

Deep Learning per il controllo qualità estetico in ambito industriale

Riccardo Rosati, Luca Romeo, Emanuele Frontoni, Gianalberto Cecchini, Flavio Tonetto

VRAI, Department of Information Engineering Università Politecnica delle Marche,

VRAI, Università di Macerata,

Sinergia Consulenze Srl

{r.rosati, l.romeo}@univpm.it, emanuele.frontoni@unimc.it, {gcecchini, ftonetto}@sinergia.it

Abstract

Oggi in ambito industriale si fa largo uso di strumenti di visione per l'automazione delle procedure di controllo qualità che si concentrano sull'analisi quantitativa e deterministica di un prodotto, al fine di assicurare che sia conforme ai requisiti espressi dal cliente, come ad esempio il controllo dimensionale o l'ispezione della rugosità dei materiali. Tuttavia, gli attuali strumenti software non consentono una modellazione e/o una generalizzazione di tutte quelle analisi qualitative in cui si vuole, invece, determinare il grado di qualità di un prodotto inteso come livello di pregio del materiale, ad esempio secondo canoni estetici. L'approccio di Deep Learning proposto ed integrato all'interno di un decision support system ha come obiettivo quello di replicare il comportamento umano nelle operazioni manuali di controllo qualità non metriche, ma qualitative (e.g. qualità estetica di marmi, legni e cuoio al fine di differenziarne la qualità estetica e il suo conseguente valore commerciale).

1 Introduction

Nel contesto dell'Industria 4.0, la crescente disponibilità di dati, i progressi nella potenza dei computer e le scoperte nello sviluppo di algoritmi hanno portato le metodologie di Intelligenza Artificiale (AI) a soluzioni appetibili in diversi ambiti industriali come la manutenzione predittiva [Sakib e Wuest, 2018; Calabrese *et al.*, 2020], il sistema di supporto alle decisioni [Romeo *et al.*, 2020] e il controllo qualità [Cadavid *et al.*, 2020; Escobar e Morales-Menendez, 2018; Wang *et al.*, 2018]. In particolare, un'area in crescita in questo scenario è la fase di QC, che è un passaggio fondamentale per rilevare problemi di produzione e per classificare la conformità del prodotto finito. L'applicazione di tecniche di Machine Learning (ML) e Deep Learning (DL) offre grandi opportunità per automatizzare l'intero processo di QC, risparmiando tempo e risorse e massimizzando le performance, pur generalizzando facilmente in diversi contesti. A riprova di ciò, queste metodologie per il compito QC sono state impiegate in diversi domini, come l'industria tessile e dei tessuti [Li *et al.*, 2017; Lee *et al.*, 2018; Fu *et al.*, 2019], l'industria della stampa [Villalba-Diez *et al.*, 2019], prototipo di fabbrica intelligente [Ozdemir e Koc, 2019], produzione additiva basata sul laser [Francis e Bian, 2019], produzione di massa di saldature [Muniategui *et al.*, 2019] e industria automobilistica [Peres *et al.*, 2019; Iqbal *et al.*, 2019]. Tutte queste soluzioni si concentrano su analisi quantitative e deterministiche: il controllo dimensionale, l'ispezione della rugosità dei materiali, il rilevamento dei difetti del tessuto modellato e il test dei parametri di produzione sono tutte procedure di valutazione misurabili. Tuttavia non esiste ancora uno strumento software che permetta la modellazione di tutte quelle analisi qualitative che sono strettamente dipendenti dall'uomo, come la valutazione estetica di un materiale.

Per questo motivo, si propone l'applicazione di una metodologia DL in un'applicazione di controllo qualità: in questo lavoro l'obiettivo è quello di fornire la classificazione della qualità estetica dei calci di fucile basata sull'analisi delle venature del legno in modo completamente automatizzato. Tuttavia, anche se il potenziale dei metodi di DL per apprendere i modelli discriminatori è molto rilevante, l'incapacità di rilevare bias dai dati e il rischio di riprodurre questo bias nel risultato del modello DL pongono un punto notevole e irrisolto nello scenario di Industria 4.0.

Partendo da queste considerazioni e originato da una specifica richiesta aziendale, l'obiettivo del paper è quello di progettare e sviluppare una metodologia di DL, specificamente fatta su misura per (i) fornire la classificazione della qualità estetica dei fucili basata sull'analisi delle venature del legno e (ii) rilevare e mitigare i bias indesiderati nei dati raccolti e nel risultato del modello DL.

Quindi i principali contributi del lavoro nello scenario dell'Industria 4.0 sono riassunti di seguito:

- la raccolta di dataset reali annotati specificamente su misura per risolvere la classificazione della qualità estetica dei fucili basata sull'analisi delle venature del legno;
- la proposta di un approccio DL basato su VGG-16
- la validazione dell'algoritmo proposto rispetto alle prestazioni di un annotatore umano e l'integrazione in un sistema di supporto alle decisioni.

2 Materials

Il banco di acquisizione (Figura 1) è composto da un sistema hardware di acquisizione basato su camere e lampade, che co-

stituiscono il banco di misura per l'ispezione automatica, un sistema software di annotazione dei dataset di addestramento e un sistema di intelligenza artificiale basato su reti neurali profonde (VGG-16) che, dopo l'addestramento, effettuerà la valutazione estetica del campione.




Figura 1: Banco di misura per l'ispezione controllo qualità

Il banco di misura costituisce il vero e proprio apparato hardware ed è composto da:

- camera RGB di tipo industriale;
- illuminatore a LED;
- schermo di protezione luce ambientale;
- PC per l'annotazione.

2.1 Software di annotazione

Le caratteristiche fondamentali del software di annotazione sono 3:

- Anagrafica livelli: definire i livelli qualitativi su cui verrà addestrato l'algoritmo DL e di conseguenza i livelli su cui l'algoritmo addestrato effettuerà la predizione. I livelli vengono archiviati sul sistema nel database di lavoro.
- Addestramento: raccogliere e archiviare le immagini del dataset annotato. Il software, una volta posizionato l'articolo sul banco di misura, consente di avviare l'acquisizione fotografica e rimane in attesa dell'indicazione da parte dell'operatore del livello anagrafico a cui l'immagine acquisita corrisponde (annotazione). Le immagini vengono archiviate nel file system sotto forma di file png e associate al tag di annotazione (comprensivo di data e ora di raccolta) su database.
- Running: questa è la modalità di lavoro operativa del sistema una volta addestrato sulle 3 reti che lo compongono. Il software dopo l'acquisizione della foto da parte dell'operatore è in grado di effettuare la predizione e archiviare le immagini con l'annotazione predetta.

3 Methods

Il workflow dell'algoritmo predittivo consta essenzialmente di 4 fasi (Figura 2):

- Preprocessing

- Estrazione delle features
- 3 modelli in parallelo di Machine Learning-Deep Learning
- Output di classificazione

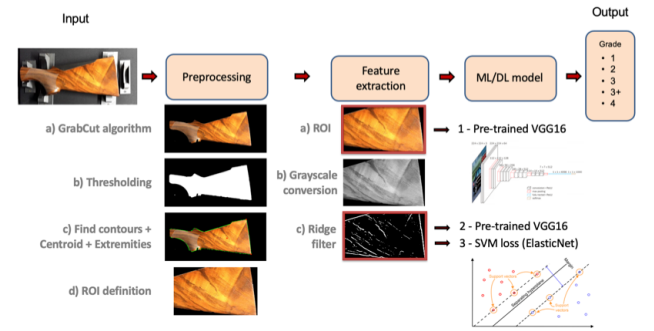


Figura 2: Overview degli algoritmi di ML/DL proposti per il controllo qualità

3.1 Preprocessing

Questa fase è utile ad estrarre in modo del tutto automatizzato una regione di interesse (ROI) dall'immagine di input che sia il più possibile focalizzata sulla parte in legno del pezzo da valutare, in modo da ridurre un possibile bias dovuto alle caratteristiche del relativo modello di fucile (forma, geometria, inserti di plastica, dimensioni, zigrinatura, etc.), concentrandosi solo sulla valutazione estetica del materiale. Per far ciò, sono definiti i seguenti steps:

- Algoritmo di Grabcut: metodo di segmentazione dell'immagine basato su graph cuts, il quale permette di rimuovere il background dell'immagine, ottenendo un ritaglio dell'oggetto di interesse. Parametri da definire: area approssimativa intorno alla regione in primo piano e numero di iterazioni dell'algoritmo (validato a 20 per il sistema in oggetto);
- Thresholding: si ottiene una maschera booleana della regione precedentemente segmentata;
- Algoritmo FindContours: si trovano i contorni della precedente maschera;
- Si calcola il centroide dell'area in base ai punti di contorno definiti;
- Per definire una ROI che sia il più possibile adatta alla parte esclusivamente in legno, è importante capire l'orientazione (lato dx/lato sx) del calcio. L'orientazione viene individuata dall'algoritmo calcolando in quale parte dell'immagine si trova la parte più ampia della maschera e in base alla sua distanza dal centroide. Successivamente, viene definita la ROI come un intorno del centroide.

3.2 Estrazione delle features

La parte di estrazione delle features serve per andare ad individuare quali sono le caratteristiche discriminanti da dare

in pasto agli algoritmi di Intelligenza Artificiale. Dovendo arrivare ad una classificazione quantitativa della qualità estetica del legno, la quale si basa sul pattern delle venature, in questa fase l'obiettivo è proprio quello di mettere in rilievo le proprietà del legname. Quindi, si converte la ROI precedentemente ottenuta in un'immagine in scala di grigi. A questa si applica un filtro Ridge binario (con parametro $\sigma = 2.0$) il quale fornisce un'immagine in bianco e nero che evidenzia le venature.

3.3 Modelli ML/DL

Sulle immagini ROI precedentemente definite, si allenano 3 modelli di Intelligenza Artificiale.

VGG16 su ROI RGB

Nel primo modello, la rete VGG16 è applicata direttamente alle immagini RGB: in questo caso, l'estrazione delle features è lasciata direttamente al modello di DL. La rete VGG16 è un noto modello di rete neurale convoluzionale (CNN) molto applicato nello stato dell'arte. L'architettura della VGG16 è caratterizzata da una relativa semplicità, utilizzando solo 13 strati convoluzionali che estraggono le caratteristiche dell'immagine. Ogni blocco convoluzionale ha filtri con un campo recettivo di 3×3 pixel ed è seguito da una funzione di attivazione ReLU. La riduzione della dimensione del volume è gestita dal max pooling. Infine, tre strati Fully-Connected (FC) seguono lo stack di quelli convoluzionali (per un totale di 16 strati di peso): i primi due hanno 4096 nodi ciascuno, lo strato finale è uno strato softmax che esegue la classificazione dell'output. Diversamente dall'addestramento del modello da zero, si è adottata una strategia di transfer learning per mettere a punto il modello sui pesi già pre-addestrati di ImageNet [2], col fine di migliorare le prestazioni di generalizzazione (considerando le piccole dimensioni del dataset, il vantaggio di questa procedura è ampiamente dimostrato nella letteratura correlata [3]). Per questo motivo, i primi 4 blocchi convoluzionali sono stati congelati e l'ultimo strato Fully-Connected è stato modificato da 1000 (classi in ImageNet) a 5 neuroni, che è la dimensione dello spazio di output per il suddetto task. Gli strati di regolarizzazione di dropout sono stati inseriti dopo il primo e il secondo strato Fully-Connected con un rate di 0,3. Inoltre, le immagini sono state ridimensionate a 224×224 pixel per corrispondere alla dimensione dell'input di ImageNet. Il valore medio è stato rimosso da ogni immagine. Per la procedura di training del modello CNN, abbiamo adottato il gradient descent (con momentum) come ottimizzatore e una Categorical Cross-Entropy come loss. Il numero di epoche è stato impostato a 30. Gli iperparametri sono stati validati in un set di validazione separato usando un approccio grid-search e sono rispettivamente 64 per la dimensione del batch, 0,001 per il learning rate iniziale e 0,8 per il momentum. Il set di dati è stato diviso con una procedura di hold-out stratificato, cioè usando il 60 % delle immagini come training, il 20 % come validazione e il 20 % come test. Le immagini appartenenti allo stesso ID fucile sono state mantenute nello stesso set. Questo controllo è stato eseguito per garantire che l'algoritmo possa essere in grado di generalizzare attraverso diversi calci di fucili non visti. Inoltre, è stata eseguita una data augmentation on-the-fly sul set di training, applicando il

flip orizzontale alle immagini originali, al fine di far fronte alle piccole dimensioni del dataset.

VGG16 su ROI RIDGE

Nel secondo modello, la rete VGG16 è applicata alle immagini Ridge. Le caratteristiche del modello e gli iperparametri sono gli stessi illustrati precedentemente.

SVM su ROI RIDGE

Nel terzo modello, il modello di Support Vector Machine con Kernel Lineare è applicato alle immagini Ridge. L'apprendimento dei pesi ottimi del modello viene svolto un ottimizzatore stocastico a discesa di gradiente (SGD): il gradiente della funzione di loss (hinge loss) viene stimato su un sottoinsieme dei dati di addestramento ed i parametri del modello vengono aggiornati iterativamente. Il modello di Support Vector Machine viene regolarizzato mediante una combinazione lineare di norma L2 e norma assoluta L1 (Elastic net regularizers) per rispettivamente minimizzare l'overfitting e indurre sparsità e interpretabilità nei pesi del modello. Gli iperparametri che pesano L2 e L1 sono stati validati su un 20

4 Risultati

Per ogni acquisizione sono state poi calcolate delle metriche globali, in modo da ottenere per ogni campione di test un risultato unico che tenga in considerazione, allo stesso tempo, la predizione ottenuta da tutti e tre i modelli. Questo approccio permette di ricavare dei risultati più robusti e una valutazione dell'intero sistema più efficiente, in quanto vengono minimizzati possibili errori dovuti ad un singolo modello. Le metriche considerate sono le seguenti:

- Predizione media: media matematica tra i valori delle predizioni dei tre modelli di IA implementati
- Deviazione: calcolata come il modulo della differenza tra il valore dell'annotazione e quello della predizione media
- Deviazione percentuale: calcolata come il rapporto tra la deviazione ed il valore dell'annotazione

Per ogni coppia tipologia (asta/calcio) – lato (sinistro/destro) è stato calcolato:

- MAE Media della Deviazione della predizione media tra modelli dal ground truth (Figura 3)
- Errore relativo: Media della Deviazione percentuale della predizione media tra modelli dal ground truth (Figura 4)

Le performance del modello calcolate come MAE dimostrano un'efficacia molto elevata nell'andare a fornire una predizione che sia il più possibile vicina al ground-truth di riferimento, infatti la predizione nel calcio sx, dx e asta sx, dx si discosta mediamente rispetto al ground-truth di un valore inferiore a 0,4, minimizzando al minimo quelli che possono essere errori di misclassificazione tra classi di qualità che risultano essere lontani. Inoltre si nota una discreta simmetria nella valutazione delle performance tra Sx e Dx che rimangono molto coerenti nei calci (MAE calcio sx: 0,347; MAE calcio dx: 0,336) ed abbastanza coerenti nelle aste (MAE asta sx: 0,322; MAE asta dx: 0,391). L'errore relativo riportato in

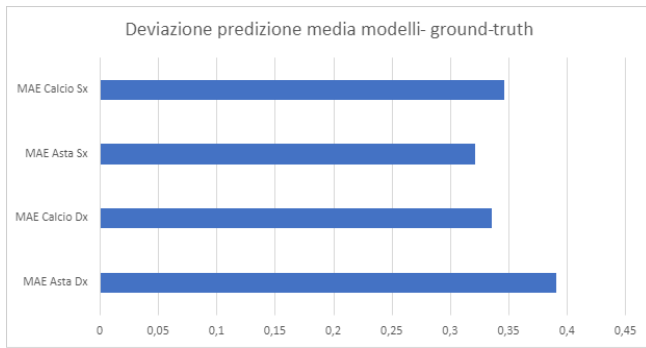


Figura 3: MAE Media della Deviazione della predizione media tra modelli dal ground truth

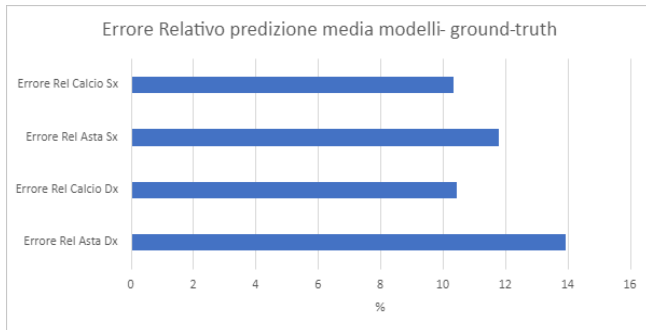


Figura 4: Errore relativo: Media della Deviazione percentuale della predizione media tra modelli dal ground truth

Figura 2 dimostra come la deviazione rispetto al ground-truth si discosta mediamente di un valore inferiore a 14%, confermando anche la simmetria tra dx e sx molto coerente nei calci (Errore relativo calcio sx: 10,336; Errore relativo calcio dx: 10,463) e abbastanza coerenti nelle aste (Errore relativo asta sx: 11,797; Errore relativo asta dx: 13,953).

5 Decision Support System per il controllo qualità

Gli algoritmi sono stati integrati un sistema di supporto alle decisioni per il controllo qualità che ha le seguenti funzionalità:

- **Supervised running.** In questa modalità schematizzata il software, dopo l'acquisizione delle foto da parte dell'operatore, rimane in attesa della classificazione (come se si trattasse di una annotazione). Successivamente consente di visionare i risultati delle reti neurali che compongono il sistema di intelligenza artificiale (Figura 5). L'operatore potrà quindi decidere se confermare la sua prima valutazione o effettuare una rivalutazione sulla base dei risultati della rete stessa (Figura 6). La registrazione di queste casistiche, come del resto una eventuale aggiunta di dataset annotati, consentiranno con opportuni sviluppi futuri di riaddestrare la rete (continuous learning).
- **Blind test.** In questa modalità il software visualizza in modo randomico le immagini annotate nella fase di ad-

destramento o nel supervised running (se presenti) e richiederà all'utente di effettuare la propria valutazione. Il software risponderà presentando la valutazione (con data e ora) dell'annotazione originale evidenziando l'errore qualora le due valutazioni discostassero. Questa modalità ha l'obiettivo di minimizzare una possibile variabilità temporale di ogni operatore.

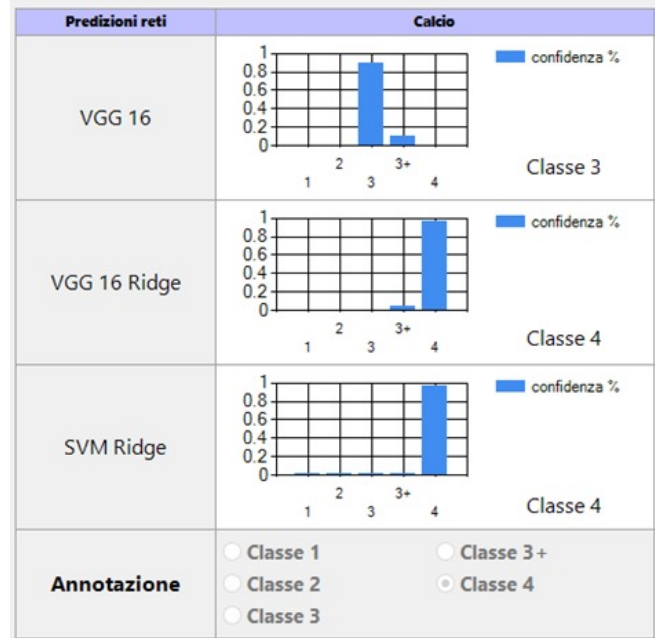


Figura 5: Interfaccia Decision Support system per il controllo qualità

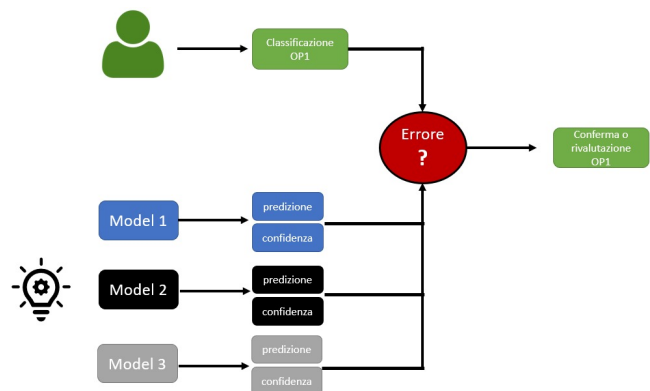


Figura 6: Supervised running: predizione e validazione dell'annotazione

6 Acknowledgment

This work was supported within the research agreement between Università Politecnica delle Marche, Benelli Armi Spa and Sinergia Consulenze srl.

Riferimenti bibliografici

- [Cadavid *et al.*, 2020] Juan Pablo Usuga Cadavid, Samir Lamouri, Bernard Grabot, Robert Pellerin, e Arnaud Fortin. Machine learning applied in production planning and control: A state-of-the-art in the era of industry 4.0. *Journal of Intelligent Manufacturing*, pages 1–28, 2020.
- [Calabrese *et al.*, 2020] Matteo Calabrese, Martin Cimmino, Francesca Fiume, Martina Manfrin, Luca Romeo, Silvia Ceccacci, Marina Paolanti, Giuseppe Toscano, Giovanni Ciandrini, Alberto Carrota, et al. Sophia: An event-based iot and machine learning architecture for predictive maintenance in industry 4.0. *Information*, 11(4):202, 2020.
- [Escobar e Morales-Menendez, 2018] Carlos A Escobar e Ruben Morales-Menendez. Machine learning techniques for quality control in high conformance manufacturing environment. *Advances in Mechanical Engineering*, 10(2):1687814018755519, 2018.
- [Francis e Bian, 2019] Jack Francis e Linkan Bian. Deep learning for distortion prediction in laser-based additive manufacturing using big data. *Manufacturing Letters*, 20:10 – 14, 2019.
- [Fu *et al.*, 2019] Guizhong Fu, Peize Sun, Wenbin Zhu, Jianxin Yang, Yanlong Cao, Michael Ying Yang, e Yanpeng Cao. A deep-learning-based approach for fast and robust steel surface defects classification. *Optics and Lasers in Engineering*, 121:397 – 405, 2019.
- [Iqbal *et al.*, 2019] R. Iqbal, T. Maniak, F. Doctor, e C. Karyotis. Fault detection and isolation in industrial processes using deep learning approaches. *IEEE Transactions on Industrial Informatics*, 15(5):3077–3084, 2019.
- [Lee *et al.*, 2018] Chia-Yun Lee, Jia-Ying Lin, e Ray-I Chang. Improve quality and efficiency of textile process using data-driven machine learning in industry 4.0. *International Journal of Technology and Engineering Studies*, 4(1):64–76, 2018.
- [Li *et al.*, 2017] Y. Li, W. Zhao, e J. Pan. Deformable patterned fabric defect detection with fisher criterion-based deep learning. *IEEE Transactions on Automation Science and Engineering*, 14(2):1256–1264, 2017.
- [Muniategui *et al.*, 2019] Ander Muniategui, Aitor García de la Yedra, Jon Ander del Barrio, Manuel Masenlle, Xabier Angulo, e Ramón Moreno. Mass production quality control of welds based on image processing and deep learning in safety components industry. In Christophe Cudel, Stéphane Bazeille, e Nicolas Verrier, editors, *Fourteenth International Conference on Quality Control by Artificial Vision*, volume 11172, pages 148 – 155. International Society for Optics and Photonics, SPIE, 2019.
- [Ozdemir e Koc, 2019] R. Ozdemir e M. Koc. A quality control application on a smart factory prototype using deep learning methods. In *2019 IEEE 14th International Conference on Computer Sciences and Information Technologies (CSIT)*, volume 1, pages 46–49, 2019.
- [Peres *et al.*, 2019] R. S. Peres, J. Barata, P. Leitao, e G. Garcia. Multistage quality control using machine learning in the automotive industry. *IEEE Access*, 7:79908–79916, 2019.
- [Romeo *et al.*, 2020] Luca Romeo, Jelena Loncarski, Marina Paolanti, Gianluca Bocchini, Adriano Mancini, e Emanuele Frontoni. Machine learning-based design support system for the prediction of heterogeneous machine parameters in industry 4.0. *Expert Systems with Applications*, 140:112869, 2020.
- [Sakib e Wuest, 2018] Nazmus Sakib e Thorsten Wuest. Challenges and opportunities of condition-based predictive maintenance: A review. *Procedia CIRP*, 78:267–272, 2018.
- [Villalba-Diez *et al.*, 2019] Javier Villalba-Diez, Daniel Schmidt, Roman Gevers, Joaquín Ordieres-Meré, Martin Buchwitz, e Wanja Wellbrock. Deep learning for industrial computer vision quality control in the printing industry 4.0. *Sensors*, 19(18):3987, Sep 2019.
- [Wang *et al.*, 2018] Tian Wang, Yang Chen, Meina Qiao, e Hichem Snoussi. A fast and robust convolutional neural network-based defect detection model in product quality control. *The International Journal of Advanced Manufacturing Technology*, 94(9-12):3465–3471, 2018.