



HAL
open science

Contrôle Qualité 2.0: Apprentissage supervisé de la notion de Qualité, application à l'injection plastique

Pierre Nagorny, Maurice Pillet, Eric Pairel

► To cite this version:

Pierre Nagorny, Maurice Pillet, Eric Pairel. Contrôle Qualité 2.0: Apprentissage supervisé de la notion de Qualité, application à l'injection plastique. CIGI-QUALITA 2019, École de Technologie Supérieure de Montréal, Jun 2019, Montréal, Canada. hal-02142331

HAL Id: hal-02142331

<https://hal.science/hal-02142331v1>

Submitted on 12 May 2020

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution - NonCommercial - ShareAlike 4.0 International License

Contrôle Qualité 2.0 : Apprentissage supervisé de la notion de Qualité, application à l'injection plastique

PIERRE NAGORNY¹, MAURICE PILLET, ERIC PAIREL

¹ Laboratoire SYMME, Université Savoie Mont Blanc
7 Chemin de Bellevue, France
pierre.nagorny@univ-smb.fr

Résumé – Lorsqu'il est réalisé au plus près de la machine, sur toutes les pièces manufacturées, le Contrôle Qualité permet de mesurer les performances de la machine et de détecter les dérives qualité. De plus, qualifier les pièces dès la sortie de la machine permet de réduire les rebus finaux qui sont causés par l'étape d'injection-moulage. Cela élimine les coûts perdus issus de l'ajout de valeur à des pièces initialement mauvaises, pendant les étapes suivantes de finition de la pièce. Dans le cas de l'injection plastique, aucun système ne répond actuellement aux contraintes du procédé. Nous avons identifié trois verrous au déploiement massif du Contrôle Qualité à cent pourcent dès la sortie de la machine : économique, technologique et humain. Nous présentons les méthodes et moyens retenus pour lever ces verrous au travers des essais expérimentaux réalisés avec un prototype de dispositif de mesure. Les résultats obtenus sont très encourageants. Les avancées en Machine Learning, dont les réseaux de neurones profonds (Deep Learning), permettent de déployer un dispositif de mesure qui intègre un modèle de la notion de Qualité créé à partir de l'Expert Qualité humain par apprentissage supervisé. L'apprentissage supervisé est réalisé au fur et à mesure de la production de manière transparente.

Abstract – Quality Control measures the performance of the machine when it is made closer to the production machine on all manufactured parts. It makes possible the optimization and detection of quality drifts. Moreover, qualifying the parts right out of the machine makes it possible to reduce the final rejects that are caused by the injection-molding step. This eliminates the cost of adding value to initially bad parts during subsequent parts finishing steps. In the case of plastic injection, no system currently meets the industrial constraints of the process. We have identified three limits to the massive deployment of quality control on all parts just after molding: economic, technological and human. We present the methods and means used to meet these limits through experimental tests carried out with a new measuring device. First results are encouraging. Recent advances in Machine Learning, including deep neural networks (Deep Learning), allow to deploy a measurement device that integrates a model of the concept of Quality created from the Human Quality Expert by supervised learning. This makes possible to learn a Quality metrics for any parts.

Mots clés – contrôle qualité ; apprentissage supervisé ; Deep Learning ; injection plastique

Keywords – quality control; supervised learning; Deep Learning; injection molding

1 INTRODUCTION

La mesure de la qualité d'une production est essentielle à la mise sous contrôle statistique du procédé. Les contraintes industrielles sont multiples. Les deux principales limites au déploiement du contrôle intégral (à cent pour cent) de la production sont le coût du moyen de mesure et la faisabilité d'une mesure fiable en temps de cycle industriel. Il n'est pas envisageable d'augmenter le temps de cycle afin de réaliser la mesure, ce qui entrainerait une forte diminution des capacités du moyen de production. C'est pourquoi la mesure par prélèvement statistique est souvent préférée lorsque la technologie de mesure requière une durée supérieure à la durée du cycle de production. La présente étude est réalisée dans le cadre d'un projet collaboratif avec des partenaires industriels plasturgistes, c'est pourquoi nous nous intéresserons uniquement au procédé d'injection-moulage des thermoplastiques.

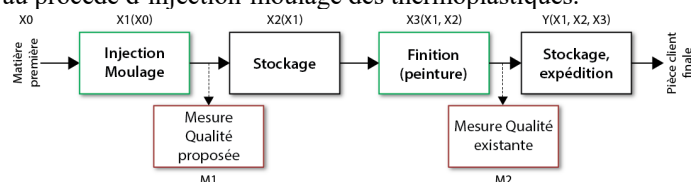


Figure 1. Intégration de la mesure de la Qualité

Dans le cas de l'injection plastique, la mesure de la qualité géométrique ne peut être réalisée que plusieurs jours après production de la pièce (Figure 1). La pièce doit avoir refroidi et la géométrie doit s'être stabilisée, c'est à dire que les contraintes internes de la matière s'équilibrent. De plus, certains défauts d'aspect n'apparaîtront qu'après la réalisation des étapes de finition. Nous excluons de notre étude les étapes de transports et stockages des pièces qui sont également la source de défauts.

La mesure par prélèvement sur un procédé qui possède des étapes successives ne permet pas d'identifier l'étape à l'origine du défaut. Enfin, pour un produit qui nécessite un niveau de qualité élevé, chaque pièce est contrôlée à la fin de la chaîne de production (contrôle à cent pour cent). Dans le cas du moulage de pièces plastiques, le contrôle qualité est effectué bien après l'étape de moulage ; soit après l'ajout de valeur des étapes de finition, ce qui prend parfois plusieurs jours. De la valeur est ajoutée aux pièces dont la qualité produite lors de l'étape de moulage était initialement mauvaise.

La notion de qualité inclut la qualité des dimensions géométriques ainsi que la qualité d'aspect. La qualité d'aspect est fortement subjective. Elle est difficile à spécifier dans un cahier des charges

[Guerra, 2008]. Un Expert Qualité est généralement le référent de cette notion de Qualité pour une usine. Il forme les opérateurs afin de leur transmettre son savoir holistique. Malheureusement, la transmission du savoir et la répétabilité de la mesure de la qualité sont difficiles à mettre en œuvre. Nous avons identifié trois verrous au déploiement massif du contrôle qualité à cent pour cent en sortie de presse à injecter :

- Économique : c'est le coût du dispositif de mesure
- Technologique : le respect du temps de cycle industriel
- Humain : Formalisation de la notion de Qualité

Lever ces verrous permettra de faire rentrer la plasturgie dans l'Industrie 4.0. Le déploiement d'un dispositif de mesure permettra également de récolter des données factuelles sur la Qualité produite en fonction des paramètres machines afin d'optimiser les réglages du procédé d'injection-moulage.

Enfin, les problématiques soulevées et leurs solutions peuvent être utiles dans le cadre d'autres procédés industriels. De nombreux programmes de recherches européen (FP7 puis H2020) portent sur la Qualité Totale (Zero Defect Manufacturing) et proposent une approche globale sur la chaîne de valeur [Eger et al., 2018]. Proches de nos travaux, les projets GRACE et GOODMAN ont permis le développement d'un dispositif de contrôle visuel de la bonne réalisation des assemblages [Stroppa et al., 2016], tandis que le projet MEGaFiT a proposé l'utilisation d'une caméra thermique pour asservir le temps d'exposition du laser en fabrication additive métallique [Renken et al., 2017]. Le développement d'une méthode robuste de mesure de la qualité permettra l'asservissement du procédé en boucle fermée pour maximiser la qualité.

2 DISPOSITIF DE MESURE NON-INVASIF MOBILE ET BAS COUT

Nous proposons de lever ces verrous par l'utilisation du Machine Learning sur une simple capture d'image, afin de proposer un dispositif de mesure de la qualité de tous types de pièces. Le Machine Learning permet de créer une modélisation de la notion de Qualité à partir du savoir de l'Expert humain. Cette modélisation est transférée au dispositif de mesure qui effectue un contrôle à cent pour cent répétable, inscrit dans une durée compatible avec le cycle industriel. La littérature propose des utilisations de l'apprentissage supervisé pour le contrôle qualité de productions industrielles [Escobar et Morales-Menendez, 2018], dont la plasturgie [Ribeiro, 2005] [Lacombe, 2018].

2.1 Viabilité économique du dispositif de mesure

Dans le cas de l'injection plastique, le coût de la matière première et de l'étape d'injection-moulage est très faible en comparaison du coût des étapes de finitions. Produire des pièces mauvaises a un coût négligeable en comparaison du coût des étapes de peinture et de finitions de pièces mauvaises. Détecter les pièces mauvaises dès la sortie de la presse d'injection, afin de les écarter de la chaîne de production, permet de diminuer les rebus finaux et de supprimer ainsi les coûts associés à leurs finitions. Le coût économique du dispositif de mesures est à rapporter au coût économique des rebus. Des industriels régionaux nous ont confirmé que le coût de la production de rebus est faible en comparaison du coût de déploiement d'un dispositif de mesure sur chaque machine. Si le coût du système de mesure dépasse les quelques milliers d'euros, il n'est pas intéressant.

2.1.1 Coût de l'instrumentation invasive des moules

Une méthode rependue afin de contrôler la qualité produite est de positionner des capteurs à l'intérieur des moules, directement en contact avec la matière. Les capteurs les plus répandus sont les sondes de température et de pression [Kurt et al., 2009]. Les données de ces capteurs sont analysées par différentes méthodes non-supervisées (carte de contrôle [Min, 2003], Analyse en Composante Principale [Zhang et al., 2015]) afin de détecter les dérives qualité sur une production stabilisée. La construction de modèle par apprentissage supervisé a également été proposée [Zhou et al., 2018]. Des capteurs plus complexes [Chen et al., 2004] et multivariés [Kazmer et al., 2011] ont été proposés, puis validés [Gordon et al., 2017].

Le coût de notre dispositif est à rapporter au coût de l'instrumentation invasive des moules. D'après nos chiffrages régionaux, l'intégration d'un capteur dans le moule représente un surcoût de vingt pourcents de la conception et fabrication de moules initialement compris entre cinquante et cent mille euros. Intégrer les canaux nécessaires au passage des fils et connecteurs est complexe et coûteux sachant que les moules intègrent également des canaux de refroidissements indispensables au procédé. Les capteurs subissent de fortes contraintes ce qui peut limiter leur durée de vie. Mais nous avons surtout observé des défaillances dans les fils de connections, lors des manipulations des moules pour les changements de productions. Enfin, un capteur intégré à un moule n'est utile que pour une unique pièce. Un dispositif mobile qui n'est pas lié à une pièce permettrait de contrôler quand le cahier des charges le nécessite, quel que soit la pièce à produire.

2.1.2 Viabilité économique du dispositif de métrologie proposé

Un prototype fonctionnel a été développé afin de répondre aux exigences de coût et contraintes du procédé. Dans un budget inférieur à cinq mille euros, nous avons intégré un dispositif d'imagerie non invasif dérivé d'une webcam commerciale, un éclairage spécifique, ainsi que les détecteurs nécessaires à l'identification de la présence des pièces. Enfin, nous avons embarqué l'intelligence de traitement dans un ordinateur fanless. Le tout est contenu dans un cube de vingt centimètres, mobile et intégrable rapidement sur toute ligne de production (Figure 2). Une interface utilisateur a été développée afin que l'Expert Qualité supervise l'algorithme d'apprentissage de la notion de qualité.




Figure 2. Schéma du dispositif de mesure non invasif

2.2 Faisabilité technologique de la mesure non invasive

Le défi du contrôle qualité à cent pourcent est de réaliser la mesure et l'analyse dans une durée inférieure au cycle de production (Figure 3). L'utilisation d'une caméra comme dispositif de mesures sans contact et de l'analyse d'image afin de détecter la présence des défauts permet au dispositif de mesure de répondre au temps de cycle. Un moyen de mesure qui nécessite le contact avec la pièce augmente le temps de la mesure d'un facteur dix. Déplacer l'outil de mesure pour palper la pièce, puis le positionner en garantissant la stabilité du dispositif est long. L'utilisation de plusieurs comparateurs fixes permet de s'affranchir du temps de positionnement de l'outil. Cependant le coût d'intégration augmente car il est nécessaire de concevoir un posage pour chaque pièce. Nous avons évalué des dispositifs de scanner 3D sans contact qui répondent au temps de cycle. Cette technologie utilise la triangulation en stéréoscopie de lignes émises par un laser avec un moyen d'acquisition ; il est alors possible de calculer l'information de profondeur de la surface.

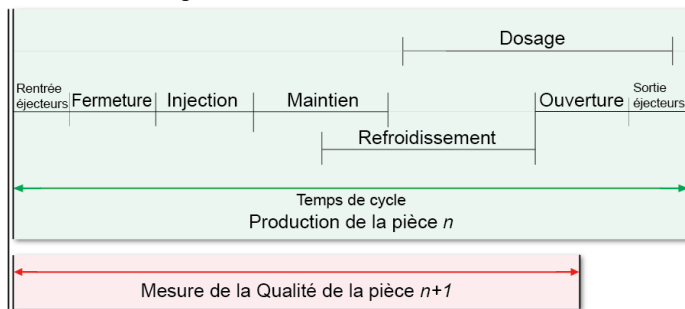


Figure 3. Chronogramme d'intégration de la mesure

La profilométrie utilise la même technique. En déplaçant la pièce avec précision dans un référentiel absolu, il est possible de reconstituer les surfaces.

Cependant, le scan laser ne permet pas d'atteindre une répétabilité suffisante pour détecter les défauts d'aspect. Certains défauts d'aspect sont des défauts géométriques : une courbure locale sur une surface entraîne un changement de l'angle de réflexion de la surface ce qui produit un effet de « tâche sombre » de l'ordre du centimètre. La courbure locale de ces défauts est de l'ordre de la dizaine de micromètres. Le moyen de mesure doit les détecter.

La microscopie confocale [Marvin, 1961] permet de détecter les défauts de l'ordre du micromètre. Cependant, l'amplitude de la profondeur de mesure est limitée à un millimètre à cause du décalage en longueur d'onde de la réflexion de la source lumineuse et de la sensibilité du capteur. Il est nécessaire d'asservir le positionnement du microscope pour s'affranchir de cette limite [George et Saseendran, 2018] [Chiariotti et al., 2018]. Les performances de ce moyen de mesure sont excellentes en résolution mais la mesure est lente en comparaison d'une simple capture d'image. Multiplier les têtes de microscopie est extrêmement coûteux. Il reste envisageable de mesurer un point local d'une pièce où les défauts critiques apparaissent. La microscopie confocale chromatique permet une résolution spatiale encore plus précise, au nanomètre [Tiziani et Uhde, 1994] [Dobson et al., 1997].

La déflectométrie de phases [Knauer et al., 2004] propose un temps de mesure proche de la seconde pour de grandes pièces. La définition du capteur est le facteur limitant. Enfin, il est intéressant

de remarquer que la technologie de lumière structurée a été miniaturisée et industrialisée pour répondre aux contraintes des systèmes embarqués tels que les smartphones. Bajard et Lacombe ont respectivement réalisés des États de l'Art concernant la mesure géométrique [Bajard, 2012] et la mesure de défauts d'aspect [Lacombe, 2018].

Tableau 1. Technologies de mesure géométrique

	Résolution	Vitesse	Coût
Microscopie confocale chromatique	0,005 μm	30 mm/s	100 k€
Microscopie confocale	0,5 μm	1 cm/s	70 k€
Profilométrie laser	5 μm	1 m/s	30 k€
Lumière structurée	10 μm	10 cm/s	100 k€
Scanner 3D	50 μm	20 cm/s	10 k€
Déflectométrie	100 μm	20 cm/s	10 k€
Lumière structurée grand public	5 cm	20 cm/s	200 €

Aux vues du coût des moyens de mesures évalués (Tableau 1), nous nous sommes intéressés à la simple capture d'image par capteur CCD, associée à un éclairage annulaire. L'image capture l'aspect de l'ensemble de la pièce avec une définition classique (1920 x 1080 pixels). Cela équivaut à une résolution d'un millimètre par pixel pour une pièce située à un mètre. Les défauts micrométriques ne sont pas détectables. Ce sont les défauts à une échelle globale de l'ordre du centimètre qui renseignent sur la qualité de la pièce, grâce au développement d'une chaîne d'analyse adaptée. Notre dispositif utilise un réseau de neurones comme extracteur des caractéristiques pertinentes de l'image. Nous avons également évalué différentes transformées spatiales (Transformée de Fourier, Décomposition en Ondelettes [Du et al., 2006], Décomposition Modale Discrète [Goic et al., 2011]). Ce prétraitement de la mesure est très rapide (dizaine de millisecondes) sur un processeur mono-cœur opérant au Gigahertz. Sur ces données prétraitées sont appliqués différents algorithmes de classification : Machine à Vecteurs Supports (SVM) [Vapnik et al., 1997] ou réseaux de neurones profonds [Lecun et al., 1998]. L'inférence de ces algorithmes de classification est inférieure à la seconde sur un ordinateur embarqué. Il est possible d'accélérer l'inférence en utilisant des composants dédiés. Le temps d'inférence est négligeable en comparaison du temps d'apprentissage de ces algorithmes.

La détection robuste de la présence ou non de pièce est un prérequis à toute mesure autonome. En effet, le temps de cycle du procédé est variable en fonction des réglages de la durée des différentes étapes (Figure 1). Une détection non robuste entraîne des erreurs de mesure qui ne sont pas acceptables (Figure 4).



Détection de présence de pièce robuste Détection de présence problématique

Figure 4. Problème de la détection de la présence des pièces

Notre dispositif combine plusieurs technologies de capteurs afin de solutionner ce problème. Les capteurs optiques sont limités en angle de réflexion et absorption des surfaces, ils sont complétés par l'analyse d'image.

2.3 Transmission du Savoir de l'Expert Qualité vers la machine

Le dernier verrou concerne la modélisation de la notion de Qualité. Cette notion est spécifique à une pièce, à un cahier des charges normalisé et à une interprétation de ces spécifications par l'Expert Qualité. Afin de rendre robuste et répétable la mesure, il est nécessaire de modéliser la notion de qualité à partir du savoir de l'Expert humain. Nous avons conçu notre dispositif en l'intégrant dans une architecture client-serveur, ceci afin de construire une base de données au fur et à mesure de la production des pièces.

Lors de la production d'une nouvelle pièce, il est nécessaire de construire une base de données contenant la mesure d'une pièce associée à une évaluation de la qualité (notation ou label). Notre dispositif ajoute à une base de données chacune des pièces. L'Expert Qualité dispose d'une interface dans laquelle il peut indiquer son évaluation de chaque pièce. L'interface peut être partagée entre plusieurs Experts qui collaborent. Dès que l'expert a renseigné la note qualité d'une pièce, cette pièce est intégrée dans la base d'apprentissage. L'Expert n'est pas contraint de renseigner la qualité de toutes les pièces. Cette évaluation peut se faire en ligne de production ce qui permet de voir les pièces produites au plus près ou bien hors-ligne à partir de l'image enregistrée.

Lorsque la base d'apprentissage contient une vingtaine de pièces à la qualité jugée bonne et une vingtaine de pièces mauvaises, l'algorithme d'apprentissage s'entraîne sur la base d'apprentissage. Par la suite l'algorithme est entraîné périodiquement lorsque le nombre de pièces augmente dans chaque catégorie. Il est important de ne pas biaiser la base d'apprentissage en intégrant beaucoup plus de pièces d'une certaine catégorie au détriment d'une autre catégorie. Les réseaux de neurones de convolutions ne sont pas robustes à ce biais [Tommasi et al., 2017]. Si un modèle de la qualité a été appris (nécessite vingt pièces notées), lors de la mesure d'une nouvelle pièce, le système retourne l'inférence donnée par le modèle préalablement appris. L'Expert ou l'opérateur humain peut alors valider la prédiction du modèle ou la modifier. Cette phase est beaucoup plus ludique car elle implique une relation de jeu entre la machine et l'humain. Chaque réponse de l'humain permet d'enrichir la base d'apprentissage.

Si les prédictions du modèle sont trop éloignées de la vérité donnée par l'Expert humain, une alarme est déclenchée afin d'avertir d'une dérive de la capacité de la prédiction du modèle. Une base de données renseignant chacune des versions du modèle est conservée, ainsi que l'évaluation de leur performance. Si un modèle est défaillant, le système retourne automatiquement au modèle, appris sur une base d'apprentissage réduite, qui obtenait de meilleures performances en prédictions.

3 ESSAIS EXPERIMENTAUX

3.1 Construction de la base de données d'apprentissage

Afin de couvrir de manière exhaustive l'ensemble des pièces pouvant être produites sur la machine, nous avons dans un premier

temps fait le choix de l'utilisation d'un plan d'expérience. Les réglages de la machine ont été modifiés selon un plan de criblage L12 [Plackett et Burman, 1946] afin de couvrir l'ensemble de l'espace des réglages de la machine. Deux cents pièces ont été produites avec 12 couples de réglages machines différents. Cela nous permet de valider les performances sur une variété complète de défauts et de points de fonctionnement du procédé. Cette démarche n'est pas applicable en production industrielle car elle est chronophage. Un second essai a été réalisé sur une pièce et une machine différente dans des conditions industrielles, sans utilisation de plan d'expérience. La base de données a été construite pendant que l'opérateur Technicien-Régleur effectuait les réglages de la machine. Nous n'avons pas observé de diminution de la performance de classification, signe que l'opérateur humain explore naturellement un espace de réglages machines suffisant pour choisir les réglages à appliquer pour produire des pièces de bonne qualité.

3.2 Notation de la qualité par expertise humaine

Afin d'appliquer une méthode rigoureuse d'évaluation de la qualité des pièces, nous avons évalué les pièces en les classant par comparaison. L'ensemble des deux cents pièces du premier essai a été positionné sur de grandes tables. Trois experts Qualité se sont réunis pour classer manuellement les pièces en les comparant entre elles. L'échelle de notation (de 0 à 12) s'est construite au fur et à mesure de la notation. Malgré l'évaluation subjective humaine, les trois experts ont pu facilement se mettre d'accord pour attribuer une note deux fois moins bonne aux pièces dont ils mesuraient la qualité deux fois moins bonne. Lors du second essai en conditions industrielles, la notation de la qualité a été réalisée pendant la phase de réglage initiale de la machine, en utilisant l'interface de notation du logiciel développé (cf 4.1.1 Interface de supervision de l'apprentissage).

3.1 Limites de la solution de capture d'image retenue

Le choix d'un unique capteur de mesure limite la mesure de la qualité à un unique point de vue (Figure 5). Dans le cadre de notre problématique industrielle, les surfaces qualitatives des pièces sont situées dans un même plan. Dans le cas de pièces courbes, il est envisageable d'utiliser notre méthode en multipliant le nombre de caméras, deux caméras pour couvrir 270 degrés d'angle de champs et trois caméras pour une sphère complète. Enfin, il serait intéressant d'évaluer la dégradation de performance de la détection de défaut en fonction de la définition du capteur, ou bien de la résolution du capteur rapportée à la dimension du défaut. Notre prototype utilise une simple webcam grand public haut de gamme, mais des solutions de caméras industrielles de plus grande définition existent à des coûts plus élevés.




Figure 5. Pièce de bonne qualité, pièce de mauvaise qualité

3.2 Deep Learning pour modélisation de la Qualité

Sur notre problématique, de précédents travaux nous ont permis de qualifier les performances supérieures des algorithmes à réseaux de neurones profonds [Nagorny et al., 2017]. Nous poursuivons ici en intégrant une méthode d'apprentissage supervisée par transfert d'un réseau pré-appris sur une grande quantité de données (*Transfer Learning*) [Saenko et al., 2010]. L'ensemble des algorithmes utilisent les bibliothèques *Tensorflow* [Abadi et al., 2016] et *Keras* [Chollet et al., 2015]. L'évaluation de différentes architectures de réseaux nous ont amené à sélectionner une architecture de convolution éprouvée dans la littérature : *VGG16* [Simonyan et Zisserman, 2014]. Les images ne subissent aucun traitement autre qu'un redimensionnement (224 x 224 pixels) pour les adapter aux dimensions du réseau pré-appris. La définition des images proposées en entrée est donc très faible ; c'est la présence d'indices de défauts à l'échelle globale qui permettra d'inférer la présence de défauts de dimensions inférieures à la résolution de l'image en entrée.

3.3 Résultats expérimentaux

L'apprentissage par transfert se déroule en deux étapes. Une première phase où seules les deux dernières couches du réseau sont entraînées après avoir été initialisées à partir d'une distribution aléatoire ; une deuxième phase de *fine-tuning* où le réseau complet est entraîné en conservant les pondérations existantes. Nous observons (Figure 6) une rapide convergence du modèle lors de la première phase, puis une très légère amélioration lors de la seconde phase. Les résultats sur la base d'évaluation obtenus sont satisfaisants. Ils confirment la performance de notre méthode (Figure 7).

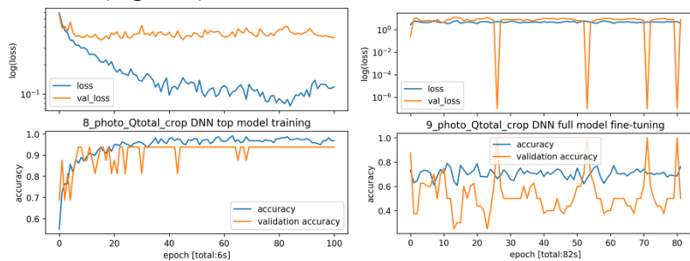


Figure 6. Performances du modèles pendant l'apprentissage

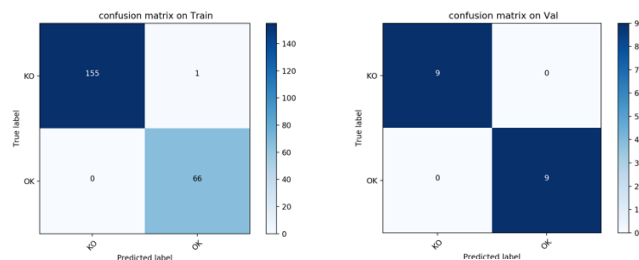


Figure 7. Matrices de confusion

Néanmoins, le nombre de pièces de la base de données est très faible en comparaison des milliers d'échantillons généralement présentés dans la littérature. Il est possible qu'un biais existe dans notre base de données qui n'ait pas été détecté, mais qui entraîne d'excellentes performances. Nous espérons éprouver rapidement la méthode sur une quantité de données plus importantes, sur des productions industrielles, ce qui nous permettra de justifier du succès de notre approche.

3.3.1 Justification de la pertinence du modèle appris

Afin d'interpréter les résultats obtenus en classification par les réseaux de neurones profonds, il est utile de construire une carte d'intérêt (carte de saillance) de l'algorithme pour les points de l'image qui ont été important pour réaliser la classification. Cette carte peut être construite en sommant les valeurs des régions de l'image pour chaque couche d'activation du réseau profond [Simonyan et al., 2013] [Li et Yu, 2015]. Les cartes que nous avons obtenues appuient la pertinence de la méthode employée. Les éléments importants de l'images sont les bords de la pièce où se situent les défauts géométriques ainsi que les régions planes où apparaissent des défauts d'aspect.




Figure 8. Carte de saillance – Guided backpropagation

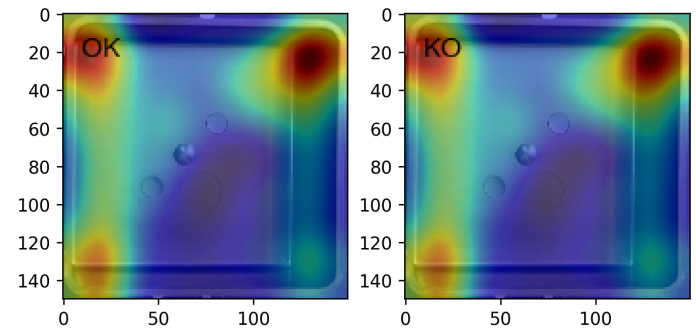


Figure 9. Carte de saillance – Grad-CAM

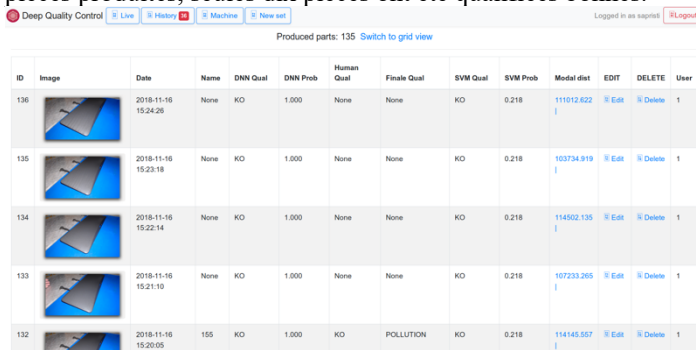
Nous utilisons deux algorithmes pour réaliser ces cartes : la rétro-propagation guidée [Springenberg et al., 2014] avec régularisation [Smilkov et al., 2017] (Figure 8), et l'algorithme Grad-CAM [Selvaraju et al., 2016] (Figure 9). Nous avons adapté la bibliothèque *keras-viz* à nos données [Kotikalapudi et al., 2017].

4 PERSPECTIVES

Ces travaux montrent l'intérêt de notre démarche. De nombreux points peuvent être développés. La méthode doit être évaluée sur une base de données d'apprentissage proche du millier de pièces. Nous envisageons de poursuivre les travaux autour de la généralisation du modèle appris. La classification non-supervisée de défauts est également un défi intéressant pour pouvoir classifier la qualité sans donnée initiale, dès la mise en route de la machine. L'interface de supervision de l'apprentissage est en développement continu afin de motiver l'humain à l'utiliser.

4.1.1 Interface de supervision de l'apprentissage

Nous avons pu réaliser le second essai en condition industrielle afin de valider la pertinence de l'interface d'apprentissage en ligne (Figure 10). Cependant, cet essai a été réalisé sur une production inférieure à cent pièces, et qui était de plus biaisée. Sur les soixante pièces produites, seules dix pièces ont été qualifiées bonnes.



ID	Image	Date	Name	DNN Qual	DNN Prob	Human Qual	Final Qual	SVM Qual	SVM Prob	Model dist	EDIT	DELETE	User
136		2018-11-16 15:26:28	None	KO	1,000	None	None	KO	0,218	11012,622	Édit	Supprime	1
135		2018-11-16 15:23:18	None	KO	1,000	None	None	KO	0,218	10374,919	Édit	Supprime	1
134		2018-11-16 15:22:14	None	KO	1,000	None	None	KO	0,218	114502,135	Édit	Supprime	1
133		2018-11-16 15:21:19	None	KO	1,000	None	None	KO	0,218	107233,265	Édit	Supprime	1
132		2018-11-16 15:20:05	155	KO	1,000	KO	POLLUTION	KO	0,218	114146,557	Édit	Supprime	1

Figure 10. Interface d'apprentissage en ligne de production

Le réseau de neurone étant sensible au biais, nous avons obtenu un modèle qui classifiait toutes les pièces comme mauvaises. Cette évaluation sera réalisée prochainement sur une production industrielle de plusieurs milliers de pièces. Cela représente une journée de production classique pour une machine dans une usine.

4.1.2 Apport de l'apprentissage semi-supervisé

La méthode de construction du modèle de la qualité présentée ici utilise une approche purement supervisée. Dans nos cas d'applications, nous ne souhaitons pas obtenir la catégorie du défaut en présence. Nous avons néanmoins observé qu'ils existent une dizaine de types de défauts. Les phases de réglages de la machine sont cruciales pour obtenir une grande variété de type de pièces. La suite d'une production industrielle stabilisée est plus monotone et seules la dérive du procédé produira des pièces mauvaises. Sur ce problème, une approche non-supervisée permettrait de détecter les pièces possédant un nouveau défaut : c'est à dire les pièces qui s'éloignent de la base de données existante. L'Expert Humain serait alors sollicité pour évaluer ces nouvelles pièces. Cela permettrait d'enrichir judicieusement la base de données d'apprentissage.

4.1.3 Vers un modèle robuste de la Qualité

La faisabilité du transfert de la modélisation de la qualité apprise sur une machine vers une autre machine produisant la même pièce est en cours d'évaluation. A terme, cette démarche permettra de réaliser l'apprentissage supervisé de la notion de Qualité sur une unique machine, puis de déployer le modèle sur un parc machines complet. L'État de l'Art en Deep Learning nous permet d'envisager la quantité de données nécessaires à rendre robuste le système à toute machine à dix mille pièces dans la base d'apprentissage (CIFAR-10 propose 6000 images par classes [Krizhevsky, 2009]). Cela implique que le modèle doit avoir acquis dans sa base d'apprentissage des images prises pour une même pièce mais dans des configurations de machines différentes. La littérature renseigne des cas de résultats satisfaisants en apparence, alors que le modèle ne s'intéressait pas aux véritables causes pour prédire, mais à des paramètres externes dépendants des véritables causes [Rajpurkar et al., 2017], [Chu et al., 2017]. Une situation similaire peut être anticipée dans notre cas où une machine possédant une grille de protection de couleur rouge

produirait uniquement des pièces mauvaises tandis qu'une machine de couleur verte produirait uniquement des pièces bonnes. Le modèle aura alors généralisé par apprentissage qu'aucune pièce ne pourra être bonne si produite à côté d'une grille rouge. Sans anticipation, ce résultat sera alors très difficile à comprendre. Les cartes de saillances peuvent aider à interpréter la décision du modèle. C'est un outil indispensable à tout déploiement massif de modèle à réseaux de neurones profonds (cf 3.3.1 Validation de l'apprentissage). Enfin, nous pouvons également envisager la construction d'un modèle de Qualité qui serait robuste à toutes pièces. Ce modèle rivaliserait avec l'humain afin de classifier les défauts de n'importe quelle pièce. Construire ce modèle nécessitera une base de données d'apprentissage supérieure à cent mille pièces (ImageNet propose quatorze millions d'images pour vingt mille catégories [Deng et al., 2009]).

5 CONCLUSION

Des contraintes technologiques et financières limitent actuellement l'existence de solution compatible avec l'industrie pour réaliser le contrôle qualité à cent pour cent dès la sortie de la machine. Réaliser ce contrôle permettra de limiter en amont de la chaîne de production les rebuts finaux, ainsi que le coût de toutes les étapes de finitions sur des pièces de mauvaise qualité. Nous proposons un dispositif de mesure de la qualité qui utilise l'apprentissage supervisé. Le prototype a été évalué en condition réelles sur un jeu de données de quantité limitée. Néanmoins, les résultats sont encourageants. La méthode proposée permet de résoudre les problèmes qui limitent actuellement le déploiement du contrôle à cent pour cent en injection plastique. Des essais proches permettront de confronter le dispositif à des quantités de pièces produites importantes.

Nous avons identifié plusieurs axes de travail. Il sera intéressant de concevoir un système capable de généraliser la notion de qualité, et de généraliser la classification des défauts, pour toutes pièces. Actuellement, notre système s'appuie sur une phase d'apprentissage spécifique à chaque pièce, lors de la mise en production d'une pièce. En augmentant d'un facteur cent la quantité de données disponible dans la base d'apprentissage, la généralisation d'un modèle semble envisageable. Enfin, l'Expert Qualité et l'Opérateur humains sont au cœur de ce système, c'est pourquoi il est important de leur proposer une interface agréable et une procédure d'utilisation la plus simple possible.

6 REMERCIEMENTS

Nous remercions l'ensemble des partenaires industriels et académiques du projet collaboratif FUI SAPRISTI, issu du 21^{ème} appel à projets du Fond Unique Interministériel (FUI), pour les échanges fructueux, ainsi que le financement accordé par BPI France pour réaliser ces travaux.

7 REFERENCES

- Eger, F., Coupek, D., Caputo, D., Colledani, M., Penalva, M., Ortiz, J. A., ... Kollegger, G. (2018). Zero Defect Manufacturing Strategies for Reduction of Scrap and Inspection Effort in Multi-stage Production Systems. *Procedia CIRP*, 67, 368-373.
- Guerra, A. S. (2008). *Métrologie sensorielle dans le cadre du contrôle qualité visuel*. Université de Savoie.
- Stroppa, L., Castellini, P., & Paone, N. (2016). Self-Optimizing Robot Vision for Online Quality Control. *Experimental Techniques*,

40(3), 1051-1064.

- Ribeiro, B. (2005). Support vector machines for quality monitoring in a plastic injection molding process. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 35(3), 401-410.
- Renken, V., Albinger, S., Goch, G., Neef, A., & Emmelmann, C. (2017). Development of an adaptive, self-learning control concept for an additive manufacturing process. *CIRP Journal of Manufacturing Science and Technology*, 19, 57-61.
- Lacombe, T. (2018). *Exploitation of a multilighting information for a generic approach of industrial automated visual quality control*. Communauté Université Grenoble Alpes.
- Escobar, C. A., & Morales-Menendez, R. (2018). Machine learning techniques for quality control in high conformance manufacturing environment. *Advances in Mechanical Engineering*, 10(2), 1687814018755519.
- Kurt, M., Saban Kamber, O., Kaynak, Y., Atakok, G., & Girit, O. (2009). Experimental investigation of plastic injection molding: Assessment of the effects of cavity pressure and mold temperature on the quality of the final products. *Materials & Design*, 30(8), 3217-3224.
- Min, B. H. (2003). A study on quality monitoring of injection-molded parts. *Journal of Materials Processing Technology*, 136(1), 1-6.
- Zhang, S., Dubay, R., & Charest, M. (2015). A principal component analysis model-based predictive controller for controlling part warpage in plastic injection molding. *Expert Systems with Applications*, 42(6), 2919-2927.
- Zhou, X., Zhang, Y., Mao, T., Ruan, Y., Gao, H., & Zhou, H. (2018). Feature extraction and physical interpretation of melt pressure during injection molding process. *Journal of Materials Processing Technology*, 261, 50-60.
- Chen, X., Chen, G., & Gao, F. (2004). Capacitive transducer for in-mold monitoring of injection molding. *Polymer Engineering & Science*, 44(8), 1571-1578.
- Kazmer, D. O., Johnston, S. P., Gao, R. X., & Fan, Z. (2011). Feasibility Analysis of an In-mold Multivariate Sensor. *International Polymer Processing*, 26(1), 63-72.
- Gordon, G., Kazmer, D. O., Tang, X.-Y., Fan, Z.-Y., & Gao, R. X. (2017). Validation of an In-Mold Multivariate Sensor for Measurement of Melt Temperature, Pressure, Velocity, and Viscosity. *International Polymer Processing*, 32(4), 406-415.
- Marvin, M. (1961). Microscopy apparatus.
- George, R. M., & Palayil Saseendran, S. (2018). *Qualitative and quantitative study of existing surface parameters and their correlation to CWS parameters in Automobile Industry : Surface texture parametric study of CWS*.
- Dobson, S. L., Sun, P., & Fainman, Y. (1997). Diffractive lenses for chromatic confocal imaging. *Applied Optics*, 36(20), 4744-4748.
- Chiariotti, P., Fitti, M., Castellini, P., Zitti, S., Zannini, M., & Paone, N. (2018). High-Accuracy Dimensional Measurement of Cylindrical Components by an Automated Test Station Based on Confocal Chromatic Sensor. In *2018 Workshop on Metrology for Industry 4.0 and IoT* (p. 58-62).
- Knauer, M. C., Kaminski, J., & Hausler, G. (2004). Phase measuring deflectometry: a new approach to measure specular free-form surfaces. In *Optical Metrology in Production Engineering* (Vol. 5457, p. 366-377). International Society for Optics and Photonics.
- Tiziani, H. J., & Uhde, H.-M. (1994). Three-dimensional image sensing by chromatic confocal microscopy. *Applied Optics*, 33(10), 1838-1843.
- Bajard, A. (2012). *Numérisation 3D de surfaces métalliques spéculaires par imagerie infrarouge*. Université de Bourgogne.
- Du, P., Kibbe, W. A., & Lin, S. M. (2006). Improved peak detection in mass spectrum by incorporating continuous wavelet transform-based pattern matching. *Bioinformatics*, 22(17), 2059-2065.
- Goic, G. L., Favrelière, H., Samper, S., & Formosa, F. (2011). Multi scale modal decomposition of primary form, waviness and roughness of surfaces. *Scanning*, 33(5), 332-341.
- Vapnik, V., Golowich, S. E., & Smola, A. J. (1997). Support Vector Method for Function Approximation, Regression Estimation and Signal Processing. In M. C. Mozer, M. I. Jordan, & T. Petsche (Éd.), *Advances in Neural Information Processing Systems 9* (p. 281-287). MIT Press.
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Tommasi, T., Patricia, N., Caputo, B., & Tuytelaars, T. (2017). A Deeper Look at Dataset Bias. In G. Csurka (Éd.), *Domain Adaptation in Computer Vision Applications* (p. 37-55). Cham: Springer International Publishing.
- Plackett, R. L., & Burman, J. P. (1946). The Design of Optimum Multifactorial Experiments. *Biometrika*, 33(4), 305.
- Nagorny, P., Pillet, M., Pairel, E., Goff, R. L., Loureaux, J., Wali, M., & Kiener, P. (2017). Quality prediction in injection molding. In *2017 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)* (p. 141-146).
- Saenko, K., Kulis, B., Fritz, M., & Darrell, T. (2010). Adapting Visual Category Models to New Domains. In K. Daniilidis, P. Maragos, & N. Paragios (Éd.), *Computer Vision – ECCV 2010* (p. 213-226). Springer Berlin Heidelberg.
- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... Zheng, X. (2016). TensorFlow: A system for large-scale machine learning. *arXiv:1605.08695 [cs]*.
- Chollet, F., & others. (2015). *Keras*.
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv:1409.1556 [cs]*.
- Simonyan, K., Vedaldi, A., & Zisserman, A. (2013). Deep Inside Convolutional Networks: Visualising Image Classification Models and Saliency Maps. *arXiv:1312.6034 [cs]*.
- Li, G., & Yu, Y. (2015). Visual Saliency Based on Multiscale Deep Features (p. 5455-5463). Présenté à Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.
- Springenberg, J. T., Dosovitskiy, A., Brox, T., & Riedmiller, M. (2014). Striving for Simplicity: The All Convolutional Net. *arXiv:1412.6806 [cs]*.
- Smilkov, D., Thorat, N., Kim, B., Viégas, F., & Wattenberg, M. (2017). SmoothGrad: removing noise by adding noise. *arXiv:1706.03825 [cs, stat]*.
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2016). Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. *arXiv:1610.02391 [cs]*.
- Kotikalapudi, R., & contributors. (2017). *keras-vis*.
- Krizhevsky, A. (2009). *Learning Multiple Layers of Features from Tiny Images* (Technical). University of Toronto.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... Ng, A. Y. (2017). CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. *arXiv:1711.05225 [cs, stat]*.
- Chu, C., Zhmoginov, A., & Sandler, M. (2017). CycleGAN, a Master of Steganography. *arXiv:1712.02950 [cs, stat]*.
- Deng, J., Dong, W., Socher, R., Li, L., Li, K., & Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition* (p. 248-255).