

| | |
|---------|--|
| 氏 名 | FUENGFUSIN NINNART (タイ) |
| 学位の種類 | 博 士 (工学) |
| 学位記番号 | 生工博甲第 4 1 9 号 |
| 学位授与の日付 | 令和 3 年 9 月 2 4 日 |
| 学位授与の条件 | 学位規則第 4 条第 1 項該当 |
| 学位論文題目 | Mixed-precision weights network for field-programmable gate array (Field Programmable Gate Array での実装に適した混合精度 重みモデルに基づくニューラルネットワーク) |
| 論文審査委員会 | 委員長 教 授 田 中 啓 文 " 田 向 権 " 森 江 隆 准教授 大 川 猛 |

学 位 論 文 内 容 の 要 旨

本論文では、Field Programmable Gate Array (FPGA) での実装に適した、2 値、3 値、16 ビット浮動小数点演算を組合せた Mixed-precision weights network (MPWN) を提案している。提案手法では混合精度の組合せを、ネットワークの認識精度、スパース度、ビット量をスコアとし、そのトレードオフをベイズ最適化により探索することで、例えば認識精度の低下を抑えながらビット量を大幅削減可能な構成を実現できることを示しており、ソフトウェア、FPGA 実装の両面でその有効性を示した。

本論文の構成は以下の通りである。

第 1 章では、序論として、本論文の研究背景、目的、問題点が述べられている。特に、エッジ機器で Deep Neural Network (DNN) を動作させる際の問題点として、演算量やメモリ量のことが取り上げられており、これらを削減しないとエッジ機器での動作は困難であることが述べられている。また、デバイスとして Graphical Processing Unit (GPU) と FPGA の比較がなされており、消費電力の面から FPGA が優位であるものの、FPGA では浮動小数点演算が取り扱いにくいいため、この削減が重要であることが述べられている。これらの問題点を解決するために、本論文の目的として MPWN を提案することが述べられている。また、本論文の貢献と構成が簡潔にまとめられている。

第 2 章では、背景として、DNN の構造や演算手法など、本研究における基本的な知識を説明している。また、FPGA や高位合成での設計法についても触れられている。

第 3 章では、本研究の関連手法として、DNN の量子化モデルに関して詳しく述べられている。特に、提案手法のベースとなる BinaryConnect, Ternary Weight Networks に関して詳しい説明がなされており、また、FPGA 向けの量子化モデルの設計ツールな

どが紹介されている。

第4章では、MPWNの提案とそのFPGAデザインについて述べられている。まず、2値、3値、16ビット浮動小数点演算の特徴について、ネットワークの認識精度、スパン度、ビット量の観点からまとめられている。次に、それらの総合スコアとしてABSという新たなネットワークの評価指標を導入している。ABSスコアが高い混合精度の組合せを見つけることが出来れば、高い認識精度で軽量なネットワークを実現できる。しかし、3つの重みモデルの組合せを全探索するためには、N層のDNNの場合、 $O(3^N)$ の組合せの探索が必要となり現実的ではない。そこで提案手法では、いくつかのルールを導入することで探索範囲を限定した上で、ベイズ最適化によりABSのスコアを最大化する。これにより、現実的な時間内に、バランスのとれたネットワークを探索できることが示されている。さらに本章では、複数精度間、例えば16ビット浮動小数点数と3値での乗算などで、効率的な演算が可能な論理回路についての提案がなされている。

第5章では、実験結果と議論について述べられている。まず、ソフトウェアシミュレーションとして、Fashion-MNIST, CIFAR10 および ILSVRC2012 (ImageNet) データセットを用いた結果が示されている。Fashion-MNIST を用いた実験では、LeNet-5 と呼ばれる比較的浅い5層のネットワークにおいて、全重みの組合せ 3^5 の全探索と、提案手法による探索で得られたネットワークを比較することで、提案手法の妥当性を示している。ベイズ最適化によるABSスコアの変動などが解析されており、提案手法のメカニズムを理解するうえで重要な結果が述べられている。CIFAR10 を用いた実験では、ResNet-18 という深層のネットワークの探索が行われており、良好な結果が得られている。さらに、ここで得たネットワーク構造にて、超大規模データセットであるImageNetを学習させることに成功している。次に、FPGA実装に関して、まず、複数精度間での演算を効率化する提案回路の論理合成結果が示されており、従来回路と比べて非常に少ない回路規模で実現できることが述べられている。この手法を用いてLeNet-5をFPGA実装し、関連研究との比較を行っている。以上、ソフトウェア、ハードウェアの両面から提案手法の有効性が示されている。

第6章は、本研究のまとめである。本論文が達成した項目、議論、今後の展望について述べられている。

学位論文審査の結果の要旨

本論文に関し、論文審査委員から、ABSスコアの構成要素や正規化の方法、ベイズ最適化において導入されたルールの妥当性といった理論的側面の質問や、高位合成による提案回路の実現方法といった回路的側面の質問が多数なされたが、いずれも著者の明快な説明により質問者の理解が得られた。

公聴会は現地（発表者、および、学内審査委員のみ）と遠隔のハイブリッド形式にて開催した。遠隔開催が主であるため、公聴会の予告は、各種WEB、メール、Facebook

などを通して広く行い、発表は ZOOM および YouTube Live で公開した。その結果、学内外より合計 37 名の出席があった (YouTube のリアルタイム視聴者を含む)。

質疑では、他の量子化ベースの学習方法との違いや、DNN フレームワークを用いて浮動小数点数を固定小数点数化することで提案手法の更なる改良の可能性があるのかどうか、また、FPGA 以外のデバイスでの提案手法の有効性、といった質問が多数なされたが、いずれも著者の明快な説明により質問者の理解が得られた。

以上により、論文審査及び最終試験の結果に基づき、審査委員会において慎重に審査した結果、本論文が博士 (工学) の学位に十分値するものであると判断した。