

手寫辨識與超解析度模型之CNN架構與量化優化分析

學生:唐妃儀


指導教授:黃崇勛

摘要


本研究探討卷積神經網路(CNN)於手寫數字辨識與影像超解析度(FSRCNN)的應用。手寫辨識部分，先以多層感知器(MLP)為基準，再與CNN比較，驗證其在特徵提取與辨識效能上的優勢。於FSRCNN模型中，導入ReLU、Depthwise Separable Convolution與Batch Normalization，以降低參數並提升訓練穩定性。最後實作後訓練量化(PTQ)，證明模型在大幅壓縮體積後，仍能維持近乎無損的輸出品質，展現CNN於影像任務的應用潛力。

研究方法


在手寫數字辨識實驗中，本研究先建立多層感知器(MLP)作為基準模型。輸入的MNIST影像需展平成784維向量，再經全連接層進行分類。此架構雖能達到基本辨識效果，但缺乏空間特徵利用。為提升效能，進一步引入卷積神經網路(CNN)，透過卷積與池化層保留二維結構與局部特徵，最後接入全連接層輸出分類結果。整體流程可分為三步驟：MNIST輸入→MLP基準→CNN架構比較。



圖一、MLP訓練流程



圖二、MLP概念性架構



圖三、本次專題實作之CNN架構圖

在影像超解析度任務中，本研究採用FSRCNN作為主要架構，流程分為三部分：①特徵提取，以卷積層將低解析度影像轉換為特徵圖；②中間映射，透過 1×1 與 3×3 卷積進行壓縮與特徵轉換，最後再以 1×1 還原維度；③上採樣重建，以反卷積生成高解析度影像。為提升效能，設計上引入ReLU取代PReLU以降低計算量，使用Depthwise Separable Convolution減少參數，並加入Batch Normalization提升收斂穩定性。此外，實作後訓練量化(PTQ)，將模型轉換為整數運算格式，以利壓縮與部署的形式。

模組名稱	包含層數
特徵提取 (Feature Extraction)	Conv2d(1→56, 5x5) + PReLU(56)
中間映射層 (Mapping/Mid part)	Shrinking+4×Mapping + Expanding+對應的PReLU
上採樣重建 (Upsampling/Last part)	ConvTranspose2d(56→1, 9x9, stride=4)

圖四、FSRCNN架構模型

原始設計	量化調整後對應	說明
使用 PReLU 激活	替換為 ReLU	PReLU 不支援量化，會導致 PyTorch fuse 出錯
Conv2d + ReLU	融合為 QuantizedConvReLU2d	符合 PTQ fuse 流程，可減少運算與記憶體使用
ReLU 被 fuse，無 Identity	加入 Identity() 層佔位	保持原始層級索引不變，便於還原與 debug

圖五、改良設計表

模組名稱	包含層數(量化前)	包含層數(PTQ 量化後)	功能說明
特徵提取 (Feature Extraction)	Conv2d(1→56, 5x5) + PReLU(56)	QuantizedConvReLU2d(1→56)+ Identity()	把低解析度圖像轉成高維特徵圖
中間映射層 (Mapping/Mid part)	Shrinking+4×Mapping + Expanding+對應的PReLU	6×QuantizedConvReLU2d+ 6× Identity()	對特徵圖進行通道壓縮、非線性映射與展開，提取高層抽象特徵
上採樣重建 (Upsampling/Last part)	ConvTranspose2d(56 → 1, 9x9, stride=4)	QuantizedConvTranspose2d(56 → 1, 9x9)	將中間特徵圖重建為高解析度輸出圖像 (Super Resolution)

圖六、量化前VS量化後FSRCNN架構模型表

研究結果

實驗結果顯示，MLP在30個Epoch後的準確率約為96%，能正確辨識大部分手寫數字，但受限於展平輸入的設計，無法有效利用影像的空間特徵，導致表現有瓶頸。相較之下，CNN藉由卷積層擷取邊緣等局部特徵，並透過池化層降低維度與雜訊，在測試集上的準確率提升至98%，優於MLP。在模型複雜度方面，MLP需要71,582個參數，而CNN僅需9,550，參數量大幅減少，記憶體需求也更低，展現出模型壓縮與資源效率的優勢。然而，由於卷積涉及大量乘加運算，CNN的MACs增加至120,885，遠高於MLP的23,865。這顯示CNN雖在效能與準確率上具優勢，但必須承擔更高的計算成本。整體來看，MLP適合在計算資源有限、追求簡單架構的情境；而CNN更適合需要高精度的影像任務，兩者各自展現不同的應用價值。

```
Epoch 27/30
1500/1500 - 2s 1ms/step - accuracy: 0.9562 - loss: 0.1311 - val_accuracy: 0.9635 - val_loss: 0.1362
Epoch 28/30
1500/1500 - 1s 948ms/step - accuracy: 0.9564 - loss: 0.1346 - val_accuracy: 0.9624 - val_loss: 0.1444
Epoch 29/30
1500/1500 - 2s 1ms/step - accuracy: 0.9563 - loss: 0.1350 - val_accuracy: 0.9636 - val_loss: 0.1444
Epoch 30/30
1500/1500 - 2s 1ms/step - accuracy: 0.9601 - loss: 0.1262 - val_accuracy: 0.9656 - val_loss: 0.1393
```

圖七、MLP訓練過程結果

```
Epoch 27/30
1500/1500 - 3s 2ms/step - accuracy: 0.9305 - loss: 0.2099 - val_accuracy: 0.9621 - val_loss: 0.0613
Epoch 28/30
1500/1500 - 3s 2ms/step - accuracy: 0.9317 - loss: 0.2150 - val_accuracy: 0.9627 - val_loss: 0.0605
Epoch 29/30
1500/1500 - 3s 2ms/step - accuracy: 0.9299 - loss: 0.2123 - val_accuracy: 0.9632 - val_loss: 0.0607
Epoch 30/30
1500/1500 - 4s 3ms/step - accuracy: 0.9308 - loss: 0.2193 - val_accuracy: 0.9627 - val_loss: 0.0592
```

圖八、CNN訓練過程結果

Total params: 9,550 (37.30 KB)
Trainable params: 9,550 (37.30 KB)
Non-trainable params: 0 (0.00 B)
Optimizer params: 47,722 (186.42 KB)
MACs: 120885

加入cnn的情況

尚未加入cnn的情況

圖九、MLP與CNN模型複雜度比較

實驗結果顯示，量化前後的FSRCNN在輸出品質上差異極小。輸出影像與原始模型幾乎一致。模型大小則由49.36 KB縮減至12.95 KB，壓縮率達73.8%，大幅降低儲存與傳輸需求。結構上，量化模型將卷積與激活融合為整數運算模組(如QuantizedConvReLU2d)，有效提升運算效率。整體而言，量化後FSRCNN兼顧效能與效率，證明其在嵌入式裝置與資源受限平台上的應用潛力。

模型版本	大小	壓縮率
原始模型	49.36 KB	
量化後模型	12.95 KB	縮減 73.8%

圖十、FSRCNN模型量化前後比較

結論與心得

本研究以手寫數字辨識與影像超解析度為例，驗證卷積神經網路(CNN)在影像任務中的優勢與潛力。與傳統多層感知器(MLP)相比，CNN能保留二維結構並自動擷取局部特徵，使模型更能應對複雜的影像模式，展現出明顯的辨識與表現優勢。在超解析度任務中，本研究選用FSRCNN作為基礎架構，並嘗試多項優化設計，包括激活函數的調整、卷積結構的輕量化，以及正規化技術的導入。這些改良不僅提升了模型的收斂效率，也展現了在效能與運算需求間取得平衡的可行性。進一步實作的後訓練量化(PTQ)則證明，模型在壓縮後仍能維持近乎一致的輸出品質，展現出高度的實用價值。整體而言，本研究強調CNN的核心價值在於其靈活性，透過適當的設計與優化策略，可以針對不同任務調整架構，兼顧效能與效率。未來可將此研究方法延伸至自製資料集或嵌入式應用，進一步驗證其在實務環境中的可行性與應用潛力。