに絞って論じてきた。その中でもさらに，周辺認識センサについてはミリ波レーダの性能向上と小型化の両立，CNN 回路の低消費電力化と，AI 更新時の検証効率化に絞り，開発した技術について述べた。本論文の最後に，これらの技術を含めた車載エッジ機器の高性能化と社会実装の実現に向けて，今後の技術開発の方向性や展望について述べる。

5.2.1 周辺認識センサについて

1 章でも述べた通り，高性能なアプリケーションを搭載したエッジ機器において最も実用化が進んでいる機能は，カメラによる画像解析である。一方で，本研究の 2 章で取り組んだミリ波レーダはカメラの苦手な環境条件での認識結果をサポートし，システムとしての信頼性を担保する位置付けで用いられている。今後は一般大衆車向けにカメラとレーダの標準搭載(社会実装)と，更に高性能な周辺認識システムの開発(次世代向けの技術開発)が要求される。これらの実現には，ハードウェアに対しては引き続き高性能化・多機能化と低コスト化，小型化が要求され続けていくと考えられる。また，カメラやレーダを搭載したエッジ機器は自動運転車両だけでなく更に多様化すると考えられ，例えば建設現場における建設機械，自動運行の鉄道車両，物流現場における物品運搬ロボット，ドローンなどのモビリティ全般に適用され，これらの安全と信頼を支えるメインセンサとして活用されることが予想される。その際，レーダには遠距離のフロントセンシングではなく，近～中距離の広角センシングも求められ，LRR とは違ったアンテナ特性が必要となる。本研究で扱ったホーンレンズアンテナは遠距離・狭角ビームに適した方式であるが，開口面にプリズム上のレンズを追加する等により，広角に電波を放射できる可能性があり，各アプリケーションの要求に合わせながら実用に向けた技術開発を行なっていく必要がある。

また，カメラの苦手な奥行方向の距離検出，レーダの苦手な横方向の方位検出や物体の形状認識を補完する次世代のセンサとして LiDAR の活用が期待されている。本研究では LiDAR の課題について触れなかったが，周囲の物体を高精度に検出するための性能はレー

ダを上回っている一方で、コストやモジュールサイズのほか、車両実装時のデザイン性も課題となっているため、市場投入まではまだ時間がかかると考えられる。今後は、LiDAR の低コスト化と小型化、デザイン性の向上に関する研究が進むことにより、カメラ、ミリ波とを組み合わせた freespace 検出や道路形状検出、落下物検出、地図連携、行動予測や経路予測などの高度なアプリケーションが実現され、より高いレベルの自動運転の実現に貢献すると考えられる。

5.2.2 処理デバイスの低消費電力化について

本研究では画像認識 AI の演算処理で発生する電力低減を課題設定とした。これまでは演算デバイスでリアルタイム性を担保するためのモデル圧縮・実装技術に関する研究開発が盛んに行われてきた。モデルの実装についてはオープンソースで様々な技術が開示されており、演算デバイスを供給するベンダのツールや IP により、ハードウェア実装技術を持たない開発者でもある程度の高効率な実装は可能となってきた。また、半導体プロセスの微細化による演算デバイスの進化により、これまでよりも大規模な AI モデルを低消費電力で実行することが出来るようになり、今後もその潮流は続くと思われ。

その一方で、AI モデルの高性能化・多機能化も更に進んでおり、これに伴って演算量も更に大規模化していくために、対応する実装技術の開発も引き続き必要となると考えられる。また、現在主流である CNN よりも更に演算量が大きく高性能な Transformer や、生成 AI、LLM(Large Language Model)といった超大規模汎用アルゴリズムも登場しており、これらをエッジ機器へ搭載したアプリケーションの開発が要求される可能性もある。このような最新アルゴリズムについての最適実装技術については過渡期であり、これからの技術開発の中心的な分野の一つになると考えられる。

5.2.3 AI の検証と信頼性について

AI の検証は世界中で議論になっており、どのような項目を検証すれば必要十分であるかについての結論は未だ出ていない。特に、自動運転などの人命に関わるアプリケーション分野においては、事故を起こしたときの責任問題にも発展するため、簡単には結論を出せるものではない。標準化や規格化などの動きもあるが、いずれも納得感や実用性のある質のものはない。そのため、結局は AI が搭載された製品を使う側が信頼性以外の要因（納期やコストなど）によって納得する以外に、検証プロセスをクローズさせることは難しい。すなわち、当面はユーザや顧客の決めた検証ルールをクリアする、というプロセスはしばらく続くと考えられる。本質的な解決には至らない状況が続く中で、本研究で取り組んだ AI 検証の効率化技術だけでなく、その方法論や標準化・規格化の精度・納得感を高める技術開発に注力することが必要である。

5.2.4 車載エッジ機器の高性能化と社会実装について

本論文では社会課題を解決するための様々なエッジ機器のうち、自動運转向けの周辺認識アプリケーションに絞り、ミリ波レーダと画像 AI に関する議論を行なった。センサの高性能化については既に述べたが、社会実装すなわち市場投入に向けて重要なのはコスト、サイズ、デザイン性とも言われている。ミリ波レーダは車両のバンパ内に実装出来るためデザイン性は問題ないが、高性能化が要求されている LRR では、アンテナ数を大きく増やす必要があるために高コストの高周波 MMIC 部品の増加、高周波プリント基板面積の増加、データ量増加に伴う高演算性能の MCU 適用など、コストとサイズが課題となる。これらの解決策の一つとして本研究は貢献出来るものであるが、それだけでは吸収しきれない部分もある。MMIC や MCU の高性能化・低コスト化や基板材料の低コスト化に加え、物体検出信号処理部に AI を適用するなどの研究開発も必要であり、ミリ波レーダ一つを取っても技術開発が必要な要素は山積している。

カメラについても同様で、より高性能・高機能化と低コスト化の実現には、カメラのハードウェアそのものの進化が必要となる。画角を広げつつ、画素数も増加させながら、レンズなどの光学部品の信頼性や製造ばらつきを担保する技術開発は引き続き行われていくと考えられる。

LiDAR については 5.2.1 で述べた通りで、コストやサイズ、デザイン性の観点で、現時点では実用化・市場投入に至っていない状況である。その他、取得した点群データを処理するポイントクラウド向け AI のアルゴリズム開発、および演算デバイスへの実装時に必要となるモデル圧縮技術などに関する研究開発は引き続き必要である。

いずれのセンサも、自動運転分野で実用化が進むと他の分野におけるアプリケーションでの実用化も加速度的に進むことはこれまでの各産業の技術的な歴史を振り返ると明らかである。社会が抱えている様々な課題に対して、エッジ機器が貢献するには自動運転の分野で技術の基礎と実績を作っていくことが近道であると考えられる。引き続き、エッジ機器の社会実装に向けた課題について、これまでに述べた項目を中心に技術開発を続けていくことが必要である。

謝辞

本論文を執筆するに当たり、神戸大学大学院システム情報学研究科教授 太田能先生、ならびに神戸大学大学院科学技術イノベーション研究科教授 永田真先生には本論文の執筆について多くのご指導ならびにご鞭撻を賜りましたことに深く感謝するとともに厚く御礼申し上げます。また、本論文の執筆に当たり、適切なご指導を頂きました神戸大学大学院システム情報学研究科教授 的場修先生、及び、神戸大学大学院システム情報学研究科教授 滝口哲也先生、神戸大学大学院科学技術イノベーション研究科准教授 三木 拓司先生に深く感謝の意を表します。

本論文の研究は主に、筆者が所属する株式会社 日立製作所 研究開発グループで行ったものであります。本研究の遂行に当たっては、筆者が日立製作所に入社以来の歴代の所長でおられた、福永泰、小島啓二、長我部信行、鈴木教洋、中屋雄一郎、矢川雄一、西澤格、花岡誠之の各氏、筆者が所属した部の歴代の部長でおられた、工藤真、井戸立身、倉田英明、竹村理一郎、山岡雅直の各氏に多大なるご支援を頂きましたことを深く感謝致します。また、筆者が日立製作所 中央研究所に入社以来の歴代のユニットリーダーでおられた、山脇大造、増田徹、前木陽、小野豪一、前田功治の各氏においては、研究生活の全般に渡り、ご指導を頂いたことを深く感謝致します。

上記の各氏以外にも、第 2 章の研究の遂行に当たって、日立製作所 永石英幸、栗山哲、赤峰幸徳、田中咲、および日立 Astemo 黒田浩司の各氏には、有益なご議論を頂いただけでなく、レーダの試作、評価等で多大なご支援を頂きました。また、第 3, 4 章の研究の遂行に当たって、平井理宇、岸本真、中野和香子および日立 Astemo の長田健一、小野塚英明、伊藤浩朗、高田雅士の各氏には、研究方針の策定から CNN の実装に関する有益なご議論、そして、電力の評価に多大なご支援を頂きました。筆者が本論文を執筆できたのは、上記の方々の的確なご指導と、研究遂行に当たっての多大なるご協力の賜物であり、厚く感謝の意を表します。

上記以外にも、日立製作所 研究開発グループ、日立 Astemo 株式会社に所属の多くの方々、国際学会や国内研究会での議論の場において、適切かつ有益なご議論を頂いた全ての皆様に深く感謝致します。

参考文献

1章参考文献

- [1-1] 経産省, ”半導体・デジタル産業戦略,”
<https://www.meti.go.jp/press/2023/06/20230606003/20230606003-1.pdf>, 2022.
- [1-2] 総務省, ”令和元年版情報通信白書(PDF 版),”
<https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r01/pdf/01honpen.pdf>, 2018.
- [1-3] 国交省, ” 「RoAD to the L4」 の全体像,”
https://www.road-to-the-l4.go.jp/publication/pdf/publication_01.pdf, 2023.
- [1-4] 富士キメラ総研, “2022 自動運転・AI カー市場の将来展望,”
- [1-5] 国交省, “道路運送車両の保安基準の細目を定める告示等の一部改正について,”
https://www.mlit.go.jp/report/press/jidosha08_hh_003618.html, 2020.
- [1-6] A.A.Smadi, M.Msallam, “Vehicle Auto Parking System,” 2022 9th International Conference on Electrical and Electronics Engineering (ICEEE)
- [1-7] D. Azshwanth, Mithul Titten Koshy and T. Balachander, "Automated car parking system", International Conference on Physics and Photonics Processes in Nano Sciences, vol. 1362, pp. 1-9, 2019.
- [1-8] M. E. Russell, et al., “Millimeter Wave Radar Sensor for Automotive Intelligent Cruise Control (ICC),” in IEEE MTT-S Int. Microw. Symp. Dig., pp. 1257–1260, Jun. 1997.
- [1-9] S. Tokoro, et al., “Electronically Scanned Millimeter-wave Radar for Pre-Crash Safety and Adaptive Cruise Control System,” in Proc. of the IEEE Intelligent Vehicles Symp., pp. 304–309, Jun. 2003.
- [1-10] Z.Feng, et al., "Verification of a Lane Detection Method with Automotive Radar based on a New Type of Road Marking", 2018 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)
- [1-11] M. Shibao, et al., "RCS Characteristics of Road Debris at 79GHz Millimeter-wave Radar", 2019 IEEE Radio and Wireless Symposium (RWS)
- [1-12] R.K.Satzoda, et al., "On-road vehicle detection with monocular camera for embedded realization: Robust algorithms and evaluations," 2014 International SoC Design Conference (ISOCC)
- [1-13] T. Ogawa, et al., “Pedestrian Detection and Tracking using in-vehicle Lidar for Automotive Application,” in Proc. of IEEE Intelligent Vehicles Symp., pp. 734–739, Jun. 2011.
- [1-14] W.J.Park, et al., “Parking Space Detection Using Ultrasonic Sensor in Parking Assistance System,” in Proc. of IEEE Intelligent Vehicles Symp., pp. 1039–1044, Jun. 2008.
- [1-15] H. Weigel, et al., “Vehicle Tracking with Lane Assignment by Camera and Lidar Sensor Fusion,” in Proc. of IEEE Intelligent Vehicles Symp., pp. 513–520, Jun. 2009.

- [1-16] M. Drams et al., "Classification and Tracking of Dynamic Objects with Multiple Sensors for Autonomous Driving in Urban Environments," in Proc. of IEEE Intelligent Vehicles Symp., pp. 1197–1202, Jun. 2008."
- [1-17] J. Steinbaeck, et al., "Next generation radar sensors in automotive sensor fusion systems", 2017 Sensor Data Fusion: Trends, Solutions, Applications (SDF)
- [1-18] K. Ramasubramanian, K. Ramaiah, A. Aginskiy, "従来の 24GHz 帯から最新の 77GHz 帯レーダへの移行," Ti com. (2017),
https://www.ti.com/jp/lit/wp/jajy073/jajy073.pdf?ts=1703741512046&ref_url=https%253A%252F%252Fwww.google.com%252F
- [1-19] L. Maurer, et al., "77 GHz SiGe Based Bipolar Transceivers for Automotive Radar Applications - An Industrial Perspective," in Proc. of IEEE New Circuits and Systems Conf., pp. 257–260, 2011.
- [1-20] Saverio Trotta, et al., "An RCP Packaged Transceiver Chipset for Automotive LRR and SRR Systems in SiGe BiCMOS Technology", IEEE Transactions on Microwave Theory and Techniques (2012)
- [1-21] J. Bock, et al., "SiGe BiCMOS and eWLB packaging technologies for automotive radar solutions", 2015 IEEE MTT-S International Conference on Microwaves for Intelligent Mobility (ICMIM)
- [1-22] J.Bai, et al., "A 28-nm CMOS 40-GHz High-Resolution Digitally Controlled Oscillator for Automotive Radar Applications", 2017 IEEE 17th Topical Meeting on Silicon Monolithic Integrated Circuits in RF Systems (SiRF)
- [1-23] D.Guermandi, et al., "A 79-GHz 2×2 MIMO PMCW Radar SoC in 28-nm CMOS",IEEE Journal of Solid-State Circuits (2017)
- [1-24] A. Kuriyama, et al., "A High Efficiency Antenna with Horn and Lens for 77 GHz Automotive Long-Range Radar," in Proc. of the 13th European Radar Conf., pp. 378–381, Oct. 2016.
- [1-25] A. Kuriyama, et al., "High Efficiency and Small Antenna with Horn and Lens for 77 GHz Automotive Radar," in Proc. of the 18th Int. Symp. on Antenna Tech. and Applied Electromagnetics, Aug. 2018.
- [1-26] A. Kuriyama, et al., "Horn and Lens Antenna with Low Height and Low Antenna Coupling for Compact Automotive 77-GHz Long-Range Radar", IEICE TRANSACTIONS on Electronics, Vol.E103-C, No.10, pp.426-433, October 2020.
- [1-27] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in Proc. Adv. Neural Inf. Process. Syst., vol. 25. 2012, pp. 1097–1105.
- [1-28] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv preprint arXiv:1409.1556, 2014.
- [1-29] C. Szegedy et al., "Going deeper with convolutions," CVPR, 2015.

- [1-30] S. Ren et al., “Faster r-cnn: Towards real-time object detection with region proposal networks,” NIPS, 2015.
- [1-31] K. He, et al., “Deep residual learning for image recognition,” in Proc. IEEE Comput. Vis. Pattern Recognit., Jun. 2016.
- [1-32] W.Liu et al., “SSD: Single Shot Multibox Detector,” ECCV2016, pp.21-37, 2016
- [1-33] S. Han, H. Mao, W. J. Dally, “Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding,” 2016, <https://arxiv.org/abs/1510.00149> (online).
- [1-34] J.H.Luo, et al, “An entropy-based pruning method for cnn compression,” CoRR, abs/1706.05791, 2017.
- [1-35] D. Murata, T. Motoya, and H. Ito, “Automatic CNN Compression System for Autonomous Driving,” 2019 18th IEEE International Conference On Machine Learning And Applications(ICMLA).
- [1-36] Y. Lin, C. Sakr, Y. Kim, N. Shanbhag, “PredictiveNet: An energy-efficient convolutional neural network via zero prediction,” 2017 IEEE International Symposium on Circuits and Systems (ISCAS).
- [1-37] D. Kim, S. Kim, S. Yoo, “FPGA Prototyping of Low-Precision Zero-Skipping Accelerator for Neural Networks,” 2018 International Symposium on Rapid System Prototyping (RSP).
- [1-38] Y. H. Kim, G. J. An, M. H. Sunwoo, “CASA : A Convolution Accelerator using Skip Algorithm for Deep Neural Network,” 2019 IEEE International Symposium on Circuits and Systems (ISCAS)
- [1-39] C. Farabet, C. Poulet, J. Y. Han et al., “CNP: An FPGA-based processor for Convolutional Networks,” in Proc. IEEE Int. Conf. F. Program. Log. Appl., pp. 32–37, 2009.
- [1-40] C. Farabet, B. Martini, B. Corda, “NeuFlow: A Runtime Reconfigurable Dataflow Processor for Vision,” in Proc. IEEE Conf. Comput. Vis. Pattern Recognit., pp. 109–116, Jun. 2011.
- [1-41] P. H. Pham, D. Jelaca, C. Farabet et al., “NeuFlow: Dataflow vision processing system-on-a-chip,” in Proc. Midwest Symp. Circuits Syst., pp. 1044–1047, 2012.
- [1-42] F. Conti and L. Benini, “A Ultra-Low-Energy Convolution Engine for Fast Brain-Inspired Vision in Multicore Clusters,” in Proc. IEEE Des. Autom. Test Eur. Conf., 2015.
- [1-43] Z. Du, R. Fasthuber, T. Chen et al., “ShiDianNao: Shifting Vision Processing Closer to the Sensor,” in Proc. ACM/IEEE Int. Symp. Comput. Archit., 2015.
- [1-44] C. Lukas, M. Michele, and B. Luca, “Accelerating Real-Time Embedded Scene Labeling with Convolutional Networks,” IEEE Design Automation Conf., Jun. 2015.
- [1-45] P. Koopman and M. Wagner, "Toward a Framework for Highly Automated Vehicle Safety Validation", in Proc. WCX World Congress Experience., 2018
- [1-46] S. Riedmaier, T. Ponn, D. Ludwig, B. Schick and F. Diermeyer, "Survey on Scenario-Based

- Safety Assessment of Automated Vehicles", IEEE Access (Volume: 8), May 2020.
- [1-47] C. King, L. Ries, J. Langner and E. Sax, "A Taxonomy and Survey on Validation Approaches for Automated Driving Systems," 2020 IEEE International Symposium on Systems Engineering (ISSE)
 - [1-48] C. Neurohr, L. Westhofen, M. Butz, M. H. Bollmann, U. Eberle and R. Galbas, "Criticality Analysis for the Verification and Validation of Automated Vehicles," IEEE Access (Volume:9, Page : 18016 - 18041), Jan 2021
 - [1-49] S. S. Shadrin, A. M. Ivanov and D. A. Makarova, "Methods of Parameter Verification and Scenario Generation During Virtual Testing of Highly Automated and Autonomous Vehicles," 2022 Intelligent Technologies and Electronic Devices in Vehicle and Road Transport Complex (TIRVED)
 - [1-50] C. M. Berumen and M. I. Akbaş, "Abstract Simulation Scenario Generation for Autonomous Vehicle Verification", 2019 SoutheastCon
 - [1-51] H. Hsiang, K. Chen, and Y. Chen, "Development of Simulation-Based Testing Scenario Generator for Robustness Verification of Autonomous Vehicles," 2022 5th International Conference on Advanced Systems and Emergent Technologies (IC_ASET)
 - [1-52] M. Mittelsteadt, "AI Verification", Mechanisms to Ensure AI Arms Control Compliance 2021
 - [1-53] CSET Issue Brief, https://cset.georgetown.edu/wp-content/uploads/AI_Verification.pdf (online)"
 - [1-54] D. Åsljung, J. Nilsson, and J. Fredriksson, "Using Extreme Value Theory for Vehicle Level Safety Validation and Implications for Autonomous Vehicles", IEEE Transactions on Intelligent Vehicles (Volume: 2, Issue: 4, December 2017)
 - [1-55] L. Klitzke1, C. Koch1, A. Haja1 and F. Koster, ""Real-world Test Drive Vehicle Data Management System for Validation of Automated Driving Systems,"" VEHITS 2019 - 5th International Conference on Vehicle Technology and Intelligent Transport Systems"

2章参考文献

- [2-1] Y. L. Sit, et al., "BPSK-based MIMO FMCW Automotive-Radar Concept for 3D Position Measurement ", 2018 15th European Radar Conference (EuRAD)
- [2-2] X. Ding, et al., "A two-channel automotive radar for three-dimensional object detection", 2015 European Radar Conference (EuRAD)
- [2-3] I. Bilik, et al., "Automotive Multi-mode Cascaded Radar Data Processing Embedded System", 2018 IEEE Radar Conference (RadarConf18)
- [2-4] W. Menzel and A. Moebius "Antenna Concepts for Millimeter-Wave Automotive Radar Sensors," in Proc. of IEEE, vol. 100, no. 7, pp. 2372–2379, Jul. 2012.

- [2-5] H.Hayashi, T.Ohtsuki, "DOA estimation in MIMO radar using temporal spatial virtual array with MUSIC algorithm," 2015 9th International Conference on Signal Processing and Communication Systems (ICSPCS)
- [2-6] B.A.Karim, H.K.Ali, "Computationally efficient MUSIC based DOA estimation algorithm for FMCW radar," Journal of Electronic Science and Technology, Volume 21, Issue 1, March 2023
- [2-7] S.Tanaka, A.Kitayama, Y.Akamine, H.Kuroda, "Feedback Signal Processing that Improves Accuracy of Velocity and Direction of Arrival Estimation for Automotive Radar, " IEICE Transactions on Electronics, 2020 Volume E103.C Issue 10 Pages 543-546
- [2-8] H.Nagaishi, A.Kuriyama, A.Kitayama, H.Kuroda, "Horn and Prism Antenna for Dual Range and Dual FOV Automotive Radar Using 77-GHz Band," 2018 18th International Symposium on Antenna Technology and Applied Electromagnetics (ANTEM)
- [2-9] D. G. Babas and J. N. Sahalos, "Synthesis Method of Series-fed Microstrip Antenna Arrays," Electronics Lett., vol. 43, issue. 2, pp. 78–80, 2007.
- [2-10] J. H. Lee, et al., "Series feeding rectangular microstrip patch array antenna for 77 GHz automotive radar" 2017 International Symposium on Antennas and Propagation (ISAP)
- [2-11] H. Iizuka, et al., T. Watanabe, K. Sato, and K. Nishikawa, "Millimeter-Wave Microstrip Array Antenna for Automotive Radars," IEICE Trans. Community., vol. E86-B, no. 9, pp. 2728–2738, Sep. 2003
- [2-12] B. Jian, et al., "Procedure to Design a Series-fed Microstrip Patch Antenna Array for 77 GHz Automotive Radar", 2019 Cross Strait Quad-Regional Radio Science and Wireless Technology Conference (CSQRWC)
- [2-13] C. P. Chao, et al., "A Series-fed Cavity-back Patch Array Antenna for a Miniaturized 77GHz Radar Module", 2019 IEEE International Symposium on Antennas and Propagation and USNC-URSI Radio Science Meeting
- [2-14] J. Yan, et al., "Planar Series-Fed Antenna Array for 77 GHz Automotive Radar", 2017 Sixth Asia-Pacific Conference on Antennas and Propagation
- [2-15] C. Trampuz et al., "Experimental Characterization of Channel Crosstalk in Interleaved Array Antennas for FMCW Radar," in Proc. of the 7th European Radar Conference, pp. 439–442, Sep. 2010.
- [2-16] B. B. Adela et al., "On-Chip Antenna Integration for Millimeter-Wave Single-Chip FMCW Radar, Providing High Efficiency and Isolation," IEEE Trans. Antennas and Propagation, vol. 64, no. 8, pp. 3281–3291, Aug. 2016.
- [2-17] C. Malaquin, "Towards ADAS to Imaging radar for automotive: market and technology trends", RF & Microwave Conferences & Workshops 2019
- [2-18] A.Kitayama, A. Kuriyama, H.Nagaishi, H.Kuroda, "High-Density Implementation Techniques for Long-Range Radar Using Horn and Lens Antennas," IEICE TRANS. ELECTRON.,

3章参考文献

- [3-1] Wei Liu, et al., W.Liu et al., “SSD: Single Shot Multibox Detector,” ECCV2016, pp.21-37, 2016
- [3-2] S. Han, H. Mao, W. J. Dally, “Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding,” 2016, <https://arxiv.org/abs/1510.00149> (online).
- [3-3] J.H.Luo, et al, “An entropy-based pruning method for cnn compression, “ CoRR, abs/1706.05791, 2017.
- [3-4] D. Murata, T. Motoya, and H. Ito, “Automatic CNN Compression System for Autonomous Driving,” 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA).
- [3-5] Cityscapes Dataset – Semantic Understanding of Urban Street Scenes (cityscapes-dataset.com), <https://www.cityscapes-dataset.com/>
- [3-6] Zynq UltraScale+ MPSoC (xilinx.com), <https://japan.xilinx.com/products/silicon-devices/soc/zynq-ultrascale-mpsoc.html#eg>
- [3-7] Y. H. Kim, G. J. An, M. H. Sunwoo, “CASA : A Convolution Accelerator using Skip Algorithm for Deep Neural Network,” 2019 IEEE International Symposium on Circuits and Systems (ISCAS)
- [3-8] K.Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” arXiv preprint arXiv:1409.1556, 2014.
- [3-9] C. Szegedy et al., “Going deeper with convolutions,” CVPR, 2015.
- [3-10] S. Ren et al., “Faster r-cnn: Towards real-time object detection with region proposal networks,” NIPS, 2015.
- [3-11] K. He, et al., “Deep residual learning for image recognition,” in Proc. IEEE Comput. Vis. Pattern Recognit., Jun. 2016.

4章参考文献

- [4-1] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks,” in Proc. Adv. Neural Inf. Process. Syst., vol. 25. 2012, pp. 1097–1105.
- [4-2] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” arXiv preprint arXiv:1409.1556, 2014.
- [4-3] C. Szegedy et al., “Going deeper with convolutions,” CVPR, 2015.
- [4-4] S. Ren et al., “Faster r-cnn: Towards real-time object detection with region proposal networks,”

NIPS, 2015.

- [4-5] K. He, et al., "Deep residual learning for image recognition," in Proc. IEEE Comput. Vis. Pattern Recognit., Jun. 2016.
- [4-6] W.Liu et al., "SSD: Single Shot Multibox Detector," ECCV2016, pp.21-37, 2016
- [4-7] J. Golson. (19 October 2016) Tesla's new autopilot will run in 'shadow mode' to prove that it's safer than human driving. Verge. [Online]. Available:
<https://www.theverge.com/2016/10/19/13341194/tesla-autopilot-shadow-mode-autonomous-regulations>
- [4-8] L.F.Capretz, S.Liu, "An Analysis of Testing Scenarios for Automated Driving Systems," [Online]. Available:
<https://ir.lib.uwo.ca/cgi/viewcontent.cgi?article=1197&context=electricalpub>, 2021
- [4-9] C. Szegedy et al., "Going deeper with convolutions," CVPR, 2015.
- [4-10] S. Ren, K. He, R. Girshick and J. Sun, "Faster r-cnn: Towards real-time object detection with region proposal networks," NIPS, 2015.
- [4-11] K. He, et al., "Deep residual learning for image recognition," in Proc. IEEE Comput. Vis. Pattern Recognit., Jun. 2016.
- [4-12] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.Y. Fu, et al., "SSD: Single Shot Multibox Detector," ECCV2016, pp.21-37, 2016
- [4-13] J. Redmon and A. Farhadi, "YOLOv3: An incremental improvement", 2018.
- [4-14] G. Jocher, "YOLOv5", 2020, [online] Available: <https://github.com/ultralytics/yolov5>.
- [4-15] T. Sugirtha and M. Sridevi, "Semantic Segmentation using Modified U-Net for Autonomous Driving," 2022 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)
- [4-16] R. Anantharaman, M. Velazquez and Y. Lee, "Utilizing Mask R-CNN for Detection and Segmentation of Oral Diseases", 2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM), pp. 2197-2204, 2018.
- [4-17] C. Liu, H. Gao and A. Chen, "A Real-Time Semantic Segmentation Algorithm Based on Improved Lightweight Network," 2020 International Symposium on Autonomous Systems (ISAS)
- [4-18] S. Han, H. Mao, W. J. Dally, "Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding," 2016, <https://arxiv.org/abs/1510.00149> (online).
- [4-19] J.H. Luo and J. Wu, "An entropy-based pruning method for cnn compression, " CoRR, abs/1706.05791, 2017.
- [4-20] D. Murata, T. Motoya, and H. Ito, "Automatic CNN Compression System for Autonomous Driving," 2019 18th IEEE International Conference On Machine Learning And Applications

(ICMLA).

- [4-21] A. Kitayama, G. Ono, and H. Ito, “Edge Device Verification Techniques for Updated Object Detection AI via Target Object Existence Detector,” The 20th IEEE Autonomous and Trusted Vehicles Conference (ATC 2023)

研究成果一覧

A. 研究論文

1. Akira Kitayama, Akira Kuriyama, Hideyuki Nagaishi, Hiroshi Kuroda, “High-Density Implementation Techniques for Long-Range Radar Using Horn and Lens Antennas,” IEICE TRANS. ELECTRON., VOL.E104–C, NO.10 OCTOBER 2021, Special Section on Microwave and Millimeter-Wave Technologies
2. Akira Kitayama, Goichi Ono, Tadashi Kishimoto, Hiroaki Ito, “Low-Power Implementation Techniques for Convolutional Neural Networks Using Precise and Active Skipping Methods,” IEICE TRANS. ELECTRON., VOL.E104–C, NO.7 JULY 2021, Special Section on Solid-State Circuit Design — Architecture, Circuit, Device and Design Methodology
3. Akira Kitayama, Goichi Ono, Hiroaki Ito, “Edge Device Verification Techniques for Updated Object Detection AI via Target Object Existence Detector,” IEICE TRANS. FUNDAMENTAL., accepted for publication. (2024)

B. 国際学会

1. Akira Kitayama, Goichi Ono, Hiroaki Ito, “Edge Device Verification Techniques for Updated Object Detection AI via Target Object Existence Detector,” Conference Paper for The 20th IEEE Autonomous and Trusted Vehicles Conference (ATC 2023)

C. 本研究に関するその他発表および寄稿

1. 北山晃, 永石英幸, 栗山哲, 黒田浩司, 佐々木勲, 「ホーンレンズアンテナを用いた 77GHz レーダによる車両検知」, 2019 年 電子情報通信学会ソサイエティ大会, C-2-82 , (2019 年 9 月)
2. 北山晃, 永石英幸, 栗山哲, 黒田浩司, 佐々木勲, 「ホーンレンズアンテナを用いた 77GHz レーダにおける方位推定精度向上の一検討」, 2020 年 電子情報通信学会総合大会, C-2-60, (2020 年 3 月)

神戸大学博士論文「車載向けエッジ機器の高性能化と社会実装に関する研究」全 97 頁

提 出 日 2024 年 1 月 15 日

本博士論文が神戸大学機関リポジトリ **Kernel** にて掲載される場合、掲載登録日（公開日）はリポジトリの 該当ページ上に掲載されます。

© 北山 晃

本論文の内容の一部あるいは全部を無断で複製・転載・翻訳することを禁じます。