

Reti neurali per il controllo della qualità su frutta e legname

Davide Boschetto, Andrea Busatto, Giancarlo Zane, Enrico Ursella, Mauro Cossi

Microtec GmbH

{davide.boschetto, andrea.busatto, giancarlo.zane, enrico.ursella, mauro.cossi}@microtec.eu

Abstract

I progressi nel campo dell'intelligenza artificiale hanno reso possibile l'integrazione di processi produttivi innovativi nell'ambito dei controlli di qualità, campo in cui la nostra ditta ha una grande esperienza. Usare reti neurali profonde ci ha permesso di migliorare le performance dei nostri scanner industriali, che vengono attualmente utilizzati in ogni continente. In questo contributo presenteremo brevemente le sfide che abbiamo dovuto affrontare per aggiornare i nostri processi produttivi per introdurre la possibilità di usare reti neurali in produzione, ambiente in cui le decisioni devono essere prese quasi in real-time su grandi moli di dati.

1 Introduzione

In ambito industriale, il controllo di qualità di un prodotto è un passo cruciale nella catena produttiva: scanner accurati e performanti permettono ai produttori di mantenere volumi elevati e di affermarsi in maniera affidabile nel loro mercato. Come produttori di scanner, il nostro lavoro richiede di trovare le migliori soluzioni per permettere ai nostri clienti di essere soddisfatti. L'intelligenza artificiale ci ha permesso di migliorare ulteriormente la nostra offerta, grazie al fatto che ora molti problemi non affrontabili con il metodo classico algoritmico sono trattabili con successo, avendo un sufficiente numero di dati etichettati in maniera accurata e coerente. Con persone esperte al timone della ricerca e sviluppo in questo ambito, che mantengano una conoscenza sui training set e sugli iperparametri scelti per allenare ogni rete neurale, è anche possibile motivare al cliente eventuali imprecisioni nelle fasi di test, necessarie prima di ottenere un prodotto completo funzionante con performance da produzione.

2 Framework e Software

Rivalutare lo stato dell'arte in questo campo più volte l'anno è importante, vista l'esistenza di molti framework concorrenti viste le potenzialità e le carenze di ciascuno di essi. Al momento per la parte di training stiamo usando

principalmente Keras e Tensorflow, ma abbiamo usato anche CNTK e PyTorch in progetti precedenti.

3 Campi d'applicazione

A livello architetturale occorrono competenze molto diversificate per poter affrontare i diversi problemi che sono tipici di un ambiente di ricerca in ambito visione artificiale. Classificazione di immagini, riconoscimento d'oggetti o di istanze, classificazione di oggetti o segmentazione semantica sono tutti problemi che richiedono approcci sostanzialmente catalogabili come "deep learning", ma completamente diversi l'uno dall'altro, che richiedono competenze a volte complementari. Nel resto di questo capitolo, toccheremo due di questi problemi (classificazione di immagine e segmentazione semantica, relativi a frutta e legno rispettivamente) descrivendo la nostra esperienza nei settori di applicazioni e i nostri risultati in ciascun campo.

3.1 Classificazione d'immagine – Frutta

In campo frutta, i problemi più frequenti sono la classificazione della qualità di un frutto partendo da una o più viste e la classificazione di un difetto già localizzato. Il valutare la qualità di un frutto è un problema con specifiche stringenti (l'intera classificazione va effettuata prima che ciascun frutto raggiunga il primo espulsore muovendosi sulla catena): in circa un secondo è infatti necessario riconoscere peso, dimensioni, difetti e qualità del frutto nella sua interezza. Questa classe di problemi è la più




Figura 1: Datteri, mele e olive di diverse classi, a seconda delle caratteristiche globali o difetti locali.




Figura 2: Esempi di difetti superficiali di agrumi e avocado.

studiata in ambito visione artificiale: tutta l'esperienza creata sui dataset campione (ImageNet, Cifar10, MNIST, ...) può essere utile per raggiungere performance migliori in questo tipo di produzioni. Ispirandoci ad alcuni dei lavori più famosi [He et al., 2015] [Ronneberger et al., 2015], adattandoli ai nostri scopi ed integrandoli con ulteriori innovazioni (tratte soprattutto dal lavoro della libreria open-source *fastai*), siamo riusciti ad ottenere risultati molto soddisfacenti in ogni contesto. Nel campo delle mele (Fig. 1, in alto a destra) al momento abbiamo in produzione due reti neurali per classificare i tagli nella zona del picciolo e del calice, molto complessi da identificare con tecniche classiche, e per identificare la presenza di foglie (per limitare false rilevazioni di difetti in frutti con foglia). Nel campo dei datteri (Fig. 1, sinistra) utilizziamo reti per valutare la qualità del dattero (in base alla quantità di buccia sollevata) e la sua umidità presso vari clienti. Abbiamo anche esplorato ambienti di produzione con specifiche hardware ristrette (inferenza in visione artificiale real-time senza schede grafiche), in particolare nel campo delle olive (Fig. 1, in basso a destra), per separare le olive rugose o di forma irregolare da quelle normali. Stiamo in questi mesi preparando per la prossima stagione nuove reti per classificare i difetti superficiali degli avocado (fra cui i morsi di topo) e gli agrumi, concentrandoci sulla classificazione del marcio e di vari difetti superficiali complessi da vedere con tecniche tradizionali (Fig. 2). Abbiamo chiaramente l'idea di migliorare ulteriormente ogni approccio e di ampliare la gamma di frutti in cui offrire controlli industriali impiegando AI in produzione.

3.2 Segmentazione – Legno

Quando il problema richiede di classificare ogni pixel di un'immagine, si ricade nel problema della segmentazione. Questo è il problema tipico che abbiamo affrontato nel campo legno, dove abbiamo più maturità come azienda. Il problema può richiedere una segmentazione binaria (presenza o meno di un difetto/classe) o multi-classe (ogni pixel può appartenere a differenti classi). Nella nostra esperienza, i due esempi più esplicativi riguardano rispettivamente l'estrazione dei nodi nelle immagini CT scattate dal CT Log (prodotto che effettua tomografie ai tronchi allo scopo di ottimizzare il pattern di taglio per massimizzare la resa) e la segmentazione di difetti colore




Figura 3: Tecniche di segmentazione semantica applicate a tomografie di tronchi e tavole di abete con difetti colore.

dovuti alla presenza di muffe (azzurramenti o macchie disomogenee marroni) in tavole scansionate dal nostro prodotto dedicato chiamato GoldenEye. In entrambi i casi, la definizione manuale di feature o algoritmi in grado di ricavare automaticamente la mappa dei difetti (nei tronchi l'umidità e la disomogeneità fra durame e albume cambiano notevolmente, così come il colore relativo fra tavola e tavola e fra segni di essiccamento, legno di compressione, midollo, crepe..) è molto complesso. Le reti neurali, invece, ci permettono di ottenere segmentazioni molto più rifinite ed affidabili rispetto ad algoritmi tradizionali precedentemente testati. Le reti relative alle tomografie sono state sviluppate a partire da circa 10.000 nodi manualmente etichettati su tronchi di pino e abete, mentre le reti applicate alle tavole si basano su circa un migliaio di tavole etichettate. Entrambi i problemi hanno requisiti temporali molto stringenti: le innovazioni in campo GPU fortunatamente ci permettono di migliorare periodicamente le performance dei e i risultati dei nostri algoritmi.

In entrambi i casi la segmentazione non è l'output finale del nostro prodotto, ma viene combinata con algoritmi tradizionali già esistenti per identificare il miglior pattern di taglio di un tronco o la qualità di una tavola.

4 Conclusioni

Approcci basati su intelligenza artificiale in produzione sono ancora piuttosto rari, ma saranno sempre più comuni con il passare degli anni. Pur trattandosi ancora di soluzioni quasi riservate ai settori R&D (in quanto in continua evoluzione), framework interni integrati in maniera trasparente a prodotti già esistenti possono essere di grande aiuto per la trattazione più precisa ed affidabile di problemi difficilmente affrontabili con approccio classico.

Riferimenti bibliografici

- [He et al., 2015] K. He, X. Zhang, S. Ren, J. Sun. *Deep Residual Learning for Image Recognition*. <http://arxiv.org/abs/1512.03385>, 2015.
- [Ronneberger et al., 2015] O. Ronneberger, P. Fischer, T. Brox. U-Net: Convolutional Networks for Biomedical Image Segmentation, <https://arxiv.org/abs/1505.04597>, 2015.