

# 22nm 製程下全數位 6T SRAM 記憶體內運算巨集於 Resnet - 20 中的邊緣運算

All-digital 6T SRAM-based In-Memory Computing (IMC) macro in 22nm technology for edge computing in ResNet-20 machine learning applications

指導教授: 王進賢 特聘教授 專題生: 林宇恩、吳明和、陳宥炘、翁嘉櫻、潘弘恩

## 研究摘要

傳統的計算架構(如 CPU、GPU)採用馮紐曼架構,需要在記憶體和運算單元之間傳輸數據。再者,深度學習涉及大量數據處理,使得資料傳輸速度比計算速度慢許多,導致時間和功耗的浪費。為了解決這個瓶頸,提出了「記憶體內運算」(IMC)的新架構。在 IMC 中,SRAM 同時作為記憶體和運算單元,讓計算和記憶體操作可以同時進行。相比傳統的馮紐曼架構,IMC 在性能和功耗上有明顯的改進,本次專題在操作電壓為 0.72V 且未加入動態電壓調節技術的情況達到 56.6 Tops/W 與 0.68 Tops/mm<sup>2</sup>之功耗表現。

專題中選擇 ResNet-20 網路,將數據大小相似的卷積層替換為 IMC 架構。本研究參考了台積電團隊在 2021 年發表於 ISSCC 期刊的 IMC 電路設計,使用 6T SRAM 和 NOR 開建立新的記憶體內運算電路,以及 2018 年 IEEE/CVF 計算機視覺與模式識別會議中的量化論文。

## 卷積層選擇介紹

由於在考量 IMC macro 硬體大小時以論文中提供的架構為優先,因此選定 ResNet-20 中資料數量與步伐(stride)最適合之卷積層:




圖 1、卷積層架構與對應資料之大小

## 研究局部設計

### Input / Weight SRAM

我們依次從上到下提取輸入激活位元,使我們能在 8 個周期內提取並計算與 kernel 卷積的 144 個輸入激活,並將一個 kernel 中 144 個 8 位元權重分為前 4 位和後 4 位,分別存放在兩個 IMC 陣列中:




圖 2、SRAM 對應資料數量之大小設計

### Sub IMC macro

#### IMC array

將 6T SRAM 中儲存的數值與 NOR gate 在迪摩根定律的應用下與 Input 相乘。並將此單元擴展成 144 列,每列四個計算單元的 IMC array。




圖 3、6T SRAM 與 NOR 之電路




圖 4、6T SRAM 與 NOR 之 layout

#### Adder tree

將 IMC array 的輸出使用 28T 全加器進行樹狀相加,並判斷是進行有號或無號的運算:




圖 5、144 inputs adder tree 架構

## Accumulator

運用 Robertson algorithm 進行逐位累加,過程中運用 counter 來將 accumulator 中累積的數值清空:




圖 6、accumulator 架構圖

## PTSQ

透過調整模型的輸入激活值和權重值的表示範圍,將浮點運算轉換為整數運算,以實現模型壓縮和推論加速。透過 zero point(Z)與 scaling factor ( $M_0 \cdot 2^{-N}$ ),將運算式寫為:

$$\text{Data after PTSQ} = \text{Data before PTSQ} \cdot (M_0 \cdot 2^{-N}) + Z$$

將權重值與輸入激活值提前量化,並把量化後的結果輸出至 output SRAM 中。

## 實作結果




圖 7、IMC macro layout

規格與功能	文獻[1]	實際實現
Input activation	1~8bits	8bits
Weight bits	4,8,12,16	8
Signed and unsigned	Signed and unsigned	signed
Dynamic Voltage Scaling	Yes	No
MAC unit	256*64	144*64
Adder tree	28T and 14T	28T
Concurrent weight update function & MAC operation	Yes	No
F <sub>max</sub>	100MHz@0.8/0.72V	50MHz@0.72V
Tops/W of single macro	unknown	66.5
Tops/ mm <sup>2</sup> of single macro	unknown	2.42
Total Tops/W	89	56.6
Total Tops/mm <sup>2</sup>	16.3	0.68

圖 8、實作結果與文獻[1]之數據比較圖

## 結論

分析了 IMC 的功耗,結果顯示在 0.72V、40°C 下,我們的設計達到 56.6 Tops/W 和 0.68 Tops/mm<sup>2</sup>。雖然低於文獻中提到的 89 Tops/W,但我們找出了功耗優化不足和架構差異等原因。未來計劃引入動態電壓調節、優化加法樹結構和佈局設計,以提升系統性能,期望接近或超越現有的研究成果。

## 參考文獻

- [1] Y. -D. Chih et al., "16.4 An 89TOPS/W and 16.3TOPS/mm<sup>2</sup> All-Digital SRAM-Based Full-Precision Compute-In Memory Macro in 22nm for Machine-Learning Edge Applications," 2021 IEEE International Solid-State Circuits Conference (ISSCC), San Francisco, CA, USA, 2021, pp. 252-254
- [2] Jacob, Benoit et al. "Quantization and Training of Neural Networks for Efficient Integer-Arithmetic-Only Inference." 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (2017): 2704-2713.