

節能系統設計 ↗ 低功耗運算核心

捨棄加速器！Tensilica 獨立自含式 DSP IP 更有效率

■文：任茲萍

網路直播的浪濤洶湧，數千人同時在線上閱聽影音內容已屬司空見慣，行動終端的運算能力亦須跟上時代，視覺串流的處理尤其備受關注；加上監控和穿戴式裝置以全年無休的「不斷線」(always-on)為發展職志，若無法壓低功耗，電力恐撐沒多久就玩完了。一般保全監控視訊、汽車光達(LiDAR)/雷達、無人機和感測器融合等應用的視覺系統需要兩種優化運算：首先，運用傳統運算攝影/成像演算法對來自攝影機的輸入進行強化，其次，由神經網路的辨識演算法執行物體偵測和辨識。為達極致省電目的，從「IP核心」根本革新有其必要性。

不只卷積層！突破 NN 引擎加速器極限，Vision C5 可加速所有運算架構

神經網路(NN)已成深度學習顯學，但運算極具挑戰。益華電腦(Cadence)旗下 Tensilica 新近發佈的 Vision C5，顛覆同業在影像數位訊號處理器(DSP)綑綁「NN 硬體加速器」(accelerator)的作



照片人物：Cadence Tensilica 處理器事業群資深總監 Steve Roddy

法，是業界首款真正專為 NN 獨立運作而生、被稱為「獨立自含式」的 DSP IP。Cadence Tensilica 處理器事業群資深總監 Steve Roddy 指出，早先 DSP+NN 引擎的方式乃將神經網路編碼分割處理，不斷在 DSP 的網路層與加速器的卷積層之間加載、卸載，而將其他層級的運算工作全數丟給主要 DSP/CPU/GPU 一肩獨攬。

「如此一來，不僅執行效率不佳、且會造成不必要的耗電」，Roddy 直戳 DSP+NN 引擎的痛

點。他深入解說，如果 NN 架構的神經元(Neurons)數量增加，其間鍵結也會隨之平方增加；若利用硬體加速 NN 的運算速度，所需硬體結構的複雜度將大幅增加而變得不容易實現。相較之下，新款 Vision C5 所建構的「通用型」神經網路 DSP，可加速所有神經網路運算架構，包括：卷積(Convolutions)、全連接(Fully connected)、池化/取樣(Pooling)及標準化(Normalization)，以精算「型態辨識」(Pattern recognition)與相鄰

資料間的關係。

Roddy 觀察到 CNN 演算法有三大發展趨勢：1. 近來不到四年的時間，運算需求狂增十六倍；2. 網路架構趨於規律化，層次分明——例如，AlexNet 適用於規模較大的卷積運算、ResNet 適用於規模較小者，以及線性 (Linear) 或分支 (branch) 運算；3. 新應用層出不窮，遍及汽車、伺服器、家庭語音助理、手機及監控等，並強調：「非卷積演算」因鏈結關係相對簡單，運算次序無傷大雅，硬體加速器尚可應付；但若是具有綿密而複雜的對應關係、須步步為營的 CNN，邏輯一旦錯位，這些次序不明確且無法判讀意義的資料會讓網路混淆。

兼顧 Always-On 低功耗與 Heavy-Duty 高運算需求


他進一步表示，「除了低功耗和高速運算，嵌入式 always-on 系統的神經網路處理器還需具備靈活性和因應未來需求的能力；而 Vision C5 藉由消除神經網路 DSP 與主要視覺 / 影像 DSP 之間的外來資料移動，提供較 NN 加速器、

GPU 和 CPU 更低功耗的解決方案及簡單的 NN 編程模型」。至於近年坊間出現的「視覺處理器」(VPU) 變種產品，Tensilica 的看法是：VPU 須用更多硬體才能實現同等的效能，將會導致整體功耗變高，亦非理想方案。簡言之，神經網路獨立運算可降低 DSP 負載，同時免去與主要 DSP 頻繁往返的疲於奔命。

於是，負責操持大局的視覺 / 影像 DSP 便能騰出更多資源、專注執行影像應用程式，將所有神經

網路運算交由同樣擁有完整戰力的 Vision C5 DSP 全權處置，分工合作。Tensilica 透露他們另一個實現低功耗的秘訣是：應對「重量級任務」(Heavy-Duty) 是以很大的運算單元一次搞定，之後便完全停工；經實驗結果證明，這將會比用大量平行運算、以低時脈分批運行的方式省電。「更重要的是，Vision C5 DSP 具備可編程和可擴展特性，易於整合。此時此刻所選定的介接硬體平台，將決定兩、三年後的產品銷售格局！」Roddy 重申。

圖 1：Tensilica Vision C5 DSP 框圖



資料來源：Cadence 官網

表：可在嵌入式系統中執行神經網路的方案比較

	CPU	GPU	NN 硬體加速器	視覺 / 影像 DS	★ Vision C5 DSP
開發容易程度	■ 純軟體 ■ IP 易獲取	■ 純軟體 ■ IP 易獲	硬體在試產瞬間已定，CPU/GPU/DSP 軟體必須在不同的可編程與加速器之間切割	■ 純軟體 ■ IP 易獲取	■ 純軟體 ■ IP 易獲取
功耗效率	最差	較 CPU 佳，但仍偏差	個別層級最佳，但全部加總後則不然	效率是 GPU 的 5~10 倍	較 DSP+NN 硬體加速器組合更佳
未來發展	可重新編程	可重新編程	難以重新編程，高風險	可重新編程	可重新編程
單一核心最大 NN 效能 (/sec)	<< 200 GFLOP (每秒浮點運算次數)	< 200 GFLOP (每秒浮點運算次數)	最高至 1 TMAC	200~250 GMAC	最高至 1 TMAC，但可擴充


資料來源：Cadence (Tensilica)；筆者整理

他並提到，神經網路的工作量會因終端市場大相逕庭，例如，手機每秒的吞吐量多在 200 GMAC (Giga Mac) 以下，但保全監控和汽車半自動駕駛由於 4K 高清畫質的帶動、以便易於辨識，就上看 1 TMAC (Tera MAC) 左右，若是全自動駕駛的無人車，則至少 10 TMAC 起跳！「因此，效能指標不是越高越好，擴充的靈活度更應列入優先考慮，只有一種規格是無法跟上市場變化腳步的」，Roddy 解釋。這多少也揭示為何 Tensilica 首發產品，是選擇從每秒 1 TMAC 的運算能力著手 (以 16nm 製程、在不到 1 mm² 的晶片面積實現)，或許正是抓取中間值而來。

Cadence 對映器工具組加持，編程及擴展皆唾手可及


根據 Tensilica 發佈的資料顯示，Vision C5 DSP 支援 1024

圖 2：Cadence 神經網路對映器工具組 (Mapper Toolset) 提供標準的開源 CNN 框架，將資訊流導入 CNN 映射器直抵 Vision C5 DSP



資料來源：Cadence 官網

圖 3：Cadence Tensilica Vision 系列 DSP 所側重的應用市場各有不同



資料來源：Cadence 官網

個 8 位元 MAC 或 512 個 16 位元 MAC，兩種位元解析度均能實現優異效能，與 GPU 相比並不遜色；要比知名 AlexNet CNN 效能基準快六倍、更是 Inception V3 CNN 效能基準的九倍！若仍力有未逮，其「平台式」的多處理器設計支援可變核心大小、深度和輸入尺寸，亦能提供數個 TMAC 的高效能。它還包含多種係數壓縮 / 解壓技術，可隨時加入最新開發的層體，為日後所需預留空間；反觀硬體加速器因重新編程的能力有限，將來若想「平滑過渡」，最壞的局面恐須全部從頭來過！

在指令集方面，Vision C5 DSP 擁有 128 路 8 位元 SIMD 或 64 路 16 位元 SIMD 的 VLIW SIMD 架構；另整合 128 位元的 iDMA 及 AXI4 記憶體介面；其附帶的 Cadence 神經網路對映器工具組可運用神經網路程式庫功能，將所有 Caffe 和 TensorFlow 等主流框架生成的神經網路，對映成可執行且高度優化的 Vision C5 DSP 編碼。Roddy 及隨機受訪的愛用

者皆不諱言，這正是 Tensilica 與 Cadence 合併的最大優勢：縮短學習曲線並簡化認證作業，讓程式碼更容易移植、編程更容易上手。

特別是新推出的 Vision C5 DSP 與 Tensilica 自身的 Vision P5/P6 DSP 採用相同的實用軟體工具組，更有助於產品及時上市。在 DSP 授權市場連年奪冠的 Tensilica，授權用戶約 250 家；全球前二十大半導體廠、就有多達十七家皆是其用戶，每年全球 IC 出貨總量約 40 億顆，在音訊 DSP 市場更是堪稱獨領風騷。事實上，除了視覺的高清辨識需要，聽覺的娛樂饗宴亦從未缺席；搭配人工智能 (AI) 演算法的語音控制系統以及具有指向性的 3D 立體聲，有朝一日甚至能有更多功能性的應用。

隨著影音浪潮的無孔不入，借助神經網路架構的機會預料將有增無減；在特定應用 DSP IP 佈局甚深、掌握專業知識的 Tensilica 有了 Cadence 集團資源加持，對於開發高效率的指令集將可獲得最實質的挹注，繼續發光發熱。 CTA