الجمـــهـوريـة الجزائريـــة الديمقراطية الشعبيـة
La république algérienne démocratique et populaire
وزارة التـــعليم العـــــالي و البحث العلـــمي
Ministère de l'Enseignement Supérieur et les Recherches Scientifiques

جامعة وهران 2 محمد بن أحمد
Université d'Oran 2 Mohammed Ben Ahmed

معهد الصيانة و الأمن الصناعي
Institut de maintenance et sécurité industrielle

Département Maintenance en Instrumentation

Mémoire de fin d'étude

Pour l'obtention de diplôme Master

Filière : Génie Industriel

Spécialité : Maintenance de l'Automatisme et de l'Instrumentation - MAI

Thème

Conception et Supervision d'une ligne agroalimentaire intégrant la détection optique de germes, la vision industrielle des produits finis et le suivi des non-conformités.

Préparé par :
HAMDI Basmala et **SOUAGUI Fatima Zohra**

Devant le jury composé de :

Nom et prénom	Grade	Establishment	Qualité
Mr. BENARBIA Taha	MCB	IMSI-Univ .d'Oran 2	**Encadreur**
Mr. Benfekir Abderrahim	MCB	IMSI-Univ .d'Oran 2	**Examinateur**
Mr. Adjloua AbdelAziz	MCA	IMSI-Univ .d'Oran 2	**Président**

2025/2026

Remerciements

En premier lieu, nous tenons à remercier notre **ALLAH**, notre créateur pour nous donner la chance d'étudier et la force pour accomplir ce travail.

Nous adressons nos vifs remerciements à nos parents qui nous aident.

Nous tenons à remercier en premier lieu et très chaleureusement notre encadrant **:**Dr. **BENARBIA Taha** pour avoir accepté de diriger notre travail, pour ses précieux Conseils, pour son esprit et pour sa disponibilité.

Nos remerciements s'adressent également aux membres de jury qui nous font l'honneur de juger notre travail.

Nous tenons à remercier tous ceux qui nous ont aidés de près ou de loin, directement ou indirectement à la réalisation de ce travail.

Enfin, nous voudrons exprimer notre reconnaissance à tous les amis et collègues qui nous ont apporté leur soutien moral et intellectuel tout au long de notre démarche.

Résume :

Ce projet vise à développer trois systèmes pour l'industrie agroalimentaire : un système de supervision de la ligne de production et de contrôle du procédé de fabrication, un système de détection optique en temps réel de la contamination microbienne des surfaces, ainsi qu'un système de contrôle qualité visuel des produits finis permettant la classification des produits conformes et non conformes, ainsi que le suivi et l'analyse des non-conformités.

Mots clés :

Ligne agroalimentaire, automatisation, détection optique, contamination microbienne, fluorescence, vision industrielle, apprentissage automatique, classification, analyse des causes, supervision, non-conformités.

Abstract:

This project aims to develop three systems for the agri-food industry: a production line supervision system and manufacturing process control system, a real-time optical detection system for microbial surface contamination, and a visual quality control system for finished products enabling the classification of conforming and non-conforming products, as well as the tracking and analysis of non-conformities.

Keywords:

Food processing line, automation, optical detection, microbial contamination, fluorescence, machine vision, machine learning, classification, root cause analysis, monitoring, non-conformities.

SOMMAIR

Introduction générale 1
Chapitre I : présentation de la ligne de production. 4
I.1. Introduction : 5
I.2. Processus de production : 5
I.2.1. Dosage d'ingrédients : 5
I.2.2. Mélange : 5
I.2.3. Remplissage : 6
I.2.4. Cuisson : 6
I.2.5. Refroidissement : 7
I.2.5. Le conditionnement : 8
I.3. Cahier des charges : 9
I.3.1. Définition des entrées et sorties : 9
I.3.1.1. Entrée : 9
I.3.1.2. Sortie : 9
I.3.2. Principe de fonctionnement : 10
I.3.2.1. Station 01 : 10
I.3.2.2. Station 02 : 11
I.3.2.3. Station 03 : 12
I.3.2.4. Station 04 : 12
I.3.2.5. Station 05 : 13
I.3.2.6. Station 06 : 13
I.3.3. Fonctionnement anormale (les alarmes) : 13
I.4. Problématique : 14
I.5. Objective : 14
I.6. Conclusion : 15
Chapitre II : Technologies de détection optique de germes. 16
II.1. Introduction : 17
II.2. Solutions existantes dans l'industrie agroalimentaire : 17
II.3. Le system proposé : 18
II.3. Positionnement de l'approche proposée : 18
II.4. Principe de fonctionnement : 18

II.4.1. La fluorescence et la réaction UV : 18
II.4.2. Fonctionnement de système : 19
II.5. Capteur et modules optiques : 19
II.5.1. Capteur : 19
II.5.2. L'émission d'UV-A : 20
II.6. Acquisition et transmission des données : 21
II.6.1. Circuit de la LED UV-A : 21
II.6.1.1. La résistance : 22
II.6.1.2. MOSFEST IRLZ44N : 22
II.6.2. Le circuit de traitement du signal de la photodiode : 23
II.6.2.1. Composant amplificateur à transimpédance (TIA) : 24
II.6.2.2. Amplificateur opérationnel MCP6022i/p : 24
II.6.2.3. Résistance de rétroaction Rf et condensateur de rétroaction Cf : 25
II.7. Niveau de propreté : 26
II.7.1. Classification des niveaux de propreté : 26
II.7.2. Méthode d'évaluation du niveau de propreté : 26
II.8. Intégration dans la ligne de production : 27
II.8.1. Principe d'intégration : 27
II.8.2. Séquence de fonctionnement : 27
II.8.3. Intégration avec PLC : 27
II.9. Conclusion : 28
Chapitre III : La vision industrielle basé sur l'intelligence artificielle. 29
III.1. Introduction : 30
III.2. Les techniques de contrôle qualité existent dans la littérature : 30
III.3. Positionnement de l'approche proposée : 31
III.4. La Vision industrielle : 32
III.4.1. Définition de la vision industrielle : 32
III.4.2. Types de systèmes de vision industrielle : 32
III.4.3. Les composants clés de la vision industrielle : 32
III.4.3.1. Objectif : 32
III.4.3.2. Éclairage : 32
III.4.3.3. Camera industrielle : 33
III.4.3.4. Unité de traitement d'images : 33
III.4.3.5. Système d'intégration et communication : 34

III.4.4. Applications de la vision industrielle dans l'industrie agroalimentaire :.....34
III.5. Défauts des biscuits étudiés : 34
III.5.1. Présentation des défauts : 34
III.5.2. Types de défauts :.....35
III.5.2.1. Biscuits trop cuits :.....35
III.5.2.2. Biscuits cassés :.....35
III.5.2.3. Biscuits fissurés : 35
III.5.3. Des causes des défauts étudiés : 35
III.5.3.1. Causes du brunissement des biscuits :.....35
III.5.3.2. Causes de la casse des biscuits :.....35
III.5.3.3. Causes de la fissuration des biscuits : 36
III.6.1. Intelligence artificielle vs apprentissage automatique vs apprentissage profond :....36
III.6.1.1. Intelligence artificielle :.....36
III.6.1.2. Apprentissage automatique :.....36
III.6.1.3. Apprentissage profond :.....36
III.6.2. Types de l'apprentissage automatique : 37
III.6.2.1. Apprentissage supervisé : 37
III.6.2.2. Apprentissage non supervisé :.....38
III.6.2.3. Apprentissage par renforcement :.....38
III.6.3. Types de techniques de l'apprentissage supervise :.....39
III.6.3.1. Classification : 39
III.6.3.2. Régression :.....39
III.7. Les CNN pour la classification : 40
III.7.1. Définition du CNN :.....40
III.7.2. Fonctionnement du CNN : 40
III.7.2.1. Propagation directe :.....40
III.7.2.2. Rétropropagation :.....42
III.7.3. Méthodes de création du modèle : 43
III.7.3.1. Apprentissage à partir de zéro :.....43
III.7.3.2. Apprentissage par transfert : 43
III.7.4. Les principaux types d'apprentissage par transfert : 43
III.7.4.1. Apprentissage par transfert transductif :.....43
III.7.4.2. Apprentissage par transfert inductif : 43
III.7.5. Les stratégies de l'entraînement en apprentissage par transfert :.....44

III.7.5.1. Extraction des caractéristiques :.....44
III.7.5.2. Ajustement fin :.....44
III.7.6. Modèles pré-entraînés populaires :.....44
III.7.7. Processus d'entraînement du modèle pré-entraîné :.....45
III.7.7.1. Stratégie de division des données :.....46
III.7.7.2. Prétraitement des données :.....46
III.7.7.3. Choix de modele :.....47
III.7.7.4. Techniques et réglages utilisées pendant l'entraînement :.....47
III.7.8. L'évaluation du modèle :.....48
III.7.8.1. Matrice de confusion :.....48
III.7.8.2. Exactitude :.....49
III.7.8.3. Précision :.....49
III.7.8.4. Rappel :.....49
III.7.8.5. F1-Score :.....50
III.8. Random Forest pour la classification.....50
III.8.1. Définition de Random Forest :.....50
III.8.2. Caractéristiques principales de l'algorithme :.....50
III.8.3. Avantages d'une forêt aléatoire :.....50
III.8.4. Le fonctionnement du foret aléatoire :.....51
III.8.5. Les hyperparamètres du foret aléatoire :.....51
III.8.6. Processus entraînement et d'évaluation le modèle :.....51
III.9. Conclusion.....52
Chapitre IV : Résultats de la Simulation et Validation des Performances. 53
IV.1. Introduction :.....54
IV.2. Partie 1 : Simulation du Cahier des Charges du Processus de Fabrication des Madeleines :.....54
IV.2.1. Configuration du système automatisé de production :.....54
IV.2.2. Les blocs utilisés :.....54
IV.2.3. Les instructions de base :.....54
IV.2.3. Interfaces IHM et contrôle des équipements :.....55
IV.2.4. Supervision du procédé par le système SCADA :.....55
IV.3. Partie 2 : Tests et Validation du Circuit de Détection des Germes :.....56
IV.3.1. Protocole expérimental :.....56
IV.3.2. Calibration du système et normalisation du signal :.....56
IV.3.3. Conditions de test et échantillons utilisés :.....58

IV.3.3.1. Surface testée :.....58
IV.3.3.2. Configuration géométrique du système : 58
IV.3.3.3. Filtrage optique :.....58
IV.3.3.4. Échantillons testés :.....58
IV.3.4. Résultats expérimentaux : 59
IV.3.4.1. Configuration Rf = 470 kΩ : 59
IV.3.5.2. Configuration Rf = 220 kΩ : 63
IV.3.6. Validation des performances du système : 67
IV.3.8. Limites du système : 68
IV.4. Partie 3 : Développement, Entraînement et Évaluation du Modèle de Contrôle Qualité : 69
IV.4.1. Le modèle de classification : 69
IV.4.1.1. Données : 69
IV.4.1.2. Développement et entraînement du modèle : 70
IV.4.1.3. Optimalisation du modèle : 71
IV.4.1.4. Résultats de simulation dans l'environnement Google Colab :.....72
IV.4.1.5. Interprétation les résultats : 74
IV.4.2. Le modèle d'analyse les causes :.....74
IV.4.2.1. Les donnes :.....74
IV.4.2.2. Développement et entraînement du modèle : 74
IV.4.2.3. Résultats de simulation : 75
IV.4.2.4. Interprétation les résultats : 77
IV.4.3. Déploiement sur Raspberry Pi :.....78
IV.4.3.1. Configuration matérielle : 78
IV.4.3.2. Résultats expérimentaux du modèle de la conformité : 78
IV.4.3.3. Résultats expérimentaux du modèle de la cause : 80
IV.4.4. Limites et perspectives des modèles :.....81
IV.4.4.1. Limitations du modèle : 81
IV.4.4.2. Perspectives d'amélioration des modèles :.....82
IV.5. Conclusion : 82
Conclusion générale.....83
Références 85

Liste des figures

Figure I.1. Mélanger industrielle [85] 6
Figure I. 2.La composition du four tunnel [5] 7
Figure I. 3.La composition de la machine d'emballage [6] 8

Figure II. 1. Le système proposé 18
Figure II. 2. Fluorescence visibles vert [15]. 19
Figure II. 3. Fluorescence visibles bleu [15] 19
Figure II. 4. Photodiode Hamamatsu S12227-1010BR [16] 19
Figure II. 5.LED UV-A seoal viosys UVZ5_CUN66A1B [17] 20
Figure II. 6. Circuit de la LED UV-A. 22
Figure II. 7. MOSFEST IRLZ44N [18] 22
Figure II.8. Amplificateur à Transimpédance (TIA) [20] 23
Figure II. 9. Circuit amplificateur à transimpédance (TIA) 24
Figure II. 10. Amplificateur opérationnel MCP6022i/p [20] 25

Figure III. 1. Les applications d'Intelligence artificielle [87] 36
Figure III. 2.Architecture d'un réseau de neurones [46] 37
Figure III. 3. Apprentissage supervisé [82] 38
Figure III. 4. Apprentissage non supervisé [49] 38
Figure III. 5.Apprentissage par renforcement [50] 39
Figure III. 6. Type de technique de l'apprentissage supervise [52] 39
Figure III.7.L'architecture du CNN [54] 40
Figure III. 8. Les couches de convolution [54] 41
Figure III. 9. Les couches de pooling [54] 41
Figure III.10. Les Couches entièrement connectées [57] 42
Figure III. 11. Méthodes de création du modèle [60] 43
Figure III.12. Cycle de fonctionnement des données [63] 46
Figure III. 13. Matrice de confusion [69] 49
Figure III. 14. L'architecture de Random Forest [72] 50

Figure IV. 1.Paramètre de calibration de la tension de base dans le code 56
Figure IV. 2.Calcul du signal (Vout − Vbase) dans le code. 56
Figure IV. 3.Normalisation du signal par rapport à la valeur maximale (0.10 V). 57
Figure IV. 4.Calcul du pourcentage de propreté à partir du signal normalisé. 57
Figure IV. 5.Table de classification des signaux de contamination 57

Figure IV. 6. Surface en inox propre.....59
Figure IV. 7.Surface en inox avec film d'eau.....59
Figure IV. 8.Surface en inox avec couche d'huile.....59
Figure IV. 9.Surface en inox avec résidus alimentaires.....59
Figure IV. 10.Réponse du système pour une surface propre en inox. 60
Figure IV. 11.Figure IV. 12. Mesure de tension de sortie (surface propre en inox).....60
Figure IV. 12.Mesure de signal et pourcentage de propreté (surface propre en inox).....60
Figure IV. 13.Réponse du système pour une surface en inox avec film d'eau. 61
Figure IV. 14.Mesure de tension de sortie (surface en inox avec film d'eau).....61
Figure IV. 15.Mesure du signal et du pourcentage de propreté (surface en inox avec film d'eau). 61
Figure IV. 16.Réponse du système pour une surface en inox avec couche d'huile.....62
Figure IV. 17.Mesure de tension de sortie (surface en inox avec couche d'huile).....62
Figure IV. 18.Mesure du signal et du pourcentage de propreté (surface en inox avec couche d'huile). 62
Figure IV. 19.Réponse du système pour une surface en inox avec résidus alimentaires. 62
Figure IV. 20.Mesure de tension de sortie (surface en inox avec résidus alimentaires). 63
Figure IV. 21.Mesure du signal et du pourcentage de propreté (surface en inox avec résidus alimentaires). 63
Figure IV. 22.Réponse du système pour une surface en inox propre. 64
Figure IV. 23.Mesure de tension de sortie (surface en inox propre). 64
Figure IV. 24.Mesure du signal et du pourcentage de propreté (surface en inox propre).....64
Figure IV. 25.Réponse du système pour une surface en inox avec film d'eau. 65
Figure IV. 26.Mesure du signal et du pourcentage de propreté (surface en inox avec film d'eau). 65
Figure IV. 27.Mesure de tension de sortie (surface en inox avec film d'eau).....65
Figure IV. 28.Réponse du système pour une surface en inox avec couche d'huile.....66
Figure IV. 29.Mesure de tension de sortie (surface en inox avec couche d'huile).....66
Figure IV. 30.Mesure du signal et du pourcentage de propreté (surface en inox avec couche d'huile). 66
Figure IV. 31.Réponse du système pour une surface en inox avec résidus alimentaires. 66
Figure IV. 32.Mesure de tension de sortie (surface en inox avec résidus alimentaires). 67
Figure IV. 33.Mesure du signal et du pourcentage de propreté (surface en inox avec résidus alimentaires). 67
Figure IV. 34.Les classes défectueuses 69
Figure IV. 35.Division les donnes. 69
Figure IV. 36.Prétraitement des données d'entraînement 70
Figure IV. 37.Création du modèle final. 70
Figure IV. 38.Compilation et entraînement du model. 71
Figure IV. 39.Dégel les couches du MobileNetv2.....71
Figure IV. 40.Matrice de confusion du modèle entraîné.....72
Figure IV. 41.Matrice de confusion du modèle lors de l'évaluation finale sur les donnes de test. 73
Figure IV. 42.Les données générées artificiellement pour l'entraînement du modèle. 74
Figure IV. 43.Les caractéristiques extraites. 74
Figure IV. 44.Paramètres utilisés dans GridSearchCV. 75

Figure IV. 45.Création du modèle Random Forest. 75
Figure IV. 46.Entraînement et prédiction du modèle 75
Figure IV. 47.Matrice de confusion du label surchauffe. 76
Figure IV. 48.Matrice de confusion du label humidité. 76
Figure IV. 49.Importance des caractéristiques pour le label surchauffe. 77
Figure IV. 50. Importance des caractéristiques pour le label humidité. 77
Figure IV. 51.Prédiction du modèle du biscuit trop cuit. 78
Figure IV. 52.Prédiction du modèle du biscuit cassé. 79
Figure IV. 53.Prédiction du modèle du biscuit bon. 79
Figure IV. 54.Prédiction du modèle du biscuit fissuré. 79
Figure IV. 55.Prédiction du modèle du biscuit fissuré 80
Figure IV. 56.Biscuit trop cuit – causes et recommandations. 81
Figure IV. 57.Biscuit cassé – causes et recommandations. 81

Liste des tableaux

Tableau I. 1.les valeurs de poids 10

Tableau II.1.Solutions existantes dans l'industrie agroalimentaire. 17
Tableau II. 2. Paramètres clés de photodiode Hamamatsu S1227- 1010BR [16] 20
Tableau II. 3. Paramètres clés de seoal viosys UVZ5_CUN66A1B [17] 21
Tableau II. 4. Caractéristiques techniques principales de l'IRLZ44N [18] : 23
Tableau II. 5. Caractéristiques techniques principales de MCP6022i/p 25

Tableau III.1. Les techniques existantes dans la classification de la conformité des produits 30
Tableau III.2. Les techniques existant dans l'analyse de cause. 31
Tableau III 3. Les différences clés d'Apprentissage automatique et Apprentissage profond [47] 37
Tableau III.4. Comparaison des performances de ResNet, MobileNet et EfficientNet [62] 45

Tableau IV. 1. Table de classification des signaux de contamination 57
Tableau IV. 2. Résultats de détection des niveaux de contamination pour une configuration de 470 kΩ. 60
Tableau IV. 3. Résultats de détection des niveaux de contamination pour une configuration de 220 kΩ 63
Tableau IV. 4. Mesures de performance du modèle lors de l'évaluation sur les donnes de validation 72
Tableau IV. 5. Mesures de performance du modèle lors de l'évaluation finale sur les donnes de test 73
Tableau IV. 6. Métriques d'évaluation du label surchauffe 75
Tableau IV. 7. Métriques d'évaluation du label humidité. 76

Liste d'équation

V_ batterie = V_R + V_LED + V_MOSFET (II.1) 22
V_out = V_ref -Iin * Rf (II. 2).....23
Propreté (%) = 100 × (1 − Ratio) (II. 3) 26
Ratio = Signal / Signal_max (II. 4).....26

Exactitude = $\frac{TP+TN}{TP+TN+FP+FN}$ (III. 1) 49
Précision = $\frac{TP}{TP+FP}$ (III. 2).....49
Rappel $= TP/((TP + FN)\ )$ (III. 3) 49
F1 =2 $\cdot \frac{Rappel \cdot Précision}{Rappel + Précision}$ (III. 4).....50

Signal = Vout – Vbase (IV. 1).....56
Ratio = Signal / Signal_max (IV. 2).....56
Propreté (%) = 100 × (1 − Ratio) (IV. 3).....57

Liste des abréviations

ADAM : Adaptive Moment Estimation
ADN : Acide DésoxyriboNucléique
API : Automate Programmable Industriel
ARN : Acide RiboNucléique
CCD : Charge-Coupled Device
CMOS : Complementary Metal-Oxide-Semiconductor
CNN : Convolutional Neural Network
CPU : Central Processing Unit
DIP : Dual In-line Package
DP : Decentralized Periphery
DSP : Digital Signal Processor
FB : Function Block
FPGA : Field-Programmable Gate Array
G120 : Variateur de fréquence Siemens SINAMICS G120
GPU : Graphics Processing Unit
HMI / IHM : Human Machine Interface / Interface Homme-Machine
IA : Intelligence Artificielle
IP : Indice de Protection
LED : Light Emitting Diode
MES : Manufacturing Execution System
MOSFET : Metal-Oxide-Semiconductor Field-Effect Transistor
NADH : Nicotinamide Adénine Dinucléotide
NF : Normalement Fermé
NIH : National Institutes of Health
NO : Normalement Ouvert
OB1 / OB32 : Organisation Block
PC : Personal Computer
PCR : Polymerase Chain Reaction
PID : Proportionnel Intégral Dérivé
PLC : Programmable Logic Controller
PN : PROFINET
PV : Process Value
RAM : Random Access Memory
RDS : Résistance Drain-Source
ReLU : Rectified Linear Unit
ResNet : Residual Network
RGB : Red Green Blue
SCADA : Supervisory Control And Data Acquisition
SP : Setpoint
SVM : Support Vector Machine
TIA : Transimpédance Amplifier / Totally Integrated Automation
TOR : Tout Ou Rien
TP700 / TP900 : Touch Panel 700 / 900
TPU : Tensor Processing Unit
USB : Universal Serial Bus

UV : Ultraviolet
VDD : Tension d'alimentation
VDS : Tension Drain-Source
VFD : Variable Frequency Drive
VGS : Tension Grille-Source
WinCC : Windows Control Center
XGBoost : Extreme Gradient Boosting

Introduction générale

Introduction générale :

Dans l'industrie agroalimentaire, et plus particulièrement dans la fabrication des produits de pâtisserie comme les madeleines et les biscuits, la qualité des produits et la sécurité des surfaces de production sont essentielles pour assurer la conformité aux exigences réglementaires et préserver la réputation de l'entreprise.

Ces lignes de production sont des environnements sensibles qui demandent un suivi constant, un contrôle rigoureux et une supervision continue afin de maintenir une bonne stabilité de la qualité et de limiter l'apparition de défauts. D'un côté, les défauts visibles comme les fissures ou les variations de couleur influencent directement la qualité du produit et son acceptation. De l'autre, les contaminations microbiennes sur les surfaces en contact avec les aliments représentent un risque important, ce qui nécessite une surveillance attentive et des actions préventives adaptées.

Dans ce contexte, et vu l'importance du contrôle et de la supervision des lignes de production de pâtisserie, notamment des madeleines et des biscuits, un système de supervision de la ligne de production des madeleines est proposé pour assurer la surveillance et le pilotage en temps réel du processus de fabrication. Il est complété par un système de détection des germes dans les madeleines ainsi qu'un système de contrôle de qualité des biscuits. L'objectif de ce travail est de concevoir ces différents systèmes et de les rendre plus performants.

Ce travail est organisé en quatre chapitres :

- Le premier chapitre présente la ligne de production des madeleines, depuis le dosage des ingrédients jusqu'au conditionnement, en passant par le mélange, le remplissage, la cuisson et le refroidissement. Il décrit également le cahier des charges du système de contrôle automatique, incluant la définition des entrées/sorties, le principe de fonctionnement des six stations de production, ainsi que la gestion des alarmes en mode de fonctionnement anormal.

- Le deuxième chapitre traite des technologies de détection optique des germes. Il présente les solutions existantes dans l'industrie agroalimentaire, le principe physique de la fluorescence et UV-A utilisent pour la détection microbienne, les composants optiques retenus notamment la LED UV-A et la photodiode, le circuit de traitement du signal par transimpédance à base de l'amplificateur opérationnel MCP6022, la classification des niveaux de propreté en quatre catégories, et l'intégration du système dans la ligne de production avec l'automate programmable.

- Le troisième chapitre présente les techniques de vision industrielle basées sur l'intelligence artificielle pour le contrôle qualité des biscuits. Il passe en revue les techniques existantes, définit les types de défauts étudiés (trop cuits, cassés, fissurés) et leurs causes liées aux paramètres du procédé, puis présente les fondements de la vision industrielle et de l'IA. Il détaille l'architecture CNN, les méthodes d'apprentissage par transfert et le processus d'entraînement du modèle MobileNetV2 pour la classification visuelle, incluant la division des données, le prétraitement et les métriques d'évaluation, ainsi que l'algorithme Random Forest, son fonctionnement, ses hyperparamètres et son processus d'entraînement pour l'analyse des causes de non-conformité.

- Le quatrième chapitre présente les résultats de simulation et de validation en trois parties : la simulation du procédé de fabrication sous TIA Portal avec supervision HMI et SCADA WinCC ; les tests expérimentaux du circuit de détection des germes sur surface en acier inoxydable, avec protocole de calibration et comparaison des deux configurations de gain ; et le développement et l'évaluation des deux modèles MobileNetV2 et Random Forest, entraînés sur des données générées artificiellement et déployés sur Raspberry Pi 4, avec une analyse des performances et une sensibilité constatée aux conditions de prise de vue.

Chapitre I :
présentation de la ligne de production.

I.1. Introduction :

Les unités de production des boulangeries, telles que les madeleines et les biscuits, sont conçues sur la base d'un mécanisme afin d'assurer la continuité, l'efficacité et la productivité des étapes de production. Les deux produits sont similaires à plusieurs étapes de la production, telles que le dosage, le pétrissage, le refroidissement et l'emballage, mais ils diffèrent par les quantités d'ingrédients, la composition de la pâte, la méthode de façonnage et les types d'équipement utilisés dans les différentes étapes.

À madeleine, la pâte est remplie dans des moules pour former, tandis que dans les biscuits, la pâte est étalée, coupée et façonnée. Ces différences rendent les systèmes conçus par machine différents entre eux.
Ce chapitre décrit le processus de production des madeleines, à partir de l'étape de dosage jusqu'à l'emballage, et la conception du cahier des conditions pour le contrôle automatique de ce processus, en mentionnant les entrées et sorties de ce système et son principe de fonctionnement dans l'étape normale ou anormale.

I.2. Processus de production :

I.2.1. Dosage d'ingrédients :

Le système de dosage (station 01) se met en marche dès que la production est lancée. Il fonctionne de façon séquentielle. Chaque ingrédient est ajouté à la cuve jusqu'à atteindre la valeur poids de consigne définie. Dès que le poids est atteint, le système passe automatiquement à l'ingrédient suivant. Le processus est continu jusqu'à la fin du dosage de tous les ingrédients. La précision du dosage est assurée par une balance équipée d'un capteur de poids qui mesure la valeur réelle de poids cumulé.

Les ingrédients liquides sont stockés dans des réservoirs. Leur transfert vers la cuve de dosage est assuré par des pompes, tandis que des électrovannes commandent l'ouverture et la fermeture du circuit.

Les ingrédients solides sont introduits à l'aide d'un système de vis d'alimentation [1] entraînée par un moteur, permettant un apport progressif de la matière vers la cuve.

À la fin de l'opération de dosage, une vanne de décharge s'ouvre automatiquement, permettant le transfert de l'ensemble des ingrédients vers le mélangeur pour l'étape suivante.

I.2.2. Mélange :

Après que l'étape de dosage est finie et la fermeture du batteur. Le cycle de mélange (station 02) se déclenche automatiquement. Le mélange s'effectue selon un cycle temporel défini, avec une variation de la vitesse de rotation du moteur. L'ajustement de la vitesse permet d'obtenir une pâte homogène. Une fois le mélange terminé, une pompe de transfert assure l'acheminement de la pâte vers l'étape suivante du processus de production.



Figure I.1. Mélanger industrielle [86]

I.2.3. Remplissage :

Station 04 débute lorsque l'opérateur lance le cycle de remplissage. Le convoyeur se met en marche pour transporter les plateaux. Lorsqu'un plateau est détecté en position, un système d'arrêt immobilise le convoyeur afin de permettre l'opération de remplissage.
Le processus de dosage commence par la prise de la pâte. Ensuite, un injecteur assure l'injection de la pâte dans les moules avec précision.
Une fois le remplissage effectué, le convoyeur avance d'un pas (fonctionnement pas à pas) pour positionner la prochaine ligne de moules d'un plateau. Ce cycle se répète plusieurs fois, assurant le remplissage complet des moules sur le plateau.

Après la fin du cycle de dosage, le plateau est libéré et le convoyeur reprend alors son mouvement pour transférer ce plateau vers l'étape suivante, tandis qu'un nouveau plateau est acheminé en position pour le cycle suivant.

I.2.4. Cuisson :

La cuisson fonctionne par un four tunnel à flamme directe composé de plusieurs systèmes.

- Le système d'évacuation contient la porte de cheminée pour évacuer les fumées et la chaleur, ainsi qu'un ventilateur extracteur qui contrôle cette évacuation.
- Le système de combustion contient un ventilateur qui fournit l'air nécessaire à la combustion. L'air fourni est acheminé par des conduits vers les brûleurs. [2]
- Le four contient deux zones : dessus et dessous. Chaque zone contient des capteurs de température et des vannes de gaz régulées par un PID et des et des brûleurs. [3]
- Le système de ventilation permet de faire circuler l'air chaud dans le four et d'assurer une répartition homogène de la chaleur. [2]
- Le système de convoyage transporte les madeleines sur des plateaux vers la chambre de cuisson. [4]

La vitesse du convoyeur détermine le temps de cuisson :

Temps de cuisson = Longueur du four tunnel ÷ Vitesse du convoyeur.

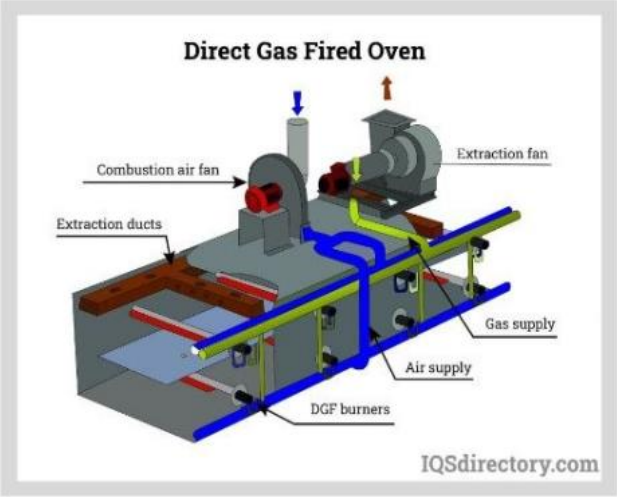


Figure I. 2.La composition du four tunnel *[5]*

I.2.5. Refroidissement :

La station de refroidissement abaisse la température des madeleines sortant du four à une température adaptée aux processus d'emballage. Elle comprend deux systèmes principaux :

- Le système de convoyage se compose de deux convoyeurs de grande longueur, assurant un temps de refroidissement suffisant avant l'emballage. De plus, sa vitesse détermine la durée de séjour des madeleines à ce poste.

- Le système de ventilation est composé de deux ventilateurs fixes installés sur le long convoyeur. Il fournit de l'air frais, accélérant ainsi le refroidissement du produit. Le débit d'air est contrôlé par la vitesse des ventilateurs, garantissant cette efficacité.

I.2.5. Le conditionnement :

Le conditionnement utilise une machine de scellage horizontale, qui se compose de plusieurs systèmes, dont :

- Le système de convoyage se compose :

  D'un convoyeur qui transporte les madeleines de la station précédente vers la station de formage, où le papier film est transformé en tube. [6]

  Ensuite, il est acheminé vers la station de scellage avec une vitesse adaptée à la vitesse de production des paquets par minute.

  Un convoyeur de décharge évacue les paquets vers la mise en carton. [7]
- Le système d'alimentation du film comprend des rouleaux qui tirent et guident le film vers la zone de formage. [6]
- Le capteur de marque de couleur détecte la présence du film ainsi que la longueur d'un paquet. Ce film est scellé longitudinalement par trois paires de molettes : la première paire est froide, tandis que la deuxième et troisième paires sont chauffées. La température de la dernière paire est inférieure à celle de la deuxième. Cette opération forme un tube.
- Après ce scellage, le tube est scellé transversalement et coupé par la lame à l'avant et à l'arrière par des mâchoires rotatives. [7], [6]
- Le scellage thermique, aussi bien transversal que longitudinal, est contrôlé par PID.
- L'opérateur saisit des consignes de température pour chaque zone de scellage du papier film (HDPE) dans la plage de 120 à 150 °C. [8]
- Le convoyeur d'entrée, le système d'alimentation du film, les molettes et les mâchoires rotatives sont synchronisés grâce à des moteurs synchrones ou à des servomoteurs.

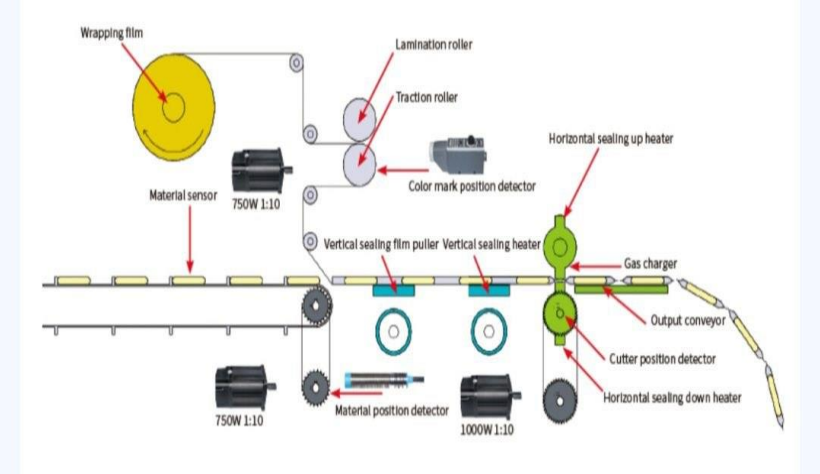


Figure I. 3.La composition de la machine d'emballage [7]

I.3. Cahier des charges :

I.3.1. Définition des entrées et sorties :

Le système d'automatisation de la ligne de production repose sur une architecture d'entrées/sorties réparties sur les différentes stations du processus : dosage des ingrédients, mélange, dosage dans les moules, cuisson, refroidissement et emballage.

I.3.1.1. Entrée :

- Commandes opérateur :

  Boutons : Marche, arrêt, arrêt d'urgence et réinitialiser pour chaque poste.

- Capteurs TOR (Tout Ou Rien) :
  Capteur de niveau.
  Capteur de porte fermée.
  Fins de course (6 capteurs pour les vérins et mécanismes)
  Capteurs de présence.
  Détecteur de gaz.
  Pressostat de gaz.
  Capteur de position de la porte d'emballage.
  Capteur photoélectrique de détection de marque.

- Capteurs analogiques :

  Capteur de poids (balance pour dosage des ingrédients).
  Quatre thermocouples des zones du four.
  Débitmètre d'air du ventilateur de combustion.
  Trois thermostats pour les molettes et les mâchoires rotatives.
  Quatre codeurs pour les moteurs synchrones.

I.3.1.2. Sortie :

- Actionneurs et pré-actionneurs (TOR) :

Électrovannes (5 sorties TOR) pour commande ouverture/fermeture.
Distributeurs pneumatiques pour vérins (cylindre, injecteur, stopper).
Pompe à membrane (dosage liquides).
Pompe de transfert.
Moteur pas à pas pour le convoyeur de remplissage.
Contacteurs pour moteurs asynchrones : porte de cheminée, ventilateurs et convoyeurs du four et du refroidissement.
Vanne d'air et vanne de gaz principale.
Quatre contacteurs pour moteurs synchrones (ou servomoteurs) de la machine d'emballage : convoyeur d'alimentation, alimentation du film, mâchoires rotatives et convoyeur de décharge.

- Actionneurs et pré-actionneurs analogiques :

Variateurs de vitesse (VFD) pour :
Moteur mélangeur.
4 moteurs vis d'alimentation.
Les ventilateurs.
Les convoyeurs four et du refroidissement.
Moteur de convoyeur d'alimentation.
Alimentation du film.
Mâchoires rotatives et convoyeur de décharge.
Quatre vannes régulatrices du gaz.
Trois résistances pour les molettes et les mâchoires rotatives.

I.3.2. Principe de fonctionnement :

I.3.2.1. Station 01 :

- Lorsque l'opérateur appuie sur le bouton marche, le système de dosage est activé. Le PLC compare la valeur réelle du poids mesurée par la balance avec les valeurs de consigne définies dans la recette.
- Le système fonctionne sur une base de poids cumulé, ce qui signifie que la valeur de mesure augmente progressivement jusqu'à atteindre le poids total de la recette.
- Chaque ingrédient est défini par une plage de consigne [SP min et SP max].
- Lorsque la valeur mesurée atteint le SP min, le système autorise l'alimentation de l'ingrédient correspondant.
- Lorsque la valeur atteint le SP max, l'alimentation est arrêtée et le système passe automatiquement à l'ingrédient suivant.

Tableau I. 1.les valeurs de poids

Poids total final : 870 kg			
Ingrédient	SP Min (kg)	SP Max (kg)	Quantité recette (kg)
Eau	0	20	20
Sorbitol	20	28	8
Glycérol	28	32	4
Œufs	32	47	15
Huile	47	82	35
Farine	82	132	50
Sucre	132	167	35
Sorbate	167	567	400
Sel	567	867	300

- Les ingrédients liquides sont dosés à l'aide de électrovannes TOR et pompes à membrane.
- Lorsque le SP max est atteint la vanne se ferme la pompe s'arrête.
- Un délai de sécurité de 3 secondes est appliqué afin de garantir la fermeture complète avant le passage à l'ingrédient suivant.
- Les ingrédients solides sont dosés par un système motorisé commandé par variateur de vitesse (VFD).
- Le moteur fonctionne à vitesse normale au début du dosage.
- Lorsque la valeur atteint SP max - 2 kg, la vitesse diminue progressivement.
- À SP max, le moteur s'arrête.
- Un délai de 3 secondes est appliqué avant de passer à l'ingrédient suivant.
- Lorsque le poids cumulé atteint la valeur totale de la recette (870 kg), le système de dosage est terminé.
- Une électrovanne de décharge s'ouvre afin de vider la cuve, et elle se referme automatiquement lorsque le poids revient à 0 kg.
- Aucun nouveau cycle de dosage ne peut commencer tant que l'opérateur n'a pas réappuyé sur le bouton marche.

I.3.2.2. Station 02 :

- Une fois les ingrédients introduits dans le mélangeur, un capteur de niveau TOR confirme la présence effective de la pâte dans la cuve ainsi que la fin complète du dosage.
- Le démarrage du moteur de mélange autorisé si la porte du mélangeur est correctement fermée, qui est confirmé par un capteur de sécurité TOR.
- Le moteur du mélangeur est commandé par un variateur de vitesse (VFD), permettant une variation de la vitesse en trois phases :

  Phase 1: 50 s à 90 rpm.
  Phase 2: 200 s à 165 rpm.
  Phase 3: 10 s à 40 rpm.
- La durée totale du cycle de mélange est d'environ 260 secondes, afin de garantir une pâte homogène.
- À la fin du cycle de mélange, une pompe de transfert est activée afin d'acheminer la pâte vers l'étape suivante du processus.
- Un capteur de niveau TOR situé en haut de la cuve de remplissage confirmé le niveau de remplissage.
- Lorsque le capteur est activé (niveau haut atteint), la pompe s'arrête.
- Lorsque le niveau est bas ou absent, la pompe redémarre automatiquement.

I.3.2.3. Station 03 :

- Cette étape débute lorsque l'opérateur lance le cycle et appuie sur le bouton marche. Le convoyeur se met en marche, tandis que le stopper est en position basse libre passage des plateaux.
- Lorsqu'un plateau est détecté sous la station de dosage par un capteur de présence, le convoyeur s'arrête et un vérin pneumatique (le stoppeur) commande par un distributeur se relève le plateau, afin de maintenir en position.
- Le cycle de remplissage commence alors selon la séquence suivante :
  Le vérin du cylindre s'active, permettant la prise et la retenue d'une quantité de pâte.
  Le vérin de l'injecteur s'ouvre, injectant la pâte dans les moules.
  Le vérin de l'injecteur se referme et revient à sa position initiale.
  Le vérin du cylindre revient également à sa position initiale sous la plaque de dosage.

- Une fois cette opération terminée, le stopper redescend et le convoyeur avance d'un pas (fonctionnement pas à pas) afin de positionner la ligne suivante de moules.
- Ce cycle est répété 7 fois pour assurer le remplissage complet du plateau.
- À la fin du cycle complet, Le stopper se rétracte complètement (position basse), et Le convoyeur reprend son mouvement continu pour transférer le plateau rempli vers l'étape suivante,
- Lorsqu'un nouveau plateau est détecté en position pour démarrer un nouveau cycle.

I.3.2.4. Station 04 :

- Appui sur le bouton Marche : démarrage du moteur de la porte de cheminée.
- Si le moteur de la porte de cheminée est en marche : Démarrage du moteur de l'extracteur à une vitesse de 10 %.
- Si la vitesse de l'extracteur est de 10 % :
  Démarrage du moteur du ventilateur d'air de combustion à une vitesse de 800 tr/min pour fournir un débit d'air prédéterminé.
- Si le débitmètre détecte la valeur prédéterminée : Ouverture de la vanne d'air.
- Si la vanne d'air est ouverte et que le détecteur de gaz n'indique pas de fuite de gaz et que le pressostat indique une pression stable : Ouverture de la vanne de gaz principale, puis ouverture des vannes modulantes de chaque zone (dessus et dessous) avec une valeur de départ de 30 % afin d'atteindre une puissance minimale des brûleurs.
- Si les vannes de gaz sont ouvertes à 30 % : Allumage des brûleurs.
- Ensuite, les thermocouples mesurent la valeur réelle. L'opérateur saisit la consigne de chaque zone (zone 1 haut : 320 °C, zone 1 bas : 330 °C, zone 2 haut : 325 °C, zone 2 bas : 335 °C). Le PID calcule l'erreur et ajuste les vannes de gaz.
- Après l'allumage des brûleurs et après 3 s : mise en marche du ventilateur de circulation d'air chaud à une vitesse initiale de 15 %, représentant la valeur de départ.

- Si le ventilateur est démarré : Démarrage du moteur du convoyeur à une vitesse selon la longueur du four (18 m) et le temps de cuisson (15 min), soit 1,2 tr/min

I.3.2.5. Station 05 :

- Appuyer sur le bouton marche : démarrage des moteurs des convoyeurs à une vitesse de 750 tr/min.

  Démarrage des moteurs des ventilateurs à une vitesse de 50 %, variable par l'opérateur selon la compatibilité avec le refroidissement des madeleines.

I.3.2.6. Station 06 :

- Appuyer sur le bouton marche et le capteur de position de la porte indique la fermeture : Démarrage des moteurs des convoyeurs d'alimentation et des mâchoires rotatives.
- L'opérateur saisit le taux de production (selon la plage de 10 à 120 paquets/min) et la longueur du sachet (mm selon la plage de 60 à 500) :
  À partir de ces paramètres est définie la vitesse du moteur des mâchoires et des convoyeurs.
- Si le moteur des mâchoires rotatives démarre :
  le moteur d'alimentation du film démarre. Ainsi, la vitesse de rotation de ce moteur est synchronisée avec la vitesse des mâchoires ; cette synchronisation est assurée par les encodeurs.
- L'opérateur saisit les consignes de température des molettes (135 °C pour la deuxième molette et 125 °C pour la troisième molette) et des mâchoires (145 °C) : les thermostats mesurent la valeur réelle et régulent cette valeur à travers le PID, qui donne en pourcentage la puissance des résistances.
- Le convoyeur de décharge démarre lorsque le convoyeur d'alimentation démarre et fonctionne à la même vitesse que ce dernier.

I.3.3. Fonctionnement anormale (les alarmes) :

En cas de déclenchement d'une alarme, le système passe en état anormal. Après l'élimination du défaut, l'alarme ne s'arrête pas automatiquement ; il est nécessaire d'appuyer sur le bouton de réinitialisation afin de rétablir le fonctionnement normal. Les alarmes sont déclenche si :

- Le moteur tourne alors que la porte de sécurité est ouverte.
- Le mélangeur et la pompe de transfert fonctionnent simultanément.
- L'injecteur s'ouvre alors que le Viren de dosage est fermé.
- Le Verin de dosage est ouvert, mais le capteur de position ne détecte pas le plateau.
- Le convoyeur ne fonctionne pas tant que le stoppeur est relevé.
- En cas de surcharge d'un moteur, le relais thermique coupe le circuit électrique et déclenche l'alarme, quel que soit le moteur concerné dans les stations 4, 5 et 6.
- Lorsque le pressostat détecte une pression de gaz instable ou hors de la valeur de consigne, une alarme de pression se déclenche et la vanne principale de gaz se ferme automatiquement.
- En cas de fuite de gaz, une alarme gaz se déclenche automatiquement et entraîne la fermeture de la vanne principale de gaz.

- Si la température de la zone 1 ou de la zone 2 atteint ou dépasse 400 °C, une alarme est déclenchée.
- Lorsque la température dans les scellages thermique des mâchoires rotatives ou des molettes dépasse 150 °C, une alarme se déclenche.

I.4. Problématique :

Dans l'industrie alimentaire, la qualité des produits et la sécurité alimentaire sont deux conditions essentielles pour garantir les normes de qualité et de santé.

Dans la fabrication des biscuits, les défauts esthétiques du produit final représentent un problème important, car ils ont un impact sur la satisfaction du consommateur ainsi que l'image de marque. En général, ces problèmes sont liés à des variations des paramètres du procédé de fabrication. C'est pour cela qu'il est important de classer la conformité des produits et d'analyser les paramètres du procédé afin de suivre les non-conformités et d'améliorer le fonctionnement du système.

De plus, les communautés microbiennes d'origine alimentaire représentent une menace importante pour la santé publique ; étant une cause d'intoxications et d'infections alimentaires. Selon les Instituts nationaux de la santé (NIH), environ 80 % des infections humaines sont liées à la formation de biofilms [9].Sur les surfaces qui touchent les aliments, comme les équipements et les canalisations, des groupes de microbes se forment. Ces microbes aident les bactéries à résister au nettoyage et à la désinfection, ce qui peut provoquer une contamination des aliments.
Les solutions existantes traitent généralement ces deux problématiques de manière séparée, sans intégration dans un même système de supervision industrielle.

Dans ce contexte, la problématique peut être formulée comme suit :

1. Comment assurer la classification de la conformité visuelle des produits et l'analyse des causes des non-conformités dans une ligne agroalimentaire automatisée ?
2. Comment assurer la supervision et le contrôle d'une ligne agroalimentaire en intégrant un système de détection optique capable d'évaluer en temps réel le niveau de contamination des surfaces, tout en permettant une interaction avec le système de commande industrielle ?

I.5. Objective :

Le but principal de ce projet est de créer un système de supervision pour une ligne de production agroalimentaire, qui assure surveillance contrôle de la qualité des produits et la vérification de la sécurité alimentaire.

Pour atteindre ce but, plusieurs sous objectifs spécifiques sont définis :

- Mettre en place un système de classification de la conformité des produits visuels afin d'assurer la qualité esthétique.
- Analyser les paramètres de production afin d'identifié les cause des liées aux non-conformités.
- Développer un système de détection optique basé sur la fluorescence pour évaluer le niveau de contamination des surfaces.

- Intégrer systèmes de détection dans une ligne de production pour supervision et assurer l'interaction avec un système de commande industrielle (PLC) afin de permettre une réaction automatique en temps réel.
- Garantir une surveillance de la qualité et niveau de contamination continue et fiable de la ligne de production.

I.6. Conclusion :

Une étude de la ligne de production de Madeleine a montré qu'elle repose sur un enchaînement précis des opérations, de sorte que le passage d'une étape à l'autre assure l'étape suivante, faisant du respect des conditions d'exploitation un élément crucial pour assurer la continuité du processus de production. Le cahier des conditions générales explique comment le système fonctionne à l'état normal, puis passe à l'état inhabituel si les conditions de fonctionnement ne sont pas remplies.

La structure de contrôle est basée sur des entrées, dont la plupart sont des capteurs TOR qui donnent un état logique, en plus de capteurs analogiques qui mesurent diverses variables physiques et des sorties qui contrôlent les actionneurs tels que les vannes, les propulseurs et les moteurs, qui assurent le contrôle automatique du mouvement et du flux du processus de production.

Chapitre II :

Technologies de détection optique de germes.

II.1. Introduction :

Dans le secteur agroalimentaire, la propreté des surfaces joue un rôle essentiel pour prévenir la contamination microbienne et garantir la sécurité alimentaire. Les pathogènes d'origines alimentaires présents sur les surfaces en contact avec les aliments peuvent entraîner de graves risques pour la santé. Pour cela, plusieurs techniques sont utilisées pour détecter et contrôler la contamination microbienne.

Dans ce contexte, le chapitre présente le principe physique de la fluorescence utilisé pour la détection microbienne, suivi d'un aperçu des solutions existantes dans la littérature. Enfin, l'approche proposée est présentée et positionnée par rapport à ces méthodes existantes.

II.2. Solutions existantes dans l'industrie agroalimentaire :

La détection et le contrôle de la contamination microbienne sur les produits alimentaires et les surfaces en contact avec le produit sont cruciaux dans le secteur agroalimentaire. Pour cela, plusieurs techniques sont utilisées qui garantissent la sécurité alimentaire et préviennent la contamination.

Tableau II.1.Solutions existantes dans l'industrie agroalimentaire.

Méthodes	Définition	Principe	Performance	Limitations	Taux de détection
Méthodes microbiologiques conventionnelles.	Méthodes classiques utilisées pour identifier et compter les microorganismes en les faisant croître sur des milieux de culture.	Comptage des colonies, incubation sur des milieux sélectifs.	Détection fiable et précise, [10]confirme les germes viables.	Lent, nécessite des conditions de laboratoire, les résultats peuvent prendre de 3 jours à 1 semaine. [11]	Haute fiabilité.
Méthodes optiques et spectroscopique.	Méthodes qui utilisent l'interaction de la lumière pour détecter le matériel biologique.	Utilisation de différentes techniques optiques, notamment la fluorescence, l'illumination UV, l'imagerie hyperspectral et la fluorescence induite par laser [10, 11].	Rapide, Utilisable en temps réel.	Nécessite un étalonnage, la sensibilité dépend de l'échantillon et de la lumière ambiante.	Bien, selon le système.
PCR et méthodes moléculaires.	Méthodes qui détectent l'ADN ou l'ARN microbien.	Amplification génétique (PCR) pour identifier les pathogènes [10].	Très sensible et spécifique, bon pour l'identification des pathogènes.	Cher, nécessite un laboratoire, parfois pas en temps réel.	Très élevé.

II.3. Le system proposé :

Le système proposé est un dispositif de détection du niveau de propreté des surfaces, basé sur une analyse optique sous illumination ultraviolette.

Il utilise une source UV et une photodiode pour mesurer la réponse optique de la surface étudiée. Le signal obtenu est traité par un microcontrôleur, qui permet d'estimer le niveau de contamination et de classer l'état de la surface en plusieurs niveaux de propreté.

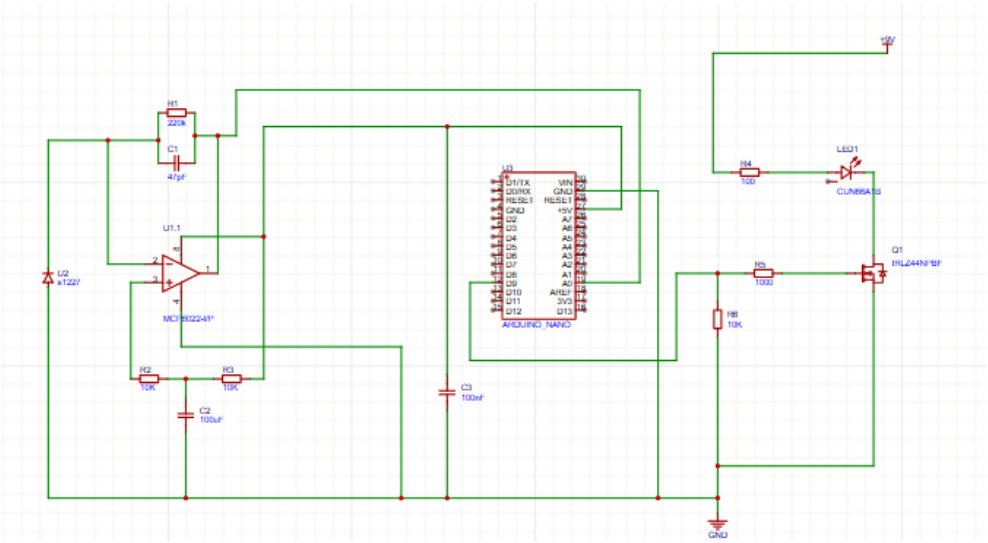


Figure II. 1. Le système proposé

II.3. Positionnement de l'approche proposée :

Le système proposé est parmi les méthodes optiques intégrées dans une ligne de production agroalimentaire, qui estiment en temps réel la propriété des surfaces en contact avec le produit. Il fournit une valeur en pourcentage représentant le niveau de contamination, qui est transmise au PLC pour permettre des actions immédiates.
Le système n'identifie pas le type de micro-organismes ni la source de contamination comparativement aux techniques existantes.

II.4. Principe de fonctionnement :

II.4.1. La fluorescence et la réaction UV :

La fluorescence est un phénomène physique dans lequel un matériau absorbe la lumière à une longueur d'onde spécifique et la réémet à une longueur d'onde plus longue.

Les pathogènes d'origine alimentaire peuvent être excités par un rayonnement ultraviolet (UV) dans une plage de 200 à 400 nm [12] à cause de certaines molécules biologiques qui peuvent absorber ce rayonnement et émettre à une longueur d'onde dans le spectre visible. Par exemple, le NADH et certains composants dans les biofilms peuvent être excités par la lumière dans la plage de 320 à 380 nm et émettre une fluorescence entre 420 et 480 nm [13].

De plus, le rayonnement UV type A (320–400 nm) [14] peut interagir avec les protéines, les acides nucléiques et l'ADN présents dans les cellules bactériennes. On utilise la lumière UV-A à 365 nm car ses photons possèdent une énergie suffisante pour exciter les molécules biologiques fluorescentes tout en assurant la sécurité pour l'exposition humaine.

II.4.2. Fonctionnement de système :

Le système de détection utilise la réaction de fluorescence comme principal mécanisme pour détecter la contamination microbienne formée sur les surfaces en contact avec les aliments. Cette contamination peut émettre des signaux de fluorescence visibles, apparaissant souvent en bleu ou en vert [15]. Cette réaction de fluorescence peut être utilisée pour détecter la présence microbienne à l'aide d'une photodiode hautement sensible combinée à une source LED UV-A à 365 nm. Lorsque les photons émis par une LED UV-A frappent les molécules présentes dans les bactéries ou les biofilms, la fluorescence émise peut être détectée par les photodiodes, qui génèreront un courant qui sera converti en tension. La variation de la tension indiquera si la surface examinée est contaminée ou non.

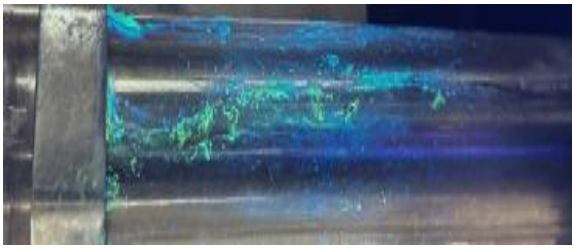


Figure II. 2. Fluorescence visibles vert [15].

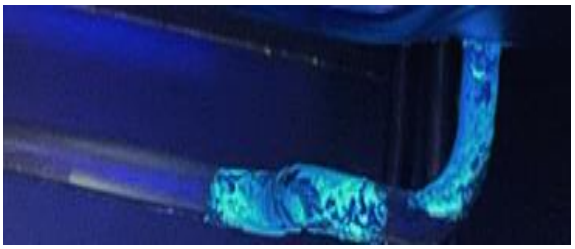


Figure II. 3. Fluorescence visibles bleu [15]

II.5. Capteur et modules optiques :

II.5.1. Capteur :

Le système de détection utilise une photodiode pour convertir la lumière fluorescente émise par les biofilms et les contaminants en photo courant. Cet appareil doit être très sensible à la plage de lumière visible, spécifiquement entre 400 nm et 520 nm. Pour cela, la photodiode Hamamatsu S1227-1010BR [16] est adaptée pour détecter la contamination microbienne.

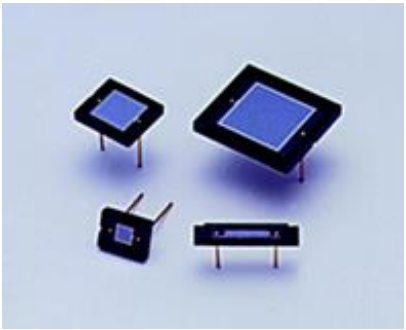


Figure II. 4. Photodiode Hamamatsu S12227-1010BR *[16]*

Les paramètres clés sont :

Tableau II. 2. Paramètres clés de photodiode Hamamatsu S1227- 1010BR *[16]*

Paramètre	Valeur	Remarque
Zone photosensible	10×10 mm (100 mm²)	Une grande surface permet de capter la fluorescence.
Plage spectrale	340-1000 nm	Parfait pour la détection de 450-520 nm.
Sensibilité maximale	720 nm (0,43 A/W)	Haute réactivité dans la plage de fluorescence verte.
Photosensibilité (400 nm)	~0,39 A/W	Forte réponse du pic NADH.
Photosensibilité (500 nm)	~0,40 A/W	Détection de riboflavine/organique.
Courant d'obscurité	50 pA	Bruit ultra-faible pour signaux faibles.
Capacité aux bornes	3000 pF	Bande Passante ~50 kHz (tr = 7 µs)
Temps de montée	7 µs typ	Suffisamment rapide
Puissance équivalente en bruit	6.7×10^{-15} W/√Hz	Détecte des signaux inférieurs à 1 pW (poussière de niveau 1)
Résistance de dérivation	Min 0.2 GΩ	Excellente linéarité

II.5.2. L'émission d'UV-A :

Le système optique fonctionne en émettant et en captant de la lumière fluorescente à partir de la surface en contact avec les produits alimentaires. Pour ce faire, le système émet principalement de la lumière UV-A d'une énergie suffisante pour exciter les molécules biologiques fluorescentes. À cette fin, le modèle seoal viosys UVZ5_CUN66A1B [17]est parfaitement adapté au système.



Figure II. 5.LED UV-A seoal viosys UVZ5_CUN66A1B *[17]*

Les paramètres clés du tableau ci-dessous [17]:

Tableau II. 3. Paramètres clés de seoal viosys UVZ5_CUN66A1B [17]

Paramètre	Symbole	Min	Typ	Max	Unité
Longueur d'onde maximale	λp	-	367	-	nm
Flux rayonnant	Φe	-	1.0	-	W
Tension directe	VF	-	3.7	-	V
Largeur à mi-hauteur du spectre	Δλ	-	10	-	nm
Radiation Angle	θ	-	120°	-	Dégrées
Courant direct	IF	100	500	700	mA

II.6. Acquisition et transmission des données :

Le système de détection optique se compose principalement de trois éléments essentiels : la photodiode S1227 [16] , la LED UV-A UVZ5-CUN66A1B [17] et le microcontrôleur.

Pour permettre la détection, ces composants doivent être connectés dans un circuit contrôlé par le microcontrôleur. À cette fin, le système est divisé en deux circuits principaux : le premier pour alimenter la LED UV-A, et le second pour conditionner le signal de la photodiode, tous deux contrôlés par le microcontrôleur.

II.6.1. Circuit de la LED UV-A :

Pour alimenter la LED UV-A ≈3,7 V, jusqu'à 500 mA [17], le circuit nécessite un circuit d'attaque composé des éléments suivants :

- LED UV-A UVZ5_CUN66A1B.
- MOSFET IRLZ44N servant de commutateur de puissance.
- Résistances servant de limiteurs de courant.
- Pile de 9 V servant de source d'énergie.

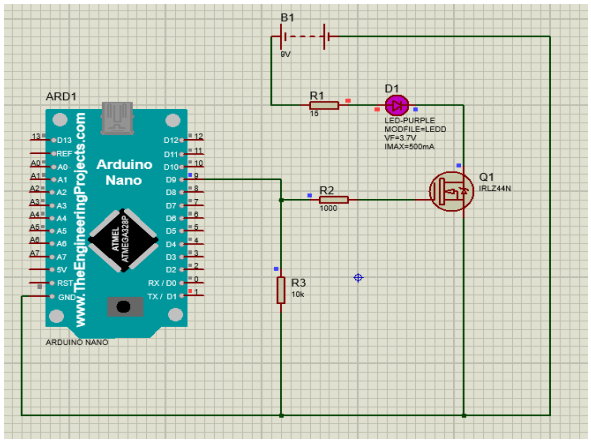


Figure II. 6. Circuit de la LED UV-A.

II.6.1.1. La résistance :

La résistance est le composant de sécurité le plus crucial du circuit à LED. Son objectif est de préserver la LED qui serait exposée à une tension d'alimentation de 9 V, ce qui pourrait causer des dommages au dispositif. La valeur de R1 est de 100 Ω ; elle a été calculée selon la loi de Kirchhoff sur les tensions dans un circuit en série :

$$V_batterie = V_R + V_LED + V_MOSFET \qquad (II.1)$$

II.6.1.2. MOSFEST IRLZ44N :

Le MOSFET fonctionne comme un commutateur électronique commandé par un microcontrôleur. Il s'agit d'un MOSFET de niveau logique, ce qui lui permet de fonctionner correctement avec la tension de sortie de 5 V du microcontrôleur.

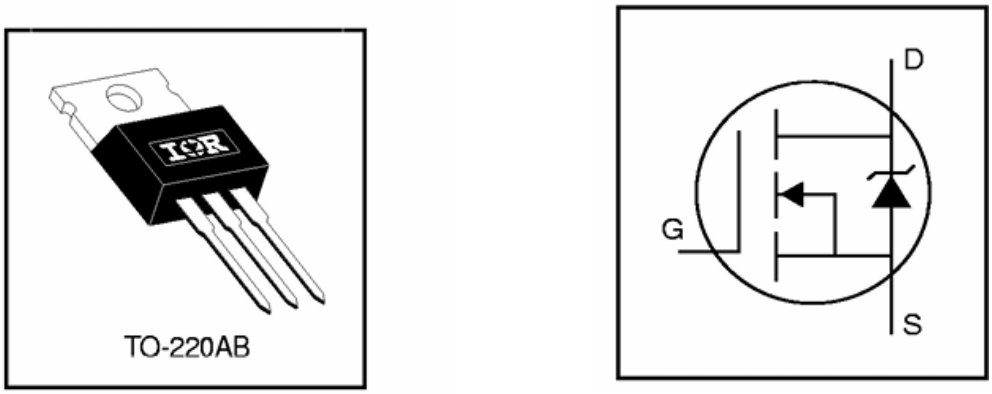


Figure II. 7. MOSFEST IRLZ44N *[18]*

Caractéristiques techniques principales de l'IRLZ44N [18] :

Tableau II. 4. Caractéristiques techniques principales de l'IRLZ44N [18] :

Paramètre	Valeur	Remarque
Type	MOSFET à canal N	Norme relative à la commutation côté bas.
VGS (th)	1-2V	S'allume complètement avec une tension de 5V.
RDS (on)	0.025Ω	Très faible résistance, donc une chute de tension minimale.
Id max	>40A	Bien supérieur à 353 mA.
VDS max	55V	>9V, sans danger.

II.6.2. Le circuit de traitement du signal de la photodiode :

La photodiode est une source de courant commandée par la lumière, c'est pourquoi le système doit convertir ce courant en tension à l'aide d'un amplificateur à Transimpédance (TIA) [19] , un circuit analogique qui convertit un courant d'entrée en une tension de sortie proportionnelle.

$$V_out = V_ref - Iin * Rf \qquad \text{(II. 2)} \qquad Iin_max * Rf < V_ref$$

Iin : courant d'entrée provenant du S1227.
Rf : résistance de rétroaction.
V_ref : tension de référence VDD/2.

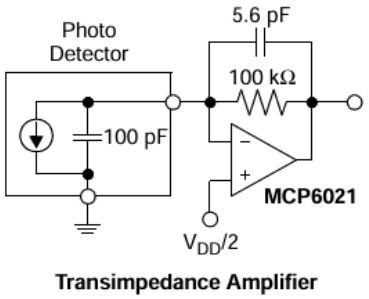


Figure II.8. Amplificateur à Transimpédance (TIA) [20].

Le circuit TIA garantit au système :

- Une tension fixe.
- Le courant circule entièrement à travers Rf.
- Une tension de sortie stable.
- Un bruit réduit au minimum.

II.6.2.1. Composant amplificateur à transimpédance (TIA) :

Le système optique doit convertir le courant photoélectrique généré par la photodiode en un signal de tension afin que microcontrôleur transmettre ces signaux aux étages de nettoyage.

L'amplificateur à transimpédance est composé de quatre éléments principaux qui garantissent une conversion rapide et sans bruit du courant en tension :

- Photodiode S1227-1010BR.
- Amplificateur opérationnel (op_amp).
- Résistance de contre-réaction Rf.
- Condensateur de contre-réaction Cf.

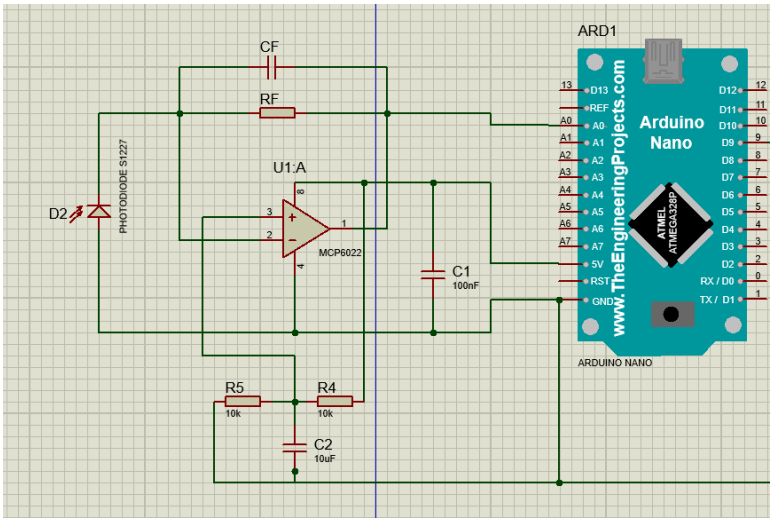


Figure II. 9. Circuit amplificateur à transimpédance (TIA)

II.6.2.2. Amplificateur opérationnel MCP6022i/p :

Le MCP6022 est un amplificateur opérationnel à double rail-à-rail. Adapté pour les applications analogiques hautes performances. Il fonctionne avec une tension d'alimentation comprise entre 2,5V et 5,5 V [20].

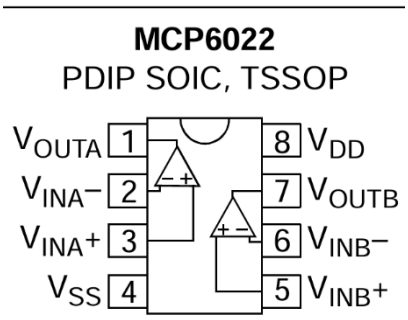


Figure II. 10. Amplificateur opérationnel MCP6022i/p [20]

Caractéristiques techniques principales de MCP6022i/p [20]. :

Tableau II. 5. Caractéristiques techniques principales de MCP6022i/p

Paramètre	Valeur
Bande passante.	10 MHz
Densité du bruit.	8.7 nV/√Hz
Tension de décalage d'entrée.	<1 mV
Plage de tension d'alimentation.	2.5V – 5.5V
Amplitude de sortie.	De rail à rail
Canaux.	2
Options de forfait.	DIP à 8 broches, SOIC et autres
Distorsion harmonique totale (THD+N).	0.00053%

II.6.2.3. Résistance de rétroaction Rf et condensateur de rétroaction Cf :

- Résistance de rétroaction (Rf) :

La résistance de rétroaction est utilisée l'amplificateur à transimpédance pour convertir la photo courante généré par la photodiode en un signal de tension. La valeur de Rf déterminer le gain du circuit [19].

- Condensateur de rétroaction (Cf) :

Le condensateur de rétroaction prévenir les oscillations assurent la stabilité du circuit [19]. Cf généralement connecté en parallèle à la Rf.

II.7. Niveau de propreté :

II.7.1. Classification des niveaux de propreté :

Une fois que la surface a été exposée aux rayons UV-A 365 nm et que le système a détecté le signal fluorescent. La mesure de la propreté d'une surface en fonction de l'intensité du signal fluorescent détecté. L'augmentation progressive du signal permet de classifier la contamination à plusieurs niveaux.

Ainsi, quatre niveaux de propreté sont définis :

- Niveau 1 : Surface propre

Ce niveau correspond à une surface ne présentant pas de contamination. Les signaux mesures sont principalement des particules inorganiques [15] .

- Niveau 2 : Résidus faibles.

Ce niveau correspond à la présence de résidus non biologiques, et de traces de produits chimiques [15].

- Niveau 3 : Matières organiques.

Ce niveau correspond à la présence de matières organiques (résidus alimentaires). Ce niveau est critique car il y a risque de développement microbien [15].

- Niveau 4 : Biofilm / contamination élevée.

Ce niveau correspond à une contamination importante liée à la présence de microorganismes et à la formation de biofilm [15].

II.7.2. Méthode d'évaluation du niveau de propreté :

Afin de traduire le signal de fluorescence en un indicateur exploitable, une méthode de quantification basée sur une comparaison relative à une ligne de base propre est adoptée Pour classifier l'état de surface, une méthode pour convertir le signal fluorescent détecté en indicateur.

$$\text{Propreté (\%)} = 100 \times (1 - \text{Ratio}) \qquad \text{(II. 3)}$$

- Calcul du ratio :

  Le niveau de ratio est évalué en comparent le signal mesure avec le signal de base

$$\text{Ratio} = \text{Signal} / \text{Signal_max} \qquad \text{(II. 4)}$$

Signal : Signal = Vout – Vbase.

Signal_max: Une mesure de référence est afin d'établir un signal maximum.

II.8. Intégration dans la ligne de production :

II.8.1. Principe d'intégration :

Le système de détection des germes est intégré dans un boîtier optique fermé avec une ouverture inférieure permettant le passage du plateau. Positionnement d'UV LED à 90 degrés ou de la photodiode.

Le système de détection des germes est positionné au-dessus du convoyeur transportant les plateaux à station de remplissage. Le système est activé automatiquement si la présence est détectée.

II.8.2. Séquence de fonctionnement :

Le fonctionnement du système suit une logique séquentielle :

- Détection du plateau et l'activation du système optique :

Lorsque le capteur de position envoi un single le système activé et la LED s'allume.

- Acquisition multizone :
- Il existe deux zones de détection :

La première est destinée à identifier l'avant du plateau, tandis que la seconde se situe à l'arrière de celui-ci.

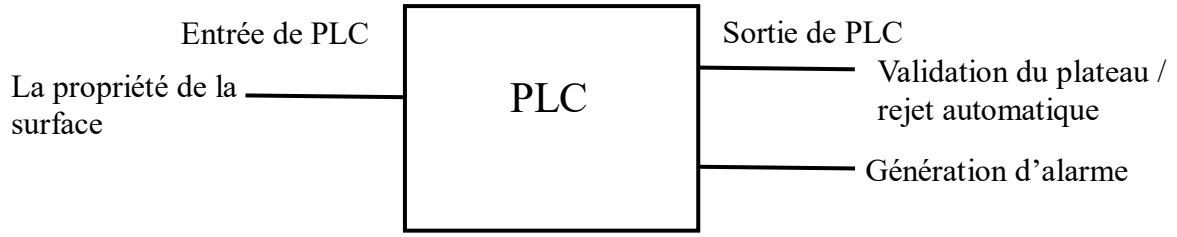
- Traitement du signal
- Prise de décision :

La décision révèle le niveau de contamination le plus élevé.

- Transmission du résultat

II.8.3. Intégration avec PLC :

Dans l'environnement industriel, le système envoie un signal analogique (la propriété du surface) a l'automate programmable PLC pour automatise les actions en fonction de niveau de propreté.



II.9. Conclusion :

Pour garantir la sécurité alimentaire, il est crucial de contrôler la contamination microbienne sur les surfaces dans l'industrie agroalimentaire. Il existe plusieurs méthodes de détection, mais beaucoup ont des limitations en termes de coût, de rapidité ou d'intégration dans les processus industriels.

Ce chapitre présente le principe de fluorescence utilisé pour la détection microbienne, passe en revue les solutions existantes et introduit l'approche proposée en comparaison avec ces méthodes.

Chapitre III : *La vision industrielle basé sur l'intelligence artificielle.*

III.1. Introduction :

Les technologies de vision industrielle et d'intelligence artificielle sont essentielles ; car elles contribuent à améliorer la qualité et à réduire les erreurs humaines.
Ce chapitre présente le cadre théorique de ce système, en passant en revue les concepts fondamentaux de la vision industrielle, de l'apprentissage automatique et de l'apprentissage profond, ainsi que leurs applications au tri des biscuits et à l'analyse des causes des défauts.

III.2. Les techniques de contrôle qualité existent dans la littérature :

Dans l'industrie biscuitière, les systèmes modernes de contrôle qualité reposent sur la classification des pièces conformes et défectueuses et l'analyse des causes des défauts. De nombreuses techniques permettent d'assurer la conformité des produits et d'améliorer le processus.

Tableau III.1. Les techniques existantes dans la classification de la conformité des produits

Technique	Modèle courant	Outil du modèle	Objectif du modèle	Qualité des données du modèle	Limites du modèle
Traitement d'image « La détection de contours » [21]	Basée sur les gaussiennes [21]	Filtre de Canny. [22]	Identifier les contours, fissures. [21], [22]	Adapté à des images complexes et bruitées. [21]	Problèmes avec les motifs complexes, Sensible à l'éclairage. [21]
Apprentissage automatique	SVM [22]	Hyperplan [23]	Sépare les données en deux catégories [23]	Peu de données. [23]	Moins efficace sur des données trop nombreuses. [23]
Apprentissage Profond	CNN [24]	Convolution, pooling, entièrement connectée [25]	Extraire automatiquement des caractéristiques des données d'entrée non-structures comme : les image. [25]	Grandes quantités de données. [25]	Coûteux en calcul, le surapprentissage. [25]

Tableau III.2. Les techniques existant dans l'analyse de cause.

Technique	Modèle courant	Outil du modèle	Objectif du modèle	Des données du modèle	Limites du modèle
Analyse de cause racine	Méthode des 5 Pourquoi. [26]	Poser cinq fois de suite la question "pourquoi" pour remonter à la cause profonde.	Remonter jusqu'à la cause racine d'un défaut pour définir une action corrective.	Données factuelles, observations terrain, historique de production.	Méthode qualitative, dépend de l'expérience des personnes, risque de subjectivité, ne convient pas toujours aux problèmes complexes ou multiples.
Apprentissage automatique	Random forest [27]	Plusieurs arbres de décision	Identifier la cause profonde du défaut. [28]	Données structurées comme les paramètres de la production. [27]	Modèle complexe, Interprétabilité réduite. [29]
Apprentissage Profond	XGBoost	Le gradient [29]	Effectuer des prédictions précises. [29]	Donnes catégorielles et numérique [29]	Nécessite un réglage précis, sensibilité élève au surapprentissage. [29]

III.3. Positionnement de l'approche proposée :

Le système proposé est basé sur un premier modèle, un réseau de neurones convolutifs (CNN), pour classer les biscuits conformes et défectueux présentant en surface des défauts de cuisson, des fissures ou des cassures, et sur un second modèle, une forêt aléatoire, pour analyser les causes de l'apparition de ces défauts en fonction des paramètres de production, notamment le poids total des ingrédients et les températures du four.

III.4. La Vision industrielle :

III.4.1. Définition de la vision industrielle :

La vision industrielle consiste à appliquer les technologies de vision par ordinateur aux problèmes de fabrication. Son principe repose sur l'automatisation des tâches d'inspection et de vérification. Cette automatisation améliore la performance et renforce la conformité et la traçabilité des produits. [30]

III.4.2. Types de systèmes de vision industrielle :

La vision industrielle change de type en fonction du nombre de dimensions des données à capturer et du domaine d'application.

Vision 1D : ces systèmes qui capturent une ligne de pixels avec une caméra linéaire utilisée sur des surfaces continues ou en mouvement.

Vision 2D : ces systèmes qui utilisent une caméra matricielle pour capturer une image 2D sont utilisés pour des tâches lentes ou stationnaires.

Vision linéaire 2D : ces systèmes construisent une image bidimensionnelle ligne par ligne de pixels au moyen d'une caméra linéaire et d'un système de synchronisation.

Vision 3D : ces systèmes qui modélisent trois dimensions de longueur, largeur et hauteur, construits via des technologies spécialisées. Il est utilisé dans des applications dans lesquelles le volume est nécessaire.

[31]

III.4.3. Les composants clés de la vision industrielle :

La vision industrielle repose sur des composants essentiels qui fonctionnent interagissent dans un système intégré ; leur choix dépend de l'application examinée.

III.4.3.1. Objectif :

Il converge la lumière vers le capteur d'image, et est choisi selon les critères suivants : taille de l'objet, taille du capteur, distance de travail. Tout cela est choisi en fonction de la distance focale, déterminant ainsi la zone de netteté et le grossissement. [32]

III.4.3.2. Éclairage :

L'éclairage assure la précision et la fiabilité du système de vision industrielle. Il en existe plusieurs types : éclairage annulaire, éclairage en dôme, éclairage linéaire et rétroéclairage.
Le choix du type d'éclairage est essentiel et dépend de l'application.

L'éclairage annulaire est utilisé pour l'inspection des surfaces mates, tandis que l'éclairage en dôme est efficace sur les surfaces brillantes. Le rétroéclairage garantit la précision des mesures dimensionnelles alors que l'éclairage linéaire aide à détecter les défauts sur de grandes surfaces. [33]

III.4.3.3. Camera industrielle :

Elle capture des images à l'aide d'un capteur d'image, ces caractéristiques sont déterminées en fonction de ces critères : la taille du défaut, la luminosité, la couleur à capturer et la vitesse de l'application. Parmi les caractéristiques importantes du capteur d'image :

- Technologies de capteurs CMOS et CCD :

CCD : la conception repose sur le traitement du signal externe, ce qui permet une haute qualité d'image et de bonnes performances en basse lumière, mais cela entraîne une vitesse plus lente et une consommation d'énergie plus élevée.

CMOS : sa consommation d'énergie moindre et sa vitesse plus élevée, résultant de sa conception basée sur le traitement du signal intégré. Ses technologies traditionnelles comportaient plus de bruit en basse lumière, mais la technologie moderne a réduit cela. Il est le leader dans les applications industrielles.

[34]

- Taille du capteur :

Sa taille dépend de la taille du pixel : plus elle est grande, plus elle permet de capturer la lumière, mais elle réduit la clarté des détails, et elle dépend également de la résolution, car plus elle est élevée, plus elle permet de capturer les plus petits défauts. [35]

Capteurs monochromes et capteurs couleur :

Les capteurs monochromes sont utilisés dans la plupart des applications, ils captent l'intensité lumineuse, pas la couleur, et ont une haute résolution.

Quant aux capteurs couleur, une seule puce utilisant des filtres rouge, vert et bleu à résolution inférieure, et trois puces utilisant le prisme à haute résolution. Ces capteurs sont utilisés où la couleur est nécessaire dans ces tâches.

[36], [37]

III.4.3.4. Unité de traitement d'images :

L'unité de traitement d'images analyse les images capturées à l'aide d'algorithmes et de logiciels de traitement d'images en temps réel, permettant une inspection rapide et précise.
Il existe des types de matériel de traitement d'images, notamment l'unité de contrôle de la vision, qui est un PC intégré à un logiciel de vision, ou un PC industriel avec des processeurs : un GPU pour le traitement par apprentissage profond, un FPGA pour le traitement rapide et un DSP pour le traitement de systèmes embarqués en temps réel, ainsi qu'une caméra intelligente qui intègre une caméra et un processeur et des E/S. [38], [39]

III.4.3.5. Système d'intégration et communication :

Le système est composé d'un ensemble d'éléments parmi lesquels :

- Des capteurs de déclenchement utilisés pour synchroniser la capture de la caméra avec la vitesse de production.
- Des API ou des robots reçoivent les résultats de l'analyse.
- Les systèmes MES ou SCADA enregistrent les données.
- Les protocoles industriels tels qu'Ethernet/IP, Modbus permettent de communiquer entre différents systèmes. [40], [41]

III.4.4. Applications de la vision industrielle dans l'industrie agroalimentaire :

La vision industrielle est utilisée à plusieurs étapes de la production alimentaire. Ses principales applications sont les suivantes :

- Contrôle de la couleur, de la taille, de la forme, de la texture et des défauts de surface du produit.
- Garantie d'une fermeture hermétique et d'un étiquetage correct.
- Détection des corps étrangers tels que les métaux et les plastiques.
- Vérification des codes-barres, des dates de péremption et des numéros de lot. [42]

III.5. Défauts des biscuits étudiés :

III.5.1. Présentation des défauts :

La qualité des biscuits est affectée par l'apparition de nombreux défauts visuels, cela entraînant des pertes de produit. Ces défauts résultent d'instabilités lors des différentes étapes de fabrication, notamment le mélange, le formage, la cuisson et le refroidissement. La détection de ces défauts est essentielle à la stabilité de la qualité.

Dans ce contexte, l'analyse et la classification de la conformité des produits constituent une étape cruciale du développement d'un système intelligent capable de les identifier automatiquement. Dans le cadre de ce travail, trois types de défauts courants rencontrés sur les lignes de production industrielle ont été étudiés parmi de nombreux autres. Ils ont été choisis en raison de leur impact significatif sur la conformité du produit.

III.5.2. Types de défauts :

III.5.2.1. Biscuits trop cuits :

Ce défaut se manifeste par un changement de couleur du biscuit, avec différents degrés de brunissement, indiquant une cuisson excessive. Le brunissement peut aller d'une couleur foncée à un état brûlé. Il peut être partiel ou total et apparaître à différentes zones du biscuit, comme sur les bords, au centre ou simultanément à plusieurs zones.

III.5.2.2. Biscuits cassés :

La cassure correspond à une détérioration partielle ou totale du biscuit, entraînant une perte de sa structure. Elle peut se manifester par des éclats, des coins manquants ou un effritement de certaines parties. La cassure peut se produire à différentes zones du produit, notamment sur les bords, au centre ou en plusieurs sections.

III.5.2.3. Biscuits fissurés :

Des fissures visibles apparaissent à la surface du biscuit, de taille et de profondeur variables, et se trouvent au centre, sur les bords ou à plusieurs zones du produit.

III.5.3. Des causes des défauts étudiés :

Les facteurs industriels les plus importants qui affectent la qualité des biscuits pendant la fabrication comprennent la température et le poids des ingrédients, ce qui conduit à des défauts évidents dans le produit final. La température est responsable du développement de la couleur durant la cuisson, tandis que le poids des ingrédients, y compris l'eau, le sucre, la graisse et la farine, affecte la cohésion de la structure produite. Par conséquent, le contrôle de ces deux facteurs est essentiel pour réduire les défauts et améliorer la stabilité de production.

III.5.3.1. Causes du brunissement des biscuits :

- Une chaleur excessive provoque le brunissement ou le brûlage de la surface.
- Une répartition inégale de la chaleur dans le four entraîne une cuisson inégale, certaines parties étant trop cuites.
- Un excès de sucre fonce la surface car il accélère la caramélisation.

III.5.3.2. Causes de la casse des biscuits :

- Une température de cuisson élevée entraîne une perte d'humidité excessive des biscuits, qui deviennent cassants.
- Une pâte trop pauvre en eau donne des biscuits secs.
- Une faible teneur en matières grasses réduit l'élasticité de la pâte, augmentant ainsi le risque de casse.
- Une pâte trop riche en farine donnera des biscuits très durs et secs.

III.5.3.3. Causes de la fissuration des biscuits :

- Une température élevée du four provoque un dessèchement rapide de la surface extérieure avant que la structure intérieure ne soit complètement formée.
- Une faible teneur en eau et en matières grasses réduit l'élasticité du biscuit, augmentant ainsi le risque de fissuration. [43] , [44]

III.6.1. Intelligence artificielle vs apprentissage automatique vs apprentissage profond :

III.6.1.1. Intelligence artificielle :

L'intelligence artificielle est un domaine qui imite certaines capacités de l'intelligence humaine ; et qui s'applique notamment à l'industrie, à la technologie et à la médecine. Parmi ces potentialités figurent le raisonnement, l'analyse et la prise de décision. Elle repose sur des systèmes tels que l'apprentissage automatique et l'apprentissage profond. [45]

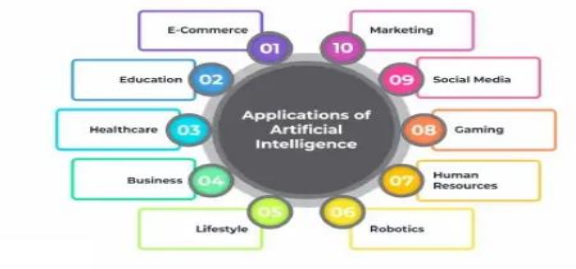


Figure III. 1. Les applications d'Intelligence artificielle [87]

III.6.1.2. Apprentissage automatique :

L'apprentissage automatique repose sur l'exploitation d'algorithmes pour que la machine apprenne à partir des données, sans règles prédéfinies afin d'effectuer des prédictions ou de prendre des décisions dans diverses applications. [45]

III.6.1.3. Apprentissage profond :

L'apprentissage profond est une branche de l'apprentissage automatique, s'inspire du fonctionnement du cerveau humain. Les réseaux neuronaux artificiels sont entraînés à analyser et à traiter de grandes quantités de données. [45]

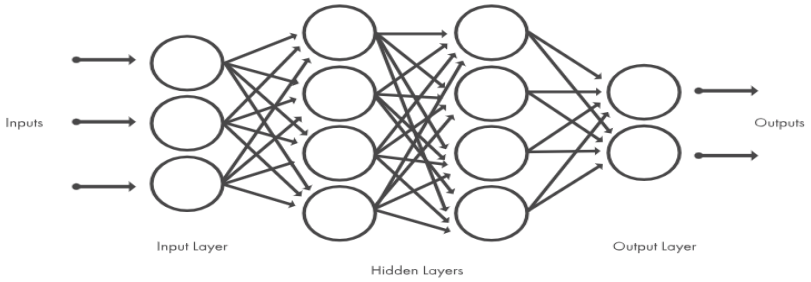


Figure III. 2.Architecture d'un réseau de neurones *[46]*

Tableau III 3. Les différences clés d'Apprentissage automatique et Apprentissage profond *[47]*

Critères	Apprentissage automatique	Apprentissage profond
Volume de données	Des ensembles modérés et structurés	Des ensembles volumineux et non structurés : images, son
Ingénierie des fonctionnalités	Extraction manuelle	Extraction automatique depuis les données brutes
Complexité des algorithmes	Simple	Complexe
Ressources Matérielles	Efficace sur CPU	Nécessaire de GPU/ TPU
Temps D'entraînement	Court	Long
Précision	Moins de précision pour les tâches complexes	Haute efficacité dans les tâches complexes
Exemples applications	Prédiction de tendances, anti-spam	Vision par ordinateur, véhicules autonomes

III.6.2. Types de l'apprentissage automatique :

L'apprentissage automatique se compose de trois types, chacun différant des autres par son fonctionnement, ses données et ses utilisations.

III.6.2.1. Apprentissage supervisé :

Le modèle est entraîné à l'aide de données étiquetées, où l'on le guide vers une sortie connue à prédire. Cette méthode est utilisée lorsque la sortie est connue .L'apprentissage supervisé est utilisé dans plusieurs domaines médicaux ou techniques ; par exemple : à partir de données sur les patients telles que leur âge, leur sexe, leur poids et leur tension artérielle, il est possible de prédire leur état de santé et de déterminer s'ils souffrent d'une maladie ou non. [48]

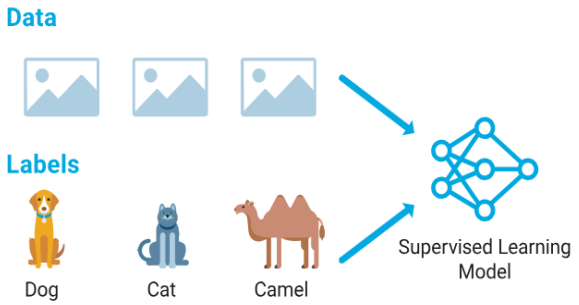


Figure III. 3. Apprentissage supervisé *[81]*

III.6.2.2. Apprentissage non supervisé :

Ce type de modèle ne nécessite pas de données étiquetées pour produire des résultats. Il extrait plutôt des caractéristiques communes des données, les classe en groupes puis effectue des prédictions. Par exemple : les caractéristiques clients ; les types de clients sont regroupés en fonction de leur comportement d'achat. [48]

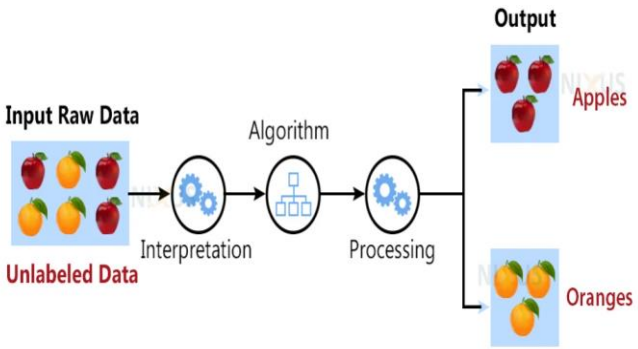


Figure III. 4. Apprentissage non supervisé *[49]*

III.6.2.3. Apprentissage par renforcement :

Le modèle interagit avec son environnement et apprend par essais et erreurs. Si la prédiction est correcte, le modèle est récompensé ; si elle est incorrecte, il est pénalisé.

Par exemple : dans le jeu Mario, si le joueur respecte les règles, il gagne des points ; sinon il en perd. [50]

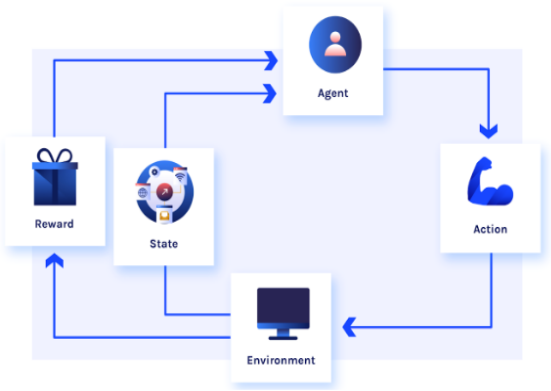


Figure III. 5.Apprentissage par renforcement *[50]*

III.6.3. Types de techniques de l'apprentissage supervise :

Il existe deux types de techniques d'apprentissage supervisé ; le choix de l'une ou l'autre dépend de la sortie prédite.

III.6.3.1. Classification :

Il s'agit d'une technique permettant de prédire des valeurs discrètes sous forme de catégories. On distingue trois types : la classification binaire, la classification multi-classe et la classification multi-label. Par exemple, un modèle reçoit des images d'animaux et prédit leur type (chat ou chien) à partir des données d'entrée. [51]

III.6.3.2. Régression :

Il s'agit d'une autre technique qui repose sur la prédiction d'une valeur continue, par exemple : prédire le prix d'un appartement en fonction de sa surface, du nombre de pièces et de son emplacement. [51]

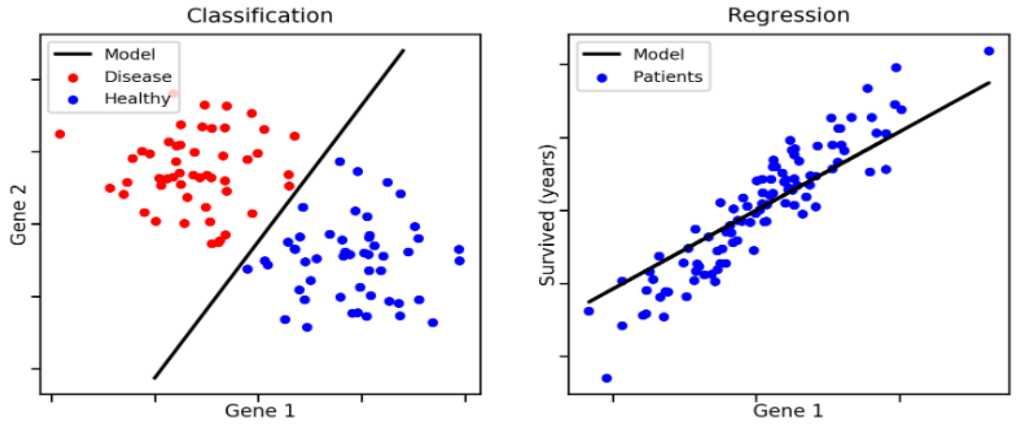


Figure III. 6. Type de technique de l'apprentissage supervise *[52]*

III.7. Les CNN pour la classification :

III.7.1. Définition du CNN :

Un réseau de neurones convolutifs (CNN) est un type de modèle d'apprentissage profond qui traite et analyse des données visuelles. Il est efficace pour les tâches de reconnaissance d'images et d'analyse visuelle. [53]

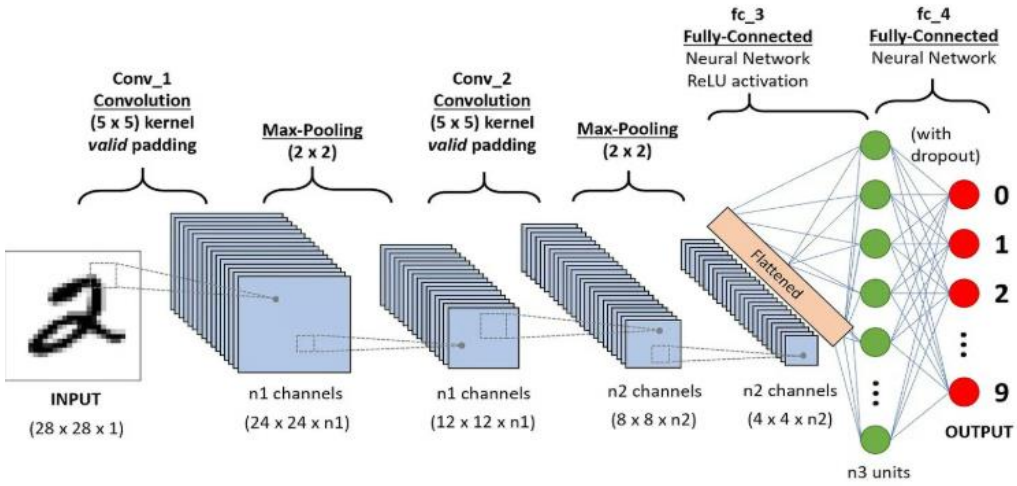


Figure III.7.L'architecture du CNN *[54]*

III.7.2. Fonctionnement du CNN :

Le fonctionnement d'un réseau neuronal convolutif comporte deux phases : propagation directe et back propagation.

III.7.2.1. Propagation directe :

Ce sont les étapes qui contiennent la transformation des données d'entrée en une prédiction à travers les couches.

- La Couche d'entrée :

Elle reçoit les données brutes qui sont des pixels d'images et les envoie à la couche de convolution pour traitement. L'entrée peut être une matrice de pixels 2D ou 3D lorsqu'il s'agit d'une image en RGB. [55]

- Les couches de convolution :

Ces couches appliquent des ensembles de filtres pour extraire des motifs, ce sont de petites matrices de poids (par exemple : 3* 3 ou 5*5). Chaque filtre effectue une opération de multiplication entre les poids et les entrées, puis additionne les résultats, tout ce qui appelle la somme pondérée. Cela permet de créer une carte des caractéristiques dont la taille est déterminée par le pas, autrement dit le déplacement du filtre sur l'image ; lorsque le pas est réduit, la taille de la carte des caractéristiques augmente, ce qui accélère le calcul mais entraîne une perte de détails.

À l'inverse, lorsque le pas augmente, la taille de la carte diminue, le calcul devient plus lent et les détails sont plus nombreux. [56]

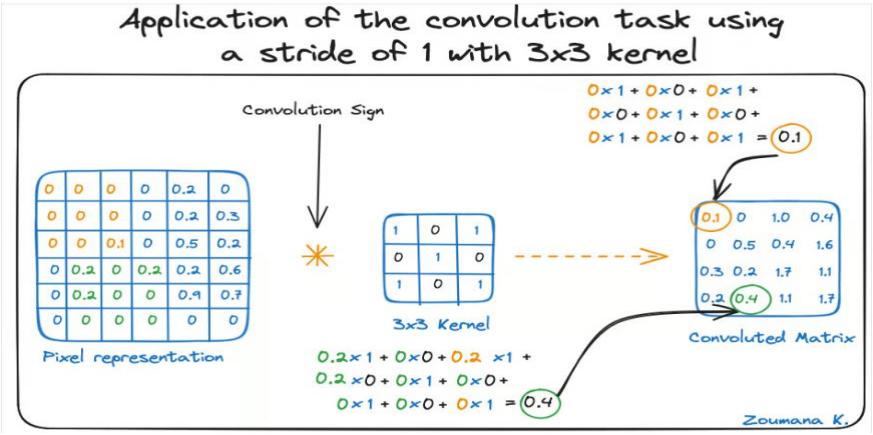


Figure III. 8. Les couches de convolution *[54]*

➢ Les fonctions d'activation :

Elles transforment les relations linéaires (la somme pondérée) en relations non linéaires afin de comprendre les relations complexes. La fonction ReLU est appliquée pour convertir une valeur négative de la carte caractéristiques en zéro et garder une valeur positive. La fonction sigmoïde convertit les valeurs en probabilités de 0 ou 1, spécifiques à la classification binaire. La fonction Softmax, quant à elle, est utilisée pour la classification multi-classes et convertit les valeurs en un ensemble de probabilités dont la somme est égale à 1. [56]

- Les couches de pooling :

Son rôle est d'accélérer les calculs et de réduire le surapprentissage. Après l'application de la fonction d'activation, la couche réduit la taille de la carte des caractéristiques en appliquant une fenêtre bidimensionnelle. Il existe plusieurs types de pooling notamment :

- Le pooling maximal, qui applique une petite fenêtre pour extraire la valeur maximale.
- Le pooling moyen qui effectue une moyenne dans la fenêtre.
- Le pooling global qui applique une fenêtre à la taille de la carte des caractéristiques, il y a deux types : maximal global ou moyen global. Le pooling global est utilisé avant les couches entièrement connectées. [56]

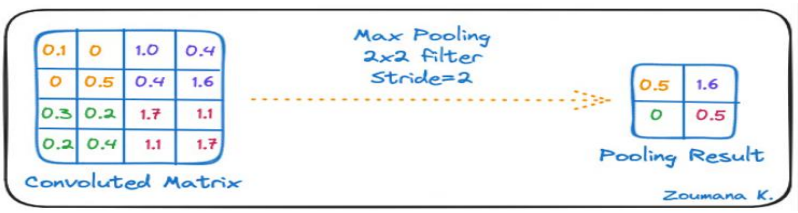


Figure III. 9. Les couches de pooling *[54]*

- Les Couches entièrement connectées :
  Ensuite, le processus de convolution, de ReLU et de pooling est répété, et tous les motifs extraits. La carte des caractéristiques est convertie d'une matrice multidimensionnelle en un vecteur unidimensionnel. Ce vecteur sert d'entrée à la couche entièrement connectée, effectue la somme pondérée avec le biais de chaque neurone de la couche précédente. La fonction d'activation–est appliquée sur le résultat, produisant des scores finaux. Ces scores sont convertis en probabilités par sigmoïde ou softmax ,à l'aide de couches de sortie entièrement connectées. [56] , [57]

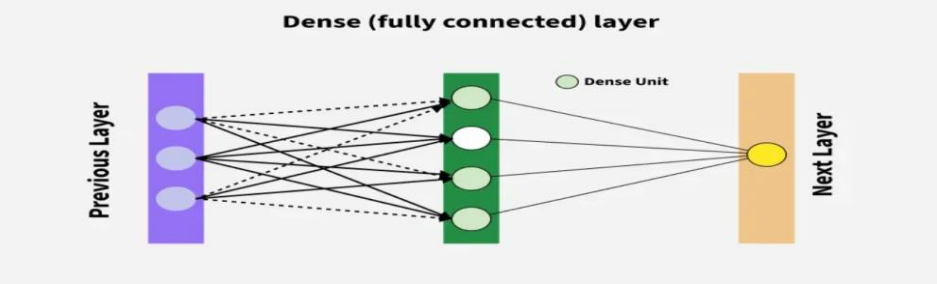


Figure III.10. Les Couches entièrement connectées *[57]*

III.7.2.2. Rétropropagation :

Pour améliorer la performance du modèle, la rétropropagation a été appliquée, qui consiste en des étapes visant à réduire l'erreur entre la valeur réelle et la valeur prédite.

- Fonction de perte :

Cette fonction calcule la différence entre la valeur réelle et la valeur prédite. Il existe de nombreuses fonctions de perte, et l'entropie croisée catégorielle est une fonction couramment utilisée dans la multi-classification. [58]

- Le gradient :

Calcul du gradient de la fonction d'activation par rapport à chaque poids et biais à travers l'application de la règle de la chaîne de calcul. [58]
Mise à jour des poids :

Les poids et les biais sont appliqués à l'aide d'un algorithme d'optimisation qui ajuste le taux d'apprentissage lors de chaque mise à jour après le calcul des gradients. Parmi les algorithmes utilisés dans CNN : l'algorithme d'optimisation Adam. [58]

III.7.3. Méthodes de création du modèle :

Il existe deux méthodes d'apprentissage ; le choix de l'une dépend de deux facteurs principaux : la taille des données et le temps nécessaire à l'entraînement.

III.7.3.1. Apprentissage à partir de zéro :

Cette méthode consiste à concevoir une architecture de réseau pour apprendre des caractéristiques, ce type d'apprentissage est adapté aux applications nouvelles ou spécifiques. L'entraînement d'un modèle d'apprentissage profond à partir de zéro nécessité la collecte d'un vaste ensemble de données étiquetées, et la durée d'entraînement peut varier de quelques heures à plusieurs semaines, selon la tâche et les ressources de calcul disponibles. [59]

III.7.3.2. Apprentissage par transfert :

Cette technique consiste à appliquer des connaissances acquises à de nouvelles données, ces connaissances sont présentes dans un modèle déjà entraîné sur un vaste ensemble de données. Cette méthode se caractérise par une courte période d'entraînement et de faibles besoins en données, ce qui la distingue de l'apprentissage à partir de zéro. [59]

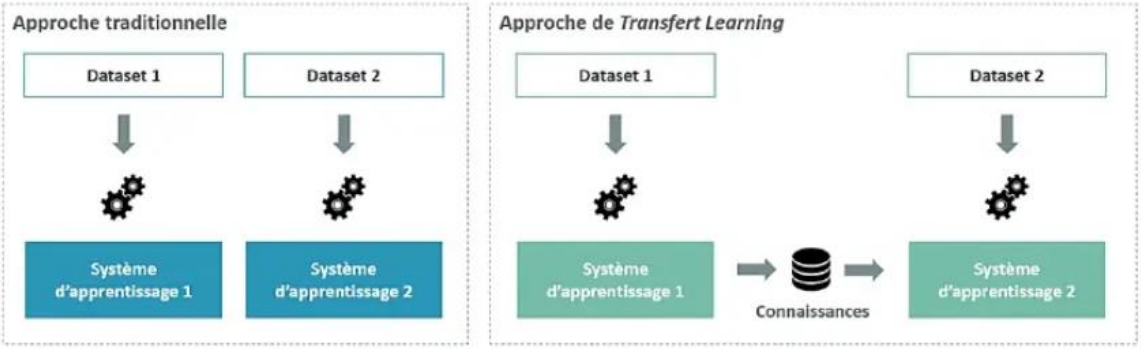


Figure III. 11. Méthodes de création du modèle *[60]*

III.7.4. Les principaux types d'apprentissage par transfert :

Parmi les types d'apprentissage par transfert, il en existe deux : transductif et inductif. Le choix du type dépend de la similarité entre les données sources et cibles, ou de la similarité entre la tâche source et la tâche cible.

III.7.4.1. Apprentissage par transfert transductif :

Dans l'apprentissage par transfert inductif, les données de la tâche initiale diffèrent de celles de la tâche cible. Mais les tâches elles-mêmes restent inchangées. Le modèle initial exploite les propriétés des données sources pour améliorer ses performances sur les données cibles. [60]

III.7.4.2. Apprentissage par transfert inductif :

La tâche à prédire diverge de celle ayant servi à l'entraînement du modèle, même si les données initiales et les données cibles sont identiques. Par exemple : un modèle entraîné à classifier les

chiens et les chats peut être utilisé pour classifier les espèces d'oiseaux, exploitant ainsi les connaissances acquises, bien que la tâche soit différente mais les données similaires. [60]

III.7.5. Les stratégies de l'entraînement en apprentissage par transfert :

Les stratégies employées dans l'apprentissage par transfert permettent aux modèles pré-entraînés de s'adapter à de nouvelles données et à différentes tâches ; ces stratégies comprennent l'extraction de caractéristiques et l'ajustement fin.

III.7.5.1. Extraction des caractéristiques :

Cette méthode repose sur des couches figées d'un modèle réentraîné sur l'ensemble de données ImageNet, afin que leurs poids ne soient pas mis à jour pendant l'entraînement, et que des couches de sortie soient ajoutées spécifiquement pour la tâche cible. [60]

III.7.5.2. Ajustement fin :

- Cette méthode dégèlera une partie des couches du modèle réentraîné afin de mettre à jour leurs poids durant l'entraînement.
- Il entraîne également toutes ces couches dégelées, ainsi que de nouvelles couches, sur les nouvelles données cibles. [60]

III.7.6. Modèles pré-entraînés populaires :

Les modèles pré-entraînés ont été entraînés sur de grandes quantités de données, ce qui permet leur réutilisation dans diverses applications. Leurs architectures varient en termes de précision, de vitesse et de taille, comme ResNet, EfficientNet et MobileNet. Le choix du modèle le plus adapté dépend de la nature du problème et des ressources disponibles.

- ResNet :

ResNet (Residual Network) a été créé en 2015. Il s'agit d'un réseau neuronal convolutif développé par Microsoft. C'est le premier réseau neuronal capable d'entraîner des centaines, voire des milliers de couches, sans rencontrer le problème de la disparition du gradient. [61]

- Efficient Net :

EfficientNet est un réseau neuronal créé par Google en mai 2019. Il a été développé par Mingxing Tan au sein du département d'intelligence artificielle. [61]

- Mobile Net :

MobileNet est un type de réseau neuronal convolutif conçu pour les appareils mobiles ; son architecture simplifiée permet de construire des réseaux neuronaux profonds et légers, offrant ainsi un équilibre optimal entre temps d'entrainement et précision [61]

Tableau III.4. Comparaison des performances de ResNet, MobileNet et EfficientNet *[62]*

Caractéristique	ResNet	MobileNet	EfficientNet
Conception de base	Connexions résiduelles profondes	Convolutions séparables en profondeur	Mise à l'échelle composée (profondeur, largeur, résolution)
Utilisation de la mémoire	Haut	Faible	Modéré
Taille du modèle	Grand	Petit	Modéré
Vitesse	Lent	Vite	Modéré
Complexité de la formation	Haut	Faible	Modéré
Précision	Haut	Modéré	Très élevé
Cas d'utilisation	Grands ensembles de données, IA haute performance	IA mobile, applications en temps réel	Charges de travail polyvalentes de l'IA

III.7.7. Processus d'entraînement du modèle pré-entraîné :

Le développement d'un modèle de classification par apprentissage par transfert sur un ensemble d'échantillons de biscuits comprend les étapes et techniques fondamentales suivantes : division des données, prétraitement, sélection du modèle approprié, ainsi qu'application de techniques d'optimisation, de régularisation et d'ajustement des hyperparamètres. Dans cette partie, décrit les différentes étapes et techniques utilisées pour développer un modèle capable de classifier des biscuits.

- Division des données :

Les données constituent la base du modèle ; leur quantité et leur qualité influent considérablement sur la précision et la fiabilité des prédictions. Ces données sont divisées en trois sections pour l'entraînement du modèle.

- Données d'entraînement :

Ces données constituent la majorité des données (entre 60 % et 80 %) ; et permettent au modèle d'apprendre les caractéristiques. Ils doivent présenter des caractéristiques telles qu'une gamme étendue et diversifiée, suffisante pour couvrir tous les scénarios ; sinon, le modèle sera soit mal adapté, soit il apprendra des schémas biaisés qui ne reflètent pas les données réelles. [63]

- Données de validation :

Les données de validation sont un ensemble de données utilisé pour évaluer les performances d'un modèle pendant son entraînement sur de nouvelles données. Elles servent également à affiner les hyperparamètres, mais avec parcimonie, car des modifications excessives peuvent empêcher le modèle de généraliser à de nouvelles données. En général, 10 à 20 % de l'ensemble de données total contribuent à détecter le surapprentissage. [63]

- Donne de test :

Cet ensemble représente 10 % à 20 % des données totales. Il est généralement isolé des données d'entraînement et de validation, car il sert à évaluer les performances du modèle final après l'entraînement sur de nouvelles données, afin d'observer ses capacités dans des scénarios réalistes. Il n'est pas utilisé pour le développement du modèle, car cela influencerait négativement l'évaluation de ses performances finales. Sa sélection repose sur l'absence d'exemples dupliqués dans les ensembles d'entraînement et de validation, pour ne pas surestimer la précision du modèle. [63].

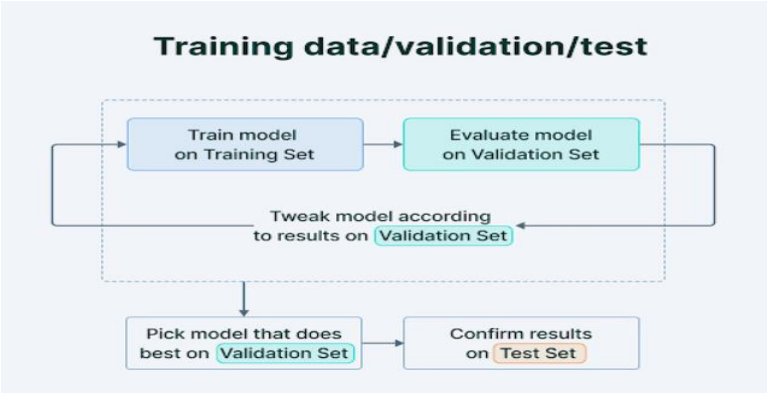


Figure III.12. Cycle de fonctionnement des données *[63]*

III.7.7.1. Stratégie de division des données :

Il n'existe pas de méthode idéale pour partitionner les données. Chaque méthode dépend du type de données et des difficultés à surmonter, notamment le déséquilibre des données. Par exemple : si l'on dispose de 1 000 images de deux groupes d'animaux, mais que le chat compte 800 images contre seulement 200 pour le chien, on constate un déséquilibre entre les deux groupes. [63]

- Division stratifiée :

Elle préserve la distribution des classes d'origine lors de la division. Elle convient aux données déséquilibrées comportant des groupes, dont certains ont un petit nombre d'échantillons. Elle permet de retrouver les mêmes groupes dans les ensembles d'entraînement, de validation et de test. [63]

III.7.7.2. Prétraitement des données :

Cette étape est cruciale car elle garantit la qualité des données d'entrée et améliore les performances des modèles d'apprentissage. De nombreuses techniques peuvent être utilisées à ce stade, notamment la normalisation, le redimensionnement et l'augmentation des données.

- Normalisation :
  Conversion de toutes les valeurs à une échelle unique, souvent entre 0 et 1 ou -1 et 1. Afin de rendre la convergence plus stable et plus rapide pendant l'entraînement. [53], [64]
- Redimensionnement :

  Les réseaux de neurones convolutifs nécessitent des dimensions d'entrée constantes ; un redimensionnement approprié est donc indispensable. Cette technique est importante car elle garantit la compatibilité avec les algorithmes du modèle (par exemple : 224×224 pixels pour ResNet) et aussi évite toute distorsion. [64]

- Augmentation des données :

  Cette technique permet de générer artificiellement de nouvelles images à partir d'images existantes dans les données d'entraînement. Le modèle gagne ainsi en précision, évite le surapprentissage et peut généraliser. L'augmentation des données se présente sous différentes formes, notamment :
- Décalage vertical
- Décalage horizontal
- Rotation
- Réglage de la luminosité et zoom [65]

III.7.7.3. Choix de modele :

La famille MobileNet a été choisie pour plusieurs raisons, notamment pour trouver un bon compromis entre précision et rapidité d'apprentissage. Parmi ses versions, c'est la version MobileNet v2 qui a été retenue, car elle offre une meilleure précision que le v1 et une complexité moindre que la v3. [66]

III.7.7.4. Techniques et réglages utilisées pendant l'entraînement :

De nombreuses techniques sont utilisées durant l'entraînement pour améliorer la précision ou l'efficacité.

- Optimisation et régularisation :

L'optimisation et la régularisation sont des techniques utilisées lors de l'entraînement des réseaux de neurones convolutifs (CNN) pour améliorer les performances du modèle et permettre la généralisation à des données inconnues. [53]

- Optimiseur ADAM :

Cet algorithme qui modifie le taux d'apprentissage et les poids du réseau pendant l'entraînement afin de réduire la fonction de perte. Il contrôle également la vitesse d'entraînement et la direction des mises à jour des poids Il est couramment utilisé pour les tâches de classification. [53]

- Le dropout :

Cette technique de régularisation qui supprime un nombre aléatoire de neurones, généralement entre 0,2 et 0,5, à chaque itération, empêchant ainsi le modèle de devenir trop dépendant des neurones afin de le rendre plus généralisable. [53]

- Les hyperparamètres :

Les hyperparamètres sont des variables utilisées lors de l'entraînement d'un modèle. Le choix de leur valeur optimale est crucial pour améliorer la stabilité, la vitesse ou la précision des modèles d'apprentissage. [67]

- Les époques :

Les époques sont un hyperparamètre déterminant qui, durant le processus d'entraînement, définit le nombre de fois où le modèle traite l'ensemble des données d'entraînement. Si ce nombre est excessivement élevé, l'efficacité du modèle s'améliore, mais le risque de surapprentissage et de limitation devient très important. . [67]

- Le taux d'apprentissage

Le taux d'apprentissage est un hyperparamètre déterminant de la vitesse et de la stabilité de la convergence du modèle pendant l'entraînement. Un taux élevé entraîne une instabilité du modèle, tandis qu'un taux faible ralentit l'entraînement. . [67]

III.7.8. L'évaluation du modèle :

Le modèle est évalué sur les données fournies à l'aide de métriques de performance adaptées à la classification, qui contribuent à l'amélioration de ses paramètres et à l'obtention d'un modèle très performant. Ces métriques permettent également de déterminer sa capacité de généralisation à un nouvel ensemble de données. Parmi ces métriques figurent :

- Matrice de confusion
- Exactitude
- Précision
- Rappel
- F1-Score

III.7.8.1. Matrice de confusion :

Une matrice de confusion est un ensemble de colonnes et de lignes ; les colonnes représentent des valeurs prédites et les lignes représentent des valeurs réelles. Comprend :

- Les vrais positifs (VP) sont le nombre de catégories positives que le modèle a correctement prédit.
- Les vrais négatifs (VN) sont le nombre de catégories négatives que le modèle a correctement prédit.
- Les faux positifs (FP) sont le nombre de catégories négatives incorrectement prédites par un modèle.
- Les faux négatifs (FN) sont le nombre de catégories positives mal prédites par un modèle. [68]

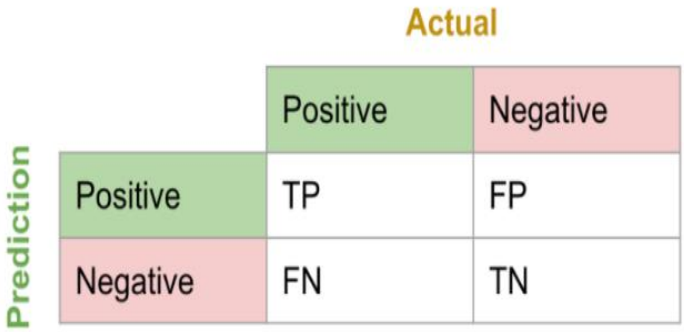


Figure III. 13. Matrice de confusion *[69]*

III.7.8.2. Exactitude :

La précision peut être déterminée en divisant le nombre de prédictions correctes par le nombre total de prédictions, il s'agit de l'une des mesures de performance les plus simples. [68]

$$\text{Exactitude} = \frac{TP+TN}{TP+TN+FP+FN} \qquad \text{(III. 1)}$$

III.7.8.3. Précision :

La précision permet de pallier les limitations de l'exactitude, elle détermine la proportion de prédictions correctes positives. [68]

$$\text{Précision} = \frac{TP}{TP+FP} \qquad \text{(III. 2)}$$

III.7.8.4. Rappel :

Le rappel mesure la proportion de cas positifs réels qui ont été identifiés incorrectement. [68]

$$\text{Rappel} = TP/((TP+FN)\quad) \qquad \text{(III. 3)}$$

III.7.8.5. F1-Score :

Le score F1 est une mesure utilisée pour évaluer un modèle, calculée à partir de la précision et du rappel. Il s'agit de la moyenne de ces deux valeurs, chacune ayant le même poids. [70]

$$F1 = 2 \cdot \frac{\text{Rappel} \cdot \text{Précision}}{\text{Rappel} + \text{Précision}} \qquad \text{(III. 4)}$$

III.8. Random Forest pour la classification

III.8.1. Définition de Random Forest :

Une forêt aléatoire est un algorithme d'apprentissage automatique qui crée plusieurs arbres de décision et regroupé leurs prédictions. Cette méthode réduit le surapprentissage et les erreurs par rapport à un arbre de décision unique. Ce modèle est utilisé pour les tâches de classification et gère efficacement les relations non linéaires. [71]

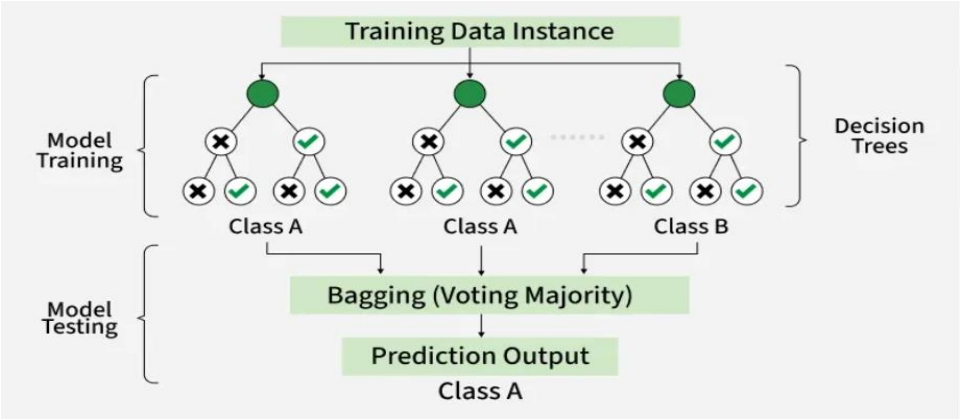


Figure III. 14. L'architecture de Random Forest *[71]*

III.8.2. Caractéristiques principales de l'algorithme :

L'algorithme gère les données manquantes et met en évidence les caractéristiques les plus pertinentes pour la prédiction, contribuant ainsi à une meilleure compréhension des données. Ses performances et sa précision augmentent avec la taille et la complexité des ensembles de données, sans ralentissement. [71]

III.8.3. Avantages d'une forêt aléatoire :

Une forêt aléatoire présente de nombreux avantages, notamment :

- L'indépendance dans la prise de décision, ce qui signifie que chaque arbre effectue sa propre prédiction sans dépendre des autres arbres.
- La sélection aléatoire des données ou des caractéristiques permet de réduire les erreurs.
- La présence de différents arbres permet des prédictions diversifiées, améliorant ainsi la précision. [71]

III.8.4. Le fonctionnement du foret aléatoire :

- L'algorithme crée plusieurs arbres de décision, chaque arbre utilisant un ensemble de données aléatoires.
- Le nombre de fonctionnalités est réparti aléatoirement de sorte que chaque arbre ne possède pas toutes les fonctionnalités, mais seulement un ensemble d'entre elles ; ce qui signifie que chaque arbre est unique.
- Chaque arbre fournit une prédiction ; la classification est déterminée par un vote majoritaire sur les prédictions. [71]

III.8.5. Les hyperparamètres du foret aléatoire :

Le nombre maximal de caractéristiques utilisées lors de la division d'un nœud contribue à réduire le surajustement. Le nombre total de caractéristiques est déterminé par :

La racine carrée du nombre total ou le logarithme binaire (base 2) du nombre total de caractéristiques.

La profondeur maximale par arbre : un arbre peu profond peut être inadapté, tandis qu'un arbre profond peut être sur adapté.

Le nombre maximal de feuilles dans l'arbre contrôle sa taille et sa complexité.

Le nombre maximal d'échantillons correspond à la quantité de données allouées à chaque arbre.

Le nombre minimal d'échantillons requis pour diviser un nœud interne. [72]

III.8.6. Processus entraînement et d'évaluation le modèle :

Le processus comprend les étapes utilisées pour développer et entraîner un modèle d'analyse des causes de biscuits défectueux, de l'extraction des caractéristiques à l'évaluation des performances du système. Parmi ces étapes figurent :

- Les caractéristiques sont extraites des données brutes ; à l'aide de méthodes statistiques telles que la moyenne et l'écart type afin de les transformer en données exploitables. [73]
- Les données tabulaires augmentent par l'ajout de bruit aléatoire à différents degrés pour améliorer la généralisation. [74]
- Les caractéristiques extraites sont combinées aux variables d'origine, à savoir le poids total des quantités et les températures des tunnels pour les deux régions. Ceci permet de distinguer les entrées des sorties, les cas de classification multi labels représentant les causes du défaut : humidité et surchauffe. [75]

- Les données sont divisées en un ensemble d'entraînement et un ensemble de test par stratification.
- Les performances du modèle d'arbre aléatoire sont optimisées en ajustant ses hyperparamètres par recherche sur grille afin de sélectionner la meilleure combinaison de paramètres, tels que le nombre d'arbres, leur profondeur et le nombre minimal d'échantillons par nœud [72]
- Les performances sont évaluées à l'aide de plusieurs métriques de classification, comme l'exactitude, la précision, le rappel et le score F1, pour chaque sortie indépendamment.

- La perte de Hamming est utilisée en classification multi-lables pour mesurer le pourcentage d'erreurs sur l'ensemble des sorties. [76]
- L'écart de généralisation calcule les performances du système sur les données d'entraînement et de test, dans le but de révéler le risque de surapprentissage. [77]

III.9. Conclusion

Ce chapitre pose les fondements théoriques nécessaires à la compréhension du mécanisme du système proposé et de ses différentes étapes de développement. Il démontre l'efficacité des réseaux de neurones convolutifs (CNN) pour la classification de la conformité, ainsi que celle des forêts aléatoires pour l'analyse causale.

Pour ce faire, il décrit les étapes fondamentales de l'entraînement, de l'évaluation et de l'amélioration du modèle, offrant ainsi un cadre complet pour le passage de la théorie à la pratique.

Chapitre IV : *Résultats de la Simulation et Validation des Performances.*

IV.1. Introduction :

Ce chapitre présente les résultats de simulation et de validation du système développé. Il est structuré en trois parties principales. La première est consacrée à la simulation du processus de production à travers ses six stations sous TIA Portal, afin de vérifier le bon fonctionnement de la logique de commande. La deuxième partie traite des tests réalisés sur le circuit de détection optique des germes pour évaluer sa fiabilité et ses performances. Enfin, la troisième partie est dédiée à l'évaluation des performances des modèles de contrôle qualité MobileNetV2 et Random Forest, puis déployés sur Raspberry Pi.

IV.2. Partie 1 : Simulation du Cahier des Charges du Processus de Fabrication des Madeleines :

Dans cette partie, la simulation du processus de fabrication des madeleines est présentée, à partir du dosage des ingrédients initiaux jusqu'à l'emballage du produit final. Nous avons représenté les différentes étapes de production au sein de l'environnement de simulation Tia Portal afin de comprendre le contrôle et la surveillance et supervision du flux du processus.

IV.2.1. Configuration du système automatisé de production :

- Un système de contrôle industriel a été mis en place basé sur deux automates programmables CPU S7-314-2 PN/DP. Le premier automate gère les stations 1 à 3, tandis que le second prend en charge les stations 4 à 6.
- Des interfaces homme-machine HMI TP700 et TP900 ont été intégrées afin de superviser et contrôler le processus en temps réel, ainsi qu'un système WinCC RT Advanced pour la supervision centrale (SCADA).
- Un variateur de vitesse G120 CU240E PN/PN a également été utilisé pour le contrôle des moteurs.
- L'ensemble des équipements est interconnecté via le réseau PROFINET, assurant une communication rapide et fiable entre les automates, les HMI, le système SCADA et les entraînements.

IV.2.2. Les blocs utilisés :

Dans ce programme, plusieurs blocs ont été utilisés afin d'organiser le fonctionnement du système et de structurer l'exécution du code. Le bloc principal OB1 assure l'exécution séquentielle du programme et l'appel des différents blocs fonctionnels. Un OB32 est utilisé pour les fonctions de PID dans la station concernée. Des FB (Function Blocks) sont utilisés pour gérer les différentes parties du procédé et séparer les fonctions de contrôle par station. Nous avons également défini les entrées et sorties du processus dans un Data Block, afin de regrouper toutes les variables système et de les lier aux éléments de contrôle, de surveillance et de supervision utilisés dans le programme.

IV.2.3. Les instructions de base :

Nous avons utilisé le langage Ladder pour le contrôle des différentes stations. Parmi les instructions de base utilisées, on trouve les contacts de base (NO et NF) pour la gestion des boutons et des états des capteurs TOR. Des bobines ont été utilisées pour représenter les différents états de fonctionnement des moteurs et des vannes, ainsi que différentes sorties. L'instruction MOVE permet le transfert des valeurs nécessaires, tandis que les temporisateurs sont utilisés pour les délais de temporisation. Les comparateurs servent à comparer les valeurs, et l'instruction SCALE

est utilisée pour la conversion des valeurs analogiques. Enfin, le bloc SR a été utilisé pour la gestion des états mémoire.

IV.2.3. Interfaces IHM et contrôle des équipements :

- Les stations sont associées à des interfaces IHM permettant la manipulation des paramètres, la saisie des consignes ainsi que les commandes de marche et d'arrêt.

IV.2.4. Supervision du procédé par le système SCADA :

- Le système SCADA est utilisé pour la supervision du procédé, l'affichage des alarmes, du graphe PID et de l'état des équipements (en marche ou à l'arrêt).

IV.3. Partie 2 : Tests et Validation du Circuit de Détection des Germes :

IV.3.1. Protocole expérimental :

Afin d'évaluer les performances du système de détection optique, une série de tests a été réalisée dans des conditions contrôlées. L'objectif est d'observer la variation du signal mesuré en fonction de l'état de la surface analysée.

Le dispositif expérimental est constitué de deux composants principaux : une LED UV-A utilisée comme source lumineuse et une photodiode permettant de capter le signal réfléchi.

Les tests ont été effectués sur différents condition de surface, Pour chaque condition, plusieurs mesures de tension ont été réalisées à l'aide du microcontrôleur (Arduino), puis converties en valeurs exploitables. Les tests ont été réalisés dans un environnement stable afin de limiter l'influence de la lumière ambiante.

Ce protocole permet d'assurer la cohérence et la fiabilité des résultats obtenus.

IV.3.2. Calibration du système et normalisation du signal :

Avant la détection de niveau de contamination, une phase de calibration est nécessaire afin de définir une référence stable du signal.

Dans ce travail, la valeur de tension de base a été déterminée expérimentalement en mesurant la tension de sortie du capteur pour une surface propre sous illumination UV-A. La valeur obtenue est d'environ 2.61 V. Cette valeur sert de point de référence pour toutes les mesures suivantes.

```
// Baseline ( real clean measurement)
float Vbase = 2.61;
```

Figure IV. 1.Paramètre de calibration de la tension de base dans le code

Le signal utile est défini comme la différence entre la tension mesurée et la tension de base :

$$Signal = Vout - Vbase \qquad (IV.\ 1)$$

Cette approche permet garde seulement les changements causés par l'état de la surface.

```
float signal =   vout- Vbase;
if (signal < 0) signal = 0;
```

Figure IV. 2.Calcul du signal (Vout − Vbase) dans le code.

Ensuite, un rapport (ratio) est calculé pour normaliser le signal par rapport à une valeur maximale.

$$Ratio = Signal / Signal_max \qquad (IV.\ 2)$$

Dans ce système, la valeur maximale du signal observée expérimentalement est d'environ 0.10V. Le ratio est donc limité entre 0 et 1.

```
// Normalize (max ≈ 0.10V)
float ratio = real_signal / 0.10;
if (ratio > 1) ratio = 1;
```

Figure IV. 3.Normalisation du signal par rapport à la valeur maximale (0.10 V).

D'après ce ratio, un pourcentage de propreté est défini :

$$\text{Propreté (\%)} = 100 \times (1 - \text{Ratio}) \qquad \text{(IV. 3)}$$

Ce pourcentage permet de convertir le signal mesuré en une information interprétable dans un système de supervision industrielle.

```
// Clean percentage
float cleanPercent = 100 * (1 - ratio);
```

Figure IV. 4.Calcul du pourcentage de propreté à partir du signal normalisé.

Le signal est utilisé pour classifier l'état de la surface selon des seuils définis expérimentalement. Cette classification permet de traduire la mesure analogique en niveaux de contamination.

Les seuils utilisés dans le programme sont les suivants :

Tableau IV. 1. Table de classification des signaux de contamination

Seuils	Niveaux de contamination
Signal < 0.01	Surface propre.
0.01 ≤ Signal < 0.03	Résidus faibles.
0.03 ≤ Signal < 0.07	Matières organiques.
Signal ≥ 0.07	Biofilm / contamination élevée.

```
// Classification
String state;

if (real_signal < 0.01) state = "CLEAN";
else if (real_signal < 0.03) state = "RESIDUE";
else if (real_signal < 0.07) state = "DIRTY";
else state = "BIOFILM";
```

Figure IV. 5.Table de classification des signaux de contamination

L'ensemble de ces traitements est implémenté dans le microcontrôleur Arduino, permettant une acquisition, un traitement et une classification du signal en temps réel.

IV.3.3. Conditions de test et échantillons utilisés :

Les tests expérimentaux ont été réalisés pour évaluer la capacité du système à classifier les différents niveaux de propreté sur une surface métallique.

IV.3.3.1. Surface testée :

La surface utilisée est une plaque en acier inoxydable (inox), choisie pour :

- Sa stabilité optique.
- Sa réflectivité relativement uniforme.
- Son utilisation fréquente dans les environnements industriels, notamment en agroalimentaire .

IV.3.3.2. Configuration géométrique du système :

Le dispositif expérimental a été mis en place selon une géométrie fixe :

- Le capteur photodiode (S1227) est positionné verticalement au-dessus de la surface, à une distance d'environ 4 cm
- La LED UV ($\lambda \approx 365–367$ nm) est placée à environ 3 cm de la surface.
- Un angle d'environ 90° est maintenu entre l'axe de la LED et celui du capteur.

Cette configuration permet de limiter la réception de la lumière directe, favoriser la détection de la lumière réémise par la surface et améliorer la sensibilité aux variations dues à la contamination.

IV.3.3.3. Filtrage optique :

Un filtre optique simple, réalisé à l'aide d'un plastique de couleur orange, a été placé devant le capteur. Son rôle est de :

- Réduire la composante de rayonnement UV direct.
- Laisser passer une partie du spectre visible (émissions secondaires).
- Améliorer le contraste du signal mesuré.

Bien que ce filtre il permet une première séparation entre la réflexion directe et la réponse optique liée à l'état de la surface.

IV.3.3.4. Échantillons testés :

Différents types de contamination ont été appliqués sur la surface inox afin de représenter plusieurs niveaux de propreté :

- Surface propre : inox nettoyé, utilisé comme référence.
- Eau : film fin simulant une contamination faible non organique.
- Huile : couche mince représentant une contamination organique.
- Résidus alimentaires : mélange simulant un état de contamination plus important, proche d'un biofilm simplifié.

Ces échantillons permettent d'obtenir une variation progressive des propriétés optiques de la surface.



Figure IV. 6. Surface en inox propre



Figure IV. 7.Surface en inox avec film d'eau.

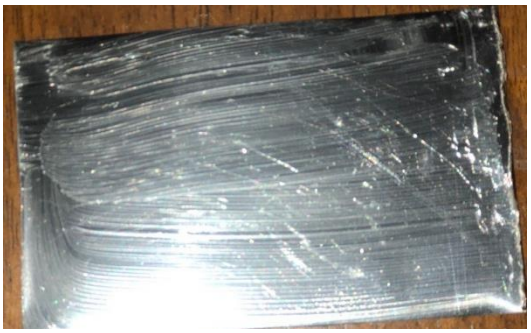


Figure IV. 8.Surface en inox avec couche d'huile.



Figure IV. 9.Surface en inox avec résidus alimentaires.

IV.3.4. Résultats expérimentaux :

Les essais expérimentaux ont été réalisés afin d'évaluer la réponse du système de détection en fonction des différents états de surface, ainsi que l'influence des paramètres de rétroaction du circuit de conversion courant-tension (Rf et Cf). Deux configurations ont été testées :

- Rf = 470 kΩ, Cf = 47 pF.
- Rf = 220 kΩ, Cf = 47 pF.

IV.3.4.1. Configuration Rf = 470 kΩ :

Les résultats obtenus pour la configuration Rf = 470 kΩ montrent comment les paramètres mesurés (tension de sortie, signal de sortie et pourcentage de propreté) évoluent en fonction du niveau de contamination.

Tableau IV. 2. Résultats de détection des niveaux de contamination pour une configuration de 470 kΩ.

Condition	Niveau	Etat	Vout (V)	Signal (mV)	Propreté (%)
Surface propre	Surface propre	Clean	2.60 -2.61	0.00	100.0
Eau	Contamination Faible.	RESIDUE	2.63-2.64	25-26	74.4-75.5
Huile	Contamination Organique.	DIRTY	2.64-2.65	34-35	65.8-65.9
Résidus alimentaires	Contamination élevée.	BIOFILM	2.68-2.69	75-76	24.8-29.0

Chaque condition est analysée ci-dessous :

- Condition 01 : Surface propre :
  Pour la surface propre, la tension de sortie mesurée est comprise entre 2.60 V et 2.61 V, correspondant à la tension de base du système.
  Le signal est nul (≈ 0 mV).
  Le pourcentage de propreté est maximal (100%).

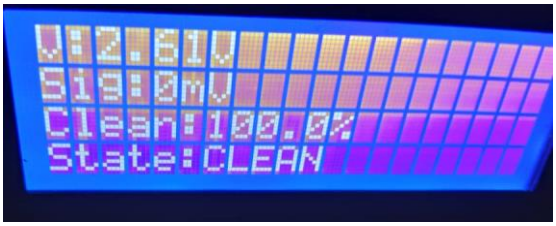


Figure IV. 10.Réponse du système pour une surface propre en inox.

Sur les graphes :

La courbe de Vout est stable.
Le signal reste proche de zéro.
La propreté est constante à 100%.



Figure IV. 11.Figure IV. 12. Mesure de tension de sortie (surface propre en inox).



Figure IV. 12.Mesure de signal et pourcentage de propreté (surface propre en inox).

Cette condition représente la référence du système. L'absence de variation du signal indique que la surface propre ne génère pas de réponse optique mesurable dans les conditions expérimentales.

- Condition 02 : Eau :

Avec l'ajout d'un film d'eau, la tension Vout augmente légèrement (2.63 – 2.64 V).
Le signal atteint 25 à 26 mV.
La propreté diminue à environ 74–75%.



Figure IV. 13.Réponse du système pour une surface en inox avec film d'eau.

Sur les graphes :

Une légère augmentation de Vout est observée.
Le signal présente une variation modérée.
La propreté diminue progressivement.

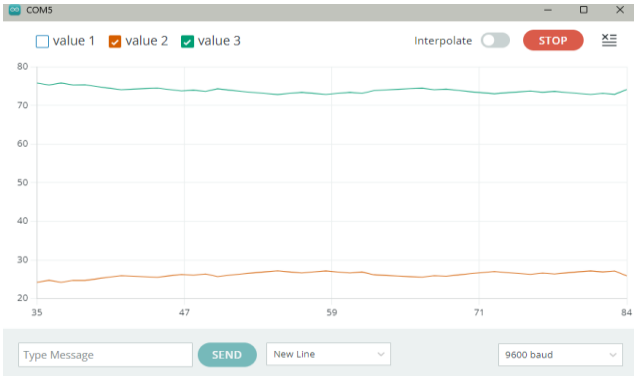


Figure IV. 15.Mesure du signal et du pourcentage de propreté (surface en inox avec film d'eau).



Figure IV. 14.Mesure de tension de sortie (surface en inox avec film d'eau).

La présence d'eau modifie les caractéristiques optiques de la surface, ce qui change le signal mesuré. Ce changement, même s'il est faible, est constaté par le système, qui provoque une diminution du pourcentage propreté.

- Condition 03 : Huile :

Pour une couche d'huile, Vout augmente davantage (2.64 – 2.65 V).
Le signal atteint 34 à 35 mV.
La propreté descend à environ 65–66%



Figure IV. 16.Réponse du système pour une surface en inox avec couche d'huile.

Sur les graphes :
La courbe Vout présente une augmentation plus marquée.
Le signal est supérieur à celui de l'eau.
La propreté continue de diminuer.

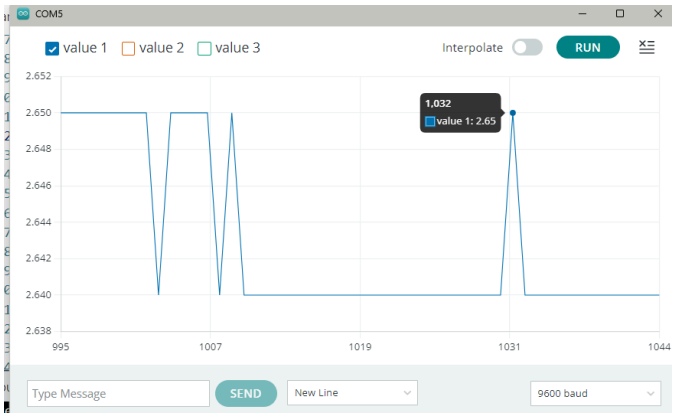


Figure IV. 17.Mesure de tension de sortie (surface en inox avec couche d'huile).

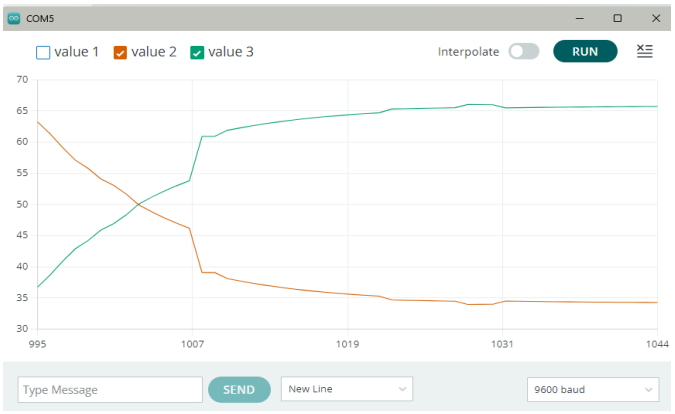


Figure IV. 18.Mesure du signal et du pourcentage de propreté (surface en inox avec couche d'huile).

L'huile a un impact plus important sur les propriétés optiques de la surface. Cette variation est détectée sous forme d'un signal plus élevé, indiquant un niveau de contamination supérieur.

- Condition 04 : Résidus alimentaires :

Avec le mélange biscuit et huile, la tension Vout atteint les valeurs les plus élevées (2.68 – 2.69V).
Le signal atteint 75 à 76 mV.
La propreté chute fortement (≈ 25–29%).



Figure IV. 19.Réponse du système pour une surface en inox avec résidus alimentaires.

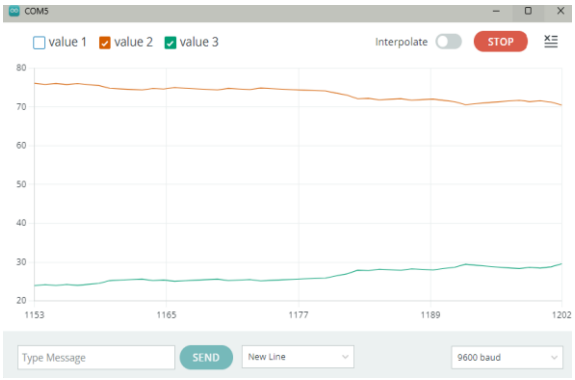


Figure IV. 21.Mesure du signal et du pourcentage de propreté (surface en inox avec résidus alimentaires).



Figure IV. 20.Mesure de tension de sortie (surface en inox avec résidus alimentaires).

Sur les graphes :
Augmentation nette de Vout.
Signal maximal observé.
Forte diminution de la propreté.

Les résidus alimentaires produisent une réponse optique importante, ce qui se traduit par une augmentation significative du signal et une diminution importante du niveau de propreté.

IV.3.5.2. Configuration Rf = 220 kΩ :

Les résultats obtenus pour la configuration Rf = 470 kΩ montrent comment les paramètres mesurés (tension de sortie, signal de sortie et pourcentage de propreté) évoluent en fonction du niveau de contamination.

Tableau IV. 3. Résultats de détection des niveaux de contamination pour une configuration de 220 kΩ

Condition	Niveau	Etat	Vout (V)	Signal (mV)	Propreté (%)
Surface propre	Surface propre.	Clean	2.58 -2.59	0.00	100.0
Eau	Surface propre.	Clean	2.59-2.60	0.00	100.0
Huile	Contamination Organique.	DIRTY	2.64-2.65	20-39	71.3-80.0
Résidus alimentaires	Contamination élevée.	DIRTY	2.65-2.66	52-57	42.1-46.4

Chaque condition est analysée ci-dessous :

- Condition 01 : Surface propre :

Pour la surface propre, la tension de sortie est comprise entre 2.58 V et 2.59 V,
Le signal est nul (0 mV).
La propreté est maximale (100%).



Figure IV. 22.Réponse du système pour une surface en inox propre.

Sur les graphes :
La tension Vout reste stable.
Le signal reste constant et nul.
La propreté reste constante.



Figure IV. 23.Mesure de tension de sortie (surface en inox propre).



Figure IV. 24.Mesure du signal et du pourcentage de propreté (surface en inox propre).

Cette condition représente également la référence du système. Aucun signal n'est généré, ce qui confirme un comportement stable en absence de contamination.

- Condition 02 : Eau :

Avec l'ajout d'un film d'eau, la tension varie légèrement entre 2.59 V et 2.60 V.
Le signal reste nul (0 mV).
La propreté reste 100%.



Figure IV. 25.Réponse du système pour une surface en inox avec film d'eau.

Sur les graphes :

Les courbes restent très proches de celles de la surface propre.
Aucune variation significative du signal n'est observée.

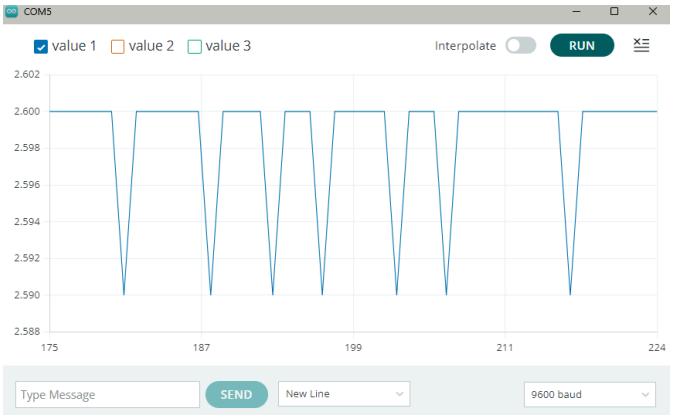


Figure IV. 27.Mesure de tension de sortie (surface en inox avec film d'eau).

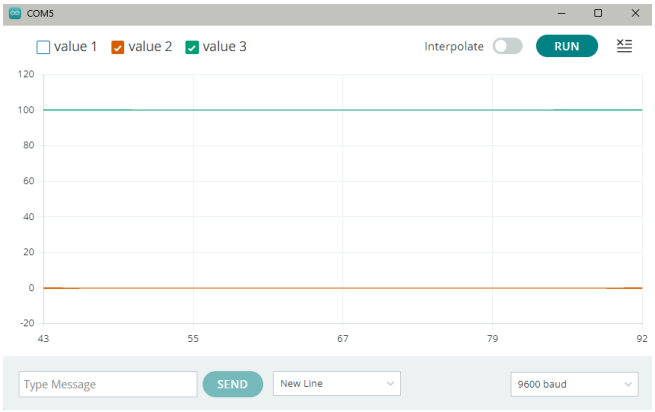


Figure IV. 26.Mesure du signal et du pourcentage de propreté (surface en inox avec film d'eau).

La variation de tension reste trop faible pour être détectée comme un signal. Dans cette configuration, le système ne distingue pas l'eau d'une surface propre.

- Condition 03 : Huile :

Pour une fine couche d'huile, la tension de sortie augmente (2.64 – 2.65 V).
Le signal varie entre 20 et 39 mV.
La propreté diminue (71–80%).



Figure IV. 28.Réponse du système pour une surface en inox avec couche d'huile.

Sur les graphes :
Une augmentation de Vout est observée
Le signal présente une variation mesurable
La propreté diminue progressivement

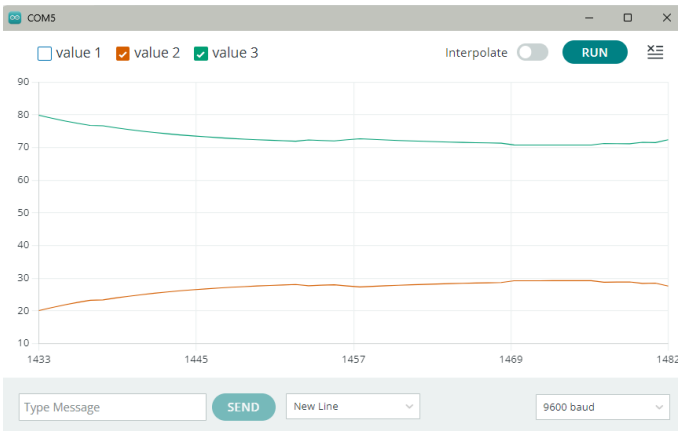


Figure IV. 30.Mesure du signal et du pourcentage de propreté (surface en inox avec couche d'huile).



Figure IV. 29.Mesure de tension de sortie (surface en inox avec couche d'huile).

La présence d'huile entraîne une modification des propriétés optiques de la surface, ce qui génère un signal détectable. Toutefois, la variation reste moins nette que dans la configuration précédente.

- Condition 04 : Résidus alimentaires :

Avec les résidus alimentaires, la tension atteint 2.66 – 2.67 V.
Le signal atteint 52 à 57 mV.
La propreté diminue (42–46%).

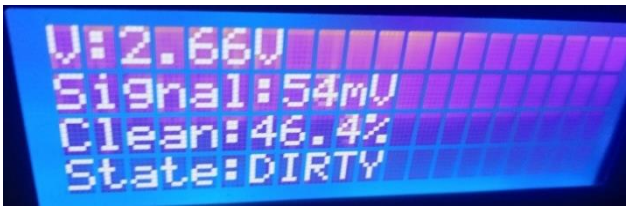


Figure IV. 31.Réponse du système pour une surface en inox avec résidus alimentaires.

Sur les graphes :

Une augmentation nette de Vout est observée.
Le signal atteint des valeurs élevées.
La propreté diminue de manière significative.

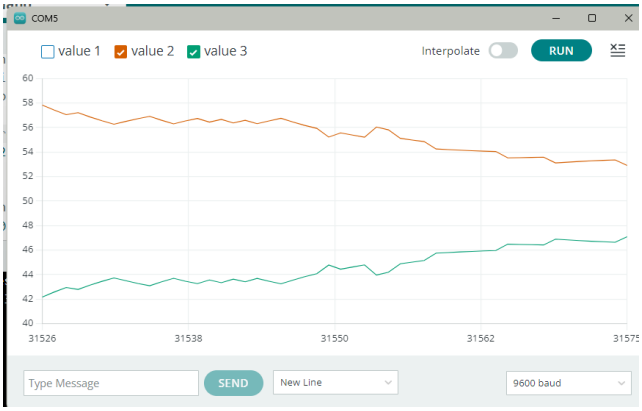


Figure IV. 33.Mesure du signal et du pourcentage de propreté (surface en inox avec résidus alimentaires).



Figure IV. 32.Mesure de tension de sortie (surface en inox avec résidus alimentaires).

Les résidus alimentaires provoquent une réponse optique importante, ce qui se traduit par une augmentation du signal mesuré. Cependant, dans cette configuration, le niveau obtenu reste inférieur au seuil de classification BIOFILM.

IV.3.6. Validation des performances du système :

La validation des performances du système repose sur une analyse comparative des deux configurations testées : Rf = 470 kΩ et Rf = 220 kΩ, afin d'identifier le meilleur compromis entre sensibilité, stabilité et capacité de discrimination des différents états de surface.

La configuration Rf = 470 kΩ présente une variation de signal plus importante entre les différents états de surface. Cela permet de mieux identifier les niveaux de contamination, notamment pour les faibles variations telles que l'eau et les résidus légers.

En revanche, la configuration Rf = 220 kΩ montre une variation de signal plus faible et des écarts de signal réduits, ce qui limite la séparation entre les niveaux de contamination, spécifiquement entre la surface propre et la contamination faible.

Avec Rf = 470 kΩ, le système permet une classification claire en quatre niveaux. Les transitions entre les états sont bien définies avec les variations mesurées.

Pour Rf = 220 kΩ, la classification de définies avec une superposition partielle entre certains niveaux, ce qui réduit la fiabilité globale du système pour une analyse fine.

L'analyse des performances met en évidence que la configuration Rf = 470 kΩ constitue le meilleur choix pour le système de détection. Elle offre :

- Une meilleure sensibilité aux variations optiques.
- Une séparation plus claire entre les niveaux de contamination.
- Une classification plus fiable.

Ainsi, la configuration Rf = 470 kΩ est retenue comme configuration optimale pour le fonctionnement du système de détection des germes dans les conditions expérimentales étudiées.

IV.3.8. Limites du système :

Il est important de noter que le système reste influencé par la réflexion optique de la surface, ce qui peut expliquer la détection de l'eau.

La possibilité d'amélioration consisterait à intégrer un filtrage optique plus sélectif pour mieux isoler le phénomène de fluorescence et diminuer l'influence des réflexions parasites sur la mesure.

IV.4. Partie 3 : Développement, Entraînement et Évaluation du Modèle de Contrôle Qualité :

IV.4.1. Le modèle de classification :

IV.4.1.1. Données :

- Collecte de données : nous avons collecté un total de 3 000 images et les avons divisées en 4 catégories : bon 1 200, fissuré 720, cassé 480 et trop cuit 600. Ces images ont été prises à l'aide d'une caméra du smartphone 1836×4080 (7 MP). Les catégories défectueuses ont été générées artificiellement d'une manière similaire aux défauts industriels, puis converties de la formule HEIC en JPG.



Figure IV. 34.Les classes défectueuses

- Division des données : les donnes ont été divisées en entraînement de 70 %, validation de 15 % et test de 15 %. Ces données ont été divisées par la méthode stratifiée de classe en raison du déséquilibre dans leur nombre entre les catégories.

```
# Split Train_temp / Test (~85% / 15%) stratifié avec random_state
split1 = StratifiedShuffleSplit(n_splits=1, test_size=0.15, random_state=42)
train_temp_idx, test_idx = next(split1.split(X, y))
X_train_temp, X_test = X[train_temp_idx], X[test_idx]
y_train_temp, y_test = y[train_temp_idx], y[test_idx]

# Split Train_temp / Validation (~70% / 15% total) stratifié avec random_state
split2 = StratifiedShuffleSplit(n_splits=1, test_size=0.1765, random_state=42)
train_idx, val_idx = next(split2.split(X_train_temp, y_train_temp))
X_train, X_val = X_train_temp[train_idx], X_train_temp[val_idx]
y_train, y_val = y_train_temp[train_idx], y_train_temp[val_idx]
```

Figure IV. 35.Division les donnes.

- Prétraitement des images : les données d'entraînement sont normalisées et la taille des données est agrandie, tandis que seules les données de validation et de test sont normalisées.

```
# Générateur pour l'entraînement avec augmentation
train_datagen = ImageDataGenerator(
    rescale=1./127.5,              # Normaliser les pixels entre 0 et 1
    rotation_range=5,            # Rotation aléatoire ±5° pour simuler léger mouvement des biscuits
    zoom_range=[0.97, 1.03],     # Zoom léger pour simuler distance caméra-produit
    width_shift_range=0.02,      # Décalage horizontal ±2% de la largeur
    height_shift_range=0.02,     # Décalage vertical ±2% de la hauteur
    brightness_range=[0.9, 1.1]  # Variation de luminosité ±10%
)
```

Figure IV. 36.Prétraitement des données d'entraînement

IV.4.1.2. Développement et entraînement du modèle :

- Déterminer la taille des images entrant dans le modèle MobileNetV2 et enlever les dernières couches de classification de ce modèle ; tout en gardant les poids entraînés sur ImageNet. Ensuite, ce modèle est chargé et ses couches sont figées, puis des couches personnalisées sont ajoutées pour construire le modèle final, afin que le modèle s'adapte au problème de classification des biscuits du projet.

```
# On fige les couches de base pour ne pas les entraîner au début
base_model.trainable = False

# ============================
# ====== Ajouter des couches personnalisées ======

x = base_model.output
x = GlobalAveragePooling2D()(x)  # transforme les cartes de caractéristiques en un vecteur
x = Dropout(0.4)(x)              # régularisation pour réduire l'overfitting
num_classes = 4                   # nombre de classes : good, fissure, overcooked, case
predictions = Dense(num_classes, activation='softmax')(x)

# Création du modèle final
model = Model(inputs=base_model.input, outputs=predictions)
```

Figure IV. 37.Création du modèle final.

- Le modèle est compilé en utilisant l'algorithme d'optimisation Adam, avec le choix d'une fonction de perte pour la classification multi-classes, et l'utilisation de la métrique d'exactitude pour évaluer les performances pendant l'entraînement.

```
model.compile(
    optimizer=Adam(learning_rate=0.001),
    loss='categorical_crossentropy',  # classification multi-classes
    metrics=['accuracy']
)

history = model.fit(
    train_generator,              # données d'entraînement
    validation_data=val_generator, # données de validation
    epochs=15,                    # nombre d'époques (modifiable selon vos besoins)
    steps_per_epoch=len(train_generator),   # nombre de batches par époque
    validation_steps=len(val_generator),     # nombre de batches pour la validation
    class_weight=class_weights
    )
```

Figure IV. 38.Compilation et entraînement du model.

- Dégel de certaines couches et recompilation du modèle et réentraînement, avec un taux d'apprentissage petit.

```
# 9. Fine-Tuning : débloquer dernières couches de MobileNetV2
for layer in base_model.layers[-30:]:
    layer.trainable = True
```

Figure IV. 39.Dégel les couches du MobileNetv2.

IV.4.1.3. Optimalisation du modèle :

- Pendant la phase d'entraînement en utilisant l'environnement Google Colab, plusieurs résultats sont apparus jusqu'à ce que de bons résultats finaux soient obtenus, avec une précision initiale relativement faible et une convergence lente du modèle ; malgré l'augmentation des époques, l'amélioration était limitée.
- Avec l'augmentation du taux d'apprentissage et du dropout, on obtenait une convergence rapide mais le système était instable.
- Lorsque le taux d'apprentissage diminuait, la convergence était lente, et lorsque le dropout diminuait, il y avait un surapprentissage.
- L'équilibre de ces valeurs entre la convergence stable et une haute précision est ce qui a conduit à de bons résultats.
- Pour améliorer ces résultats, des poids ont été ajoutés aux classes, comme celles fissurées qui avaient la précision la plus faible entre les classes, en donnant un poids plus élevé à chacune de ces classes, mais cela n'a pas suffi à augmenter significativement la précision.
- Pour obtenir une précision plus élevée, un dégel partiel des couches profondes du réseau pré-entraîné a été réalisé, ce qui a permis que le dégel d'un grand nombre de couches détériore la précision du modèle, mais le dégel d'un nombre raisonnable augmente considérablement la précision du modèle.
- Cette précision représente les résultats de la simulation, et ce modèle final a également été utilisé pour le déploiement.

IV.4.1.4. Résultats de simulation dans l'environnement Google Colab :

Tableau IV. 4. Mesures de performance du modèle lors de l'évaluation sur les donnes de validation

Classes	Précision	Rappel	F1-score
Biscuit cassé	1.00	0.96	0.98
Biscuit fissuré	0.98	0.94	0.96
Biscuit bon	0.95	0.99	0.97
Biscuit trop cuit	0.97	0.97	0.97

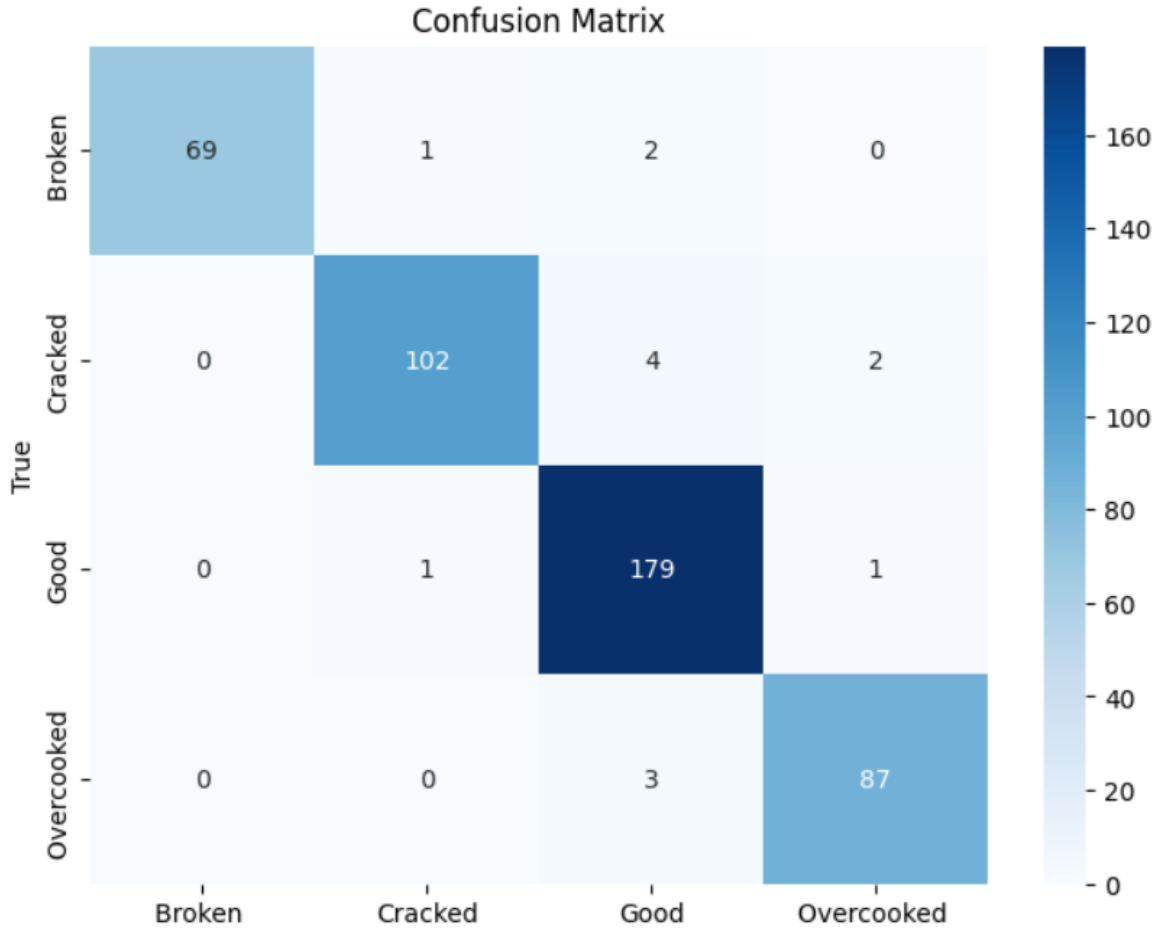


Figure IV. 40.Matrice de confusion du modèle entraîné

Tableau IV. 5. Mesures de performance du modèle lors de l'évaluation finale sur les donnes de test

Classes	**Précision**	**Rappel**	**F1-score**
Biscuit cassé	1.00	0.96	0.98
Biscuit fissuré	0.97	0.94	0.95
Biscuit bon	0.95	0.99	0.97
Biscuit trop cuit	0.98	0.97	0.97

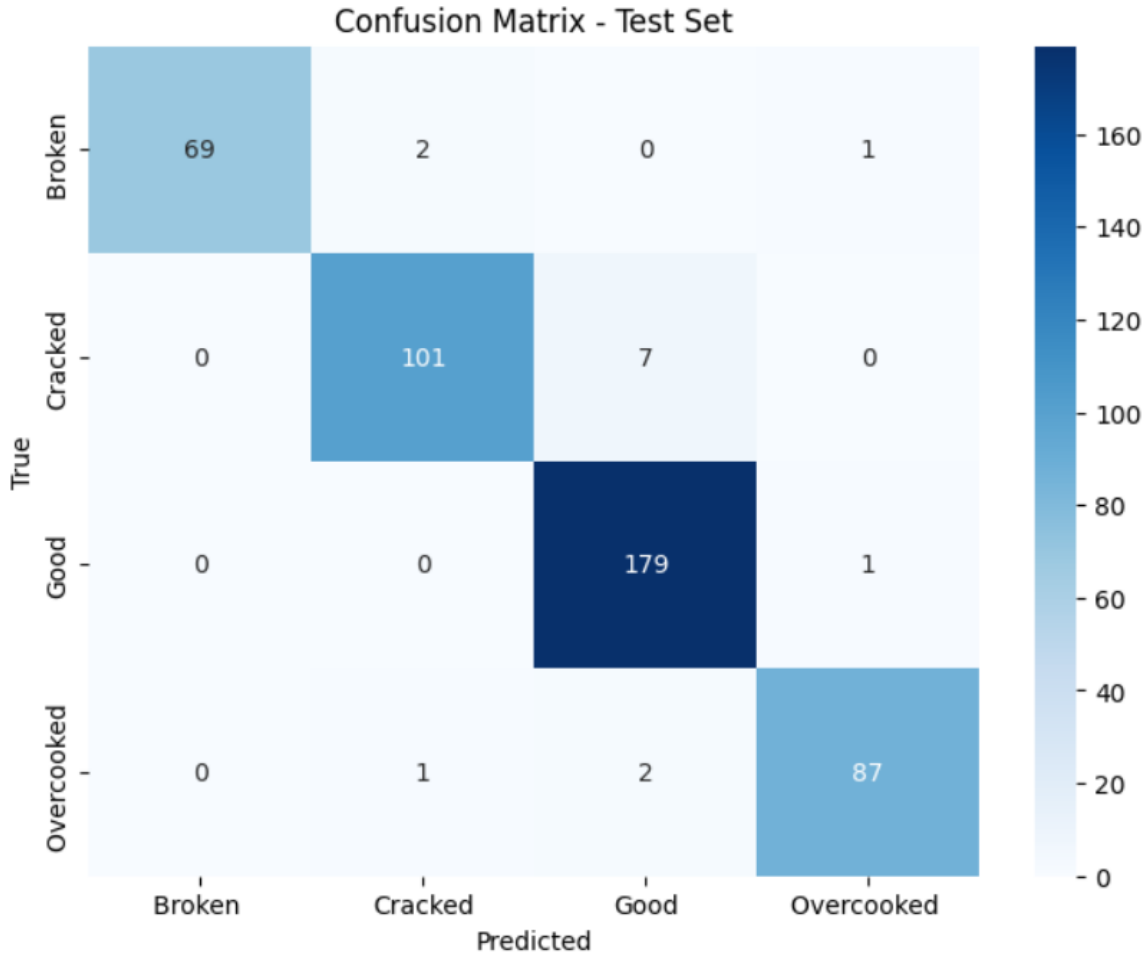


Figure IV. 41.Matrice de confusion du modèle lors de l'évaluation finale sur les donnes de test.

IV.4.1.5. Interprétation les résultats :

- Les résultats de l'évaluation ont montré que le modèle atteint un rappel élevé, ce qui indique qu'il détecte correctement la plupart des cas réels de chaque catégorie.
- Quant à l'exactitude était bonne, ce qui indique que le nombre d'erreurs résultant d'une classification incorrecte des échantillons était faible.
- La matrice de confusion montre également le nombre de pièces classées pour chaque catégorie par rapport au nombre total, montrant que la plupart des échantillons ont été correctement classés dans leurs catégories réelles, avec quelques types de confusion entre les catégories similaires.

IV.4.2. Le modèle d'analyse les causes :

IV.4.2.1. Les donnes :

Ces données ont été générées artificiellement à partir de valeurs approximatives représentant l'état bon, avec l'ajout de déviations pour simuler les défauts associés à chaque type, de manière à ce que les données reflètent les différences entre plusieurs lots de production, et se manifestent dans le poids total des ingrédients et les températures du four, supérieure et inférieure, pour les première et deuxième zones par rapport aux entrées, tandis que les sorties sont représentées par les indicateurs surchauffe et humidité, qui varient en fonction des entrées.

Les données de production ont été associées à l'état dominant de chaque lot, codé comme suit : 0 = casse, 1 = fissuré, 2 = bon, 3 = trop cuit. L'état dominant du lot est considéré comme bon lorsque la proportion de chaque défaut reste inférieure au seuil de non-conformité défini. En revanche, si la proportion d'un ou de plusieurs défauts dépasse ce seuil, le code attribué correspond au défaut dominant du lot.

id	weight_total	temp_top1	temp_bottom1	temp_top2	temp_bottom2	Heating	Moisture
1	96,7002	209,7628	230,2163	208,3311	187,8139	0	1
1	110,762	223,8796	227,6536	215,7787	200,4853	1	1
3	116,5211	246,1599	241,2253	241,9334	210,6292	1	1
0	103,7309	237,258	244,2143	206,5669	200,5287	1	0
2	104,6664	226,6942	239,5158	207,4447	195,734	0	0
2	103,9853	216,5842	238,8738	208,9914	195,0614	0	0

Figure IV. 42.Les données générées artificiellement pour l'entraînement du modèle.

IV.4.2.2. Développement et entraînement du modèle :

- Les caractéristiques ont été extraites des données brutes et ajoutées aux entrées. Les données ont été divisées en ensembles d'entraînement et de test, puis augmentées par ajout de bruit.

```
df["temp_mean"] = df[["temp_top1","temp_bottom1","temp_top2","temp_bottom2"]].mean(axis=1)
df["temp_std"] = df[["temp_top1","temp_bottom1","temp_top2","temp_bottom2"]].std(axis=1)
```

Figure IV. 43.Les caractéristiques extraites.

- La recherche par grille définit un ensemble de valeurs pour les paramètres tels que le nombre d'estimateurs, la profondeur maximale et le nombre minimum d'échantillons par feuille.

```
param_grid = {
    "n_estimators": [120, 180, 250],
    "max_depth": [6, 8, 10],
    "min_samples_leaf": [5, 8, 10]
}
```

Figure IV. 44.Paramètres utilisés dans GridSearchCV.

- Le modèle de forêt aléatoire est construit à partir des paramètres définis par la méthode GridSearchCV.

```
grid = GridSearchCV(
    RandomForestClassifier(class_weight="balanced", random_state=42),
    param_grid,
    cv=3
)
```

Figure IV. 45.Création du modèle Random Forest.

- Le meilleur modèle a été sélectionné. Ensuite, il a été réentraîné puis utilisé pour effectuer des prédictions sur les données de test.

```
grid.fit(X_train, y_train)

print("\nBEST PARAMETERS:")
print(grid.best_params_)

model = grid.best_estimator_
model.fit(X_train, y_train)
y_pred = model.predict(X_test)
```

Figure IV. 46.Entraînement et prédiction du modèle

IV.4.2.3. Résultats de simulation :

Tableau IV. 6. Métriques d'évaluation du label surchauffe.

Etat de classe	Précision	Rappel	F1-score
0	0.98	0.88	0.93
1	0.91	0.99	0.94

Tableau IV. 7. Métriques d'évaluation du label humidité.

Etat de classe	Précision	Rappel	F1-score
0	0.94	0.98	0.96
1	0.99	0.98	0.98

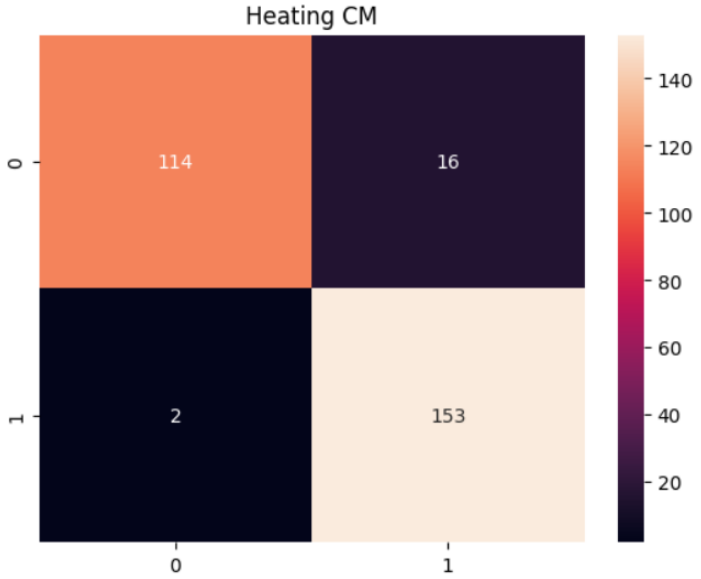


Figure IV. 47.Matrice de confusion du label surchauffe.

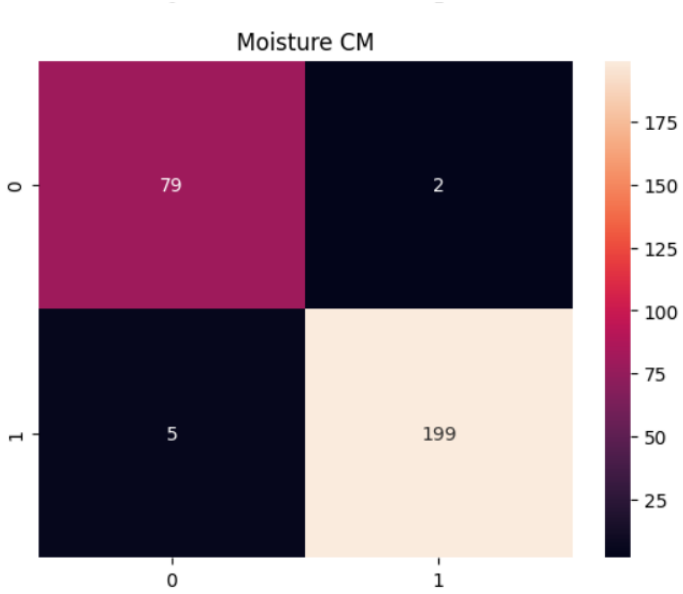


Figure IV. 48.Matrice de confusion du label humidité.

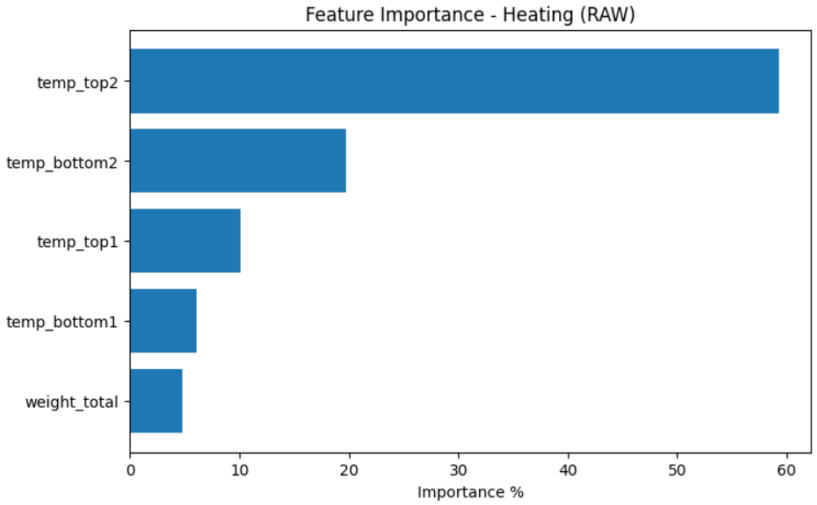


Figure IV. 49.Importance des caractéristiques pour le label surchauffe.

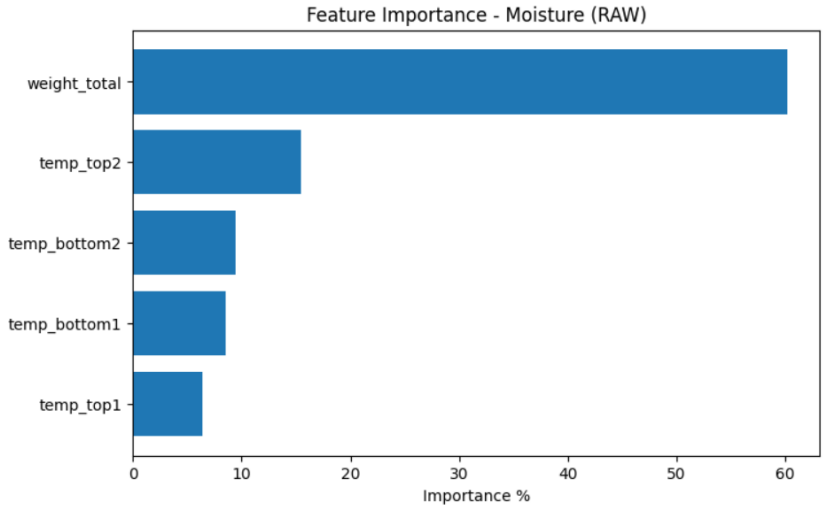


Figure IV. 50. Importance des caractéristiques pour le label humidité.

IV.4.2.4. Interprétation les résultats :

- Le modèle a montré de bonnes performances en classification, avec une perte de Hamming d'environ 0,044, indiquant peu d'erreurs au niveau des prédictions.
- Il y a aussi un gap de 0,3508, ce qui indique un surapprentissage acceptable.
- Les performances en matière d'humidité étaient excellentes et très précises, tandis que celles du système de surchauffe étaient bonnes mais moins stables par rapport à l'humidité, avec quelques erreurs de prédiction.

- Les meilleurs hyperparamètres du modèle sont : max_depth = 10, min_samples_leaf = 8, n_estimators = 120.
- L'analyse de l'importance des variables montre que, pour la sortie surchauffe, les entrées les plus influentes sont principalement la température de la zone 2 (partie supérieure), tandis que pour la sortie humidité, la variable la plus déterminante est le poids total.

IV.4.3. Déploiement sur Raspberry Pi :

IV.4.3.1. Configuration matérielle :

Les modèles précédemment entraînés fonctionnaient sur le Raspberry Pi 4 (64 bits, 4 Go de RAM) avec trois types d'appareils d'imagerie : caméra Raspberry Pi v2 (8MP), webcam USB et smartphone via une application webcam IP.

IV.4.3.2. Résultats expérimentaux du modèle de la conformité :

Les résultats ont montré que les performances et la précision du modèle changent avec les conditions de prise de vue en termes d'arrière-plan, d'éclairage, de distance entre l'appareil photo et d'angle de prise de vue, car certaines catégories sont correctement reconnues, sauf dans des circonstances spécifiques ; par exemple, le « fissuré » la catégorie est mieux reconnue sur un fond brun et de près, tandis que les catégories « trop cuit », « cassé » et « bon » fonctionnent mieux sur un fond blanc.

Les expériences appliquées à 11 échantillons pour chaque catégorie ont montré une différence de performance selon le type d'appareil photo. En utilisant la webcam, la catégorie « plus cuit » a été correctement identifiée (11/11), tandis que la catégorie « cassé » a donné 9 résultats corrects sur 11. La catégorie « Bon » s'est également révélée sensible aux changements de luminosité et d'emplacement, ce qui a conduit à des erreurs initiales avant que les conditions ne se stabilisent. La catégorie « fissuré » était moins précise dans certains cas en utilisant une webcam.

En revanche, l'appareil photo du téléphone a fourni des performances plus stables, identifiant correctement toutes les classes dans la plupart des cas lorsque les conditions de prise de vue étaient proches des données d'entraînement. Le Raspberry Pi v2 a montré une mauvaise qualité d'image, ce qui a entraîné une baisse significative de la précision globale des notes.



Figure IV. 51.Prédiction du modèle du biscuit trop cuit.



Figure IV. 52.Prédiction du modèle du biscuit cassé.

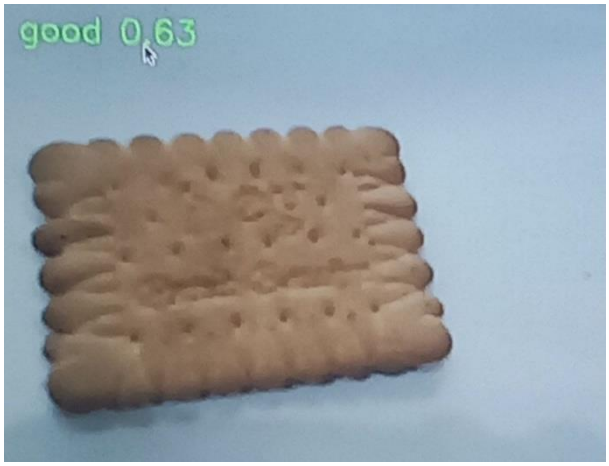


Figure IV. 53.Prédiction du modèle du biscuit bon.



*F*igure IV. 54.Prédiction du modèle du biscuit fissuré.

IV.4.3.3. Résultats expérimentaux du modèle de la cause :

- Sur la plateforme Raspberry Pi, le modèle n'a pas été testé directement à l'aide de données de production réelles, mais des données représentatives ont été générées en supposant qu'elles reflètent l'état dominant de chaque lot. La classe « bon » correspond à un lot dont les proportions de tous les défauts restent inférieures aux seuils de non-conformité définis. En revanche, lorsqu'un ou plusieurs défauts dépassent ces seuils, la classe attribuée correspond au défaut dominant du lot, c'est-à-dire celui dont la proportion est la plus élevée parmi les défauts non conformes.

- Ces données sont ensuite traitées par le modèle Random Forest sauvegardé depuis Google Colab, qui analyse si la situation est liée à une surchauffe ou à un problème d'humidité en fonction des données générées.

- Les résultats du modèle sont satisfaisants dans les cas de surchauffe et d'humidité lorsque les valeurs sont (0,0) ou (1,1). En revanche, lorsque l'une des valeurs est égale à 1 et l'autre à 0, les résultats deviennent moins stables, ce qui peut s'expliquer par la nature des données générées ou par la capacité limitée du modèle à généraliser sur des situations moins représentées.

- Après l'obtention du résultat, le système fournit des recommandations correctives sous forme de messages d'aide et non de solutions définitives. Ces recommandations indiquent les équipements susceptibles d'être à l'origine des variations observées, tels que le capteur de poids, les capteurs du four, le moteur de transport des ingrédients secs, la vanne d'alimentation en ingrédients liquides, ou encore la turbine de distribution de chaleur. Elles sont affichées en fonction de la gravité de la cause identifiée.

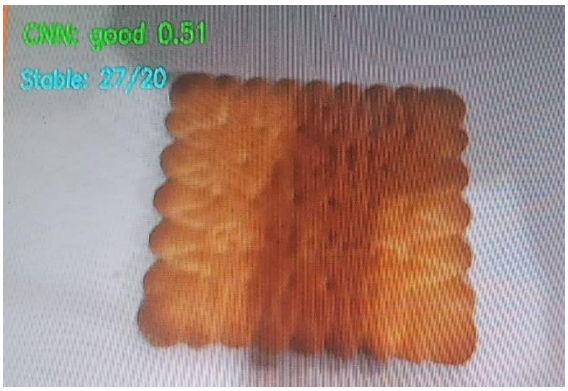


Figure IV. 55.Prédiction du modèle du biscuit fissuré.



Figure IV. 56.Biscuit trop cuit – causes et recommandations.



Figure IV. 57.Biscuit cassé – causes et recommandations.

IV.4.4. Limites et perspectives des modèles :

IV.4.4.1. Limitations du modèle :

Le modèle d'analyse des causes est basé sur des données générées artificiellement plutôt que sur des données réelles, et les relations entre les entrées et les sorties sont plus statistiques que causales. En outre, le manque de diversité des données de production rend les résultats du modèle approximatifs et limite sa précision.

Quant au modèle de classification, il ne couvre pas tous les types de défauts potentiels, ne prend pas en compte la possibilité que plusieurs défauts apparaissent en même temps et n'inclut pas une analyse de la base ou de l'intérieur du produit.

IV.4.4.2. Perspectives d'amélioration des modèles :

Ce travail peut être amélioré en utilisant plus de données de capteurs pour augmenter la précision du modèle d'analyse des causes et mieux comprendre les causes. Le modèle s'appuie sur la classe dominante des réseaux de neurones convolutifs pour représenter chaque lot, avec la possibilité d'utiliser des méthodes d'analyse plus approfondies pour étudier les causes. Le modèle de classification peut être amélioré en tenant compte de la variété des défauts présents dans une seule pièce, ainsi que des défauts plus complexes.

IV.5. Conclusion :

Ce chapitre a permis de valider les différents composants du système automatisé développé. La simulation sous TIA Portal a confirmé la cohérence de l'architecture de contrôle répartie entre les six stations, ainsi que l'efficacité de la supervision via les interfaces HMI et le système SCADA.

Le système de détection des germes a également été réalisé et validé expérimentalement, montrant sa capacité à détecter et classifier les niveaux de contamination, avec toutefois une sensibilité aux réflexions lumineuses sur la surface de l'échantillon, ce qui peut être amélioré par un filtrage optique plus précis.

Par ailleurs, le modèle de classification a montré de bonnes performances, mais il ne couvre pas l'ensemble des types de défauts ni leur diversité au sein d'une même pièce. Le modèle d'analyse des causes présente des résultats moyens à bons, avec des limites liées à l'utilisation de données synthétiques.

Des améliorations futures peuvent être envisagées à travers l'enrichissement des types de défauts pour le modèle de classification, l'utilisation de données réelles pour le modèle d'analyse des causes, ainsi que l'amélioration des recommandations correctives afin d'augmenter la précision et la fiabilité globale du système.

Conclusion générale

Conclusion générale :

Ce projet avait pour ambition de concevoir un système intégré de supervision d'une ligne agroalimentaire, alliant automatisation industrielle, détection optique de contamination microbienne et contrôle qualité par intelligence artificielle.

Les travaux réalisés ont permis de valider les trois axes principaux du projet. Le procédé de fabrication a été modélisé et simulé avec succès, confirmant la cohérence de l'architecture de contrôle sur l'ensemble des stations de production. Le système de détection optique des germes a démontré sa capacité à discriminer différents niveaux de contamination de surface en temps réel, avec une configuration optimale retenue pour sa meilleure sensibilité. Les modèles d'intelligence artificielle développés ont atteint des performances satisfaisantes pour la classification des produits conformes et non conformes l'identification des causes de non-conformités, avec un déploiement embarqué confirmant la faisabilité pratique du système.

Cependant, certaines limites ont été identifiées. Les performances du modèle de classification visuelle restent sensibles aux conditions de prise de vue et à la qualité de la caméra. Le modèle d'analyse des causes n'a pas été testé sur des données de production réelles, ce qui limite sa fiabilité en contexte industriel. Le circuit de détection optique reste quant à lui influencé par les réflexions de la surface.

En perspective, ces travaux ouvrent plusieurs axes d'amélioration : la collecte de données réelles de production, l'amélioration des conditions d'acquisition des images, l'intégration d'un filtrage optique plus sélectif, et le déploiement complet du système en environnement industriel réel pour une validation en conditions de production.

Références

[1] «Screw feeder - 4 models from D10 to D13,» Palamatic Process, [En ligne]. Available: https://www.palamaticprocess.com/en-us/bulk-handling-equipment/screw-feeder. [Accès le 14 03 2026].

[2] «wd-brickmachine,» [En ligne]. Available: https://www.wd-brickmachine.com/fr/news/a-beginners-guide-to-tunnel-kiln-principles-structure-and-operation/. [Accès le 3 4 2026].

[3] «amfbakery,» [En ligne]. Available: https://amfbakery.com/fr/equipement/etuvage-et-cuisson/cuisson/fours-tunnels/four-tunnel-multibake-d. [Accès le 6 4 2026].

[4] «mae-innovation,» 25 3 2026. [En ligne]. Available: https://mae-innovation.com/comment-choisir-le-bon-tunnel-de-cuisson-pour-votre-ligne-agroalimentaire/. [Accès le 3 4 2026].

[5] «Baking Oven Manufacturers,» [En ligne]. Available: https://industrial-ovens.net/baking-ovens/. [Accès le 02 05 2026].

[6] «foshansoontrue,» 12 3 2026. [En ligne]. Available: https://www.foshansoontrue.com/article/working-principle-of-flow-wrapping-machines-how-horizontal-flow-wrappers-really-work.html. [Accès le 4 4 2026].

[7] A. Lim, 27 12 2023. [En ligne]. Available: https://www.chlbpack.com/fr/blog/guide-to-horizontal-form-fill-seal-machine/. [Accès le 3 4 2026].

[8] «Packaging Machine flow wrapping,» 9 3 2017. [En ligne]. Available: https://fr.scribd.com/document/341343715/Bosch-Guide-to-Flow-Wrapping. [Accès le 3 4 2026].

[9] S. P. J. Y. J. K. J. L. S. B. K. G. K. Ahyeong Lee, «Detecting Bacterial Biofilms Using Fluorescence Hyperspectral Imaging and Various Discriminant Analyses,» *Sensors,* vol. 21, n° %16, p. 2213, Sensors.

[10] H. A. S. A.-E. O. A. AsemM.Abdelshafy, «Recent Advances in Detection and Control Strategies for foodborne bacteria in Raw and Ready-to-Eat Fruit and Vege,» *Food Frontiers,* vol. 6, n° %12, pp. 605-629, 2025.

[11] Y. Aswathi Soni, «Hyperspectral imaging and machine learning in food microbiology: Developments and challenges in detection of bacterial, fungal, and viral contaminants.,» *COMPREHENSIVE REVIEWS IN FOOD SCIENCE AND FOOD SAFETY,* vol. 21, n° %14, pp. 3717-3745, 2022.

[12] J. L. L. ,. B. T. D. ,. E. G. ,. D. J. K. ,. N. S. P. ,. A. R. L. ,. P. M. W. F. ,. C. D. Taylor M Cannon, «Characterization of NADH fluorescence properties under one-photon excitation with respect to temperature, pH, and binding to lactate dehydrogenase,» *osa continuum and indexed in pubmed ,* vol. 4, n° %15, p. 1610–1625, 2021.

[13] W. C. J. H. X. L. Y. M. B. Z. Liang Shen, «Effective management of pre-existing biofilms using UV-LED through,» *Journal of Hazardous Materials,* vol. 486, n° %10304-3894, p. 136925, 2025.

[14] D. N. F. Almazyad, «Effects of Ultraviolet Radiation on Microbes,» *International Journal of Current Microbiology and Applied Sciences ,* vol. 11, n° %14, pp. 1-5, 2022.

[15] «COMPLETE MANUAL FOR GETTING STARTED WITH BIODTEX,» BioDtex, [En ligne]. Available: https://www.crimsonchemicals.com/wp-content/uploads/2024/11/BioFilm-USER-MANUAL-Manual-CC.pdf. [Accès le 02 03 2026].

[16] «Si photodiode S1227 series,» HAMAMATSU PHOTONICS, [En ligne]. Available: https://www.hamamatsu.com/content/dam/hamamatsu-photonics/sites/documents/99_SALES_LIBRARY/ssd/s1227_series_kspd1036e.pdf. [Accès le 25 02 2026].

[17] «UV Z5 series (CUNx6A1B),» seoal viosys, 09 09 2024. [En ligne]. Available: https://www.seoulviosys.com/en/product/detail/2. [Accès le 26 02 2026].

[18] «IscN-ChannelMOSFETTransistor,» isc, [En ligne]. Available: https://www.alldatasheet.com/datasheet-pdf/view/1010480/ISC/IRLZ44N.html. [Accès le 15 02 2026].

[19] «Design and Construction of Ultraviolet and Incoming Solar Irradiance,» *Iraqi Journal of Science,* vol. 63, n° %112, pp. 5197-5207 , 2022.

[20] «MCP6021/1R/2/3/4,» Microchip Technology, [En ligne]. Available: https://ww1.microchip.com/downloads/aemDocuments/documents/MSLD/ProductDocuments/DataSheets/MCP6021-Data-Sheet-DS20001685.pdf. [Accès le 20 02 2026].

[21] A. Vina, 25 8 2025. [En ligne]. Available: https://www.ultralytics.com/fr/blog/edge-detection-in-image-processing-explained. [Accès le 16 5 2026].

[22] A. S.Nashat, «Machine vision for crack inspection of biscuits featuring pyramid detection scheme,» *d'ingénierie alimentaire,* 2014.

[23] S. Ammar, 25 6 2025. [En ligne]. Available: https://fr.scribd.com/document/881585286/Chapitre-4-Classification. [Accès le 17 5 2026].

[24] M. K. Oya Kilici, «Classification automatisée de la qualité des biscuits a l'aide des modéles YOLOv8 dans l'industrie alimentaire,» vol. 18, 2025.

[25] S. S. Gagandeep Kaur, «Performance Evaluation of Machine Learing Algorithms--SVM, DT, CNN and KNN,» *Electrical Systems,* 2026.

[26] Q. Ma, H. Li et A. Thorstenson, «A Big Data-driven Root Cause Analysis System: Application of Machine Learning in Quality Problem Solving,» *Computers and Industrial Engineering.,* 2021.

[27] C. G. Liakos, V. Athanasiadis, E. Bozinou et S. I. Lalas, «Apprentissage automatique pour le contrôle qualité dans l'industrie alimentaire : une revue,» 2025.

[28] J. Senoner. [En ligne]. Available: https://www.ethon.com/articles/a-terrible-idea-using-random-forest-for-root-cause-analysis-in-manufacturing. [Accès le 11 5 2026].

[29] B. Wohlwend, 3 7 2023. [En ligne]. Available: https://medium.com/@brandon93.w/decision-tree-random-forest-and-xgboost-an-exploration-into-the-heart-of-machine-learning-90dc212f4948. [Accès le 13 4 2026].

[30] «Université Larbi Ben M'hidi Oum El Bouaghi,» [En ligne]. Available: Chapitre1 Introduction À La Vision Industrielle. [Accès le 13 2 2026].

[31] «meaxpert,» [En ligne]. Available: https://meaxpert.com/fr/blog/types-de-base-de-systemes-de-vision-industrielle/. [Accès le 13 2 2026].

[32] A. TALEB-AHMED, 2005. [En ligne]. Available: https://www.j3ea.org/articles/j3ea/pdf/2005/02/j3ea05033.pdf. [Accès le 16 2 2026].

[33] Vincent, 07 10 2025. [En ligne]. Available: https://vrautomation.fr/vision-industrielle-quel-type-declairage-choisir/. [Accès le 17 2 2026].

[34] «RHISHI,» 21 02 2025. [En ligne]. Available: https://www.aiusbcam.com/fr/news/746373899818070043.html. [Accès le 18 2 2026].

[35] «HIFLY,» 07 04 2025. [En ligne]. Available: https://www.szhifly.com/fr/Machine-Vision-Camera-Guide-How-to-Choose-the-Right-Camera-for-Industrial-Inspection. [Accès le 17 2 2026].

[36] «COGNEX,» 6 11 2025. [En ligne]. Available: https://www.cognex.com/fr/tools-and-resources/resource-center/machine-vision/machine-vision-hardware-components. [Accès le 12 2 2026].

[37] G. v. Elmbt, 4 11 2025. [En ligne]. Available: https://va-imaging.com/fr/blogs/centre-de-connaissances-en-vision-industrielle/cameras-couleur-vs-cameras-monochromes. [Accès le 18 2 2026].

[38] «SINSMART,» 13 8 2024. [En ligne]. Available: https://www.sinsmarts.com/fr/blog/components-of-a-machine-vision-system/. [Accès le 7 2 2026].

[39] «VIE MACHINERY,» [En ligne]. Available: https://viemachinery.com/fr/comprendre-les-systemes-de-vision-types-composants-et-applications/. [Accès le 10 2 2026].

[40] «SCORTEX,» 18 6 2024. [En ligne]. Available: https://scortex.io/en/la-vision-industrielle-qu-est-ce-que-c-est. [Accès le 12 2 2026].

[41] «EVT,» 28 5 2025. [En ligne]. Available: https://www.evt-web.com/introduction-to-industrial-machine-vision-fundamentals-and-applications/. [Accès le 13 2 2026].

[42] «visionplatform.ai,» 9 9 2023. [En ligne]. Available: https://visionplatform.ai/fr/vision-industrielle-machine-vision-dans-lindustrie-agroalimentaire/. [Accès le 11 5 2026].

[43] «HSYL,» 4 2 2026. [En ligne]. Available: https://www.hsylfoodline.com/fr/equipment-know-how/why-your-hard-biscuits-crack-5-common-causes-and-machinery-adjustments.html. [Accès le 7 5 2026].

[44] Aboudjenane, «École Supérieure des Sciences de l'Aliment et des Industries Agroalimentaires,» 07 11 2025. [En ligne]. Available: https://fr.scribd.com/presentation/956818402/Cours-4-Les-Principaux-Defauts-de-Qualite-Des-Pates-Et-Confiseries. [Accès le 10 3 2026].

[45] M. Gupta, 27 1 2025. [En ligne]. Available: https://www.appliedaicourse.com/blog/ai-vs-ml-vs-dl/. [Accès le 14 2 2026].

[46] «mathworks,» [En ligne]. Available: https://fr.mathworks.com/discovery/neural-network.html. [Accès le 6 5 2026].

[47] J. RATIER, 23 9 2025. [En ligne]. Available: https://www.koncile.ai/ressources/deep-learning-vs-machine-learning-quelles-sont-les-differences. [Accès le 16 2 2026].

[48] «Equipe Databricks,» [En ligne]. Available: https://www.databricks.com/fr/blog/what-are-machine-learning-models. [Accès le 12 5 2026].

[49] «NIXUS,» [En ligne]. Available: https://nixustechnologies.com/unsupervised-machine-learning/. [Accès le 12 5 2026].

[50] «Datatonic,» [En ligne]. Available: https://datatonic.com/insights/reinforcement-learning-identifying-opportunities-use-cases/. [Accès le 3 5 2026].

[51] A. Grignola, 19 3 2026. [En ligne]. Available: https://www.data-bird.co/blog/classification-vs-regression-machine-learning. [Accès le 3 5 2026].

[52] «machinelearningtricks,» 24 11 2018. [En ligne]. Available: https://machinelearningtricks.blogspot.com/2018/11/classification-vs-regression.html. [Accès le 14 5 2026].

[53] Daniella, 5 6 2024. [En ligne]. Available: https://www.innovatiana.com/fr/post/convolutional-neural-network. [Accès le 13 4 2026].

[54] Z. Kelta, 14 11 2024. [En ligne]. Available: https://www.datacamp.com/fr/tutorial/introduction-to-convolutional-neural-networks-cnns. [Accès le 24 3 2026].

[55] «geeksforgeeks,» [En ligne]. Available: https://www.geeksforgeeks.org/machine-learning/introduction-convolution-neural-network/. [Accès le 10 2 2026].

[56] geeksforgeeks. [En ligne]. Available: https://www.geeksforgeeks.org/deep-learning/deep-learning-interview-questions/. [Accès le 2 3 2026].

[57] «geeksforgeeks,» [En ligne]. Available: https://www.geeksforgeeks.org/deep-learning/what-is-fully-connected-layer-in-deep-learning/. [Accès le 15 4 2026].

[58] «geeksforgeeks.,» [En ligne]. Available: https://www.geeksforgeeks.org/deep-learning/neural-networks-a-beginners-guide/. [Accès le 20 2 2026].

[59] «mathworks,» [En ligne]. Available: https://fr.mathworks.com/discovery/deep-learning.html. [Accès le 15 3 2026].

[60] Koulibalyhamam, 13 5 2025. [En ligne]. Available: https://fr.scribd.com/document/838732601/00-Support-de-Cours-DL-Transfert-LEarning1?v=0.481. [Accès le 10 4 2026].

[61] «Medium,» 26 5 2024. [En ligne]. Available: https://medium.com/@jaguuai/cnn-vgg-resnet-densenet-mobilenet-effecientnet-and-yolo-2329a9fa2d0f. [Accès le 13 4 2026].

[62] «mljourney,» [En ligne]. Available: https://mljourney.com/resnet-vs-mobilenet-vs-efficientnet-dive-into-cnn-architectures/. [Accès le 20 12 2026].

[63] «LIGHTLY.AI,» [En ligne]. Available: https://www.lightly.ai/blog/train-test-validation-split. [Accès le 7 3 2026].

[64] «vimberia,» 7 3 2025. [En ligne]. Available: https://www.vimberia.com/2025/03/07/pretraitement-des-images/. [Accès le 10 3 2026].

[65] «towardsdatascience,» 26 10 2022. [En ligne]. Available: https://towardsdatascience.com/image-data-augmentation-for-deep-learning-77a87fabd2bf/. [Accès le 10 3 2026].

[66] «flyriver,» [En ligne]. Available: https://www.flyriver.com/g/mobilenet-v1-v2-v3. [Accès le 6 3 2026].

[67] «ibm,» [En ligne]. Available: https://www.ibm.com/fr-fr/think/topics/hyperparameter-tuning. [Accès le 4 3 2026].

[68] Demonkingaeron, 27 10 2025. [En ligne]. Available: https://fr.scribd.com/document/938859828/Performance-Metrics-in-Machine-Learning?_gl=1*1s9u05w*_gcl_au*MTYzMTk5ODk5Ny4xNzc0NjUxODk4&v=0.325. [Accès le 16 4 2026].

[69] «Ai Cheat Sheet,» [En ligne]. Available: https://ai.nuhil.net/statistics/f1-score-f-measure. [Accès le 05 05 2026].

[70] P. Kashyap, 2 12 2024. [En ligne]. Available: https://medium.com/@piyushkashyap045/understanding-precision-recall-and-f1-score-metrics-ea219b908093. [Accès le 11 4 2026].

[71] «geeksforgeeks,» [En ligne]. Available: https://www.geeksforgeeks.org/machine-learning/random-forest-algorithm-in-machine-learning/. [Accès le 10 3 2026].

[72] «geeksforgeeks,» [En ligne]. Available: https://www.geeksforgeeks.org/machine-learning/random-forest-hyperparameter-tuning-in-python/. [Accès le 4 4 2026].

[73] «geeksforgeeks,» [En ligne]. Available: https://www.geeksforgeeks.org/machine-learning/what-is-feature-extraction/. [Accès le 11 5 2026].

[74] A. MAZRAEH, 6 3 2025. [En ligne]. Available: https://medium.com/@adnan.mazraeh1993/data-augmentation-from-basics-to-advanced-concepts-179963c25a9a. [Accès le 25 4 2026].

[75] «geeksforgeeks,» [En ligne]. Available: https://www.geeksforgeeks.org/random-forest-classifier-using-scikit-learn/. [Accès le 11 4 2026].

[76] «scikit-learn,» [En ligne]. Available: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.hamming_loss.html. [Accès le 10 4 2026].

[77] V. AV, 8 10 2024. [En ligne]. Available: https://medium.com/@varunaven3/generalization-and-complexity-763c49851a31. [Accès le 15 5 2026].

[78] [En ligne]. Available: https://industrial-ovens.net/baking-ovens/.

[79] aboudjenane, «École Supérieure des Sciences de l'Aliment et des Industries Agroalimentaires,» 07 11 2025. [En ligne]. Available: https://fr.scribd.com/presentation/956818402/Cours-4-Les-Principaux-Defauts-de-Qualite-Des-Pates-Et-Confiseries. [Accès le 10 3 2026].

[80] adnan, 3 2025. [En ligne]. Available: https://fr.scribd.com/document/960310211/4#google_vignette. [Accès le 5 5 2026].

[81] «mathworks,» [En ligne]. Available: https://fr.mathworks.com/discovery/supervised-learning.html. [Accès le 10 2 2026].

[82] «koulibalyhamam,» 13 5 2025. [En ligne]. Available: https://fr.scribd.com/document/838732601/00-Support-de-Cours-DL-Transfert-LEarning1?v=0.481. [Accès le 10 4 2026].

[83] «demonkingaeron,» 27 10 2025. [En ligne]. Available: https://fr.scribd.com/document/938859828/Performance-Metrics-in-Machine-Learning?_gl=1*1s9u05w*_gcl_au*MTYzMTk5ODk5Ny4xNzc0NjUxODk4&v=0.325. [Accès le 16 4 2026].

[84] 4 12 2024. [En ligne]. Available: https://medium.com/@piyushkashyap045/understanding-precision-recall-and-f1-score-metrics-ea219b908093. [Accès le 10 3 2026].

[85] V. AV, 8 10 2024. [En ligne]. Available: https://medium.com/@varunaven3/generalization-and-complexity-763c49851a31. [Accès le 6 5 2026].

[86] «Highland Blenders, Agitators & Mixers,» Highland Equipment Inc., [En ligne]. Available: https://www.highlandequip.com/products/blenders-agitators-mixers/. [Accès le 16 03 2026].

[87] Adnan, 3 2025. [En ligne]. Available: https://fr.scribd.com/document/960310211/4#google_vignette. [Accès le 5 5 2026].

[88] P. Kashyap, 4 12 2024. [En ligne]. Available: https://ai.nuhil.net/statistics/f1-score-f-measure. [Accès le 10 3 2026].

Annexe A

Présentation des outils utilisés

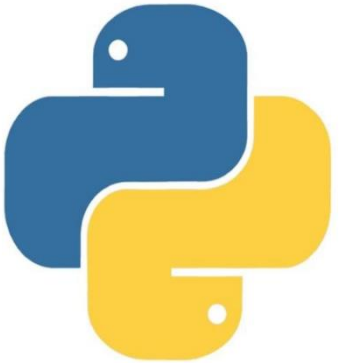
Google Colab

Google Colab est une plateforme en ligne qui permet d'exécuter du code Python directement depuis un navigateur web, sans installation particulière. Grâce à l'accès à des ressources de calcul performantes, notamment les GPU, il a été utilisé dans ce projet pour entraîner et tester les modèles de contrôle qualité chargés de déterminer la conformité des produits et d'identifier les causes de non-conformité.



Python

Python est un langage de programmation très utilisé dans les domaines de l'analyse de données et de l'intelligence artificielle. Dans ce projet, il a servi à préparer les données, développer les différents modèles, analyser les résultats obtenus et réaliser les traitements nécessaires au fonctionnement de l'application.



TensorFlow

TensorFlow est une bibliothèque open source dédiée au développement de modèles d'apprentissage profond. Dans ce projet, elle a été utilisée pour mettre en œuvre et entraîner le modèle MobileNetV2 destiné à la classification des produits.



NumPy



NumPy est une bibliothèque Python spécialisée dans le calcul numérique et la manipulation de données sous forme de tableaux. Elle a été utilisée pour effectuer les traitements mathématiques et les opérations nécessaires à la préparation des données avant leur exploitation par les modèles.

Scikit-learn



Scikit-learn est une bibliothèque d'apprentissage automatique proposant de nombreux algorithmes et outils d'évaluation. Dans ce projet, elle a été utilisée pour créer le modèle Random Forest et mesurer les résultats obtenus à l'aide de différents indicateurs de performance.

Seaborn



Seaborn est une bibliothèque de visualisation de données construite sur Matplotlib. Elle permet de produire des graphiques clairs et faciles à interpréter. Dans ce projet, elle a été utilisée pour représenter les matrices de confusion et faciliter l'analyse des résultats de classification.

OpenCV

OpenCV est une bibliothèque dédiée au traitement d'images et à la vision par ordinateur. Dans ce projet, elle a été utilisée pour récupérer les images capturées par la caméra et effectuer les traitements nécessaires avant leur analyse par les modèles de contrôle qualité.



Arduino IDE

Arduino IDE est l'environnement de développement utilisé pour programmer les cartes Arduino. Dans ce projet, il a servi à développer le programme du système de détection des germes et à assurer la communication entre les différents composants électroniques du circuit.



C++ embarqué :

C++ embarqué est une version du langage C++ utilisée pour programmer des systèmes électroniques et des microcontrôleurs, où les ressources matérielles sont limitées et où le temps de réponse est important. Dans ce projet, il a servi à programmer le système de détection des germes, en assurant le traitement des signaux des capteurs et la gestion du fonctionnement du circuit en temps réel.



LiquidCrystal

LiquidCrystal est une bibliothèque permettant de contrôler un écran LCD à partir d'une carte Arduino. Elle a été utilisée dans ce projet pour afficher les résultats de détection des germes ainsi que les messages relatifs à l'état du système.

TIA Portal

TIA Portal est l'environnement de développement de Siemens dédié à l'automatisation industrielle. Dans ce projet, il a été utilisé pour programmer la logique de commande de la ligne de production, concevoir les interfaces homme-machine (IHM), mettre en place la supervision SCADA et réaliser la simulation du procédé de fabrication des madeleines conformément au cahier des charges.

Proteus

Proteus est un logiciel de simulation de circuits électroniques utilisé pour concevoir et tester des systèmes embarqués avant leur réalisation matérielle.
Dans ce projet, il a servi à simuler le circuit de détection des germes basé sur Arduino.

Annexe B

Programmation et supervision sous TIA Portal

Cette annexe présente les principales réalisations effectuées sous TIA Portal. Elle regroupe les éléments essentiels du développement, notamment la configuration du PLC, les blocs fonctionnels, les interfaces IHM et la supervision SCADA.

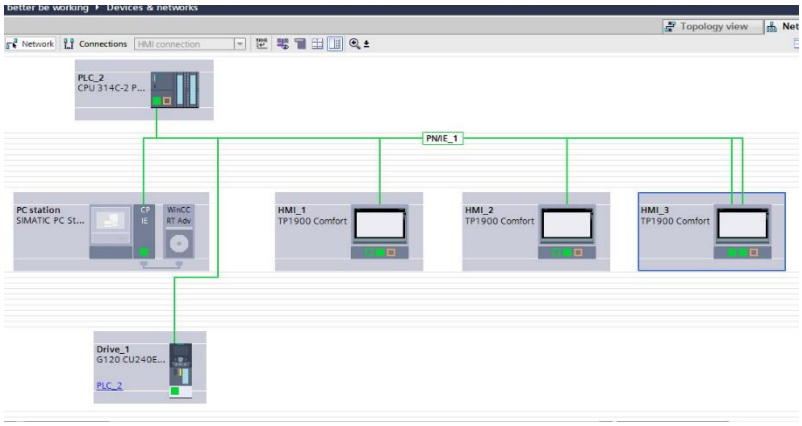


Figure B.1. Configuration de CPU S7-314-2 PN/DP de stations 1 à 3

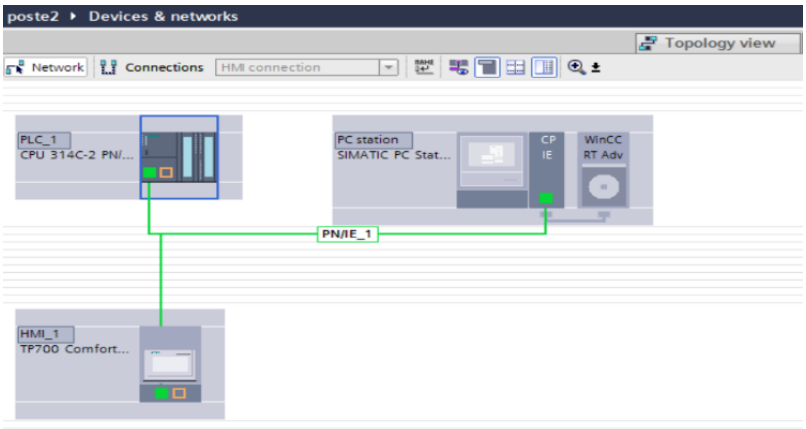


Figure B.2. Configuration de CPU S7-314-2 PN/DP de station 4 à 6

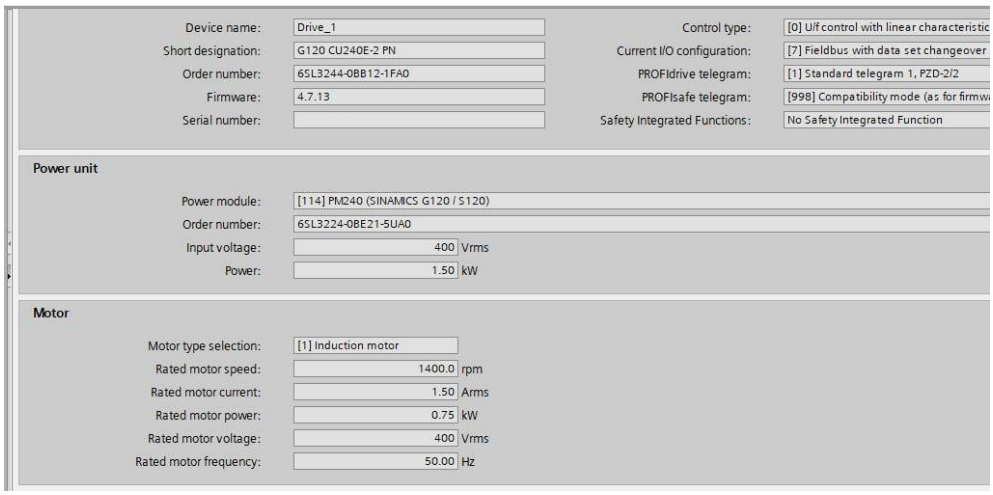


Figure B.3. Configuration de SINAMICS G120 CU240E PN/PN

Data_block_1

	Name	Data type	Offset	Start value	Retain	Visible in ...
1	Static					
2	alarme extracteur	Bool	0.0	false	☑	☑
3	alarme ventilateur de ...	Bool	0.1	false	☑	☑
4	alarme chemenie	Bool	0.2	false	☑	☑
5	alarme pression	Bool	0.3	false	☑	☑
6	alarme detecteur gaz	Bool	0.4	false	☑	☑
7	alarme convoyeur de ...	Bool	0.5	false	☑	☑
8	alarme convoyeur de ...	Bool	0.6	false	☑	☑
9	alarme ventillateur de ...	Bool	0.7	false	☑	☑
10	alarme conv machine ...	Bool	1.0	false	☑	☑
11	alarme moteur de cou...	Bool	1.1	false	☑	☑
12	alarme temp de zone 1	Bool	1.2	false	☑	☑
13	alarme temp de zone 2	Bool	1.3	false	☑	☑
14	alarme temp5	Bool	1.4	false	☑	☑
15	alarme temp6	Bool	1.5	false	☑	☑
16	alarme temp7	Bool	1.6	false	☑	☑
17	alarme lenght	Bool	1.7	false	☑	☑
18	alarme speed	Bool	2.0	false	☑	☑
19	marche1	Bool	2.1	false	☑	☑
20	arret1	Bool	2.2	false	☑	☑
21	arret urgence 1	Bool	2.3	false	☑	☑
22	marche2	Bool	2.4	false	☑	☑
23	arret2	Bool	2.5	false	☑	☑
24	arret urgence 2	Bool	2.6	false	☑	☑
25	reset0	Bool	2.7	false	☑	☑
26	relai th 1	Bool	3.0	false	☑	☑
27	relai th2	Bool	3.1	false	☑	☑
28	relai th3	Bool	3.2	false	☑	☑
29	relai th4	Bool	3.3	false	☑	☑

Figure B.4. Les entrées et sorties de stations 4 à 6

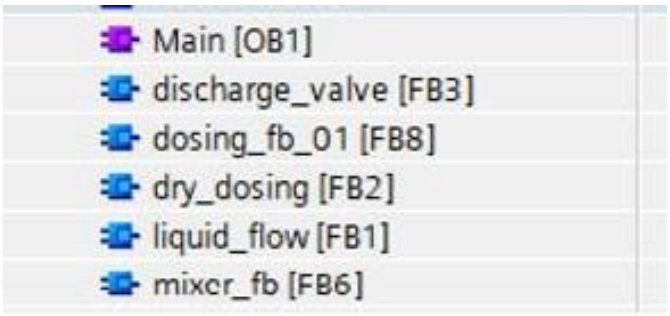


Figure B.5. Les fonctions block de station 1 à 3

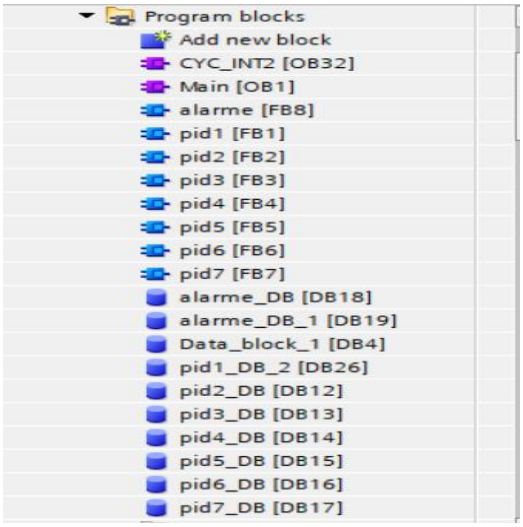


Figure B.6. Les fonctions block de station 4 à 6

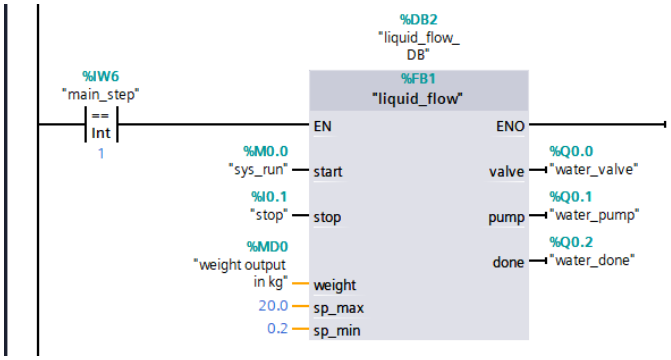


Figure B.7. Bloc fonctionnel de dosage des ingrédients liquides.

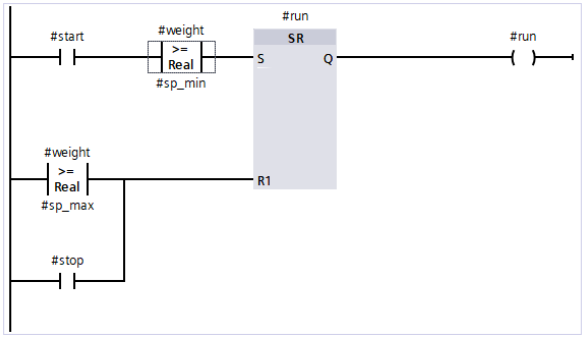


Figure B.8. Bloc SR de commande du démarrage du dosage liquide

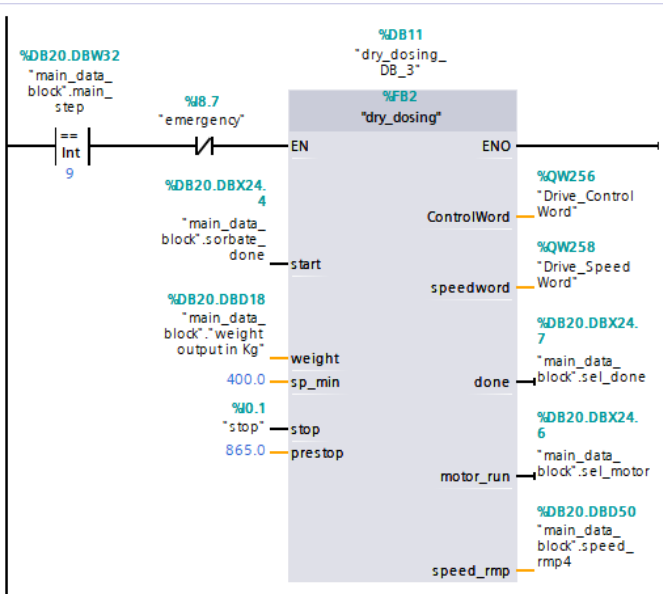


Figure B.9. Bloc fonctionnel de dosage des ingrédients solides.

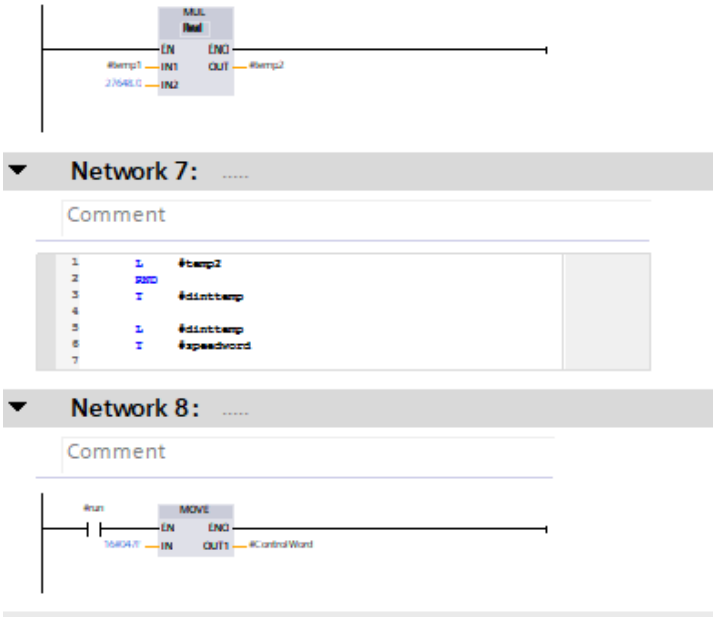


Figure B.10. Commande de VFD pour les moteurs de dosage.

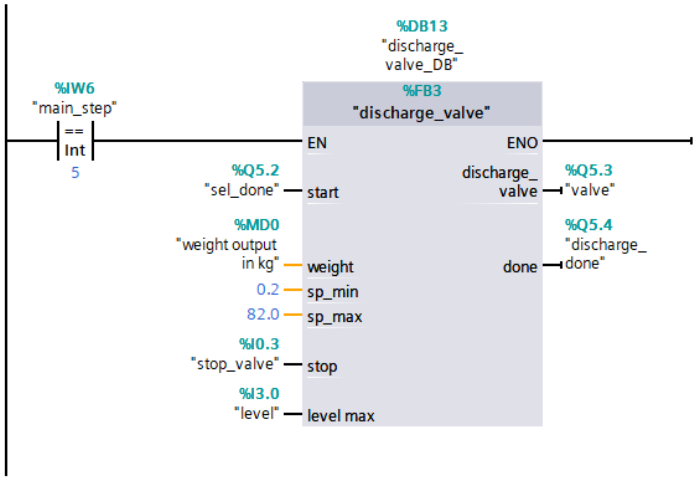


Figure B.12. Bloc fonctionnel de commande de la vanne de décharge.

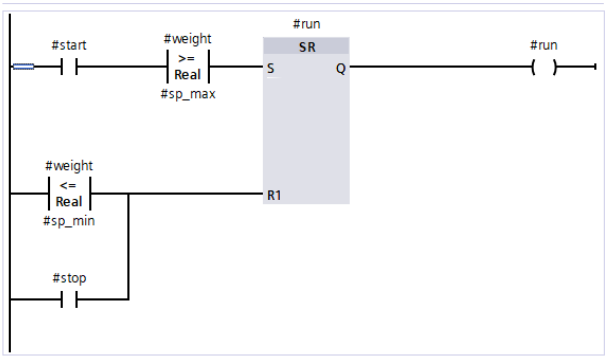


Figure B.12. Bloc SR de commande du démarrage de la vanne de décharge

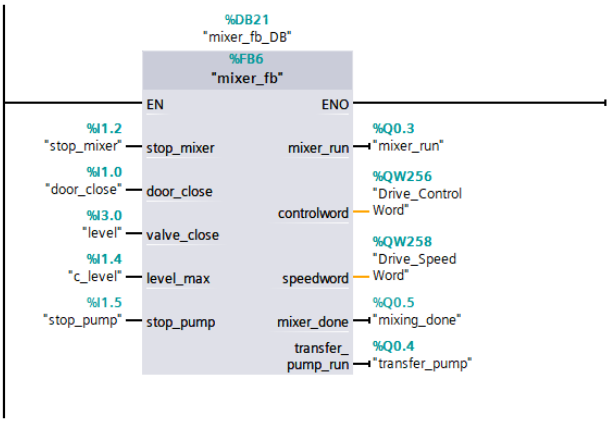


Figure B.13. Bloc fonctionnel de commande du mélangeur

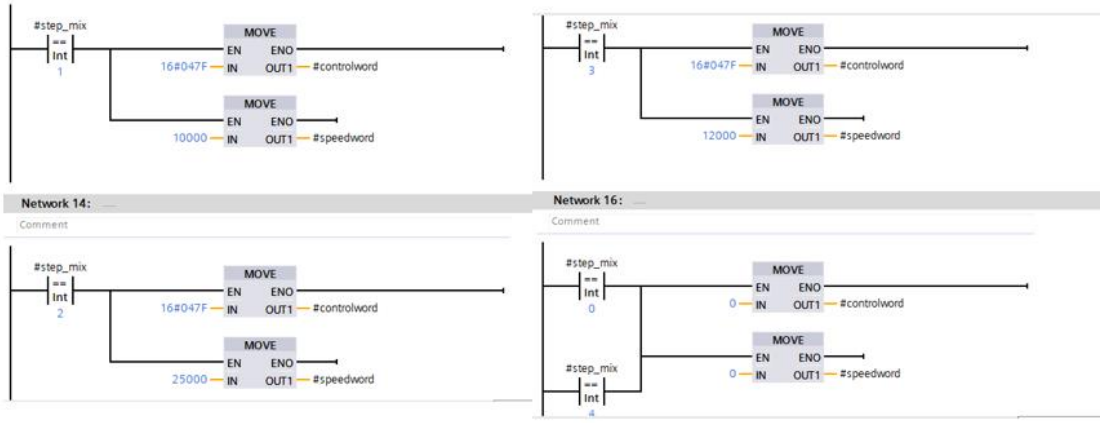


Figure B.15. Commande du moteur de mélange via variateur de vitesse (VFD)

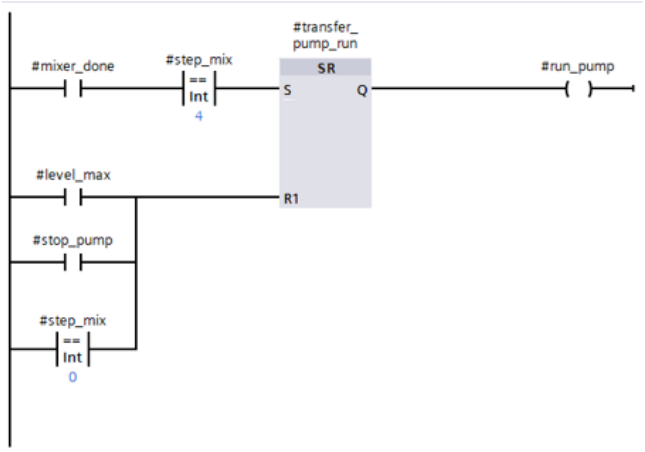


Figure B.15. Bloc SR de commande du démarrage du pompe de transférer

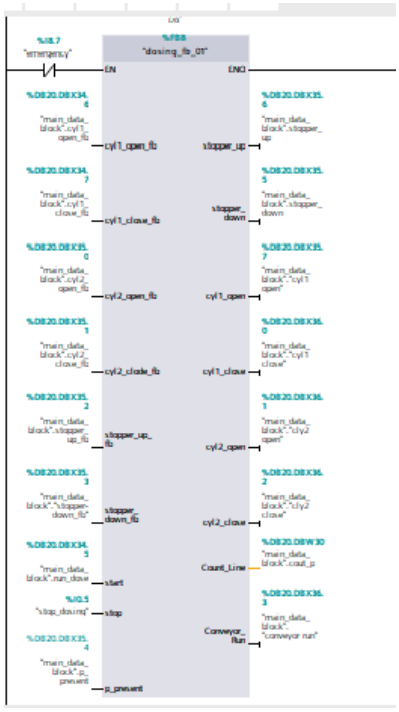


Figure B.16. Bloc fonctionnel de commande du remplissage

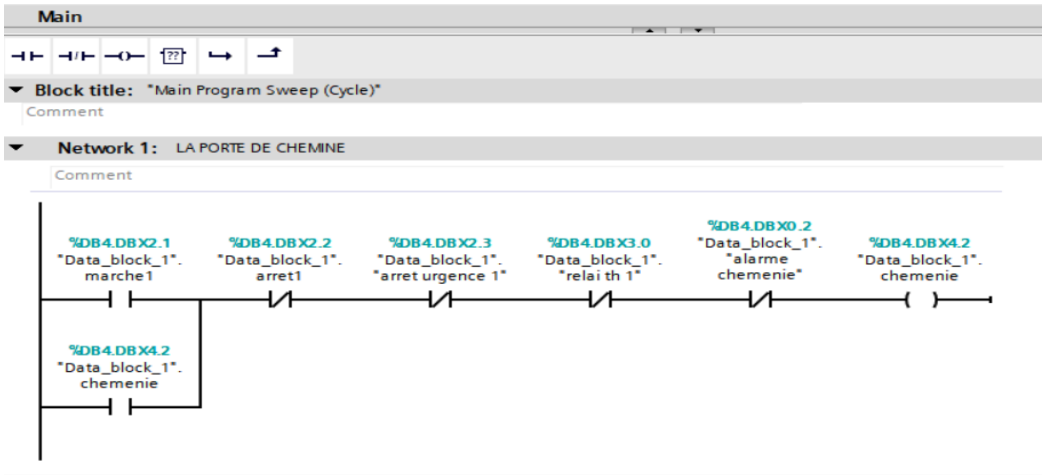


Figure B.17. Commande de la porte de cheminée

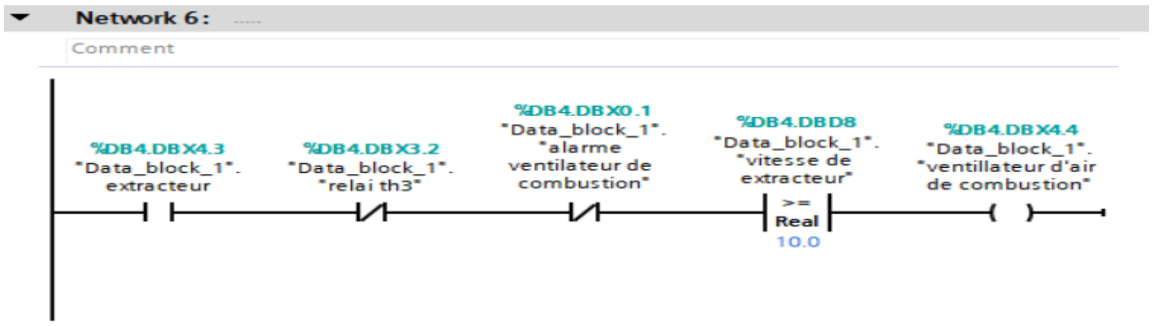


Figure B.18. Commande du ventilateur d'air de combustion

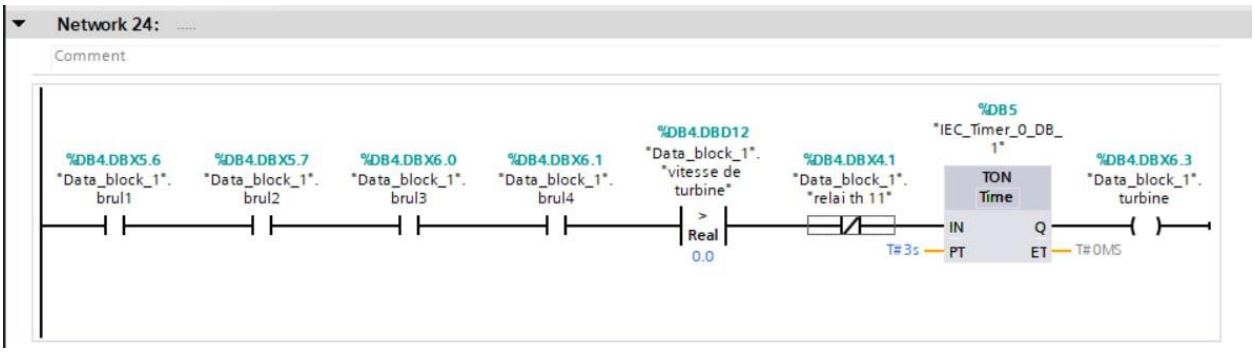


Figure B.19. Temporisation de démarrage de la turbine

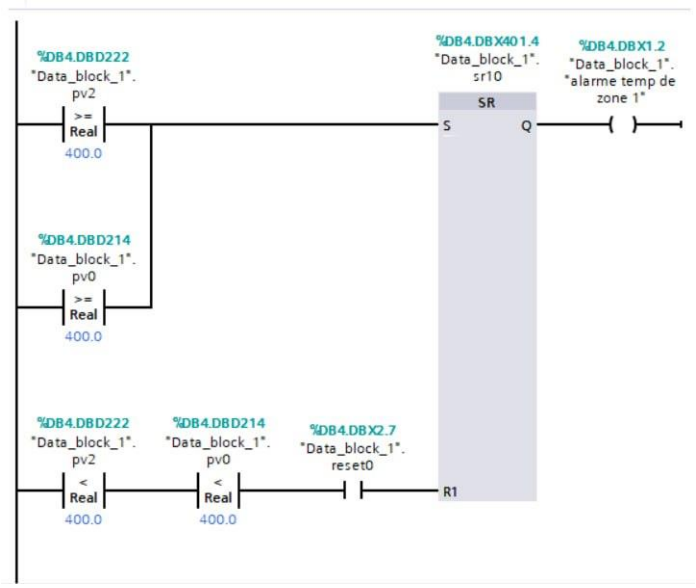


Figure B.20. Alarme de température de la zone 1

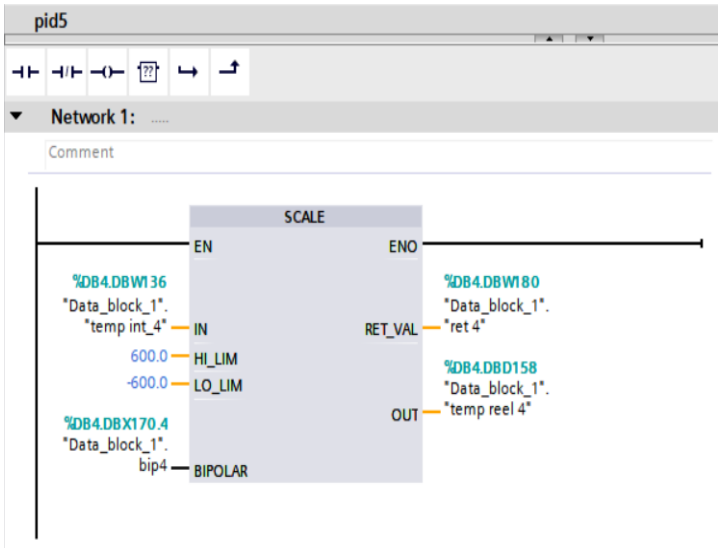


Figure B.21. Mise à l'échelle du signal de température

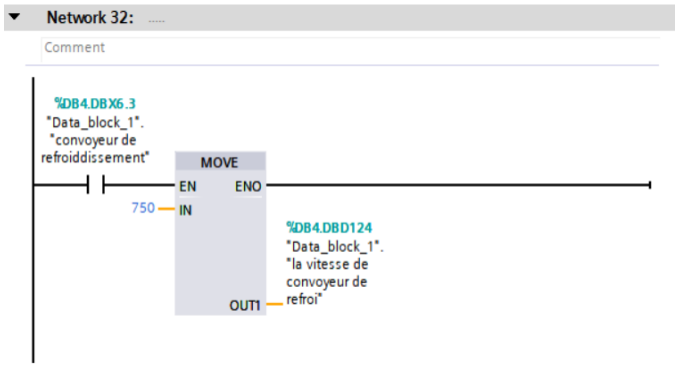


Figure B.22. Transfert de la vitesse du convoyeur de refroidissement

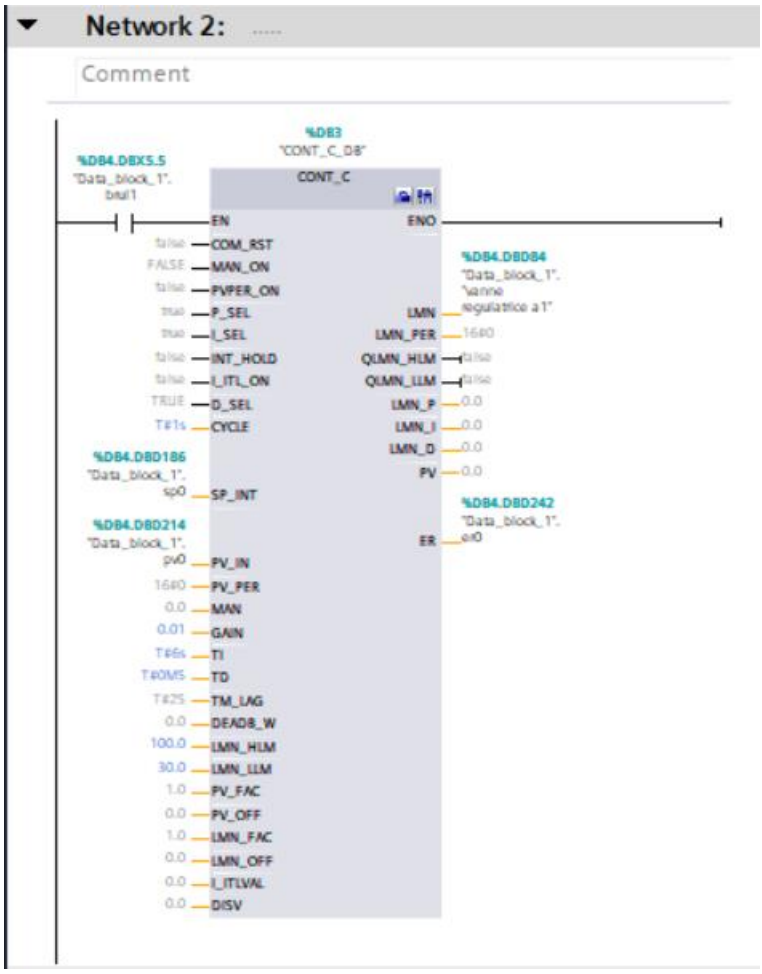


Figure B.23. PID de température

HMI :

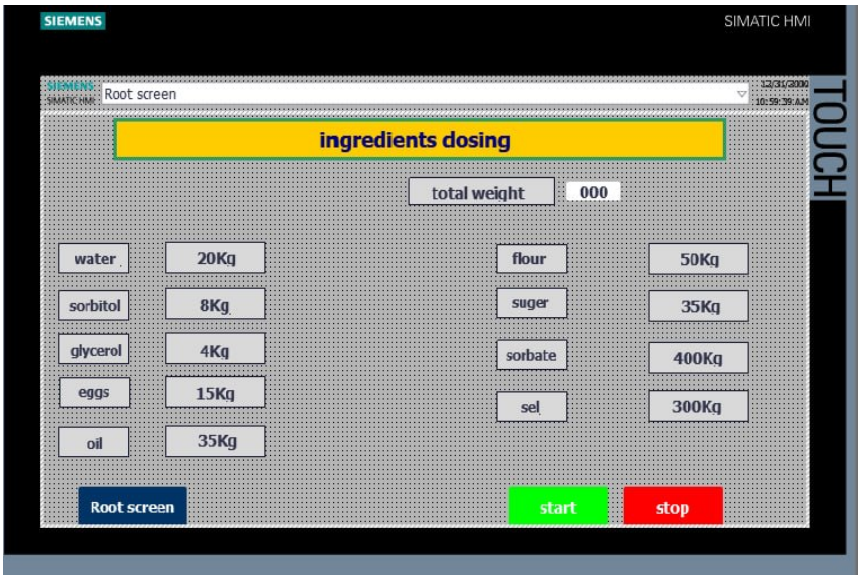


Figure B.24. Interface HMI pour les consignes des ingrédients.

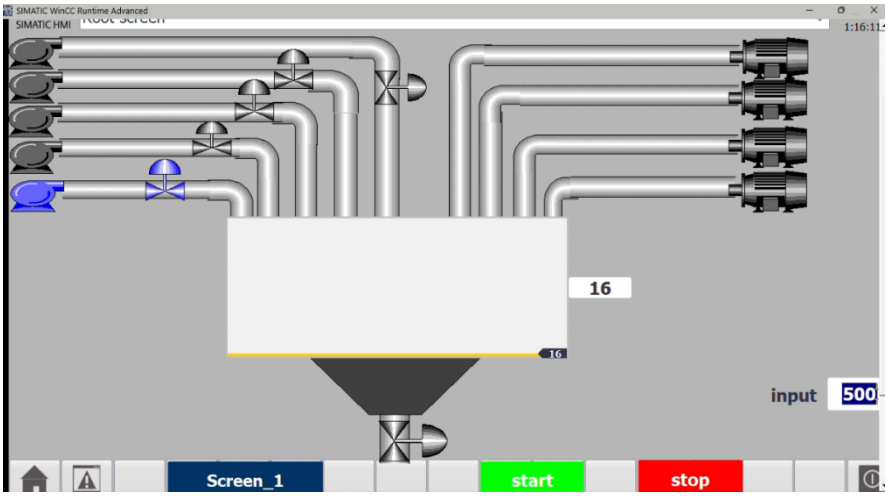


Figure B.25. Interface HMI pour station de dosage.

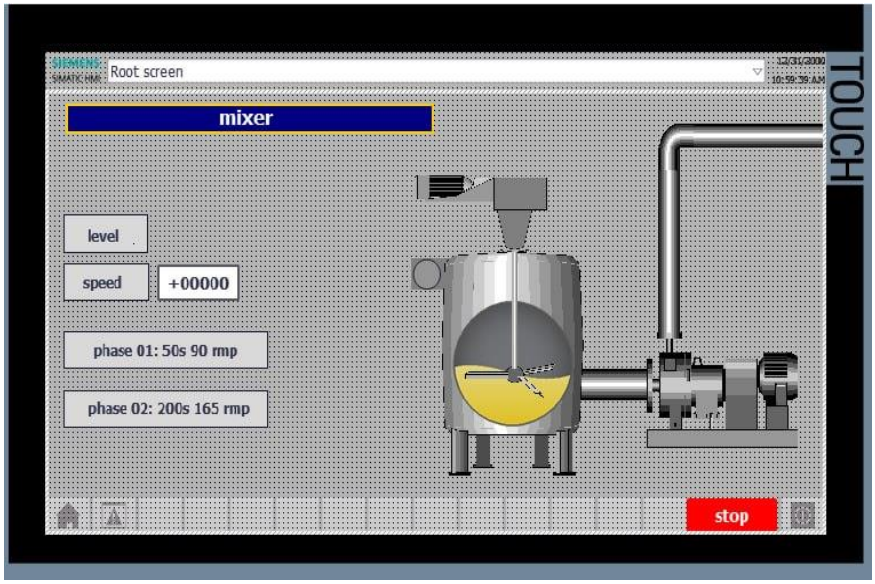


Figure B.26. Interface HMI pour station de mélange

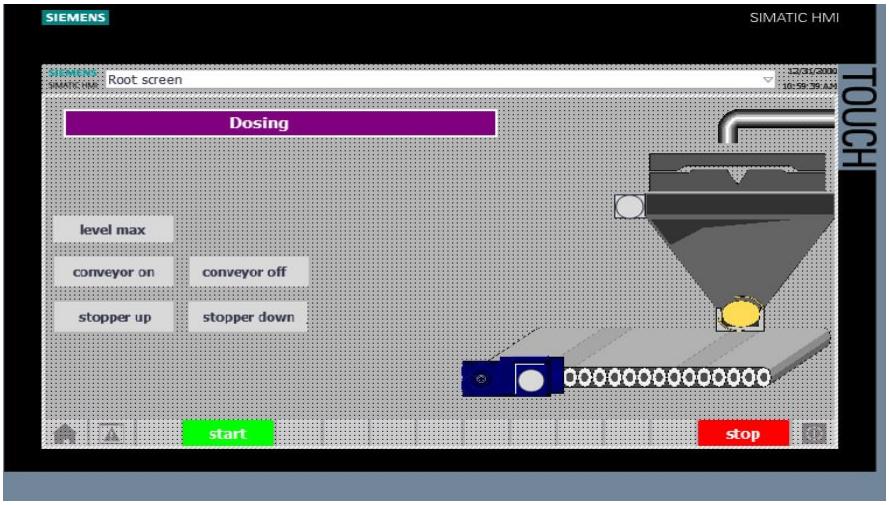


Figure B.27. Interface HMI pour station de remplissage

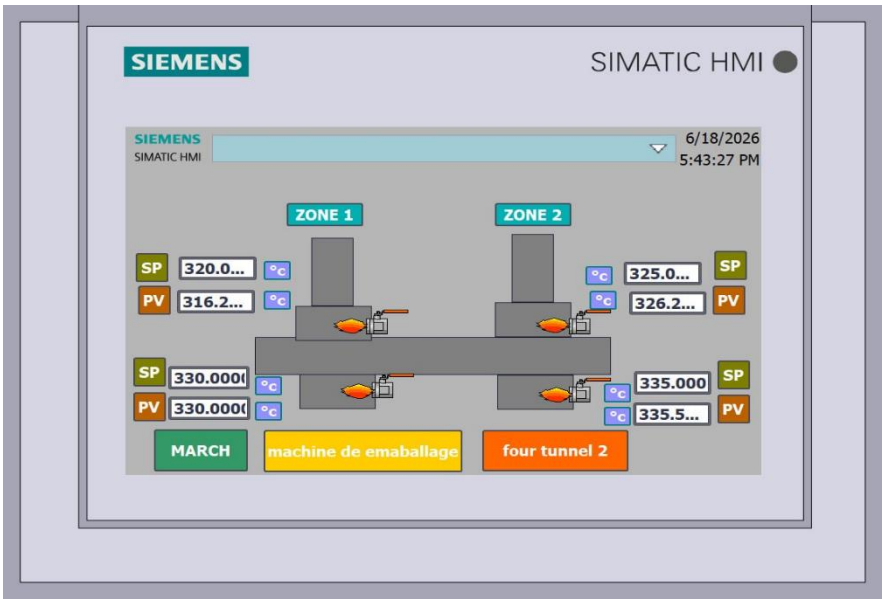


Figure B.28. La première interface IHM pour la station de cuisson

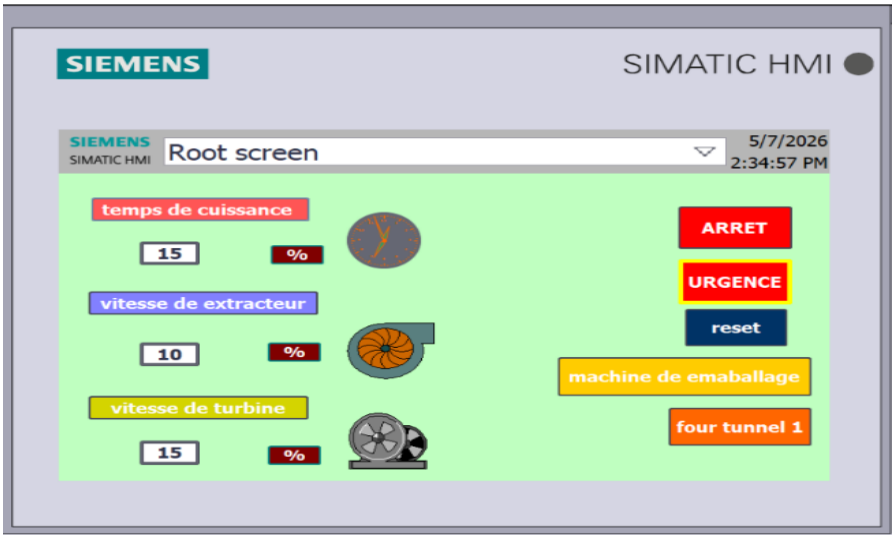


Figure B.29. La deuxième interface IHM pour la station de cuisson

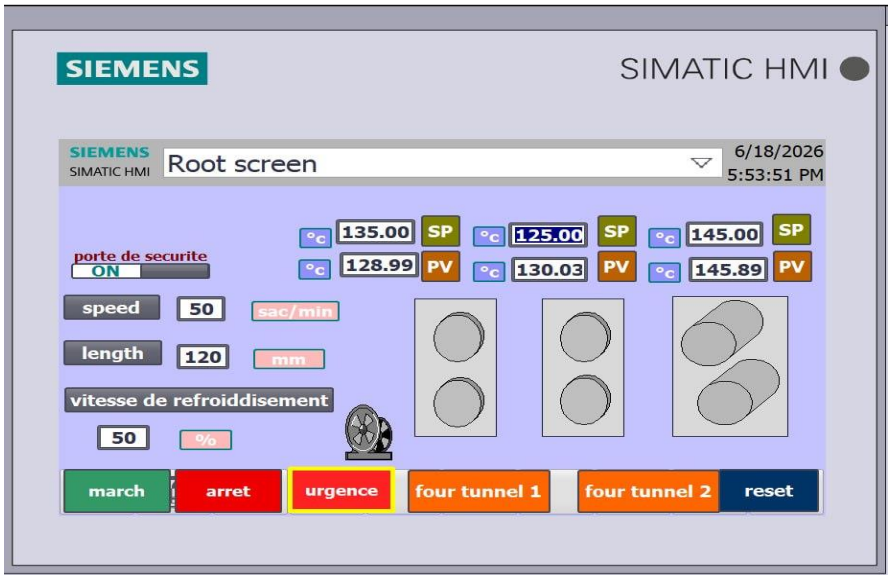


Figure.B.30. Interface IHM pour les stations de refroidissement et d'emballage

- Supervision du procédé par le système SCADA :

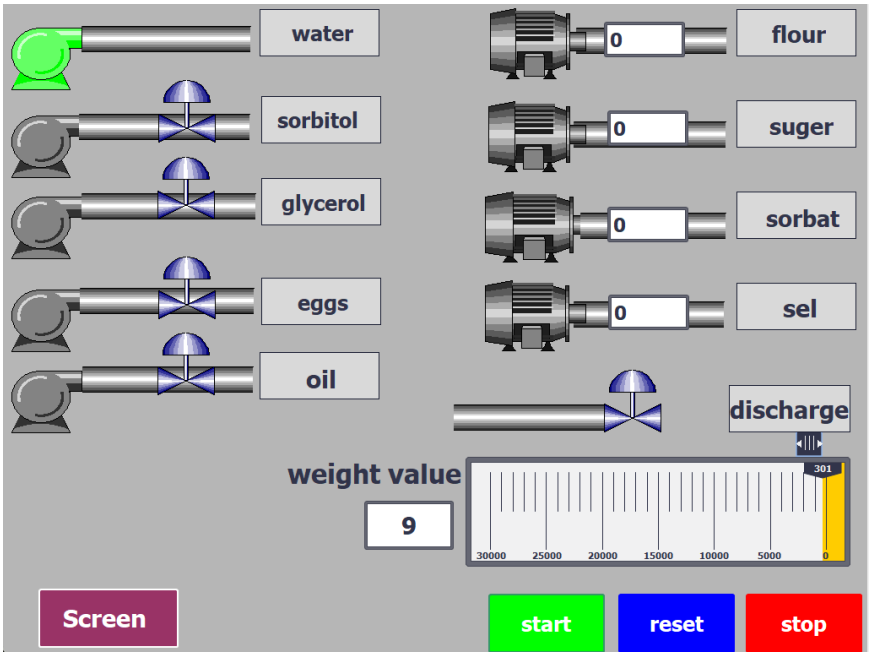


Figure B.31. SCADA de station 1

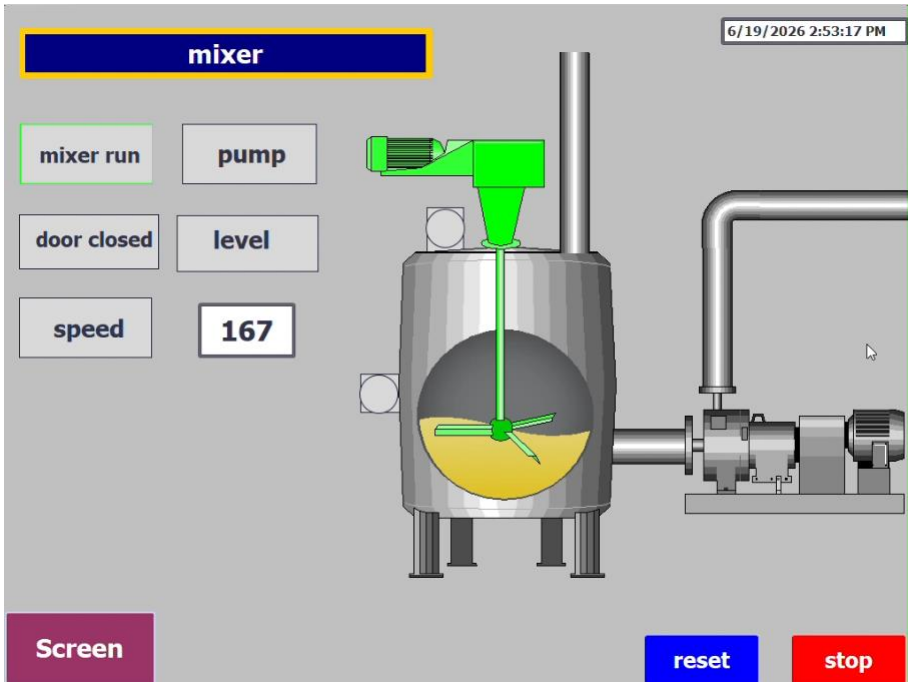


Figure B.32.SCADA de station 2.

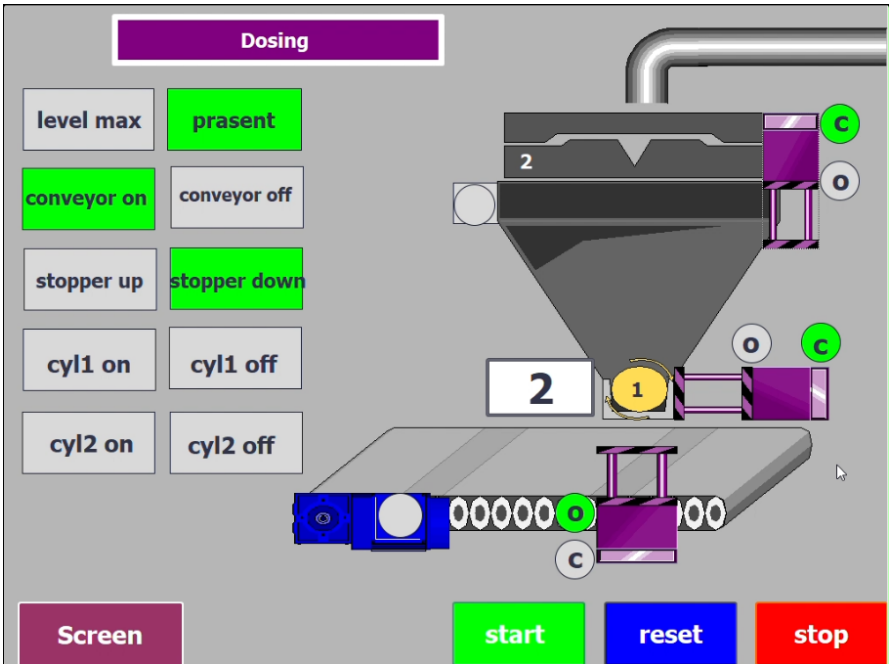


Figure B.33. SCADA de station 3

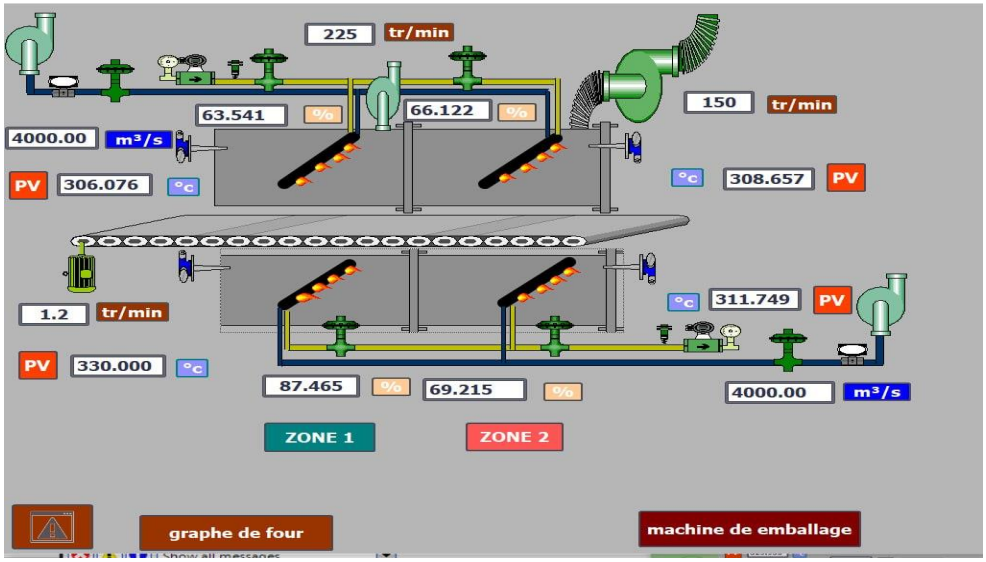


Figure B.34. SCADA de station 4

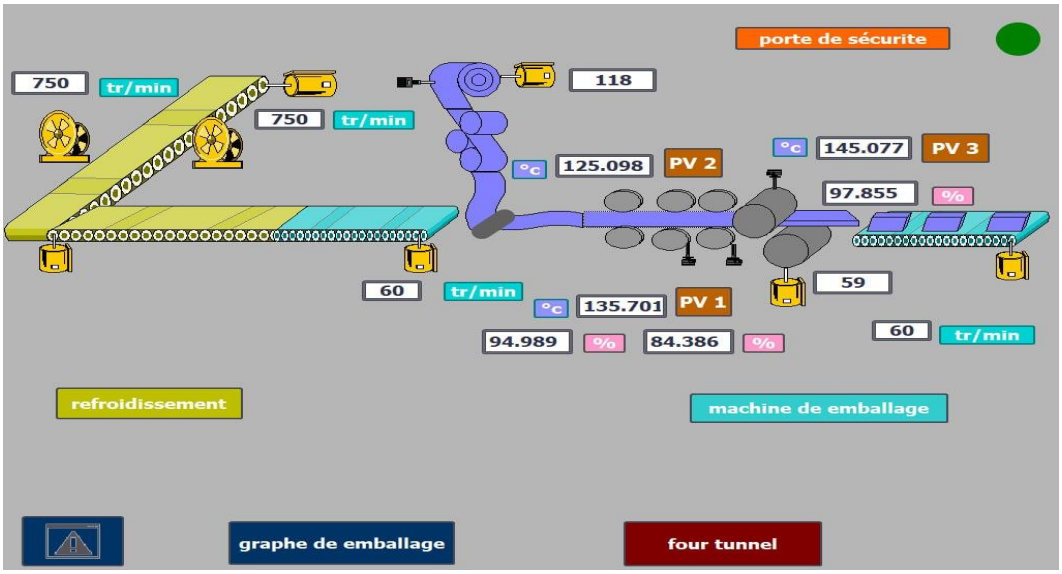


Figure B.35. SACDA de station 5 et 6



Figure B.36. Tableau d'alarme

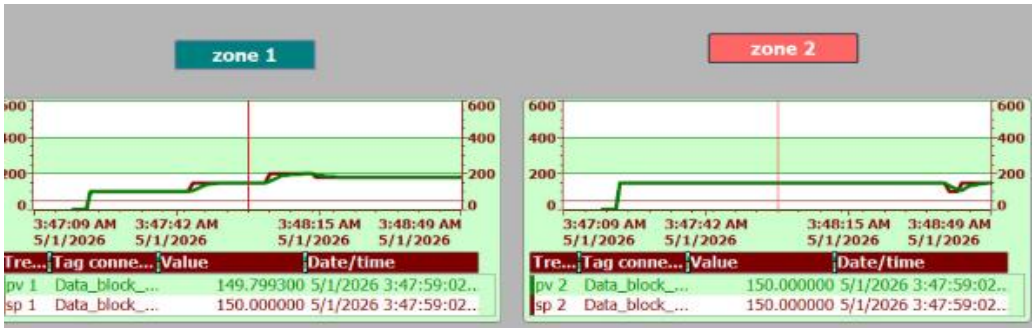


Figure B.37. Les courbes du PID de la station 4 (partie supérieure) représentent le SP et le PV