



**HAL**  
open science

# Détection des ruptures de la chaîne du froid par une approche d'apprentissage automatique

Julie Loisel

► **To cite this version:**

Julie Loisel. Détection des ruptures de la chaîne du froid par une approche d'apprentissage automatique. Autre [q-bio.OT]. Université Paris-Saclay, 2023. Français. NNT : 2023UPASB014 . tel-04103865

**HAL Id: tel-04103865**

**<https://pastel.hal.science/tel-04103865v1>**

Submitted on 23 May 2023

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

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

# Détection des ruptures de la chaîne du froid par une approche d'apprentissage automatique

*Detection of Cold Chain Breaks Using a Machine Learning Approach*

## Thèse de doctorat de l'université Paris-Saclay

École doctorale n° 581 : Agriculture, Biologie, Environnement et Santé (ABIES)

Spécialité de doctorat : Mathématiques appliquées

Graduate School : Biosphera. Référent : AgroParisTech

Thèse préparée dans les unités de recherche **MIA** (Université Paris-Saclay, AgroParisTech, INRAE) et **FRISE** (Université Paris-Saclay, INRAE), sous la direction d'**Antoine CORNUÉJOLS**, Professeur, la co-direction d'**Onrawee LAGUERRE**, Directrice de Recherche, le co-encadrement de **Steven DURET**, Chargé de Recherche

Thèse soutenue à Paris-Saclay, le 04 avril 2023, par

**Julie LOISEL**

## Composition du Jury

Membres du jury avec voix délibérative

<b>Jocelyn BONJOUR</b> Professeur, INSA Lyon	Président
<b>Philippe BOHUON</b> Professeur, L'Institut Agro Montpellier	Rapporteur & Examineur
<b>Thomas GUYET</b> Chargé de Recherche (HDR), INRIA (centre de Lyon)	Rapporteur & Examineur
<b>Ahlame DOUZAL</b> Maîtresse de Conférences, Université Grenoble-Alpes	Examinatrice
<b>Olivier DUCHESNE DE LAMOTTE</b> CEO, Biotraq	Invité

**Titre :** Détection des ruptures de la chaîne du froid par une approche d'apprentissage automatique

**Mots clés :** chaîne du froid, rupture, apprentissage automatique, température, qualité des produits

**Résumé :** La chaîne du froid est indispensable pour assurer la sécurité sanitaire et éviter le gaspillage alimentaire. Pour suivre l'évolution de la température de l'air à travers la chaîne du froid, les capteurs sans fil sont de plus en plus utilisés, mais l'exploitation de ces mesures est encore limitée. Cette thèse explore comment l'apprentissage automatique peut être utilisé pour prédire la température de différents types de produits alimentaires à partir d'une mesure de la température de l'air dans une palette et détecter les ruptures de chaîne du froid. Nous avons d'abord introduit une définition de rupture de la chaîne du froid en fonction de deux grandes catégories de produits : les produits qui doivent être conservés à une température réglementée tels que les viandes et les poissons et les produits pour lesquels une température de conservation est recommandée tels que les fruits et légumes. Pour les premiers, les ruptures de la chaîne du froid peuvent entraîner une intoxication alimentaire et pour les seconds, elles peuvent dégrader les qualités organoleptiques. Pour les produits à température réglementée, il est crucial de prédire la température des produits afin d'assurer qu'ils ne dépassent pas le seuil réglementaire. Bien que plusieurs études aient déjà démontré l'efficacité des réseaux de neurones pour la pré-

diction de la température des produits, aucune n'a comparé les données synthétiques et expérimentales pour les entraîner. Dans cette thèse, nous avons proposé de comparer ces deux types de données afin de fournir des directives précises pour le développement de réseaux de neurones. En pratique, les produits et les emballages sont très variés, il est donc impossible de faire des expériences pour chaque application en raison de la lourdeur de la mise en œuvre. En comparant les données synthétiques et expérimentales, nous avons pu déterminer les meilleures lignes directrices pour développer des réseaux de neurones pour prédire la température des produits et maintenir la chaîne du froid. Pour les produits dont la température est réglementaire, une fois la rupture détectée, ils ne sont plus consommables et doivent être éliminés. Pour les produits dont la température est recommandée, nous avons comparé trois approches différentes pour détecter les ruptures et mettre en place une action correctrice : a) méthode basée sur un seuil de température, b) méthode basée sur un classifieur qui détermine si le produit sera livré avec les qualités attendues et c) méthode également basée un classifieur mais qui intègre le coût de l'action correctrice dans la prise de décision. Les performances des trois méthodes sont discutées et des perspectives d'amélioration sont proposées.

**Title :** Detection of Cold Chain Breaks Using a Machine Learning Approach

**Keywords :** cold chain, breaks, machine learning, temperature, food quality

**Abstract :** The cold chain is essential to ensure food safety and avoid food waste. Wireless sensors are increasingly used to monitor the air temperature through the cold chain, however, the exploitation of these measurements is still limited. This thesis explores how machine learning can be used to predict the temperature of different food products types from the measured air temperature in a pallet and detect cold chain breaks. We introduced, firstly, a definition of a cold chain break based on two main product categories : products obligatorily preserved at a regulated temperature such as meat and fish, and products for which a temperature is recommended such as fruits and vegetables. The cold chain break leads to food poisoning for the first product category and organoleptic quality degradation for the second one. For temperature-regulated products, it is crucial to predict the product temperature to ensure that it does not exceed the regulatory temperature. Although several studies demonstrated the effectiveness of neural networks for the prediction, none has compared the synthetic and experimental

data to train them. In this thesis, we proposed to compare these two types of data in order to provide guidelines for the development of neural networks. In practice, the products and packaging are diverse ; experiments for each application are impossible due to the complexity of implementation. By comparing synthetic and experimental data, we were able to determine best practices for developing neural networks to predict product temperature and maintain cold chain. For temperature-regulated products, once the cold chain break is detected, they are no more consumable and must be eliminated. For temperature-recommended products, we compared three different approaches to detect cold chain breaks and implement corrective actions : a) method based on a temperature threshold, b) method based on a classifier which determines whether the products will be delivered with the expected qualities, and c) method also based on a classifier but which integrates the cost of the corrective measure in the decision-making process. The performances of the three methods are discussed and prospects for improvement are proposed.

# Remerciements

Je tiens tout d'abord à remercier mon directeur de thèse, Antoine Cornuéjols, pour sa confiance et son soutien tout au long de ce projet. Je lui suis également reconnaissante pour ses précieux conseils.

Je remercie également ma directrice de thèse, Onrawee Laguerre, pour son soutien et sa motivation tout au long de ces années de recherche. Sa patience, son encouragement et son organisation ont été précieux pour moi et m'ont permis de mener à bien ce travail.

Mon plus grand merci s'adresse à mon encadrant Steven Duret, qui m'a partagé pendant trois ans ses connaissances, toujours avec passion et pédagogie. Merci de m'avoir guidée et soutenue en me laissant explorer mes propres idées, je souhaite à tous les doctorants d'avoir un encadrant aussi passionné et impliqué que toi.

Je remercie les membres du jury d'avoir accepté d'évaluer mon travail. Leurs suggestions et remarques ont été précieuses pour améliorer ce mémoire et pour préciser les perspectives de nos travaux. Je remercie vivement Monsieur Thomas Guyet et Monsieur Philippe Bohuon, qui ont assuré la fonction de rapporteurs en apportant une analyse détaillée du manuscrit. Je remercie également le président du jury Monsieur Jocelyn Bonjour, et Madame Ahlame Douzal qui a examiné ce travail.

Un grand merci à l'unité FRISE pour leur accueil et leur soutien. Je tiens à remercier Dihia pour son soutien quotidien et sa bienveillance. Les trajets passés en sa compagnie et les déjeuners partagés m'ont permis de trouver de la motivation grâce à son positivisme et sa volonté de m'aider. Je suis reconnaissante pour le soutien qu'elle m'a apporté. Je remercie également Yasmine pour sa motivation pendant la rédaction de ma thèse et

les pauses thé que nous avons partagées. Jules et Nada, merci à vous deux avec qui j'ai partagé mes bureaux et pour votre bonne humeur pendant ces années.

Je tiens à remercier chaleureusement mes parents qui m'ont soutenue depuis toujours et encore plus depuis trois ans. Chaque séjour chez eux a été une source de réconfort, de chaleur et de bonheur. Je suis particulièrement reconnaissante pour leurs appels et leurs messages qui m'ont rappelé chaque jour que je pouvais compter sur leur présence et leur soutien.

Je tiens à remercier chaleureusement ma sœur Mélanie pour son soutien, ses conseils et nos moments de détente partagés à la campagne. Je remercie également mon frère jumeau Adrien pour son soutien constant et ses encouragements tout au long de mon parcours de doctorat.

Je remercie ma chère amie Gabrielle pour son soutien sans faille. Merci pour tes appels de motivation, tes mots de réconfort, nos dîners et nos promenades dans Paris. Je te suis reconnaissante pour ta bonne humeur et ta positivité contagieuse qui m'ont aidée ces dernières années.

Enfin, je tiens à exprimer ma reconnaissance à l'université Paris-Saclay et AgroParisTech pour leur soutien financier et leur confiance en ce projet.

Je termine en remerciant toutes les personnes qui ont de près ou de loin contribué à la réalisation de cette thèse, et qui ont été pour moi une source de motivation et d'encouragement.

# Liste des publications

- *Cold chain break detection and analysis : Can machine learning help ?* - Julie Loisel, Steven Duret, Antoine Cornuéjols, Dominique Cagnon, Margot Tardet, Evelyne Derens-Bertheau et Onrawee Laguerre, Trends in Food Science & Technology, 2021 (Loisel et al. [2021])
- *Machine learning for temperature prediction in food pallet along a cold chain : Comparison between synthetic and experimental training dataset*, Julie Loisel, Antoine Cornuéjols, Onrawee Laguerre, Margot Tardet, Dominique Cagnon, Olivier Duchesne de Lamotte, Steven Duret - Journal of Food Engineering, 2022 (Loisel et al. [2022])



# Table des matières

<b>Table des matières</b>	<b>ix</b>
<b>Table des figures</b>	<b>xiv</b>
<b>Liste des tableaux</b>	<b>xv</b>
<b>Liste des algorithmes</b>	<b>xvii</b>
<b>Nomenclature</b>	<b>xxiv</b>
<b>Introduction</b>	<b>1</b>
<b>1 État de l’art, étude bibliographique</b>	<b>11</b>
1.1 Rupture de la chaîne du froid . . . . .	11
1.1.1 Définitions . . . . .	11
1.1.2 Méthodes de détection de rupture . . . . .	14
1.1.2.1 Intégrateurs Temps-Température (ITT) . . . . .	14
1.1.2.2 Capteurs de température . . . . .	15
1.2 IA et chaîne du froid : travaux existants . . . . .	21
1.2.1 Prédire la température des produits en temps réel . . . . .	21
1.2.2 Optimiser l’acquisition des données de température pour éviter la surcharge du réseau . . . . .	24
1.2.3 Gérer la demande dans une chaîne logistique en prenant en compte la qualité . . . . .	25



1.3	Comment obtenir des données d'apprentissage? . . . . .	25
1.3.1	Données expérimentales . . . . .	26
1.3.2	Données synthétiques . . . . .	27
1.4	Synthèse de l'étude bibliographique . . . . .	28
1.5	Conclusions et questions de recherche . . . . .	30
<b>2</b>	<b>Prédiction de la température des produits</b>	<b>33</b>
2.1	Matériel et Méthodes . . . . .	35
2.1.1	Expérimentation . . . . .	35
2.1.1.1	Choix de l'équipement . . . . .	35
2.1.1.2	Choix du produit . . . . .	35
2.1.1.3	Description du dispositif . . . . .	36
2.1.2	Modèle thermique . . . . .	38
2.1.2.1	Calcul de la température de l'air . . . . .	38
2.1.2.2	Calcul de la température des produits . . . . .	39
2.1.3	Comment prédire la température : un problème de régression . . . . .	40
2.1.4	Méthodes de régression et réseaux de neurones artificiels . . . . .	41
2.2	Données d'apprentissage et génération de données . . . . .	44
2.2.1	Jeu de données expérimental . . . . .	44
2.2.2	Jeu de données synthétiques . . . . .	45
2.2.3	Préparation des données . . . . .	45
2.3	Entraînement de réseaux de neurones . . . . .	47
2.3.1	La question du choix de l'architecture . . . . .	47
2.3.2	Les architectures testées . . . . .	49
2.4	Évaluation des modèles d'apprentissage . . . . .	49
2.5	Résultats . . . . .	52
2.5.1	Performance sur les 10 scénarios . . . . .	52
2.5.1.1	Position du capteur de température dans la palette . . . . .	52
2.5.1.2	Comparaison des types jeux de données . . . . .	55

2.5.1.3	Estimation de la performance du modèle sans données expérimentales . . . . .	56
2.5.1.4	Impact des données synthétiques additionnelles pour l'en- traînement des réseaux de neurones . . . . .	57
2.5.1.5	Impact du choix des scénarios . . . . .	60
2.5.2	Performance moyenne sur les 10 scénarios selon plusieurs initiali- sations . . . . .	62
2.5.2.1	Impact de données synthétiques supplémentaires . . . . .	62
2.6	Discussion . . . . .	64
<b>3</b>	<b>Modèle de simulation de chaîne du froid fictive</b>	<b>69</b>
3.1	Description du circuit logistique . . . . .	71
3.1.1	Enchaînement des étapes . . . . .	71
3.1.2	Durées et températures des étapes . . . . .	71
3.1.3	Calcul de la température des produits . . . . .	73
3.2	Calcul du coût énergétique . . . . .	73
3.3	Évolution de la qualité des produits . . . . .	75
3.3.1	Modèle qualité . . . . .	75
3.3.2	Choix de la durée de vie initiale du produit . . . . .	77
3.3.3	Variabilité biologique du produit . . . . .	77
3.3.4	Label qualité . . . . .	78
3.4	Intégration des modèles . . . . .	78
<b>4</b>	<b>Méthodologie de prise de décision en temps réel</b>	<b>81</b>
4.1	Définitions . . . . .	82
4.1.1	État . . . . .	82
4.1.2	Actions, scénarios . . . . .	84
4.1.3	Politique . . . . .	84
4.1.4	Évaluation des méthodes : coût moyen . . . . .	87
4.1.5	Alertes : différents types d'erreurs . . . . .	87

4.1.5.1	Fausse alerte . . . . .	87
4.1.5.2	Alerte non détectée . . . . .	88
4.1.5.3	Alerte non optimale . . . . .	88
4.1.6	Nombre d'actions par maillon . . . . .	88
4.2	Méthode à seuil . . . . .	89
4.2.1	Sélection de $T_{seuil}$ par $\alpha_{energie}$ . . . . .	89
4.2.2	Nombre d'alertes et de fausses alertes . . . . .	91
4.2.3	Coût moyen d'une action . . . . .	93
4.3	Méthode avec un classifieur $h$ . . . . .	93
4.3.1	Sélection de $s$ par $\alpha_{energie}$ . . . . .	96
4.3.2	Nombre d'alertes et de fausses alertes . . . . .	96
4.3.3	Coût énergétique moyen d'une action . . . . .	99
4.4	Méthode adaptative . . . . .	100
4.4.1	Coût d'une action : un compromis entre la qualité et l'énergie . . .	101
4.4.1.1	Estimation des probabilités liées à la précision du classifieur	106
4.4.1.2	Estimation des probabilités liées à l'efficacité d'une action	109
4.4.2	Estimation du maillon optimal . . . . .	110
4.4.3	Entraînement de la méthode adaptative . . . . .	111
4.4.4	Validation . . . . .	113
4.5	Test, comparaison des méthodes et interprétation . . . . .	115
4.5.1	Coût par méthode et par $\alpha_{energie}$ . . . . .	116
4.5.2	Nombre d'actions par méthode et par $\alpha_{energie}$ . . . . .	117
4.5.3	Fausse alertes par méthode et par $\alpha_{energie}$ . . . . .	119
4.5.3.1	Méthode à seuil . . . . .	119
4.5.3.2	Méthode avec un classifieur . . . . .	121
4.5.3.3	Méthode adaptative . . . . .	123
4.5.4	Comment améliorer ces méthodes? . . . . .	124
4.5.4.1	Améliorer la précision du classifieur . . . . .	124
4.5.4.2	Nombre de clusters par maillon . . . . .	125

4.5.4.3	Ajouter une contrainte sur la température . . . . .	125
4.6	Limites . . . . .	125
4.6.1	Géométrie du circuit logistique . . . . .	125
4.6.2	Méthode adaptative . . . . .	125
<b>5</b>	<b>Conclusions et perspectives</b>	<b>131</b>



# Table des figures

1.1	Exemples d'intégrateurs temps-température (ITT) : à gauche un processus proposé par (Galagan and Su [2008]) basé sur l'oxydation, et à droite un processus proposé par Monitor Mark (MonitorMark™) et commercialisé par 3M Company (St Paul, Minnesota, USA) basé sur des principes physiques (diffusion). . . . .	15
1.2	Schéma de fonctionnement d'un WSN (Cho and Cho [2020]) . . . . .	18
1.3	Organisation du manuscrit . . . . .	32
2.1	Organisation du Chapitre 2 - Prédiction de la température des produits . . . . .	34
2.2	Représentation schématique d'un niveau de palette . . . . .	35
2.3	Dispositif expérimental vu de profil . . . . .	37
2.4	Dispositif expérimental vu de dessus : pour le calcul des transferts thermiques, les zones de la palette sont indicées par $i, j$ . Pour l'apprentissage, les zones sont indicées par $z$ allant de 1 à 16. . . . .	37
2.5	Principe de fonctionnement d'un neurone artificiel . . . . .	42
2.6	Principe de fonctionnement d'un Perceptron multicouche . . . . .	44
2.7	Profils de température d'entrée d'air des scénarios de chaîne du froid étudiés : (A) et (B) - Profils expérimentaux, (C) et (D) - Profils synthétiques (les profils expérimentaux ont été lissés pour obtenir des profils de l'entrée du modèle thermique). Les 10 profils ont été représentés sur deux graphiques différents pour plus de lisibilité. . . . .	45

2.8	Exemple de <i>lag</i> des données pour la température de l'air dans la zone 4 . . . . .	47
2.9	Représentation schématique d'un Perceptron multicouche à une couche cachée de taille $k$ qui prend en entrée la température de l'air à la position $z$ (mesurée par un capteur) du temps $t - \lambda_{lag}\Delta t$ au temps $t$ et prédit la température de 16 produits au temps $t$ . . . . .	48
2.10	Procédure de validation croisée pour évaluer la performance des modèles sur 10 scénarios indépendants des scénarios d'entraînement - Calcul des $RMSE_s$ . . . . .	53
2.11	Impact de la position du capteur sur la distribution des $RMSE_s$ pour cinq modèles NN entraînés avec des données expérimentales. Les boxplots représentent la distribution des 10 $RMSE_s$ résultant de la validation croisée (cf. Figure 2.10). Les points blancs représentent la moyenne des 10 $RMSE_s$ et les valeurs aberrantes sont représentées par les diamants noirs. . . . .	54
2.12	Distribution des $RMSE_s$ de cinq NN entraînés sur des données synthétiques ou expérimentales. (A) Capteur mesurant la température de l'air à l'arrière l'arrière (B) Capteur mesurant la température de l'air à l'avant. Les boxplots représentent la distribution des 10 $RMSE_s$ issus de la validation croisée résultant de la validation croisée (cf. Figure 2.10). Les points blancs représentent la moyenne des 10 $RMSE_s$ et les valeurs aberrantes sont représentées par les diamants noirs. . . . .	55
2.13	Distribution de $RMSE_s$ de cinq NN entraînés sur des données synthétiques et testés sur : des données expérimentales, des données synthétiques non bruitées et données synthétiques avec trois bruits différents, en particulier $2x\sigma = 0.2^\circ\text{C}$ qui correspond à l'incertitude du thermocouple. Le capteur est placé à l'arrière de la palette. Les boxplots représentent la distribution des 10 $RMSE_s$ résultant de la validation croisée. . . . .	57

2.14 Scénarios de température en fonction du temps générés aléatoirement - Ligne noire : température de l'air à l'entrée de la palette (générée aléatoirement) - Ligne bleue : température de l'air dans la palette (calculée avec le modèle thermique) - Ligne orange : température d'un produit (calculée avec le modèle thermique) . . . . .	59
2.15 Distribution des $RMSE_s$ de 5 NN entraînés sur les données synthétiques avec les 10 scénarios décrits dans la section 2.2.2 (bleu) et 10 scénarios générés aléatoirement en suivant l'algorithme 1. Ces résultats ont été obtenus avec un capteur placé au fond de la palette . . . . .	60
2.16 Procédure de validation croisée pour évaluer la performance des modèles sur l'ensemble des 10 scénarios, avec des initialisations différentes - Calcul des $RMSE_i$ . . . . .	62
2.17 Impact du nombre de scénarios ajoutés au jeu de données original sur le $RMSE_i$ (cf. figure 2.16) . . . . .	63
3.1 Exemple d'un circuit logistique simulé . . . . .	72
3.2 Modèle de simulation de chaîne du froid . . . . .	80
4.1 $\hat{T}_{seuil}$ en fonction de $\alpha_{energie}$ . . . . .	90
4.2 Nombre d'actions par maillon et par $T_{seuil}$ . . . . .	91
4.3 Nombre de fausses alertes par maillon et par $T_{seuil}$ pour la méthode à seuil	92
4.4 Taux de fausses alertes (Nombre de fausses alertes/nombre d'actions par maillon pour la méthode à seuil) . . . . .	92
4.5 Coût moyen $\overline{C_e}$ d'une action par $T_{seuil}$ . . . . .	93
4.6 Construction de l'ensemble d'apprentissage $\mathcal{D}_m$ pour l'entraînement du classifieur $h_m$ . . . . .	94
4.7 $\hat{s}$ sélectionné pour la méthode classifieur, par $\alpha_{energie}$ . . . . .	97
4.8 Nombre d'actions par maillon pour la politique classifieur $\pi_h$ par seuil sur le classifieur $s$ . . . . .	98



4.9	Nombre de fausses alertes par maillon pour la politique classifieur $\pi_{h_s}$ par seuil sur le classifieur $s$ . . . . .	98
4.10	Taux de fausses alertes par maillon pour la politique classifieur $\pi_{h_s}$ par seuil sur le classifieur $s$ . . . . .	99
4.11	Coût moyen $\overline{C_e}$ d'une action pour la politique classifieur $\pi_{h_s}$ par seuil sur le classifieur $s$ . . . . .	100
4.12	Représentation schématique du passage d'un ensemble d'états à un ensemble de clusters (K=2) . . . . .	106
4.13	Représentation schématique de l'estimation de la précision d'un classifieur au maillon $m$ sur un ensemble d'états de clusters (K=2) . . . . .	107
4.14	Représentation schématique de l'apprentissage de la méthode adaptative .	113
4.15	Coût moyen par $\alpha_{energie}$ et par politique de décision. En rose la politique $\pi_{-a}$ qui n'agit jamais, en rouge la politique basée sur un seuil $\pi_{T_{seuil}}$ , en bleue la politique classifieur $\pi_{h_s}$ et en vert la politique adaptative $\pi_{adapt}$ . .	116
4.16	Nombre d'actions par maillon et par $\alpha_{energie}$ pour la méthode à seuil sur la température. . . . .	117
4.17	Nombre d'actions par maillon et par $\alpha_{energie}$ pour la méthode classifieur. .	118
4.18	Nombre d'actions par maillon et par $\alpha_{energie}$ pour la méthode adaptative. .	119
4.19	Fausses alertes par maillon et par $\alpha_{energie}$ pour la méthode à seuil. . . . .	120
4.20	Taux de fausses alertes par maillon et par $\alpha_{energie}$ pour la méthode à seuil. .	120
4.21	Fausses alertes par maillon et par $\alpha_{energie}$ pour la méthode classifieur. . .	121
4.22	Taux de fausses alertes par maillon et par $\alpha_{energie}$ pour la méthode classifieur. .	122
4.23	Fausses alertes par maillon et par $\alpha_{energie}$ pour la méthode adaptative. . .	123
4.24	Taux de fausses alertes par maillon et par $\alpha_{energie}$ pour la méthode adaptative. . . . .	124

# Liste des tableaux

- 1 Études terrain sur les ruptures de la chaîne du froid . . . . . 3
- 2 Études expérimentales sur l'impact des ruptures de la chaîne du froid sur la qualité et durée de vie des produits - Les températures de ruptures marquées par un (\*) sont des ruptures issues de scénarios observés sur le terrain . . . . . 5
- 1.1 Modèles d'apprentissages appliqués à la chaîne du froid . . . . . 23
- 3.1 Construction du circuit logistique : lois de distributions . . . . . 71
- 4.1 Ensemble des paramètres pour apprendre et tester la méthode classifieur . 96
- 4.2 Ensemble des paramètres pour entraîner et valider la méthode adaptative 114



# Liste des algorithmes

1	Simulation d'un profil aléatoire . . . . .	58
2	Simulation d'un scénario suivant la politique $\pi$ . . . . .	86
3	Construction de l'ensemble d'apprentissage $\mathcal{D}$ sans action . . . . .	96
4	Simulation d'un scénario suivant la politique adaptative . . . . .	111
5	Construction de l'ensemble d'apprentissage $\mathcal{D}^a$ contenant des actions . . .	112
6	Apprentissage de la méthode adaptative . . . . .	114



# Nomenclature

## Acronymes

CFD	Computational Fluid Dynamics
IA	Intelligence Artificielle
IoT	Internet of Things
ITT	Intégrateurs Temps-Température
LOO	Leave-one-out
MLP	Multilayer Perceptron, Perceptron Multicouche
NN	Neural Network, Réseaux de neurones
ReLU	Unité de rectification linéaire
RFID	Radio-IDentification
RMSE	Root Mean Squared Error, Racine de l'erreur quadratique
WSN	Wireless Sensor Networks

## Énergie

$Conso_e$	Consommation énergétique	J
$COP$	Coefficient de Performance (Carnot)	
$K$	Coefficient de transfert thermique global de l'équipement	$W m^{-2} K^{-1}$
$P$	Charge thermique associée aux déperditions par les parois	W
$Q_c$	Charge thermique associée au refroidissement des produits	J
$S_{eq}$	Surface de l'équipement	$m^2$
$T^{ext}$	Température de l'air à l'extérieur	$^{\circ}C$

$T^{prod}(t_0)$	Température du produit à l'entrée dans l'équipement	°C
$T^{prod}(t_{end})$	Température du produit à la sortie de l'équipement	°C
$T^{th}$	Température du thermostat	°C
$T_{cold}$	Température de source froide	°C
$T_{hot}$	Température de source chaude	°C
<b>Apprentissage</b>		
$(\mathbf{x}_i, y_i) \in \mathcal{D}$	le $i$ -ème exemple d'apprentissage composé du vecteur $\mathbf{x}_i$ et de son label associé $y_i$	
$\Delta t$	Pas de temps entre deux mesures de température	s
$\hat{y}_i$	Prédiction d'un modèle d'apprentissage qui prend en entrée $\mathbf{x}_i$	
$\lambda_{lag}$	Taille du décalage temporel	
$\mathbf{x} = (x_1, \dots, x_n)$	Entrée d'un modèle d'apprentissage, vecteur de $n$ variables explicatives	
$\mathbf{x}^t$	$T_{z,t-\lambda_{lag}\Delta t}^{air}, \dots, T_{z,t}^{air}$	
$\mathcal{D} = (\mathbf{x}_i, y_i)_{i \in [1,n]}$	Ensemble d'apprentissage composé de $n$ exemples	
$\varphi$	Fonction d'activation	
$\hat{T}_{z,t}^{coeur}$	Température du cœur dans la zone $z$ au temps $t$ prédite par le MLP	
		°C
$\alpha_i^j$	$j$ -ième neurone de la $i$ -ième couche d'un MLP	
$b$	Biais d'un neurone artificiel	
$B = \{b_i^k\}$	Vecteurs des biais d'un réseau de neurones	
$f$	Fonction à estimer, <i>classifieur</i> si $y$ variable qualitative, <i>régresseur</i> si $y$ continue	
$N_{zone}$	Nombre de zones dans la palette (16)	
$RMSE_{s,i}$	RMSE associé au scénario $s$ et à l'initialisation $i$	
$RMSE_s$	RMSE associé au scénario $s$	
$RMSE_t$	RMSE au temps $t$	
$T_{z,t}^{air}$	Température de l'air dans la zone $z$ au temps $t$	°C

$t_{max}$	Durée d'un scénario	
$T_{z,t}^{coeur}$	Température du cœur dans la zone $z$ au temps $t$	°C
$W = \{w_{i,j}^k\}$	Vecteurs des poids d'un réseau de neurones	
$w_i$	$i$ -ème poids d'un neurone artificiel	
$y$	Sortie d'un modèle d'apprentissage, vecteur des variables à expliquer	
$y^t$	$T_{1,t}^{coeur}, \dots, T_{16,t}^{coeur}$	
$z$	Indice sur la zone dans la palette	
MLP(k,l)	Multilayer Perceptron à deux couches cachées de tailles $k$ et $l$	
<b>Politique de décision</b>		
$\alpha_{energie}$	Pénalité sur la consommation énergétique	
$\alpha_{qualite}$	Pénalité sur la qualité	
$\beta$	Paramètre qui modélise la probabilité qu'une action soit efficace	
$\hat{s}$	Seuil sur le classifieur sélectionné pendant la validation pour minimiser $\overline{Cost}_{\alpha_{energie}}$	
$\hat{T}_{seuil}(\alpha_{energie})$	Seuil sur la température sélectionné pendant la validation pour minimiser $\overline{Cost}_{\alpha_{energie}}$	
$\hat{y}_m$	Prédiction du classifieur $h_m$ pour l'état $x_m$ au maillon $m$	
$\mathbf{x}_M^i$	$i$ -ème scénario d'un ensemble d'apprentissage	
$\mathbf{x}_M$	Scénario : suite de $M$ couples (état, action)	
$\mathcal{A}$	Ensemble des actions possibles	
$\mathcal{C}^m = \{c_k^m\}_{k \in [1:K]}$	Ensemble des $K$ clusters d'états au maillon $m$	
$\mathcal{D}'_m$	Ensemble d'apprentissage des états au maillon $m$ pour l'entraînement de l'algorithme de clustering	
$\mathcal{D} = \{(\mathbf{x}_m^i, y^i)\}_{\substack{m \in [1:M] \\ i \in [1:N]}}$	Ensemble d'apprentissage de $M$ états composé de $N$ scénarios	
$\mathcal{D}_m = \{(\mathbf{x}_m^i, y^i)\}_{i \in [1:N]}$	Ensemble d'apprentissage des états au maillon $m$ pour l'entraînement des classifieurs	
$\mathcal{S}$	Ensemble des états possibles	



$x_m$	État du système au maillon $m$	
$\overline{Cost}_{\alpha_{energie}}$	Coût moyen calculé sur $N$ scénarios pour une pénalité sur l'énergie $\alpha_{energie}$	
$\pi : \mathcal{S} \rightarrow \{a, \neg a\}$	Politique de décision	
$\pi_{\neg a}$	Politique qui n'agit jamais	
$\pi_{a_m}$	Politique qui agit seulement au maillon $m$	
$\pi_h$	Politique basée sur un classifieur $h$	
$\pi_{T_{seuil}}$	Politique de décision basée sur un seuil sur la température $T_{seuil}$	
$\{ok, \neg ok\}$	Ensemble des labels qualité	
$a_m$	Action lancée au maillon $m$	
$C(x_m)$	Coût espéré de l'action au maillon $m$ pour l'état $x_m$	
$c_k^m$	$k$ -ième cluster d'états au maillon $m$	
$C_e$	Coût énergétique (différence entre la consommation énergétique avec et sans action)	
$d$	Fonction de décision qui à un label associe une décision	
$D_i$	Durée de l'étape $i$	
$G : \mathcal{S} \rightarrow \mathcal{S}$	modèle génératif qui décrit un circuit logistique	
$h : \mathcal{S} \rightarrow \{ok, \neg ok\}$	Classifieur	
$h_m : \mathcal{S} \rightarrow \{ok, \neg ok\}$	Classifieur au maillon $m$	
$i$	Étape de la chaîne (indice sur les étapes)	
$M$	Nombre de maillons de la chaîne	
$m$	Maillon de la chaîne (indice sur les maillons)	
$N$	Nombre de scénarios	
$T^{ext}$	Température de l'air ambiant	°C
$T_i$	Température de l'étape $i$	°C
$T_m$	Température de l'air du maillon $m$	°C
$T_{seuil}$	Seuil sur la température	°C
$y^i$	$i$ -ème label associé au scénario $\mathbf{x}_M^i$	

**Qualité**

$A$	Indicateur qualité du produit	
$A_0$	Qualité initiale du produit	100 %
$E_a$	énergie d'activation	$\text{J mol}^{-1}$
$k$	Constante de la cinétique	$\text{s}^{-1}$
$N_j$	Durée de vie du $j$ -ième produit	jours
$Qual(\mathbf{x})$	label qualité $\in \{ok, -ok\}$	
$R$	Constante universelle	$8.31 \text{ J mol}^{-1} \text{ K}^{-1}$
$RSL_j$	Durée de vie restante du produit $j$ (Remaining Shelf-Life)	%
$T_{ref}$	Température de référence du produit	$^{\circ}\text{C}$

**Thermique**

$\alpha$	Diffusité thermique	$\text{m}^2 \text{ s}^{-1}$
$\dot{m}$	Débit massique de l'air	$\text{kg s}^{-1}$
$\lambda$	Conductivité thermique	$\text{W m}^{-1} \text{ K}$
$Cp^{air}$	Capacité thermique de l'air	$\text{J kg}^{-1} \text{ }^{\circ}\text{C}^{-1}$
$Cp^{prod}$	Capacité thermique du produit	$\text{J kg}^{-1} \text{ K}^{-1}$
$h$	Coefficient d'échange convectif	$5 \text{ W m}^{-2} \text{ K}^{-1}$
$i, j$	Indices de la zone de la palette pour le calcul des transferts thermiques	
$m$	Masse du produit	kg
$r$	Indice radial	m
$R^{prod}$	Rayon de la pomme	m
$S$	Surface d'échange entre l'air et le produit	$\text{m}^2$
$T^{air}(t)$	Température de l'air au temps $t$	$^{\circ}\text{C}$
$T_{entre}^{air}(t)$	Température de l'air à l'entrée de la palette au temps $t$	$^{\circ}\text{C}$
$T_{i,j,t}^{air}$	Température de l'air en position $i, j$ au temps $t$	$^{\circ}\text{C}$
$T^{prod}(t)$	Température du produit au temps $t$	$^{\circ}\text{C}$
$T_{i,j,t}^{surface}$	Température de surface du produit en position $i, j$ au temps $t$	

		°C
$T^{th}$	Température du thermostat	°C
$z$	Indices de la zone de la palette pour l'apprentissage	

*À mes parents, qui m'ont encouragée et soutenue durant ces années d'études.*



# Introduction

La réfrigération est essentielle pour prolonger la durée de conservation des denrées périssables et fournir aux consommateurs des aliments sûrs et sains. En effet, les basses températures réduisent l'activité biologique des aliments périssables limitant ainsi les taux de maturation, les réactions de brunissement et les pertes d'eau. De plus, les basses températures limitent également le développement des micro-organismes pathogènes ou d'altération (James and James [2010], Laguerre et al. [2013]). L'utilisation de la réfrigération pour la préservation des aliments s'est fortement développée au cours des dernières décennies dans la plupart des pays développés et en développement. Du fait de l'augmentation de la durée de vie des aliments et du développement des moyens de transport de plus en plus efficaces, les chaînes d'approvisionnement en produits alimentaires périssables se sont étendues. Aujourd'hui, les chaînes d'approvisionnement en produits alimentaires réfrigérés ou surgelés, appelées chaînes du froid, acheminent des milliards de tonnes de produits alimentaires entre les régions, pays et continents.

L'utilisation du terme *chaîne* met l'accent sur l'importance de la maîtrise de la basse température tout au long des différentes étapes du circuit logistique : usine de production, entrepôt, transport, chambre froide, meuble de vente et réfrigérateur domestique. Une défaillance dans la maîtrise de la température à une étape peut mettre en péril les efforts de toutes les autres étapes et peut entraîner la détérioration du produit. Ces défaillances, appelées perturbations, ruptures, abus, interruptions, excursions, peuvent avoir différentes causes telles que :

- une panne d'équipement

- un mauvais réglage de la température de consigne dans un équipement frigorifique
- une température trop élevée dans certains endroits due à une répartition inégale de l'air
- une exposition trop longue à l'air ambiant lors du chargement et du déchargement des denrées pendant la livraison (Commere and Billard [2008], Brenner [2015], Mercier et al. [2017])

Le Tableau 1 présente la bibliographie des études terrain sur les ruptures de la chaîne du froid. Les étapes de la chaîne qui présentent des défaillances dans le maintien de la température d'un produit ont été identifiées, documentées et rapportées dans Ndraha et al. [2018]. Derens et al. [2006] ont observé qu'environ 12% des produits dans le transport frigorifique et les plateformes de distribution avaient une température moyenne supérieure à leur valeur recommandée. Il est à noter que dans cette étude, les produits ont été acheminés dans une chaîne logistique sans la supervision d'un opérateur comme souvent pratiquée par des professionnels. Ainsi, les causes des ruptures citées dans ces études n'ont pas pu être identifiées. Par ailleurs, il n'y avait aucune information sur les ruptures potentielles causées par l'attente du produit entre deux étapes de la chaîne du froid (par exemple, chargement et déchargement d'un véhicule lors de la livraison).

TABLE 1 – Études terrain sur les ruptures de la chaîne du froid

Pays	Produit	Données		Qualité			Capteurs	Étape de la chaîne	Référence
		Température	Structure de la chaîne	Qualité	Microbiologique	Chimique	Sensoriel		
Thaïlande	Chaîne de restaurants	x	x					Enregistreurs de données, Caméras thermiques infrarouges	Entreposage frigorifique, Camion à température contrôlée Chaitangjit and Ongkunaruk [2019]
France	Yaourt	x			x				Transport jusqu'à la vente Derens-Bertheau et al. [2015]
Chine, Australie	Viande de bœuf réfrigérée emballée sous vide	x			x	x	x	Enregistreurs de données (intervalle 25 min et 15 min)	traitement (processing), expédition, distribution Frank et al. [2019a]
Afrique du Sud	raisins, prunes, fruits à pépins	x	x	x		x		Enregistreurs de données (intervalle 30 min)	de la récolte (verger) jusqu'au port de destination Goedhals-Gerber et al. [2015]
Espagne	Viande cuite	x	x		x	x		Enregistreurs de données	Réfrigérateurs domestiques Jofré et al. [2019]
États-Unis	Huîtres	x	x		x			Enregistreurs de données	six différents types de chaînes Love et al. [2020]



TABLE 1 – Études terrain sur les ruptures de la chaîne du froid

Pays	Produit	Données			Qualité			Capteurs	Étape de la chaîne	Référence
		Température	Structure de la chaîne	Qualité	Microbiologique	Chimique	Sensoriel			
Taiïwan	Crevettes congelées	x	x	x	x	x	x	Enregistreurs de données (enregistrement continu)	livraison à domicile	Ndraha et al. [2019]
Belgique	Endive	x			x			Enregistreurs de données (intervalle 1min)	de la récolte au restaurant	Rediers et al. [2009]
États-Unis, Espagne	Mélange de romaine fraîche emballée	x			x			Enregistreurs de donnée	Transport commercial, Vente au détail	Zeng et al. [2014]

En raison des difficultés à mettre en œuvre des études de terrain, de nombreuses études ont été effectuées en laboratoire pour mettre en évidence l'impact des ruptures de la chaîne du froid sur la qualité et la durée de conservation des produits (Tableau 2). Sur les 27 études rapportées dans ce tableau, seules 10 ont basé leurs scénarios de rupture sur des températures observées dans des études de terrain. Plusieurs types de produits (viande, poisson, fruits et légumes) ont été étudiés en fonction de différents critères de qualité, tels que l'altération, les aspects sanitaires, sensoriels, les vitamines et la durée de conservation. Selon le type de produit, une rupture de la chaîne du froid de deux heures peut réduire la durée de conservation de 10 à 40 %. Pour les produits les plus périssables, l'occurrence, le niveau et la durée de la rupture de la chaîne du froid peuvent avoir un impact important sur la qualité du produit. Il est donc nécessaire de bien caractériser les ruptures de température dans la chaîne du froid afin de prévenir la détérioration de la qualité des produits alimentaires.

**TABLE 2** – Études expérimentales sur l'impact des ruptures de la chaîne du froid sur la qualité et durée de vie des produits - Les températures de ruptures marquées par un (\*) sont des ruptures issues de scénarios observés sur le terrain

Pays	Produit	Température de référence (°C)	Ruptures testées		Indicateur qualité			Impact (% durée de vie)	Référence
			Température (°C)	Durée	Microbiologique	Chimique	Sensoriel		
Allemagne	Poulet	4	7, 15	<5%	x			-3 à 31.1	Bruckner et al. [2012]
	Porc							-6.8 à 27.7	
Spain	Poulet	1	15 → 4*	6h → 112h	x			-	Alonso-Hernando et al. [2013]
		4	15 → 10 20 → 7	6h → 96h 6h → 96h					
	Poires	1-4	8*	5 j	x	x	x	-	Medà et al.
Bénin	Maquereau-18		coupure d'électricité	(3h or 6h or 12h) par jour x 3		x	x	-	Assogba [2019]
Portugal	Cresson	-18	4, -10, 25 *	15min à 1h		x	x	-	Cruz et al. [2009]
	Framboises surgelées	-18	4, -10, 25 *	15min à 1h		x	x	-	
Chine	Brocoli	1	4, 10, 25	13j		x	x	Impact higher during 60d Pre-storage	Gao et al. [2018]
	Poulet	4	4 → 28 → 4	12h → 7h → 53h	x			-	Li et al. [2017]

**TABLE 2** – Études expérimentales sur l'impact des ruptures de la chaîne du froid sur la qualité et durée de vie des produits - Les températures de ruptures marquées par un (\*) sont des ruptures issues de scénarios observés sur le terrain

Pays	Produit	Température de référence (°C)	Ruptures testées		Indicateur qualité			Impact (% durée de vie)	Référence
			Température (°C)	Durée	Microbiologique	Chimique	Sensoriel		
China, USA	Melons, ananas, radis	4	8, 12, 35	7j, 7j, 2h	x			-	Huang et al. [2015]
Irlande	Légumes frais et cuits	3	3 → 12 → 8	168h → 12h → 48h	x	x	x	-	Thomas and O'Beirne [2000]
Vietnam	Panga	1	1 * 9 * 28-30	48h/27h/50h 5min-2h 2h/1min-30min-2h	x	x	x	- - -	Mai and Huynh [2017]
Malaisie	Lait		15, 25, 35	2h, 4h, 6h	x		x	-	Siti Norashikin et al. [2018]
Islande	Ombre	1	18	24h	x	x	x	-10%	Odoli Ogombe Cyprian et al. [2008]
	Maquereau-25		-12	1 mois		x	x	-	Romotowska et al. [2017]
	Lieu noir	2	16	0h 1h	x	x	x	- -22%	Mu et al. [2017]

**TABLE 2** – Études expérimentales sur l'impact des ruptures de la chaîne du froid sur la qualité et durée de vie des produits - Les températures de ruptures marquées par un (\*) sont des ruptures issues de scénarios observés sur le terrain

Pays	Produit	Température de référence (°C)	Ruptures testées			Indicateur qualité			Impact (% durée de vie)	Référence
			Température (°C)	Durée		Microbiologique	Chimique	Sensoriel		
				2h -				-44%		
Italie	Poulet précuit	4	30	1j	x			-	Degli Esposti et al. [2018]	
France	Volaille (foies, filets)	-18	4 or 20	0, 5, 1, 2, 4, 6, 8h	x			-	Faullimel et al. [2005]	
Chili	Avocat	7	15 25	24h or 48h 24h or 48h			x	no reduction early softening	Undurraga et al.	
Iran	Yaourt	5, 20	interrupted cold chain	24h		x	x	-	Ferdousi et al. [2013]	
Inde	Roquette	5	13	24h (2 fois, aux jours 2 et 6)		x		-	Mastrandrea et al. [2017]	
Hongrie	Porc sous vide	5	15, 25, 35 *	1h	x			- 6j	Géczi et al. [2017]	
		5	15, 25, 35 *	3h				- 50%		
Nouvelle-Zélande	Lait	5	25 *	8h	x	x		reduction	Sadhu [2018]	

**TABLE 2** – Études expérimentales sur l’impact des ruptures de la chaîne du froid sur la qualité et durée de vie des produits - Les températures de ruptures marquées par un (\*) sont des ruptures issues de scénarios observés sur le terrain

Pays	Produit	Température de référence ( ° C)	Ruptures testées			Indicateur de qualité		Impact (% durée de vie)	Référence
			Température ( ° C)	Durée	Microbiologique	Chimique	Sensoriel		
Afrique du sud	Avocat	4 à 8		5h/20h/10h			x	-	Lemmer and Kruger [2010]

Aujourd’hui, avec le développement de l’IoT, les capteurs de température sont commercialisés à un prix abordable et il est désormais techniquement possible de mesurer la température en temps réel tout au long des circuits logistiques (Bouzembrak et al. [2019], Sarac et al. [2010]). Toutefois, si les données de température de terrain seront disponibles dans les années à venir, l’arrivée de ces nouvelles sources de données soulève plusieurs questions. Par exemple, la définition d’une rupture de température, le positionnement des capteurs pour être représentatif de l’ensemble du chargement dans un équipement ou encore les méthodes à utiliser pour détecter et caractériser les ruptures de température. L’apprentissage automatique, qui inclut diverses méthodes, pourrait être un moyen de répondre à ces questions. Un état de l’art des travaux déjà présents dans la littérature scientifique permettant de détecter et caractériser les ruptures à partir de capteurs de température placés dans les équipements frigorifiques est proposé dans le chapitre 1. Nous rappellerons également dans ce chapitre la définition de la notion de rupture. Les chapitres 2, 3 et 4 de ce manuscrit décrivent les approches mises au point afin de détecter et caractériser en temps réel les ruptures dans la chaîne du froid. Une

première approche adaptée aux produits dont la température est réglementée (viande, poisson ; chapitre 2) et une seconde approche pour les produits dont la température est recommandée (fruits, légumes ; chapitre 3 et 4). Pour la seconde approche, la méthodologie mise au point propose également d'inclure des mesures correctrices permettant de limiter les pertes et gaspillages des denrées alimentaires.



# Chapitre 1

## État de l'art, étude bibliographique

### 1.1 Rupture de la chaîne du froid

#### 1.1.1 Définitions

La chaîne du froid est un réseau logistique complexe dont l'objectif est d'acheminer aux consommateurs des denrées périssables dans de bonnes conditions hygiéniques, nutritionnelles et organoleptiques. Le règlement européen (EC) N°852/2004 précise que :

*“Les matières premières, les ingrédients, les produits semi-finis et finis susceptibles de favoriser la reproduction de micro-organismes pathogènes ou la formation de toxines ne doivent pas être conservés à des températures qui pourraient entraîner un risque pour la santé. La chaîne du froid ne doit pas être interrompue.”*

En d'autres termes, tout dépassement de cette température est donc considéré comme une rupture. Cependant, le règlement précise également :

*“il est admis de les soustraire à ces températures pour des périodes de courte durée à des fins pratiques de manutention lors de l'élaboration, du transport, de l'entreposage, de l'exposition et du service des denrées alimentaires, à condition que cela n'entraîne pas de risque pour la santé”.*



D'après cette définition, les ruptures peuvent être tolérées à condition d'apporter la preuve que ces dernières ne représentent pas de risque pour la santé humaine. D'après Commere and Billard [2008], les ruptures de la chaîne du froid concernent des situations très diverses qui ont en commun le fait que le produit ne répond plus aux attentes des clients en termes d'hygiène, de durée de conservation et de qualité organoleptique (couleur, aspect, goût, etc.). De même, de nombreuses autres études ont pris en compte l'impact sur la qualité dans leur définition (Freiboth et al. [2013], Ruiz-Garcia et al. [2009], Thompson [2002]). Un problème avec ce type de définition est qu'elle dépend du produit considéré et donc qu'il existe autant de types de ruptures de la chaîne du froid que de produits alimentaires.

Dans cette thèse, nous avons décidé de faire une dichotomie entre deux grands types de produits : produits pour lesquels la température est *réglementée*, et produits pour lesquels la température est seulement *recommandée*. La chaîne du froid peut être modifiée pour deux raisons : soit une élévation de température au-dessus d'une température réglementée a été observée, et dans ce cas, la vente de ce produit devient illégale, soit sa qualité organoleptique le rend hors des attentes du consommateur et le produit risque d'être jeté.

En effet, les produits pour lesquels la température est réglementée sont des produits propices au développement de micro-organismes pathogènes et peuvent donc devenir dangereux pour la santé si consommés. Dans ce cas, comme c'est le cas pour les produits carnés ou le poisson par exemple, la loi établit un seuil réglementaire sur la température des produits. Ainsi, une rupture de la chaîne du froid est un dépassement du seuil réglementaire. Un produit est considéré comme non conforme si sa température a dépassé ce seuil. Ainsi, une rupture est définie pour les produits dont la température est réglementée comme suit :

Une rupture, pour les produits dont la température est réglementée, est une élévation de température du produit au-delà de la température réglementaire.

Dans ce cas, si une rupture est détectée, le produit ne peut plus être vendu et le circuit est modifié. Après une analyse microbiologique du produit, celui-ci peut, dans le

meilleur des cas, être réutilisé dans des produits préparés, sinon jeté. En pratique, étant données les incertitudes de mesures, une certaine tolérance peut être accordée au-delà du seuil de température lors d'un contrôle ponctuel. Si la mesure à une position donnée est légèrement supérieure au seuil (par exemple de 2°C), d'autres mesures à différentes positions peuvent être effectuées pour vérifier la conformité du chargement.

Les produits pour lesquels la température est recommandée sont par exemple les fruits et légumes. Dans ce cas, même si une température est recommandée, un dépassement de cette recommandation n'implique aucune conséquence sanitaire. Ce qui risque de mettre en péril le bon déroulement de la chaîne, c'est une baisse de qualité des produits. La qualité des fruits et légumes est évaluée en fonction de leur calibre, leur goût (sucre, acidité). Ces caractéristiques sont peu altérées pendant le transport. Cependant, la fermeté, les pourritures et les moisissures, plus visibles, peuvent évoluer pendant le transport, en particulier si une température basse n'est pas maintenue. Si une cargaison arrive à sa destination avec trop d'altérations, le circuit est modifié, par exemple, la cargaison peut être refusée par le client et renvoyée au fournisseur. Dans ce cas, elle est souvent réorientée vers un circuit moins exigeant (transformation, don à une banque alimentaire), méthanisée, détruite ou incinérée. Dans le cas des fruits et légumes, une ou plusieurs élévations de température successives peuvent altérer la qualité dû à l'effet d'accumulation. Par exemple, une première élévation de 30 min n'impacte pas la qualité alors qu'une seconde élévation de 30 min peut être néfaste pour celle-ci. Ainsi, une rupture est définie comme suit : La rupture, pour les produits dont la température est recommandée, est une ou plusieurs élévations de température qui rendent la qualité du produit hors des attentes du client.

Dans tous les cas, une rupture de la chaîne du froid a pour conséquence de modifier le circuit initialement prévu, entraînant ainsi des coûts divers (logistique, énergétique, manque à gagner en cas de rupture d'approvisionnement...).

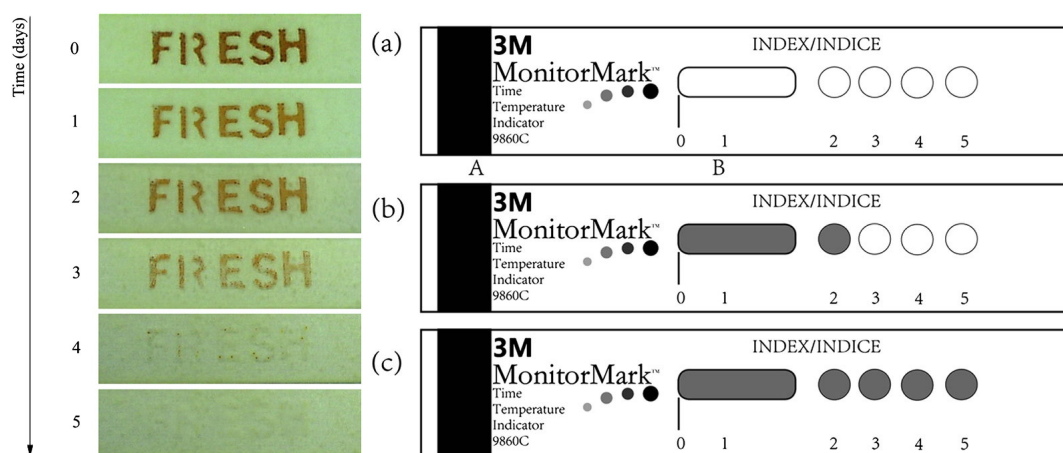
## 1.1.2 Méthodes de détection de rupture

### 1.1.2.1 Intégrateurs Temps-Température (ITT)

En lien avec la littérature définissant une rupture comme un événement ayant un impact sur la qualité du produit, la manière la plus intuitive de détecter une rupture serait de mesurer la qualité du produit. Par exemple, des indicateurs de qualité nutritionnelle (vitamine C), microbiologiques (*Listeria monocytogenes*, flore totale) ou sensoriels (apparence, couleur, goût) peuvent être mesurés. Cependant, il est difficile de mesurer ces indicateurs pour tous les produits en raison de coûts et de lourdeur de la mise en œuvre. Par ailleurs, certaines mesures entraînent la destruction des produits, ce qui rend la gestion du flux de marchandises délicate.

Les ITT ont été développés comme alternative au cours des deux dernières décennies. Ils permettent d'estimer l'évolution de la qualité des aliments en intégrant la mesure de la température dans le temps au cours d'une chaîne logistique. Ces indicateurs sont basés sur des réactions chimiques, biologiques ou physiques (Wang et al. [2015]) dont la cinétique de réaction dépend de la température. En effet, ces indicateurs sont conçus pour faire correspondre la réaction chimique/biologique/physique à l'évolution de la qualité du produit en fonction de la température mesurée. Enfin, ils indiquent la durée de conservation restante par un tampon de couleur (Taoukis and Labuza [1989]). Les ITT présentent l'avantage d'être petits et peu coûteux, et peuvent être fixés sur les aliments ou les emballages alimentaires qui suivent un circuit logistique jusqu'au consommateur. Les ITT sont un moyen rentable de détecter des ruptures de la chaîne du froid (Gianakourou et al. [2005]). Cependant, même si les ITT ont été reconnus comme des outils de surveillance (AFNOR [2013]), l'indication des changements de couleur est trop imprécise. Leur précision étant ainsi limitée, cela constitue un obstacle à leur utilisation dans les chaînes du froid. En outre, comme la transition de couleur due aux réactions biochimiques est irréversible, il est impossible d'obtenir des informations sur le moment où les changements de température du produit ont lieu, car ceux-ci peuvent se produire à différents moments de la chaîne du froid. Malgré leur facilité d'utilisation et leur faible

coût, les ITT ne permettent pas un suivi précis de la qualité. La figure 1.1.2.1 montre des exemples d'utilisation d'ITT.



**FIGURE 1.1** – Exemples d'intégrateurs temps-température (ITT) : à gauche un processus proposé par (Galagan and Su [2008]) basé sur l'oxydation, et à droite un processus proposé par Monitor Mark (MonitorMark™) et commercialisé par 3M Company (St Paul, Minnesota, USA) basé sur des principes physiques (diffusion).

### 1.1.2.2 Capteurs de température

La température est le premier facteur influençant l'évolution de la qualité des produits et sa mesure est facilement réalisable en pratique. Pour détecter les ruptures, les opérateurs mesurent la température à un ou plusieurs endroits d'une palette à un moment donné. Cette mesure est souvent effectuée à l'expédition ou à la réception d'une cargaison avec des thermomètres infrarouge (sans contact) ou des sondes placées entre deux produits ou à cœur d'un produit (avec contact). Cependant, ces mesures effectuées à quelques positions ne fournissent pas une indication fiable de la température sur l'ensemble de la palette. En effet, une hétérogénéité pouvant aller jusqu'à plusieurs degrés peut être observée au sein d'une palette ou d'un chargement dans un équipement (Laguerre et al. [2014]). De plus, les mesures à un moment donné ne permettent pas de détecter les ruptures antérieures. Une cargaison de produit peut être refusée si la tempé-

rature est trop élevée, même si la qualité est conforme aux attentes du client. Inversement, une cargaison ayant subi préalablement une ou plusieurs ruptures peut être acceptée si la température mesurée respecte le cahier des charges et que la dégradation de qualité du produit n'est pas repérée par l'opérateur.

En conséquence, certains opérateurs utilisent des enregistreurs de données pour surveiller la température tout au long de la chaîne du froid. Grâce aux profils température enregistrés, il est possible d'analyser les caractéristiques de la rupture. Par exemple, Goedhals-Gerber and Khumalo [2018] ont identifié l'influence des activités logistiques sur les ruptures de la chaîne du froid lors de l'exportation de fruits de l'Afrique du Sud au Royaume-Uni. Ces auteurs ont déterminé le pourcentage de ruptures à chaque étape de la chaîne en considérant qu'une rupture se produisait lorsque la température ambiante était supérieure à 2 °C au-dessus de la température de référence (-0.5 °C) pendant plus de 90 minutes. Les capteurs utilisés étaient placés dans les cargaisons et renvoyés en fin de chaîne au laboratoire pour les analyses a posteriori. Cette étude de terrain a permis d'identifier les maillons faibles de la chaîne, par exemple, plus de la moitié des ruptures ont lieu pendant le transport en camion, en particulier au début du transport. En outre, l'étude montre que les ruptures sont des événements fréquents : dans seulement 9.2% des cas, les chaînes ne contenaient pas de rupture. L'essor des capteurs sans fil permet de suivre l'évolution de température dans l'intégralité de la chaîne du froid. L'analyse a posteriori des températures enregistrées permet d'identifier les points faibles d'une chaîne, et de tester des actions d'amélioration pour optimiser la qualité de produit et la consommation énergétique des équipements frigorifiques. (Onwude et al. [2022]) ont utilisé des données de température ambiante enregistrées sur terrain grâce à des capteurs sans fil. Ces auteurs ont également généré des données de température de produit à l'aide d'un modèle thermique discrétisé par la méthode des éléments finis. Ce modèle thermique a été couplé avec un modèle de qualité d'un fruit (orange). La combinaison de modèles thermiques et de qualité, appelée "jumeau numérique", permet de simuler l'évolution d'un fruit soumis aux températures ambiantes mesurées sur le terrain. En intégrant ce jumeau numérique dans un processus de Monte Carlo, les auteurs ont pris

en compte les variabilités des paramètres thermique et de qualité du produit en simulant 1000 "jumeaux numériques". Cette approche a permis d'identifier les facteurs influençant la variabilité de la qualité finale du produit. À partir des distributions de températures récoltées lors d'études terrain (Duret et al. [2019]) ont simulé la chaîne du froid des cinq dernières étapes de la chaîne du froid : transport frigorifique, chambre froide du magasin, meuble frigorifique de vente, transport après achat par le consommateur et conservation dans un réfrigérateur domestique. Ces auteurs ont étudié plus particulièrement l'impact des conditions de conservation du dernier maillon (réfrigérateur domestique) sur la charge en *L. monocytogenes*. Plusieurs scénarios ont été testés sur la conservation domestique pour identifier celui qui permet de réduire le plus le risque sanitaire tout en limitant la consommation énergétique du réfrigérateur. Cette étude recommande de régler son réfrigérateur domestique à 4°C pour réduire le risque sanitaire de 68%, le gaspillage de 48% tout en augmentant la consommation énergétique que de 9%.

Aiello et al. [2012] ont estimé la qualité du produit à son arrivée au magasin en se basant sur des données de température récoltées sur le terrain et un modèle de qualité. Cette étude permet d'évaluer la performance d'une chaîne et le taux de pertes alimentaires. Ces données terrain sont donc utilisées pour effectuer des simulations, a posteriori, permettant d'estimer la qualité des produits en fin de chaîne. Il a été rapporté par ces auteurs que 8% des pêches arrivent déjà périmés, et que si le seuil de qualité est fixé à 70% de la durée de vie initiale des produits), seulement 2% des produits arrivent en bon état. Cette étude montre qu'il est possible d'estimer l'impact économique de plusieurs paramètres de cette chaîne, et ainsi de mieux la concevoir en amont pour optimiser les pertes/gaspillage et la consommation énergétique

Récemment, on a assisté à un progrès considérable du développement des objets connectés (IoT), notamment les technologies de capteurs sans fil (Wireless Sensor Technology - WST), les réseaux de capteurs sans fil (Wireless Sensor Network - WSN) et la technologie de Radio-Identification (RFID). En effet, les WSN sont largement utilisés dans divers domaines, notamment l'agriculture, la médecine, le contrôle de l'environnement et les bâtiments intelligents. Un WSN (Figure 1.2) est composé de plusieurs nœuds

de capteurs sans fils (sensor node), qui transmettent les données au *sink* node. Ces données sont transmises en temps réel à des plateformes Web (base station) par Internet ou satellite. Dans la chaîne du froid, les capteurs sans fils peuvent mesurer la température, l'humidité, le taux de CO<sub>2</sub>, la luminosité pour détecter les ouvertures de portes, les vibrations qui peuvent endommager les produits et la géolocalisation d'une palette dans une chaîne logistique (Abad et al. [2009], Ruiz-Garcia et al. [2009]).

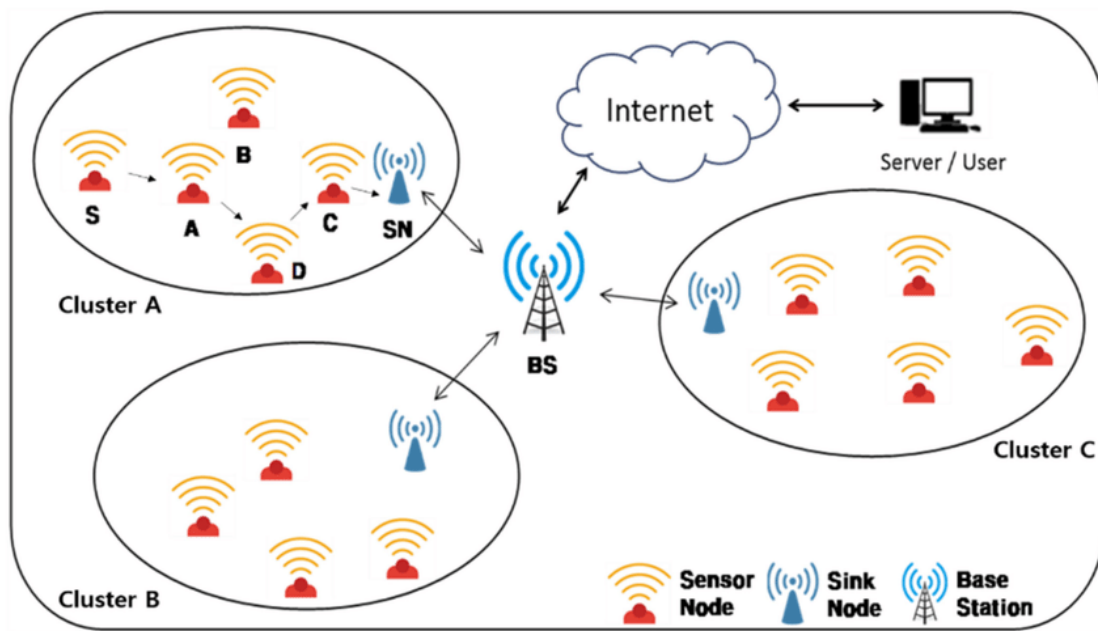


FIGURE 1.2 – Schéma de fonctionnement d'un WSN (Cho and Cho [2020])

La RFID est utilisée dans plusieurs domaines tels que les transports publics (pass Navigo), les transactions financières (paiement sans contact) et le commerce (antivols). La technologie RFID est rendue possible grâce à la combinaison d'un code barre sur une étiquette (*tag* en anglais) collée sur l'emballage du produit ou posé dans la palette. À l'aide d'un lecteur, de nombreuses étiquettes peuvent être lues et transmises à un serveur simultanément. La communication entre l'étiquette et le lecteur peut s'effectuer par transfert électromagnétique à distance variant de 10 à 200 m selon le type d'étiquette et de lecteur. La plupart de ces dispositifs sont "actifs", c'est-à-dire qu'ils disposent de leur propre source d'énergie pour fonctionner. Les deux technologies RFID et WSN peuvent

être combinées pour bénéficier des avantages de l'une et de l'autre à la fois.

La démocratisation de ces technologies implique une masse de données sur la chaîne du froid à exploiter. Il serait alors possible de détecter et d'alerter la rupture de la chaîne du froid en temps réel. Les professionnels commencent à les déployer et ce développement se poursuivra dans les années à venir. Pour faciliter la manipulation, la température de l'air est souvent mesurée en continu tout au long de la chaîne dans un équipement donné et non pas la température du produit. L'avantage de ces dispositifs est que des alertes automatiques peuvent être envoyées aux opérateurs afin de mettre en place des actions correctives pour éviter la dégradation de la qualité des aliments. Cependant, les critères définissant les alertes doivent être bien définis ; un critère trop indulgent peut impliquer des ruptures non détectées et conduire ainsi à un risque sanitaire, un produit refusé par le client ou jeté car trop dégradé. D'un autre côté, un critère trop strict peut provoquer de fausses alertes et des actions correctives inutiles entraînant ainsi des coûts logistiques élevés. Il est intéressant de noter que les deux types de critères, indulgent et stricte, entraînent un coût supplémentaire ou un gaspillage alimentaire (par exemple pour les produits représentant un risque sanitaire et qui doivent être détruits en cas de détection de rupture). Dans le cas d'un critère indulgent, le gaspillage se ferait au détriment du consommateur, tandis que dans le cas d'un critère trop strict, le gaspillage se ferait au détriment des opérateurs de la chaîne. Par ailleurs, l'action mise en place à l'issue d'une alerte devrait être considérée dans le coût de la logistique. Par exemple, si une alerte implique de jeter toute une cargaison car le risque sanitaire est trop élevé, le coût d'une fausse alerte correspond au coût de produit perdu induit par cette décision. Si une alerte implique de réorienter une cargaison vers d'autres marchés (par exemple, des fruits vendus moins chers car destinés à être transformés), un coût logistique doit être pris en compte. En conclusion, pour définir un système d'alerte optimisant le gaspillage alimentaire, les risques sanitaires et les coûts logistiques, il est nécessaire de minimiser le nombre des alertes non détectées et des fausses alertes (Hafliðason et al. [2012]).

La détection et l'analyse des ruptures peuvent être effectuées en temps réel (Hafliðason et al. [2012]) ou a posteriori (Goedhals-Gerber and Khumalo [2018]). De nombreuses



études montrent que la température à l'intérieur d'un équipement frigorifique est hétérogène et qu'elle varie en fonction de la position (Laguerre et al. [2014], Lecoq et al. [2016], Chaomuang et al. [2019]). Pour avoir une meilleure connaissance de température, la solution idéale serait de la mesurer de tous les éléments du produit dans un équipement. Les progrès technologiques pourraient rendre cette solution possible à l'avenir par exemple grâce à l'utilisation de capteurs passif sous forme de pastilles comestibles collées sur le produit (Salvatore et al. [2017]). Cependant, à ce jour, cette solution est complexe à mettre en œuvre avec le coût élevé et le temps d'analyse des données important. Cela conduit à la question de savoir si la température mesurée à une position donnée peut être représentative de l'ensemble du chargement.

Comme cité précédemment, la température de l'air enregistrée est souvent utilisée pour l'analyse de la chaîne du froid en pratique, car elle est plus facile à mesurer que la température du produit. Cependant, la température de l'air fluctue au cours du fonctionnement classique du système de production de froid (cycles de "marche" et "arrêt" du compresseur) et au cours de dégivrage (compresseur en arrêt). Par conséquent, l'utilisation de la température de l'air à la place de celle du produit pour l'analyse de la rupture doit être plus étudiée.

En conclusion, pour mettre en œuvre un système efficace de détection des ruptures basé sur la mesure de température de l'air par des capteurs placés dans les palettes ou dans l'équipement, il convient d'abord de se concentrer sur une définition de rupture appropriée basée sur le type de produit et, ensuite, de développer une solution robuste permettant d'estimer la température du produit et son hétérogénéité dans un chargement. Enfin, lorsqu'une rupture est détectée, il est nécessaire, dans le cas où des actions correctrices sont effectuées (réorientation du circuit, baisse de la température dans un équipement...), de prendre en compte les coûts associés à ces actions. Par exemple, si le produit a une forte valeur en comparaison du coût de la mesure correctrice, il sera avantageux d'appliquer l'action correctrice. Dans le cas d'un produit à faible valeur, il n'est peut-être pas nécessaire de mettre en place d'action coûteuse.

## 1.2 Intelligence Artificielle (IA) et chaîne du froid : travaux existants

### 1.2.1 Prédire la température des produits en temps réel

Le tableau 1.1 présente des exemples d'applications de l'apprentissage automatique à la chaîne du froid. La température des produits, un facteur déterminant la qualité, est à estimer, car la mesure directe est invasive. Ainsi, l'estimation en temps réel la température des produits à partir d'un capteur mesurant la température d'air est un des enjeux de la chaîne du froid. Cette estimation est possible grâce à une approche basée sur l'Intelligence Artificielle (IA) qui nécessite des données d'entraînement pour des réseaux de neurones (Neural Network – NN). Ces données peuvent être générées expérimentalement en laboratoire. Par exemple, des produits réels ou fictifs dans un équipement sont instrumentés de capteurs de température de l'air et du produit. En effet, l'expérimentation réalisée dans une cellule d'essai à température ambiante contrôlée permet d'obtenir des données plus fiables que celles de terrain. Ainsi, cela permet d'avoir un label  $y$  fiable pour l'apprentissage. Nunes et al. [2014] a entraîné des réseaux neuronaux en utilisant la température ambiante enregistrée pour prédire la température du produit (des baies) sur une palette. Ces auteurs ont développé un NN capable de prédire la température du chargement à partir d'un seul capteur mesurant la température de l'air. Un modèle de qualité associé aux réseaux neurones a permis de prédire la durée de vie de produits. Badia-Melis et al. [2016] a entraîné des NN sur des données expérimentales pour estimer la distribution de la température du produit dans une palette conservée dans un équipement frigorifique. Les températures ont été enregistrées lors des conditions ambiantes diverses dans l'équipement, y compris les ruptures telles que les pannes. De meilleures performances ont été obtenues en utilisant les réseaux neuronaux artificiels. En effet, les réseaux neuronaux sont plus performants en termes de précision de prédiction pendant les périodes de panne par rapport à deux autres méthodes testées (Krigage et transfert thermique). De plus, les performances des réseaux neuronaux augmentent avec le nombre de capteurs disposés à différentes positions dans la palette. Les périodes de panne de l'équi-

pement étant celles qui ont le plus d'impact sur la qualité des produits, les réseaux de neurones se montrent avantageux pour détecter les ruptures. Ces deux études ont montré que l'utilisation des réseaux de neurones permettait d'obtenir de bonnes prédictions aussi bien dans des conditions de fonctionnement normal (avec froid) et de dysfonctionnement (panne) des équipements. Compte tenu de la précision de la prédiction de la température des produits avec les réseaux de neurones, une amélioration significative de la précision de la prédiction de la durée de vie restante des produits a été obtenue. Pour pallier le temps de l'instrumentation par des capteurs de température dans les équipements, une mesure sans contact par une caméra thermique peut être une alternative. Une caméra thermique permet d'estimer la température de surface des produits et non de l'air, avec l'avantage par rapport aux capteurs habituels de pouvoir mesurer la température à plusieurs positions en même temps. Badia-Melis et al. [2016] ont utilisé ces images thermiques en entrée d'un réseau de neurones pour estimer la température des produits (pommes) d'une cargaison entière (périphérie et centre). Les températures estimées par l'image thermique seule ont été comparées à celles estimées à l'aide de réseaux neuronaux et la différence maximale entre la prédiction et la valeur réelle était faible ( $0.7^{\circ}\text{C}$ ). L'utilisation d'une image thermique combinée à un réseau de neurones permet de prédire la température des produits tout en se limitant à une seule caméra. Mellouli et al. [2019] ont développé un réseau de neurones utilisant les conditions externes comme variables d'entrée telles que la température ambiante externe, la période d'effacement électrique (coupure anticipée de l'approvisionnement en électricité), le cycle de travail du compresseur pour prédire les températures de l'air et du produit dans l'équipement. L'objectif de cette étude était d'optimiser l'effacement des procédés de réfrigération de chambres froides. Cette étude a montré que les LSTM (NN particuliers) étaient adaptés à cette application. Le principal inconvénient de l'utilisation de données expérimentales pour entraîner des NN est qu'il est nécessaire de produire beaucoup de données avec des dispositifs expérimentaux complexe et parfois coûteux. Comme alternative, il est possible de générer des données de température par simulation grâce à un modèle thermique pour constituer une base de données (jeu de données) d'apprentissage. L'avantage de l'approche de simulation pour

produire des données de température est la possibilité de fixer la valeur des paramètres d'entrée de modèles, ceux-ci ont été précédemment développés, validés (en comparant la température prédite avec des valeurs expérimentales) et publiés. Parmi ceux-ci, on peut citer Mercier and Uysal [2018a]. Dans cette étude, les auteurs ont simulé des évolutions de températures de produits à partir d'un modèle thermique (implémenté avec le logiciel Comsol Multiphysics 5.1). Les températures à différentes positions ont été utilisées pour l'entraînement des réseaux de neurones dont les performances ont été évaluées. Ces auteurs ont constaté que le nombre de capteurs et leurs positions étaient des facteurs déterminant pour la précision de la prédiction de la distribution de la température dans une palette. Ceci serait dû au fait que plusieurs capteurs contiennent plus d'informations qu'un seul capteur. Ces auteurs ont également rapporté que la température dans certaines positions comme le haut de la palette contiennent plus d'informations que d'autres car l'influence des conditions ambiantes sur le produit à cette position est plus visible.

**TABLE 1.1** – Modèles d'apprentissages appliqués à la chaîne du froid

Modèles	Objectif	Type de données	Capteurs	Référence
Réseau de neurones	Prédiction des évolutions et tendances, contrôler les variations de température	Série Temporelle (Température)	RFID	Chen and Shaw [2011]
Réseau de neurones	Prédiction de température dans une palette à partir d'un capteur	Série Temporelle	-	Mercier and Uysal [2018a]
Réseau de neurones (BP)	Estimation de risques	-		Xu et al. [2014]
Réseau de neurones	Prédiction de température dans une palette	Image thermique	-	Badia-Melis et al. [2016]
Firefly algorithm	Minimisation automatique du risque	Géospatiales	Zigbee, RFID	Sichao Lu and Xifu Wang [2016]

Réseau de neurones	Prédiction de température dans une palette pour prédire la durée de vie restante des produits			do Nascimento Nunes et al. [2014]
Régression Logistique à noyau	Decision making support to Optimize quality with minimum cost	Température	RFID	Mohebi and Marquez [2014a]
Réseau de neurones, Kriging	Predict ambient temperature	Température	RFID	Badia-Melis et al. [2016]
Compressed Sensing	CO2 signal reconstruction	CO <sub>2</sub>	RFID, WSN	Draganic et al. [2017a]

### 1.2.2 Optimiser l'acquisition des données de température pour éviter la surcharge du réseau

Le Compressive Sensing (CS) est une technique de traitement du signal permettant d'acquérir, de comprimer et de reconstruire un signal en même temps, ainsi le nombre de mesures est réduit et la mémoire est optimisée. Dans le domaine médical, ce type de méthode est utilisé pour compresser et décompresser des images IRM. Dans cette application, le CS permet de réduire le nombre de mesures (images) à effectuer pour reconstituer l'image (comme le cerveau) avec précision. Ainsi, le temps d'acquisition est significativement réduit ou la précision de l'image est améliorée. Dans la chaîne du froid, l'image à reconstruire est la distribution de température (ou d'humidité) dans un équipement. Draganic et al. [2017b] a utilisé le CS dans la chaîne du froid de vin pour prédire les niveaux de CO<sub>2</sub>, en réduisant le nombre de mesures à effectuer pour éviter la surcharge de communication. Ils ont montré que le signal entier peut être reconstruit à partir de 45 % des mesures. Xiao et al. [2016] ont utilisé cette méthode (par le biais du système WSN) pour améliorer la prédiction de la durée de conservation du poisson frais dans la chaîne du froid. Lorsque le nombre de capteurs est élevé et qu'une analyse en

temps réel est nécessaire, le trafic de données devient dense et la prédiction de la durée de vie restante devient moins efficace. Dans ce cas, le CS fournit une méthode pour acquérir les données compressées et pour reconstruire la totalité des données. Autrement dit, le CS permet à chaque capteur de faire moins de mesures et ainsi l'alléger le trafic.

### **1.2.3 Gérer la demande dans une chaîne logistique en prenant en compte la qualité**

L'apprentissage automatique est utilisé dans le domaine de la logistique pour prédire la demande des clients et gérer les stocks en conséquence. Cette gestion est autant plus importante quand il s'agit de produits périssables. Mohebi and Marquez [2014b] utilisent une régression logistique à noyau pour une prise de décision en temps réel et il a été montré qu'elle permettait à la fois de réduire le coût logistique, mais aussi d'améliorer la qualité des produits.

Les méthodes présentées nous montrent le même intérêt : être capable de prédire la température de produit et d'estimer la durée de vie restante des produits à partir de la mesure de la température de l'air à l'aide d'un capteur. Ainsi se présentent deux défis : où placer ces capteurs ? Comment acquérir les données sans surcharger le trafic ? Les études présentées dans cette section ne traitent pas de la détection de rupture directement, probablement dû à la difficulté de trouver une définition universelle, et donc de labelliser les données.

## **1.3 Comment obtenir les données de la chaîne du froid pour l'apprentissage automatique ?**

Dans cette section, la circulation de l'air et la distribution de la température des équipements frigorifiques dans de nombreuses études expérimentales et numériques sont présentées. Dans l'ensemble, le potentiel et les limites de l'utilisation de ces données pour alimenter un algorithme capable de détecter et de caractériser les ruptures de température sont également discutés.

### 1.3.1 Données expérimentales

Dans la plupart des études expérimentales, le flux d'air et le champ de température dans les équipements frigorifiques sont étudiés simultanément en raison de l'interaction entre ces 2 phénomènes. La vitesse de l'air et la direction de l'écoulement dans les équipements vides et chargés sont souvent mesurés à l'aide d'un anémomètre à fil chaud (Duret et al. [2014]), de LDV (Laser Doppler Velocimetry, (Merai et al. [2018]; Pham et al. [2019]) ou de PIV (Particle Imagery Velocimetry, (Chaomuang et al. [2017])). Les températures de l'air et du produit sont en général mesurées à l'aide de thermocouples. Le plus souvent, le protocole expérimental consiste en une installation de l'équipement dans une salle d'essai dans laquelle la température ambiante (et parfois la vitesse et l'humidité) pendant l'expérience est contrôlée (Laguerre et al. [2013]). L'analyse des données obtenues permet de mieux comprendre les phénomènes de transfert thermique et d'écoulement d'air dans l'équipement étudié. Elle permet aussi de valider le modèle en comparant les valeurs expérimentales avec les valeurs prédites. Le domaine de la chaîne du froid a la possibilité de générer des données expérimentales utilisables par les algorithmes d'apprentissage automatique. Cependant, les données des études existantes citées précédemment ne peuvent pas être utilisées telles quelles pour l'analyse des ruptures de la chaîne du froid car les expériences ont été menées sous le régime de fonctionnement normal du système de production de froid. Il est nécessaire de développer un dispositif expérimental spécifique des ruptures de la chaîne du froid pour générer des données. Il consiste à soumettre un produit à une ambiance chaude pendant une période donnée et à suivre l'évolution de la température du produit en fonction du temps. Il est à rappeler que l'augmentation du nombre de capteurs de température et le choix de la position des capteurs dans le dispositif sont les facteurs déterminants de la précision de la prédiction. Récolter des données sur le terrain, est une autre façon d'obtenir des données. Habituellement, des capteurs de températures sont placés dans une palette ou sur/dans un produit et on suit cette palette ou ce produit dans des maillons de la chaîne. Le Tableau 1 montre les études terrain sur les ruptures de la chaîne du froid de différents produits. L'inconvénient de ces données terrain est que les conditions de mesure sont inconnues

par exemple, la position du produit instrumentée dans l'équipement et le maillon où le produit est situé à l'instant  $t$  sont inconnus. L'avantage est que ce sont des données réelles, et donc réalistes. Selon le type de capteur, sans fil ou non, les données récoltées contiennent différentes informations. Deux types de capteurs prédominent : enregistreur de température (data loggers) à utilisation unique ou réutilisables et capteurs sans fils (cf. section 1.1.2.2). Derens et al. [2006] et Goedhals-Gerber and Khumalo [2018] placent des enregistreurs de température dans le produit et le consommateur en fin de chaîne les retourne au laboratoire pour une analyse. Seule la température du produit est connue et non pas celle de l'air. Comme la mesure est destructive (le produit instrumenté devait être jeté après) et pour éviter les coûts importants de l'enquête, un faible nombre de produits a été instrumenté. Ainsi, la perte du capteur implique la perte des données. dans cette étude, le taux de retour des capteurs était de 60% Derens et al. [2006]. Gogou et al. [2015] ont utilisé ces données de terrain pour construire une base de données des distributions de température et des durées de séjour de produits dans des équipements constituant la chaîne du froid. Les capteurs sans fil décrits dans la section 1.1.2.2 permettent à la fois d'obtenir plus d'informations comme la position et de transmettre des données en quasi-temps réel. De plus, la perte du capteur n'implique pas la perte des données. Cette arrivée de capteurs va vraisemblablement faciliter les études terrain comme Frank et al. [2019b], qui ont publié ces données publiques via des data papers. Leurs données publiées sont plus complètes : elles contiennent la température, la position, le maillon de la chaîne. En effet, les données de terrain sont indispensables, mais souvent incomplètes. Elles ne permettent pas, par exemple, de connaître la température à toutes les positions dans un équipement.

### 1.3.2 Données synthétiques

En guise d'alternative à l'expérimentation, la Computational Fluid Dynamics (CFD) ou d'autres approches de modélisation simplifiées peuvent être utilisées pour générer des données sur le changement de température des produits exposés à différents scénarios de rupture de la chaîne du froid. Les géométries des modèles CFD étaient simplifiées il



y a quelques années en raison de limitations numériques (Nahor et al. [2005], Verboven et al. [2006], Hoang et al. [2015]), mais l'augmentation des puissances de calcul permet d'avoir des géométries plus réalistes telles que des emballages de fruits dans les cartons (O'Sullivan et al. [2017]). De plus, en combinant la tomographie à rayons X avec les modèles CFD, il est désormais possible d'inclure la forme du produit et la variabilité du motif de remplissage dans les modèles (Gruyters et al. [2018, 2020]). Les modèles CFD sont capables de calculer l'évolution de la température du produit dans une palette dans des différents équipements de la chaîne du froid (Wu et al. [2018]) et fournissent une distribution détaillée de la température. Cependant, cette approche nécessite des ordinateurs puissants, car le temps de calcul peut durer plusieurs jours et des connaissances d'expert en mécanique des fluides. Ceci explique la limite de son application à l'apprentissage automatique à ce jour. Ambaw et al. [2021] présente les modèles CFD développés dans le cadre de projets académiques ou de collaborations industrielles. Une solution pour surmonter la complexité des modèles CFD est de développer des modèles simplifiés basés sur une approche zonale. Ces modèles, qui sont également basés sur la physique, permettent de prédire en quelques secondes la température du produit dans différentes zones d'un équipement frigorifique (Laguerre et al. [2014], Lecoq et al. [2016], Chaomuang et al. [2019]). Les modèles simplifiés apportent une description moins détaillée, mais permettent de générer des données de température des produits dans de nombreux scénarios temps-température qui peuvent être utilisés pour entraîner les modèles d'apprentissage automatique.

## 1.4 Synthèse de l'étude bibliographique

La maîtrise de la température dans la chaîne du froid est essentielle pour réduire les pertes alimentaires et les risques sanitaires, et pour garantir la qualité des produits au consommateur. La pratique actuelle du contrôle de la température est complexe en raison de l'hétérogénéité de la température dans les équipements frigorifiques. Des travaux ont montré l'avantage de l'utilisation de méthodes d'apprentissage automatique pour pré-

dire les températures d'un chargement en fonction de la mesure de la température de l'air à une position donnée. De plus, du fait des nombreuses études expérimentales et des nombreux modèles développés pour décrire les transferts de chaleur dans les différents équipements de la chaîne du froid, de nombreuses données sont déjà disponibles et d'autres données pourraient être générées afin d'entraîner ces modèles d'apprentissage. De fait, l'utilisation des méthodes d'apprentissage automatique, montrant de bonnes performances pour prédire la température des produits, semble tout à fait pertinente dans le domaine de la chaîne du froid. Malgré les études existantes permettant de prédire la température des produits à partir d'un capteur de température placé dans un chargement, à notre connaissance, aucun modèle d'apprentissage automatique n'a été développé pour détecter les ruptures en temps réel, alerter les opérateurs et mettre en place des mesures correctrices dans le but de préserver les qualités des produits et réduire le gaspillage alimentaire causé par les ruptures. Dans cette synthèse bibliographique, nous avons mis en évidence que pour construire une telle approche, il est dans un premier temps nécessaire de définir précisément la notion de rupture et de développer un dispositif robuste permettant de minimiser les fausses alertes et les ruptures non détectées. Enfin, la prise de décision doit inclure les coûts engendrés par les actions correctrices afin d'optimiser les coûts associés au gaspillage par rapport aux coûts associés à la mise en œuvre des mesures correctrice.

Les capteurs de température sans fil et la transmission de données devraient être largement utilisés dans les chaînes du froid et fournir une grande quantité de données. Les systèmes d'alerte automatiques pourront ainsi prendre en compte la variabilité des évolutions de la température et de la qualité des produits au sein d'un équipement. Par ailleurs, il deviendra possible de classer les ruptures en fonction de leur cause : transfert de produit entre deux maillons d'une chaîne du froid en exposant le produit à une température ambiante trop élevée ou mauvais réglage de la température de consigne dans un équipement frigorifique. Cela permettrait de mettre en place des actions correctrices appropriées.

## 1.5 Conclusions et questions de recherche traitées dans ce manuscrit

L'état de l'art a montré que la détection des ruptures dans la chaîne du froid peut être abordée différemment selon le type de produit. Dans le cas des produits dont la température est réglementée, la définition des ruptures peut être abordée en définissant un seuil de température (par exemple : la température réglementaire du produit). Dans ce cas, il est important de connaître avec précision la température du chargement dans son ensemble à partir d'une mesure à une position donnée. Cet aspect a déjà été étudié dans la littérature comme discuté dans la section 1.2.1. Cependant, dans chacune de ces études, un seul type de données a été utilisé pour l'apprentissage (expérimental et synthétique). Chaque type de données présente des avantages et des inconvénients. Les données expérimentales sont plus précises, mais aussi plus difficiles à produire, car elles nécessitent un dispositif expérimental important et des temps longs pour produire suffisamment de données. Les données synthétiques ont l'avantage de pouvoir être générées rapidement à partir de modèles numériques (validés avec des données expérimentales). Cela offre la possibilité de générer rapidement des données selon différents paramètres (vitesse et direction de l'air, propriétés thermiques des produits, ajoutage des cagettes...). Cependant, comme pour tout modèle, les données générées présentent une incertitude. Cet aspect soulève un certain nombre de questions :

1. Quel est l'impact de l'incertitude des données d'apprentissage synthétiques sur les températures prédites par les modèles d'apprentissage automatique ?
2. Comment évaluer les performances d'un modèle d'apprentissage automatique entraîné avec données synthétiques ?

Ces questions sont abordées dans le chapitre 2. Les aspects traités dans ce chapitre sont importants afin de développer une méthodologie la plus robuste possible pour entraîner des modèles permettant de prédire précisément les températures des produits à partir d'une position donnée.

À l'inverse, pour les produits de type fruits et légumes, les températures des produits

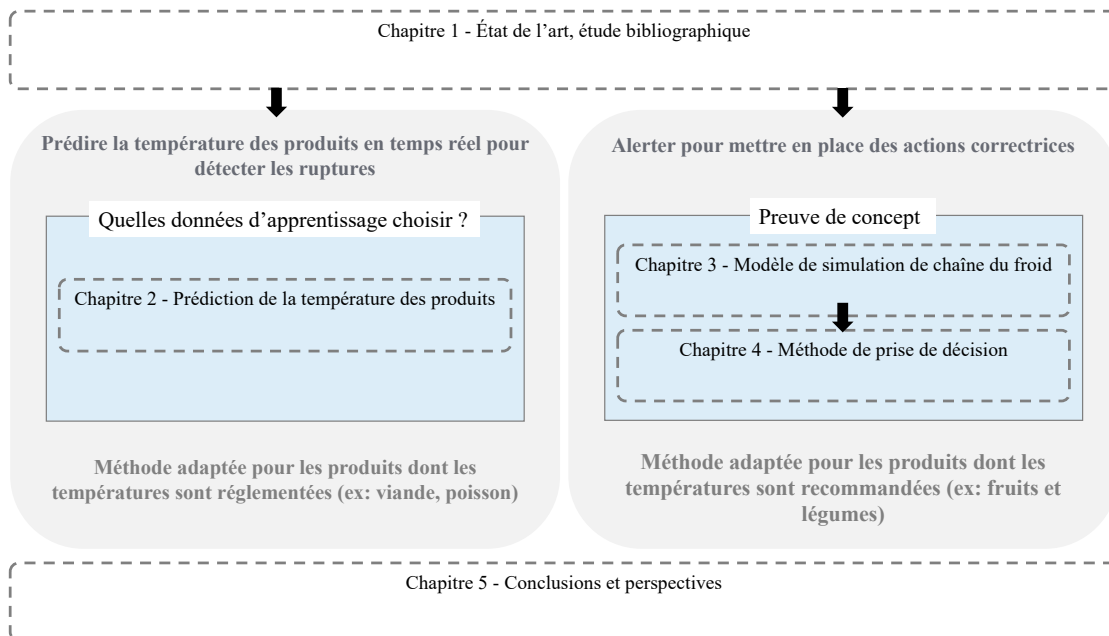
ne sont plus réglementées, mais recommandées. Dans ce cas, la définition d'une rupture est plus ambiguë, car elle est liée à la qualité organoleptique du produit. Le paramètre essentiel n'est plus la température des produits mais que les produits soient livrés au client avec les qualités organoleptiques attendues. Lorsqu'une excursion de température est détectée, cela n'implique pas forcément que le produit sera dégradé à la livraison. Il est encore possible de mettre en place une ou plusieurs actions correctrices afin de garantir les qualités organoleptiques des produits au moment de la livraison. Cependant, afin d'optimiser les coûts, le coût de l'action correctrice ne doit pas dépasser les coûts associés à la perte des produits. De plus, afin de limiter les coûts, il est important de minimiser les fausses alertes et les alertes non détectées. Le système le plus simple pour détecter une rupture est de fixer un seuil de température et de mettre en place une action correctrice à chaque fois que la température cible est dépassée. Toutefois, le risque d'une telle approche est d'avoir un grand nombre fausses alertes. Une autre approche pourrait être de définir un seuil d'alerte comme étant le dépassement d'une température cible pendant une durée donnée (par exemple : 8°C pendant 30 min), dans ce cas, le risque serait de ne pas détecter la dégradation prématurée des produits en cas de répétition des hausses des températures pendant des faibles périodes (<30 min, transfert lors du déchargement, cycle frigorifique, dégivrage...). Comme alternative, nous avons proposé dans ce travail de thèse une méthode de détection basée sur les méthodes de classification qui, à partir de la mesure de la température de l'air en continu le long de la chaîne du froid, prédit la probabilité pour les produits d'être livrés avec les qualités organoleptiques attendues ou non. L'avantage d'utiliser un classifieur par rapport aux autres méthodes est qu'il peut prendre en entrée plusieurs variables comme la position du produit dans la chaîne du froid, l'historique de la température mesurée dans la chaîne du froid, la température extérieure... À notre connaissance, aucune étude n'a encore été réalisée sur la mise en place d'une telle approche. Pour réaliser la preuve de concept de cette nouvelle approche, nous avons construit une chaîne du froid fictive. Un modèle de simulation de la chaîne du froid d'un produit générique est proposé dans le chapitre 3. Ce modèle permet de prédire l'évolution de la température et de la qualité des produits dans une chaîne

du froid composée de quatre maillons. Le modèle de détection des ruptures basé sur la classification pour la prise de décision est développé dans le chapitre 4. Les résultats de cette approche sont également présentés dans ce chapitre 4.

Pour résumer, ce manuscrit de thèse est organisé autour de deux axes pour la détection des ruptures dans la chaîne du froid :

1. Prédiction de température des produits à partir de la température de l'air
2. Détection de ruptures en temps réel de la chaîne du froid pour mettre en place des actions correctrices

La figure 1.3, présente à la fois l'organisation du manuscrit et les applications possibles des modèles d'apprentissages développés.



**FIGURE 1.3** – Organisation du manuscrit

## Chapitre 2

# Prédiction de la température des produits

Dans ce chapitre, les modèles d'apprentissage automatique pour prédire la température des produits dans un niveau de palette à partir de la température de l'air sont présentés. La température de l'air peut être, selon les cas, mesurée à une ou plusieurs positions. Deux jeux de données, un expérimental et un synthétique, ont été générés pour une même configuration de palette afin d'entraîner des modèles d'apprentissage. La figure 2.1 présente l'organisation de ce chapitre. Les deux sources de données sont décrites, puis la génération des deux jeux de données est détaillée. Ensuite, l'entraînement des réseaux de neurones est expliqué, ainsi que la procédure d'évaluation de ces modèles pour comparer les données.

Dans un premier temps, nous présentons la méthodologie mise en place pour comparer les jeux de données. Cela inclue :

- La configuration étudiée, le dispositif expérimental et le modèle thermique développé pour générer les deux jeux de données.
- Les différentes méthodes de régression et réseaux de neurones utilisés.
- Les différents profils de température générés pour les deux jeux de données
- La méthode utilisée pour évaluer les performances des modèles entraînés.

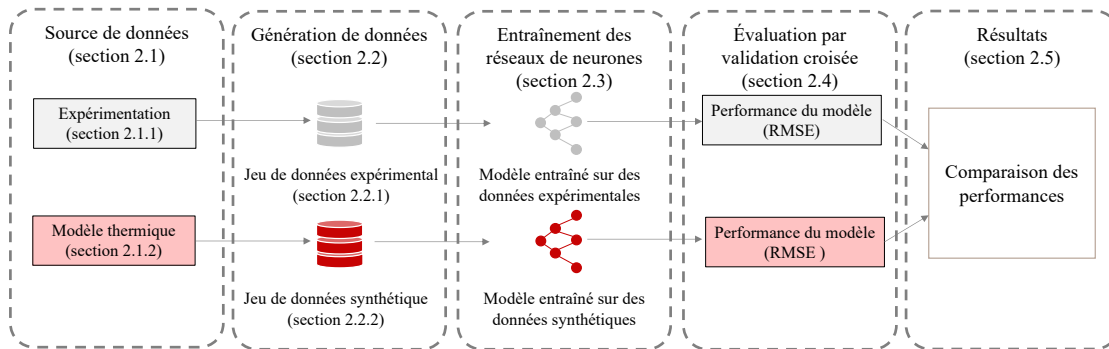


FIGURE 2.1 – Organisation du Chapitre 2 - Prédiction de la température des produits

Dans un second temps, nous présentons les résultats obtenus en discutant :

- L'impact de la position du capteur de température de l'air sur la précision de la prédiction de la température de produit.
- Les performances des modèles d'apprentissage automatique entraînés avec les deux jeux de données.
- Les stratégies pouvant être mises en œuvre pour optimiser les performances des modèles d'apprentissage automatique lorsque seules des données synthétiques sont disponibles.

## 2.1 Matériel et Méthodes

### 2.1.1 Expérimentation

#### 2.1.1.1 Choix de l'équipement

Pour simplifier l'étude expérimentale, un seul niveau intermédiaire de palette a été étudié (Figure 2.2). En effet, à part le niveau supérieur et inférieur de la palette, les autres niveaux des palettes ont généralement des profils de température assez similaires. Un dispositif expérimental représentant le niveau d'une palette (1.2 m de long, 1 m de large et 0.1 m de haut) a donc été construit et installé dans une salle d'essai à température contrôlée de  $29\text{ m}^3$  (3.4 m de long, 3.4 m de large et 2.5 m de haut).




FIGURE 2.2 – Représentation schématique d'un niveau de palette

#### 2.1.1.2 Choix du produit

Les pommes ont été choisies pour l'expérience, car ce sont des fruits résistants. Cela a permis de réaliser des expérimentations pendant plusieurs semaines et ainsi obtenir des profils de température selon plusieurs scénarios de temps-température ambiante avec les mêmes produits. De plus, leur forme simple peut être assimilée à une sphère, ce qui a facilité l'implémentation d'un modèle thermique du dispositif. Une autre possibilité aurait été d'utiliser des fruits fictifs, par exemple, des sphères en plastique remplis du gel carraghénane disponibles au laboratoire de FRISE. Toutefois, ces sphères ont le diamètre



plus grand (0.08 m), cela aurait limité les variations de température des produits lors des différents scénarios que nous souhaitions étudier. Le choix s'est donc porté sur les pommes RubINETTE, dont le calibre est petit, de masse moyenne de 120 g et de diamètre moyen de 0.064 m. Cela nous a permis une mise en place du dispositif expérimental rapide et d'obtenir des variations de température de produit importantes.

### 2.1.1.3 Description du dispositif

Le dispositif est constitué de huit caisses remplies de 28 pommes chacune pour représenter un niveau d'une palette. Deux plaques de polystyrène (5 cm d'épaisseur) ont été placées au-dessus et en dessous des caisses pour les isoler, ainsi les résultats obtenus peuvent représenter les niveaux intermédiaires d'une palette.

La figure 2.3 représente le dispositif expérimental vu de profil. L'air est aspiré à travers le dispositif par trois ventilateurs situés à la sortie du dispositif et permettant un flux d'air unidirectionnel stable. Les parois latérales étant fermées, l'air circule seulement dans l'espace situé au-dessus des caisses. Le dispositif est constitué de deux entrées d'air, une entrée d'air froide provenant de la salle d'essai à température contrôlée. Une entrée chaude dont l'air est chauffé avant l'entrée dans le dispositif à l'aide de trois résistances électriques de 500 W chacune. La puissance de chauffe des résistances est contrôlée par un alternostat (variateur de tension). Ainsi, la température de l'air d'entrée est modifiable instantanément en faisant basculer un volet à différents moments pour alterner entre l'air froid et l'air chaud. Le dispositif permet donc de simuler des changements brusques (par exemple, exposition rapide à l'air ambiant lors du déchargement d'un camion) et des changements plus lents (par exemple, changement de consigne d'une chambre froide ou panne). Grâce à ce dispositif, un grand nombre de profils de temps-température de l'air d'entrée ont été générés pour représenter différents scénarios d'une chaîne logistique.

Les températures ont été mesurées avec des thermocouples de type T préalablement étalonnés à 0°C, 10°C, 20°C, 30°C et 40°C (précision +/- 0.2°C). Ces thermocouples ont été placés à cœur des pommes, et dans l'air environnant. La figure 2.4 représente le dispositif expérimental vu de dessus : 16 pommes, soit 2 pommes par caisse, ont été

instrumentées. De plus, un thermocouple a été placé à l'entrée de l'appareil pour mesurer la température de l'air d'entrée.

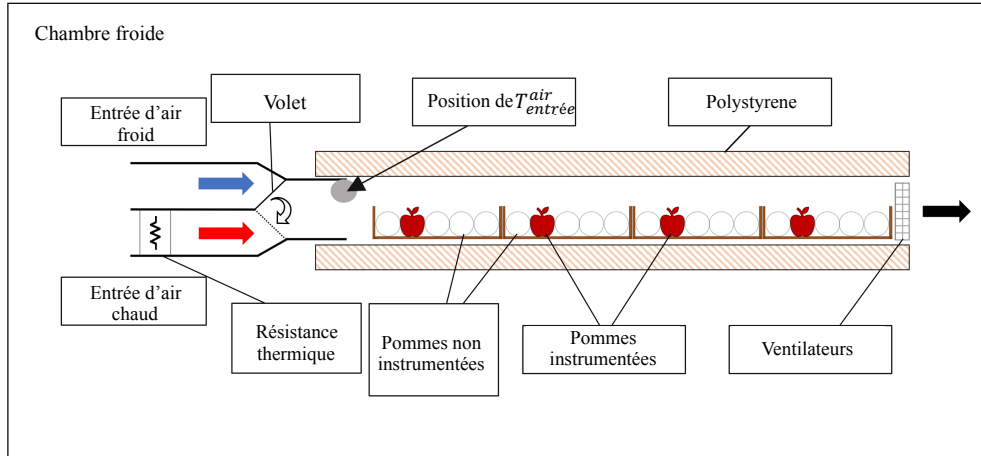


FIGURE 2.3 – Dispositif expérimental vu de profil

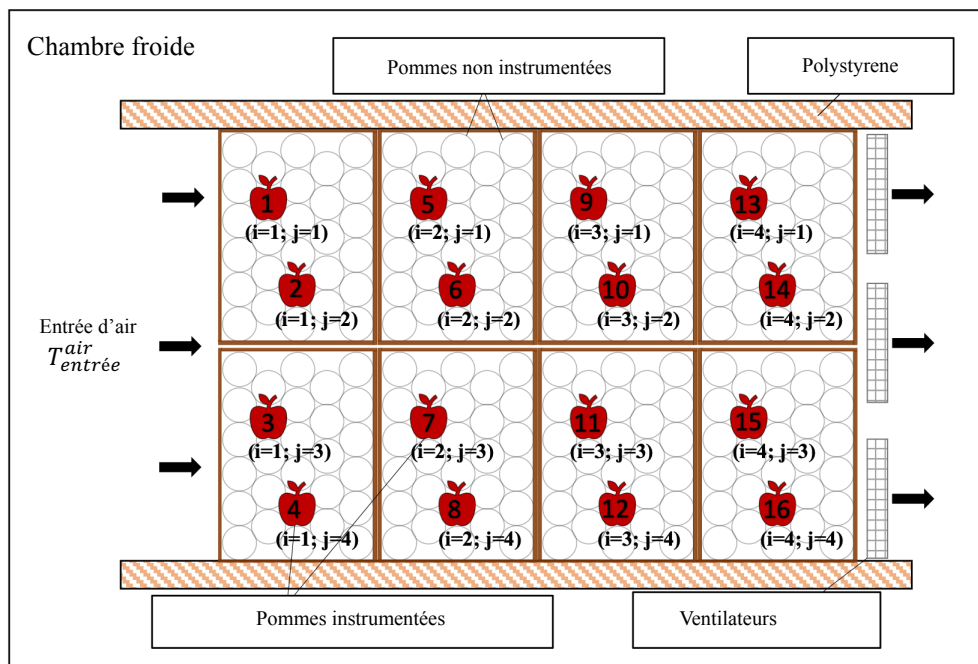


FIGURE 2.4 – Dispositif expérimental vu de dessus : pour le calcul des transferts thermiques, les zones de la palette sont indicées par  $i, j$ . Pour l'apprentissage, les zones sont indicées par  $z$  allant de 1 à 16.

Dans chaque expérience, la température initiale est homogène dans le niveau de palette, mais elle peut être différente en fonction des 10 scénarios étudiés (voir section 2.2). Les températures ont été enregistrées toutes les 20 secondes pendant 12 heures pour chaque scénario. La vitesse de l'air a été fixée à  $0.2 \text{ m s}^{-1}$  à l'entrée de la palette pour toutes les expériences, elle correspond à la valeur souvent observée autour des palettes dans les équipements frigorifiques tels que chambres froides et camions frigorifiques.

### 2.1.2 Modèle thermique

Un modèle thermique a été développé pour prédire les températures de l'air et du produit aux mêmes positions de mesure dans le dispositif expérimental. Le profil de température de l'air à l'entrée du dispositif est utilisé comme paramètre d'entrée du modèle pour prédire les températures du produit, appelées données synthétiques. Le modèle est basé sur une approche zonale qui considère qu'une caisse est composée de 2 zones. Chaque zone est caractérisée par une température d'air et une température à cœur de produit. Ainsi, un niveau de palette est composé de 16 zones correspondant aux 16 pommes instrumentées dans le dispositif expérimental.

#### 2.1.2.1 Calcul de la température de l'air

Seul l'échange thermique convectif entre l'air et le produit a été considéré. En effet, la chaleur latente due à l'évaporation de l'eau est faible comme montré dans une précédente étude dans la même configuration (Duret et al. [2014]), ainsi, elle a été négligée. Le rayonnement a aussi été négligé car l'évolution de la température des parois du dispositif est assez similaire à celle de la surface des produits. Le principe de fonctionnement du modèle pour le calcul de la température de l'air dans les différentes zones de la palette est le suivant : A l'instant  $t$ , l'air entrant de température  $T_{entree}^{air}$  échange avec le produit dans la zone 1 (avec un coefficient de transfert de chaleur convectif  $h$ ), ce qui donne la sortie d'air de  $T_{1,1}^{air}$ , qui est l'air entrant de la zone 2, qui va échanger avec le produit de la zone 2, et ainsi de suite. La généralisation de l'équation de bilan thermique sur 16

zones est présentée comme suit :

$$\dot{m} \times Cp^{\text{air}} \times (T_{i,j,t}^{\text{air}} - T_{i-1,j,t}^{\text{air}}) + h \times S \times (T_{i,j,t}^{\text{air}} - T_{i,j,t}^{\text{surface}}) = 0 \quad (2.1)$$

Avec

- $\dot{m}$ , le débit massique de l'air ( $\text{kg s}^{-1}$ )
- $Cp^{\text{air}}$  la capacité thermique de l'air ( $\text{J kg}^{-1} \text{ } ^\circ\text{C}^{-1}$ )
- $T_{i,j,t}^{\text{surface}}$  la température de surface du produit en zone  $i, j$  ( $^\circ\text{C}$ )
- $T_{i,j,t}^{\text{air}}$  la température de l'air en zone  $i, j$  ( $^\circ\text{C}$ )
- $S$  la surface du produit ( $\text{m}^2$ )
- $h$  le coefficient de transfert de chaleur par convection entre l'air et la surface du produit considéré comme constant dans toutes les zones

Le coefficient d'échange convectif  $h$  a été identifié en minimisant la somme des carrés des erreurs sur un profil indépendant (un refroidissement de  $20^\circ\text{C}$  à  $4^\circ\text{C}$ ) et un  $h$  de  $5 \text{ W m}^{-2} \text{ } ^\circ\text{C}^{-1}$  a été obtenu. Cette valeur est cohérente à celle obtenues dans d'autres études expérimentales dans conditions similaires (Duret et al. [2014]).

### 2.1.2.2 Calcul de la température des produits

Pour simplifier, une pomme a été considérée comme une sphère sans production de chaleur dû à la respiration et avec une diffusivité thermique constante  $\alpha$  ( $\alpha = 1.1 \times 10^{-7} \text{ m}^2 \cdot \text{s}^{-1}$ ). À l'intérieur d'un produit, le transfert de chaleur par conduction dans la direction radiale a été considérée (modèle 1D). L'équation de conduction thermique en régime transitoire en coordonnées radiales est :

$$\frac{1}{\alpha} \frac{\partial T}{\partial t} = \frac{1}{r^2} \frac{\partial}{\partial r} \left( r^2 \frac{\partial T}{\partial r} \right) \quad (2.2)$$

Pour les conditions aux limites, une symétrie thermique a été considérée pour le cœur du produit

$$-\lambda \frac{\partial T}{\partial r} \Big|_{r=0} = 0 \quad (2.3)$$

Pour la surface :

$$-\lambda \left. \frac{\partial T}{\partial r} \right|_{r=R} = h (T^{air} - T^{surface}) \quad (2.4)$$

La méthode FTCS (Forward Time Centered Space, Thibault et al. [1987]) a été utilisée pour résoudre ces équations.

Ainsi, on peut calculer les températures de cœur des produits dans chaque zone, notées  $T_{i,j,t}^{cœur}$ , à partir de la température de l'air.

Dans la suite de ce chapitre, les zones de la palette ne seront plus indicées par  $i, j$  mais par un indice  $z$ , avec  $z$  allant de 1 à 16 ( $T_{1,1,t}^{cœur}$  deviendra  $T_{1,t}^{cœur}$ ).

### 2.1.3 Comment prédire la température : un problème de régression

Prédire la température des produits en temps réel un des enjeux de la chaîne du froid. Cependant, les modèles thermiques CFD qui décrivent les transferts de chaleur au sein d'un équipement sont complexes et leur temps de calcul peut s'élever l'ordre de plusieurs jours. Les méthodes d'apprentissage pourraient, quant à elles, offrir une estimation des températures des produits en temps réel.

Les méthodes d'apprentissage supervisé apprennent une fonction entre les variables d'entrée  $\mathbf{x}$  et la variable cible  $y$  à partir d'un échantillon de telles correspondances  $\mathcal{D} = (\mathbf{x}_i, y_i)_{i \in [1, m]}$  où  $m$  est la taille de l'échantillon. Le but de l'apprentissage supervisé est d'apprendre une fonction  $f$  capable de décrire les relations (linaires ou non) entre les variables d'entrée  $\mathbf{x}$  et la variable de sortie  $y$ . On parle d'une tâche de *classification* lorsque la variable de sortie  $y$  est discrète (*ok/-ok*, couleur, classe, chien/chat etc.). Dans ce cas,  $f$  est appelée un *classifieur*. Lorsque la variable de sortie  $y$  est continue (température, énergie), on parle d'une tâche de *régression*. Pour ces deux tâches, de nombreuses techniques ont été appliquées, souvent avec succès, dans un large éventail de domaines d'application.

Dans le domaine de la chaîne du froid, la classification pourrait correspondre à la prédiction qu'une rupture s'est produite ou non, tandis que la régression pourrait correspondre à la prédiction de la température d'un produit alimentaire à partir de la tempé-

rature de l'air. Le défi est de pouvoir apprendre une fonction qui s'applique à toutes les données d'entrée à partir d'un nombre limité d'exemples d'apprentissage. Dans ce chapitre,  $y$  est la température du produit, une variable continue, il s'agit donc d'une tâche de régression.

#### 2.1.4 Méthodes de régression et réseaux de neurones artificiels

Les méthodes de régression font référence à l'ensemble des méthodes statistiques permettant d'estimer la fonction  $f$  qui modélise les relations entre une variable de sortie  $y$  (continue) et les variables d'entrée  $\mathbf{x}$ . De nombreuses méthodes de régression ont été développées dans la littérature, allant des méthodes statistiques les plus courantes comme la régression linéaire, aux méthodes d'apprentissage comme les réseaux de neurones. Nous présentons dans ce chapitre le Perceptron multicouche (Multilayer Perceptron - MLP), un réseau de neurone.

Un Perceptron multicouche est un réseau de neurones composé de neurones artificiel, connecté entre eux. Le principe de fonctionnement d'un neurone artificiel (Figure 2.5) est le suivant :

1. prend en entrées les données  $\mathbf{x} = x_1, x_2, \dots, x_n$  et un biais  $b$
2. fait une somme pondérée de ces entrées avec les poids  $w_0, w_1, w_2, \dots, w_n$
3. applique une fonction non linéaire  $\varphi$  à cette somme

La sortie de ce neurone est donc  $\varphi(\sum_{j=1}^n x_j w_j + b w_0)$ .

Les poids associés à chaque entrée permettent d'accorder une importance plus ou moins grande à chaque variable d'entrée. La fonction non linéaire  $\varphi$ , appelée *fonction d'activation*, peut être différente selon les cas et doit être adaptée au problème que l'on souhaite résoudre. Quelques exemples de fonctions d'activation :

— Unité de rectification linéaire (ReLU) :


$$\varphi(x) = \begin{cases} x & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad (2.5)$$

— Identité :

$$\varphi(x) = x \quad (2.6)$$

— Logistique (ou sigmoïde) :

$$\varphi(x) = \frac{1}{1 + e^{-x}} \quad (2.7)$$



**FIGURE 2.5** – Principe de fonctionnement d'un neurone artificiel

On note  $\mathbf{x}$  un vecteur d'entrées  $x_1, \dots, x_n$ , et  $\mathbf{x}_i$  un  $i$ -ème exemple de ce vecteur et  $y_i$  son label associé. Pour un ensemble d'apprentissage  $\mathcal{D} = (\mathbf{x}_i, y_i)_{i \in [1, m]}$  donné, l'algorithme du Perceptron est un algorithme itératif qui détermine les poids  $w_j$  de ce neurone et le biais  $b$  de façon à minimiser l'erreur entre la valeur prédite par le neurone (sortie)  $\hat{y}_i$  et la valeur dans le jeu de données d'apprentissage  $y_i$ .

Plusieurs de ces neurones peuvent être connectés sur plusieurs couches et ainsi former un Perceptron multicouche. Dans cette extension du Perceptron, chaque neurone de chaque couche prend en entrée les sorties des neurones de la couche précédente. La figure 2.6 présente le fonctionnement d'un réseau de neurones à deux couches cachées de tailles  $k$  et  $l$  : cette architecture est notée  $(k, l)$ . On note  $a_0^1$  le premier neurone de la première couche. Chaque neurone de la couche d'entrée prend en entrée les données  $x_1, x_2 \dots x_n$ . Ensuite, chaque neurone de la première couche cachée applique une somme pondérée de

ces entrées + un biais  $b_1^0$  avec les poids correspondants  $(w_{11}^1, w_{12}^1 \dots w_{k1}^1)$ , et y applique la fonction d'activation  $\varphi$ . Ainsi, en sortie de ce neurone on aura

$$\varphi\left(\sum_j x_j w_{1j}^1 + b_1^0 w_{10}^1\right) \quad (2.8)$$

Parallèlement le deuxième neurone de cette couche va effectuer le même procédé et sortir

$$\varphi\left(\sum_j x_j w_{2j}^1 + b_1^0 w_{20}^1\right) \quad (2.9)$$

Le neurone de la deuxième couche va alors prendre en entrée ces deux sorties

$$\varphi\left(\sum_{i=1}^k w_{ij}^2 \times \varphi\left(\sum_{j=1}^n x_j w_{ij}^1 + b_j^0 w_{j0}^1\right)\right) \quad (2.10)$$

Et ainsi de suite.

Plusieurs fonctions d'activations peuvent être utilisées pour chacune des couches du Perceptron Multicouche.

En réalité, cette architecture complexe n'est qu'une fonction dépendant des vecteurs de poids non linéaire  $W = \{w_{i,j}^k\}$ , des biais  $B = \{b_i^k\}$ , qui prend en entrée les données  $x_1, x_2 \dots x_n$ . Le but de l'algorithme du Perceptron multicouche est de trouver les paramètres  $W$  et  $B$  de cette fonction qui permettront de prédire au mieux la sortie  $y$  du réseau. L'algorithme du Perceptron multicouche est un algorithme itératif qui permet d'estimer  $W$  et  $B$  pour minimiser une perte (erreur) préalablement définie. Dans le cas de la régression,  $y$  est un réel et une perte adaptée est la perte au carré. Si on note  $\hat{y}$  la sortie du Perceptron multicouche, autrement dit la prédiction du réseau, la perte au carré  $L$  est

$$L(y, \hat{y}) = (y - \hat{y})^2 \quad (2.11)$$



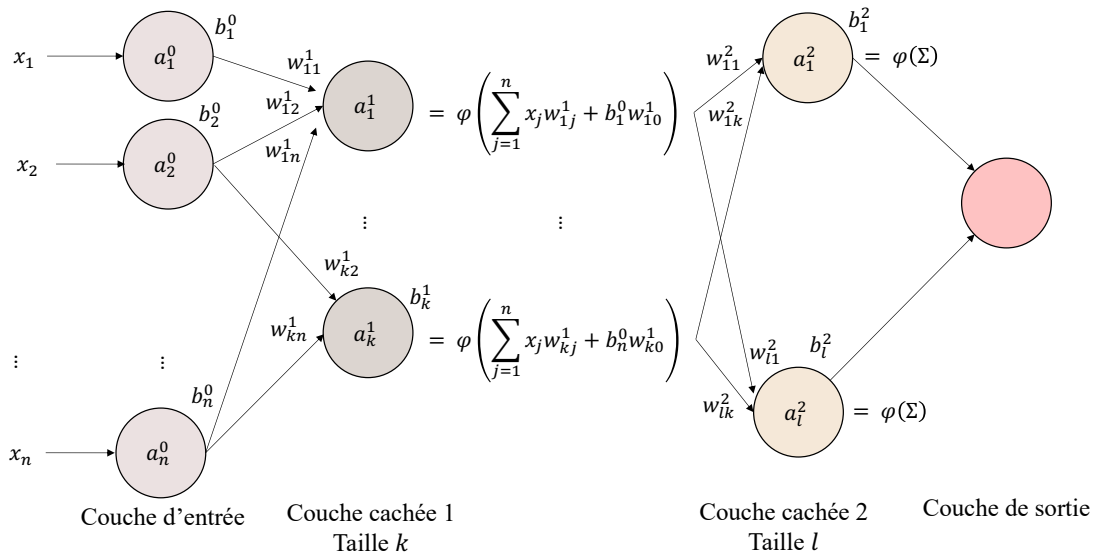


FIGURE 2.6 – Principe de fonctionnement d'un Perceptron multicouche

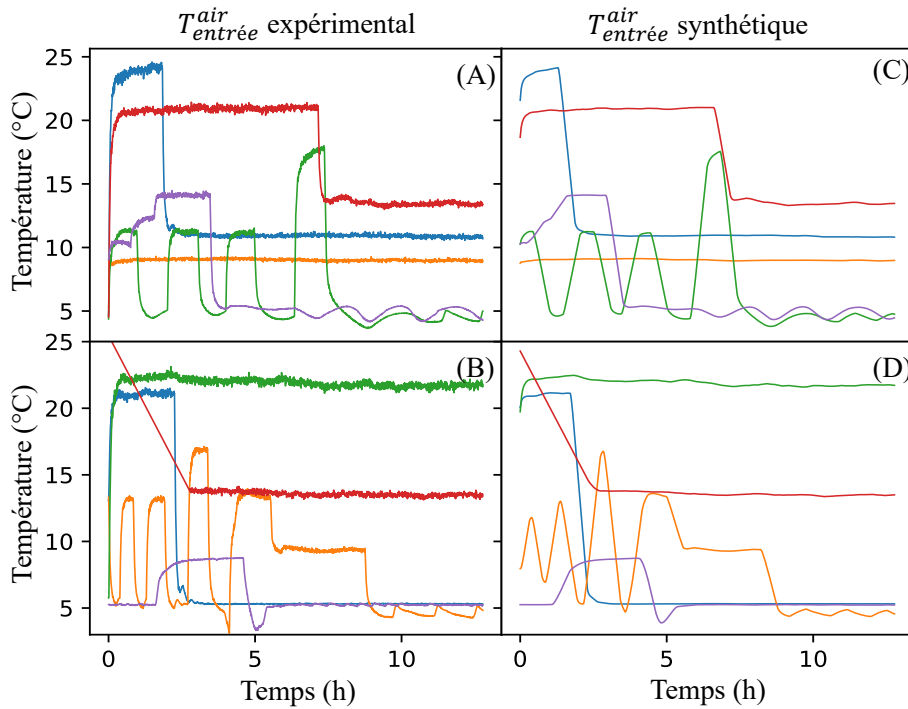
## 2.2 Données d'apprentissage et génération de données

### 2.2.1 Jeu de données expérimental

Dix profils de la température de l'air d'entrée ont été créés en utilisant le dispositif expérimental pour représenter 10 scénarios de la chaîne du froid (5 scénarios dans Figure 2.7 A & B) pour une durée fixe de 12 h chacun. Ces scénarios ont été construits en combinant des événements successifs de refroidissement et de réchauffement de la température de l'air d'entrée pour représenter ceux observés dans des situations réelles, par exemple le chargement/déchargement de produits dans un équipement frigorifique, les fluctuations de température dues aux cycles marche/arrêt du compresseur, le dégivrage pendant lequel le compresseur est éteint, le transfert de produits d'un équipement frigorifique à un autre dans lequel les températures de consigne sont différentes. La moyenne et l'écart type de la température de l'air d'entrée dans ces scénarios étaient différents afin de représenter autant que possible les conditions réelles. Il est à souligner que pour un scénario, la température de cœur du produit et la température de l'air dans 16 zones du dispositif expérimental ont été générées.

### 2.2.2 Jeu de données synthétiques

Les profils de température d'entrée d'air, utilisés comme entrées du modèle thermique pour la génération de données synthétiques (Figure 2.7 C & D), ont été obtenus en appliquant une méthode de lissage par moyenne mobile sur les profils expérimentaux. De cette manière, des données non bruitées ont été générées à partir des 10 mêmes scénarios. Comme pour l'ensemble des données expérimentales, chaque scénario a généré une température de cœur du produit et une température de l'air dans les 16 zones.



**FIGURE 2.7** – Profils de température d'entrée d'air des scénarios de chaîne du froid étudiés : (A) et (B) - Profils expérimentaux, (C) et (D) - Profils synthétiques (les profils expérimentaux ont été lissés pour obtenir des profils de l'entrée du modèle thermique). Les 10 profils ont été représentés sur deux graphiques différents pour plus de lisibilité.

### 2.2.3 Préparation des données

Dans la majorité des cas, la définition des variables d'entrées et de sorties est donné par le cas d'usage. Par exemple, si on veut classifier des photos avec le label "chat" ou "chien", la variable d'entrée  $x$ , est la photo et  $y$  est le label "chat" ou "chien". De même

pour un problème de régression, si on veut prédire le prix d'une maison en fonction de statistiques des conditions environnantes, les variables d'entrée sont l'ensemble des variables telles que : la ville, le nombre d'habitants, le nombre d'écoles et la sortie  $y$  est le prix de la maison.

Dans le cas de la prédiction de température, les données doivent être pré-traitées pour arriver à construire un  $\mathbf{x}$ , un  $y$  et  $\mathcal{D} = \{(\mathbf{x}_i, y_i)\}_{1 \leq i \leq m}$ . Les séries temporelles multivariées doivent être transformées en un ensemble de variables d'entrées, et un ensemble de variables de sorties. Les variables d'entrées sont l'ensemble des  $\lambda_{lag}$  dernières mesures au temps  $t$  de la température de l'air à la position  $z$ , avec un pas de temps  $\Delta t$  :

$$\mathbf{x}^t = T_{z,t-\lambda_{lag}\Delta t}^{air}, \dots, T_{z,t}^{air} \quad (2.12)$$

Et les variables de sorties, sont les 16 températures de produits au temps  $t$  :

$$y^t = T_{1,t}^{coeur}, \dots, T_{16,t}^{coeur} \quad (2.13)$$

Si on note  $\mathbf{x}_j$  la série temporelle multivariée obtenue à l'issue du  $j$ -ème scénario, on construit le jeu de données d'apprentissage sur 10 scénarios de la façon suivante :

$$\mathcal{D} = \{(\mathbf{x}_j^t, y_j^t)\}_{j \in \{1,10\}}_{t \in [0, t_{end}]} \quad (2.14)$$

La figure 2.8 montre un exemple de *lag* des données de température d'air mesurées par le capteur en position 4.

TS	$T_{4,t}^{air}$	$T_{4,t-\Delta t}^{air}$	$T_{4,t-2\Delta t}^{air}$	$T_{4,t-3\Delta t}^{air}$
0	8.9	NaN	NaN	NaN
60	12.2	8.9	NaN	NaN
120	12.3	12.2	8.9	NaN
180	12.5	12.3	12.2	8.9
240	12.6	12.5	12.3	12.2
300	12.7	12.6	12.5	12.3

FIGURE 2.8 – Exemple de  $lag$  des données pour la température de l'air dans la zone 4

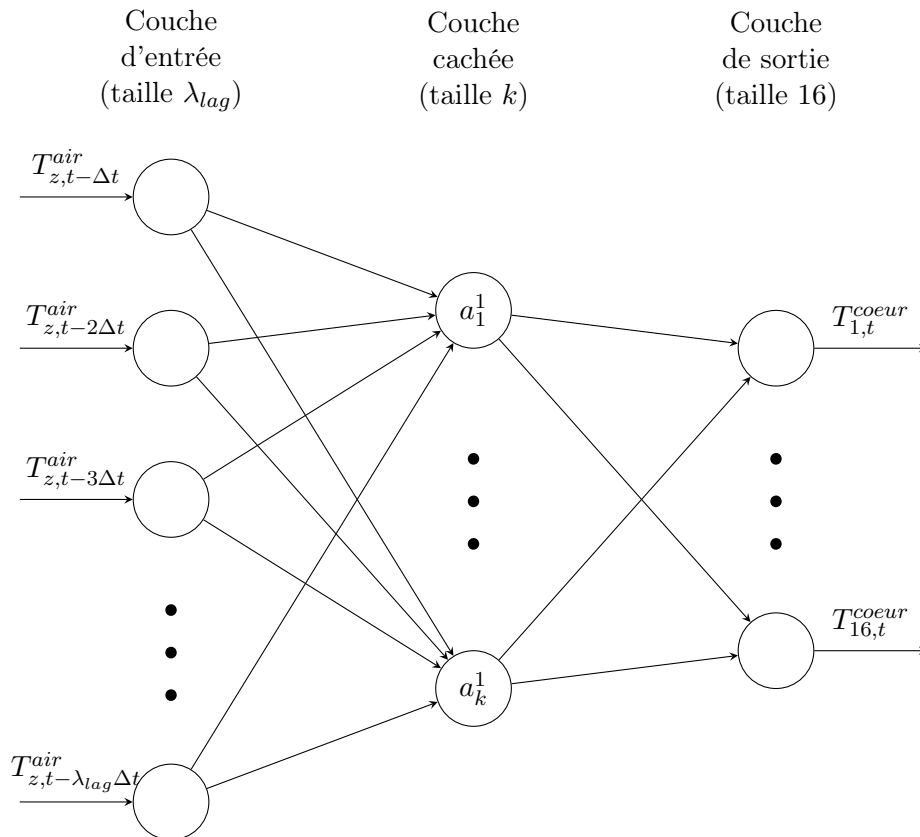
## 2.3 Entraînement de réseaux de neurones

### 2.3.1 La question du choix de l'architecture

Les réseaux de neurones ont une quantité infinie de configurations. Dans le cas du Perceptron multicouche décrit précédemment, le choix du nombre de neurones dans la couche d'entrée correspond au nombre de variables d'entrée et la couche de sortie correspond au nombre de variables à prédire.

La figure 2.9 présente la structure d'un réseau de neurone à une couche cachée de taille  $k$ , qui modélise une relation entre  $\lambda_{lag}$  variables d'entrées et 16 variables de sortie. Dans ce chapitre, la couche d'entrée correspond aux  $\lambda_{lag}$  dernières températures d'air mesurées par le capteur en position  $z$  et la couche de sortie correspond aux 16 températures de produits au temps  $t$ . Chaque couche cachée est composée de neurones qui pondèrent et somment leurs entrées pour les propager à la couche suivante. Il faut entraîner le réseau avec des données de températures pour *apprendre* à prédire les relations entre les entrées et les sorties. Le nombre de couches cachées et leur taille restent à déterminer en fonction de l'application. Plus les relations à modéliser sont complexes, plus le nombre de couches

cachées est élevé, et plus le réseau est profond.



**FIGURE 2.9** – Représentation schématique d'un Perceptron multicouche à une couche cachée de taille  $k$  qui prend en entrée la température de l'air à la position  $z$  (mesurée par un capteur) du temps  $t - \lambda_{lag}\Delta t$  au temps  $t$  et prédit la température de 16 produits au temps  $t$

### 2.3.2 Les architectures testées

Le type de NN utilisé est le régresseur Perceptron multicouche (MLP), qui utilise la rétro-propagation et la descente de gradient stochastique pour optimiser la perte quadratique. La fonction d'activation pour les couches cachées est la fonction d'unité linéaire rectifiée (ReLU, Eq. 2.5). Pour tous les NN testés, les hyperparamètres (par exemple  $\alpha$  : paramètre de pénalité L2) ont été fixés aux valeurs par défaut de la bibliothèque scikit-learn (Pedregosa et al. 2011). Dans ce cas, la version multi-sortie du MLP a été implémentée : la taille de la couche de sortie est de 16, correspondant aux 16 températures des pommes, et la couche d'entrée est de taille  $\lambda$ . Des tests ont été effectués sur différentes architectures de NN, de 1 couche cachée à 3 couches cachées pour évaluer l'impact de différentes stratégies (ajout de bruit, augmentation des données). Les différentes tailles des couches cachées ont été choisies en fonction de simulations préliminaires. En effet, l'objectif de ce travail n'est pas de trouver le meilleur modèle, mais de comparer la qualité des données d'entraînement. Ces simulations préliminaires ont donc été utilisées pour sélectionner différentes architectures assez performantes, mais il n'y a eu pas de travail approfondi pour sélectionner une architecture et des hyperparamètres optimaux. Finalement, 5 architectures de couches cachées différentes ont été présentées dans ce travail.

- Architectures à une couche cachée : 5 et 15
- Architecture à deux couches cachées : (10, 4)
- Architectures à trois couches cachées : (5, 5, 5) et (24, 12, 4)

## 2.4 Évaluation des modèles d'apprentissage : validation croisée

Les modèles ont été entraînés et testés en suivant la procédure de validation croisée "leave-one-out" (LOO). La procédure de LOO est souvent utilisée en Machine Learning et plus généralement en statistiques pour évaluer la précision du modèle sur un nouvel individu et ainsi optimiser les paramètres du modèle. Cette procédure évalue la capacité

du modèle à prédire la variable d'intérêt sur un nouveau profil. Cette procédure est présentée sur la figure 2.10). Dans notre cas, un ensemble de données comprend 10 scénarios de température (16 températures de l'air et 16 températures à cœur du produit dans chaque scénario). Un modèle a été entraîné sur 9 scénarios (scénarios 2 à 10) puis testé sur le scénario restant (scénario 1 en orange sur la figure 2.10). Dans la deuxième étape, le scénario 2 est utilisé pour le test, dans la troisième étape, le scénario 3 est utilisé pour le test et ainsi de suite.

Nous avons modifié cette procédure afin que les scénarios utilisés pour le test soient toujours expérimentaux. Même lorsque les NN sont entraînés avec des données synthétiques, leur performance est évaluée en les testant sur des données expérimentales. De cette manière, les modèles NN entraînés avec les ensembles de données expérimentales et synthétiques sont évalués sur les mêmes données et il est possible de comparer leurs performances. De plus, cela correspond aux conditions opérationnelles du terrain puisque ces NN sont destinés à prédire la température à partir d'un capteur sans fil placé dans une palette. Cette procédure de validation croisée permet d'estimer la performance du modèle sur un scénario réel et indépendant.

La métrique d'évaluation choisie est la racine de l'erreur quadratique moyenne (RMSE - Root Mean Square Error) :

$$RMSE = \sqrt{\frac{\Delta t}{N_{\text{zone}} \times t_{\text{max}}} \sum_{z=1}^{N_{\text{zone}}} \sum_{t=0}^{\frac{t_{\text{max}}}{\Delta t}} \left( \hat{T}_{z,t}^{\text{coeur}} - T_{z,t}^{\text{coeur}} \right)^2} \quad (2.15)$$

Avec

- Le nombre de zones  $N_{\text{zone}} = 16$
- Le pas de temps  $\Delta t = 60s$
- $t_{\text{max}} = 12 \times 3600s$
- $T_{z,t}^{\text{coeur}}$  et  $\hat{T}_{z,t}^{\text{coeur}}$  sont respectivement les températures mesurées et prédites (par le MLP) de la pomme dans la zone  $z$  au temps  $t$ .

L'initialisation des réseaux de neurone se fait aléatoirement. En informatique, les

nombres aléatoires n'existent pas : l'ordinateur utilise des nombres dits *pseudo-aléatoires* générés de façon déterministe à partir d'une graine (la graine du générateur). Si cette graine n'est pas explicitement spécifiée dans le code, l'ordinateur en prend une par défaut, basée sur l'heure à laquelle l'algorithme a été lancé. Ainsi, le même réseau de neurones entraîné sur les mêmes données, initialisé à des instants différents, sera différent. Les conclusions de la comparaison des NN entraînés avec les deux jeux de données doivent être indépendantes de cette graine. Ainsi, plusieurs NN initialisés avec plusieurs graines différentes vont être entraînés et testés pour chaque combinaison de paramètres et pour chaque étape de la validation. Pour cette expérience, nous avons décidé d'initialiser les NN avec 50 graines différentes.

Selon les analyses fournies, certaines spécifications du calcul du *RMSE* seront données.



## 2.5 Résultats

### 2.5.1 Performance sur les 10 scénarios

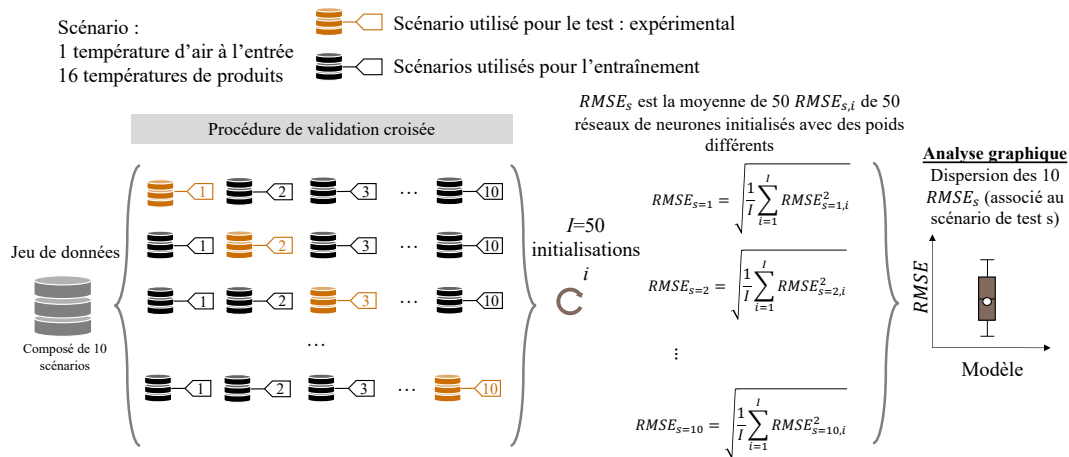
Dans cette section, l'erreur  $RMSE_s$  associée au scénario  $s$  est calculée puis représentée graphiquement. La figure 2.10 présente la procédure de validation croisée et le calcul du  $RMSE_s$ . À l'issue du test, pour un modèle donné, ce même modèle est entraîné et testé sur 10 sous-ensembles d'entraînement et de test différents (correspondant chacun à un scénario de test  $s$ ). Pour chaque modèle et scénario de test  $s$ , les réseaux de neurones ont été initialisés avec 50 graines différentes numérotées par un indice  $i$ . Pour un modèle, on obtient donc  $50 \times 10$   $RMSE_{s,i}$ .  $i$  allant de 1 à 50 et  $s$  allant de 1 à 10. Ensuite, la valeur moyenne est calculée  $RMSE_s$  :

$$RMSE_s = \sqrt{\frac{1}{50} \sum_{i=1}^{50} RMSE_{s,i}^2} \quad (2.16)$$

Chaque scénario est représenté par des boxplots décrivant la distribution des 10  $RMSE_s$ . Ces boxplots représentent, en d'autres termes, la distribution des performances en fonction des 10 scénarios de température. Cela nous permet de présenter des résultats moyennés sur 50 initialisations différentes, et ainsi d'estimer plus précisément la performance moyenne du modèle sur un nouveau scénario.

#### 2.5.1.1 Position du capteur de température dans la palette

Toutes les positions des capteurs ont été testées, mais seuls deux résultats avec des capteurs placés à l'avant et à l'arrière sont présentés sur la figure 2.11. En effet, cette figure montre la distribution des  $RMSE_s$  en fonction de la position du capteur dans la palette et de l'architecture du NN testé. Compte tenu des valeurs des  $RMSE_s$ , les résultats obtenus avec un capteur placé à l'avant étaient les moins bons sur les 16 capteurs, et ceux avec le capteur à l'arrière le meilleur. Parmi les différents NN proposés (nombre de couches cachées, taille des couches cachées), aucune des architectures n'a montré des performances systématiquement meilleures. Dans les configurations à un seul capteur, les





**FIGURE 2.10** – Procédure de validation croisée pour évaluer la performance des modèles sur 10 scénarios indépendants des scénarios d'entraînement - Calcul des  $RMSE_s$

performances du NN sont meilleures lorsque le capteur est placé à l'arrière ( $RMSE_i = 0.95^\circ\text{C}$ ; en aval du flux d'air) qu'à l'avant de la palette ( $RMSE_i = 1.41^\circ\text{C}$ ; en amont du flux d'air).

Les résultats sont en accord avec des études similaires dans la littérature (Badia-Melis et al. [2016], Mercier and Uysal [2018b]). En effet, la température de l'air (mesurée par le capteur) à l'arrière dépend des températures de l'air et des produits situés en amont de la palette. En d'autres termes, l'évolution de la température de l'air à l'arrière contient des informations des températures de l'air et des produits des zones précédentes. La température de l'air à l'avant, en revanche, dépend principalement de l'air ambiant extérieur. Sur le terrain, il est difficile de maîtriser la direction du flux d'air autour d'une palette. De plus, la position de la palette dans un équipement peut changer tout au long de la chaîne du froid, par exemple, une caisse située à l'arrière (flux d'air aval) dans un équipement spécifique peut devenir la caisse située à l'avant (flux d'air amont) dans un autre équipement. En tenant compte de ce fait, lorsqu'un seul capteur est disponible, il devrait être placé au centre de la palette. Si deux capteurs sont disponibles, il devraient être placés aux deux côtés opposés dans une palette (Mercier and Uysal [2018b]). Placer deux cap-

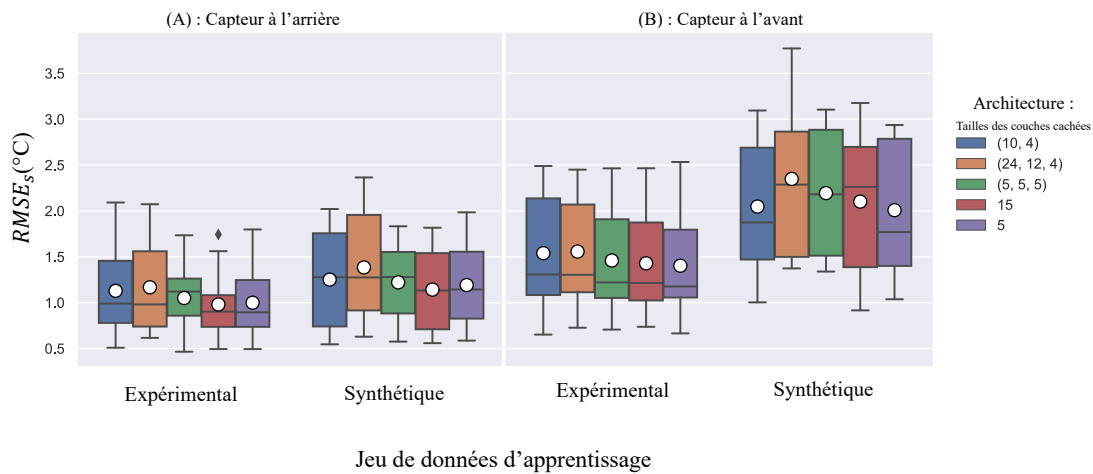
teurs à deux positions permet d'obtenir des résultats plus robustes ( $RMSE_i=0.65^\circ\text{C}$ ), mais à un coût d'entraînement plus élevé. Plusieurs facteurs doivent être pris en compte dans l'analyse des coûts : les performances du système de détection de rupture de la chaîne du froid, le coût de mise en œuvre (lié au nombre de capteurs), la valeur économique du produit et le coût des pertes de produits suite à la rupture de la chaîne du froid. Cette analyse faciliterait la prise de décision quant à la solution la plus appropriée pour un produit donné.



**FIGURE 2.11** – Impact de la position du capteur sur la distribution des  $RMSE_s$  pour cinq modèles NN entraînés avec des données expérimentales. Les boxplots représentent la distribution des 10  $RMSE_s$  résultant de la validation croisée (cf. Figure 2.10). Les points blancs représentent la moyenne des 10  $RMSE_s$  et les valeurs aberrantes sont représentées par les diamants noirs.

### 2.5.1.2 Comparaison des types jeux de données


Les performances des réseaux entraînés avec deux sources de données (expérimentales et synthétiques) sont illustrées sur la figure 2.12 pour deux positions de capteur (arrière et avant). Pour tous les NN testés, les RMSE des NN entraînés avec des données expérimentales sont inférieures aux RMSE des NN entraînés avec des données synthétiques. Ces résultats étaient attendus car le calcul des RMSE pour les sources de données est effectué sur des données expérimentales. En outre, cela est également dû à l'incertitude des données synthétiques, car cet ensemble de données a été généré à partir d'un modèle numérique avec sa propre incertitude. Cependant, la différence de performances entre les deux types de données est plus faible lorsque le capteur est situé à l'arrière de la palette (jusqu'à 0.2 °C; Figure 2.12.A) que lorsque le capteur est placé à l'avant (jusqu'à 0.6 °C; Figure 2.12.B). Bien que les NN entraînés avec des données expérimentales montrent de meilleures performances, leur génération présente des contraintes liés à la lourdeur de mise au oeuvre.



**FIGURE 2.12** – Distribution des  $RMSE_s$  de cinq NN entraînés sur des données synthétiques ou expérimentales. (A) Capteur mesurant la température de l'air à l'arrière l'arrière (B) Capteur mesurant la température de l'air à l'avant. Les boxplots représentent la distribution des 10  $RMSE_s$  issus de la validation croisée résultant de la validation croisée (cf. Figure 2.10). Les points blancs représentent la moyenne des 10  $RMSE_s$  et les valeurs aberrantes sont représentées par les diamants noirs.

### 2.5.1.3 Estimation de la performance du modèle sans données expérimentales

Bien qu'il soit possible d'entraîner des NN avec des données synthétiques, l'évaluation des performances d'un NN sans aucune donnée expérimentale ou de terrain est plus complexe. Lorsqu'aucune donnée expérimentale n'est disponible, il faut entraîner les NN et effectuer le processus de validation croisée LOO sur des données synthétiques. Cependant, comme le montre la figure 2.13, les  $RMSE_s$  estimées en utilisant des données synthétiques sans bruit comme données de test ( $0.7 \pm 0.35$  °C) sont inférieures aux  $RMSE_s$  calculées à l'aide de données expérimentales ( $1.22 \pm 0.47$ °C), cette différence observée de  $0.5$ °C peut être expliquée par le fait que les NN sont entraînés en utilisant des données synthétiques sans bruit. En effet, le bruit des données mesurées est principalement dû à l'incertitude du thermocouple ( $\pm 0.2$ °C). Lorsque des NN entraînés entraînés avec des données synthétiques sont également testés avec des données synthétiques, cela peut conduire à une sur-estimation des performances réelles des NN entraînés. Il est important de prendre quelques précautions avant de conclure sur les performances réelles des NN. Pour limiter la sur-estimation des performances des NN entraînés avec des données synthétiques et testés sur des données synthétiques, différents niveaux de bruit ont été ajoutés aux données synthétiques de test. Cependant, dans tous les cas testés, les  $RMSE_s$  ont été sous-estimées par rapport aux  $RMSE_s$  calculées sur les données expérimentales.



**FIGURE 2.13** – Distribution de  $RMSE_s$  de cinq NN entraînés sur des données synthétiques et testés sur : des données expérimentales, des données synthétiques non bruitées et données synthétiques avec trois bruits différents, en particulier  $2x\sigma = 0.2^\circ\text{C}$  qui correspond à l’incertitude du thermocouple. Le capteur est placé à l’arrière de la palette. Les boxplots représentent la distribution des 10  $RMSE_s$  résultant de la validation croisée.

#### 2.5.1.4 Impact des données synthétiques additionnelles pour l’entraînement des réseaux de neurones

Auparavant, les modèles NN ont été entraînés avec des jeux de données expérimentaux et synthétiques générés à partir de 10 scénarios de chaîne du froid. Sur la base de ces 10 scénarios, les performances des NN entraînés avec les données expérimentales sont meilleures que les NN entraînés avec les données synthétiques. Toutefois, il est très simple et assez rapide de produire un grande quantité de données avec le modèle thermique. A partir de ce constat, de nombreuses questions se posent :

- Peut-on générer n’importe quel type de scénario avec le modèle thermique ? Cela a-t-il une influence sur les performances des NN ? ou doit-on connaître des profils de température représentatifs de ce que l’on peut rencontrer dans la chaîne du froid ?
- Les performances des NN s’améliorent-elles en utilisant plus de données pour leur entraînement ?

Pour répondre à ces questions, 50 scénarios aléatoires supplémentaires (la figure 2.14 montre 10 de ces 50 scénarios) ont été générés et utilisés comme entrée du modèle thermique pour générer des données synthétiques. Ces 50 scénarios, de 12 heures chacun, ont été générés aléatoirement par l'algorithme 1, qui consiste à tirer aléatoirement  $p$  points  $(t, T_{entree}^{air}(t))$  du profil, puis à les interpoler pour former le profil aléatoire.

---

**Algorithme 1** Simulation d'un profil aléatoire

---

Tirer aléatoirement un nombre de points  $p$  uniformément entre 2 et 10

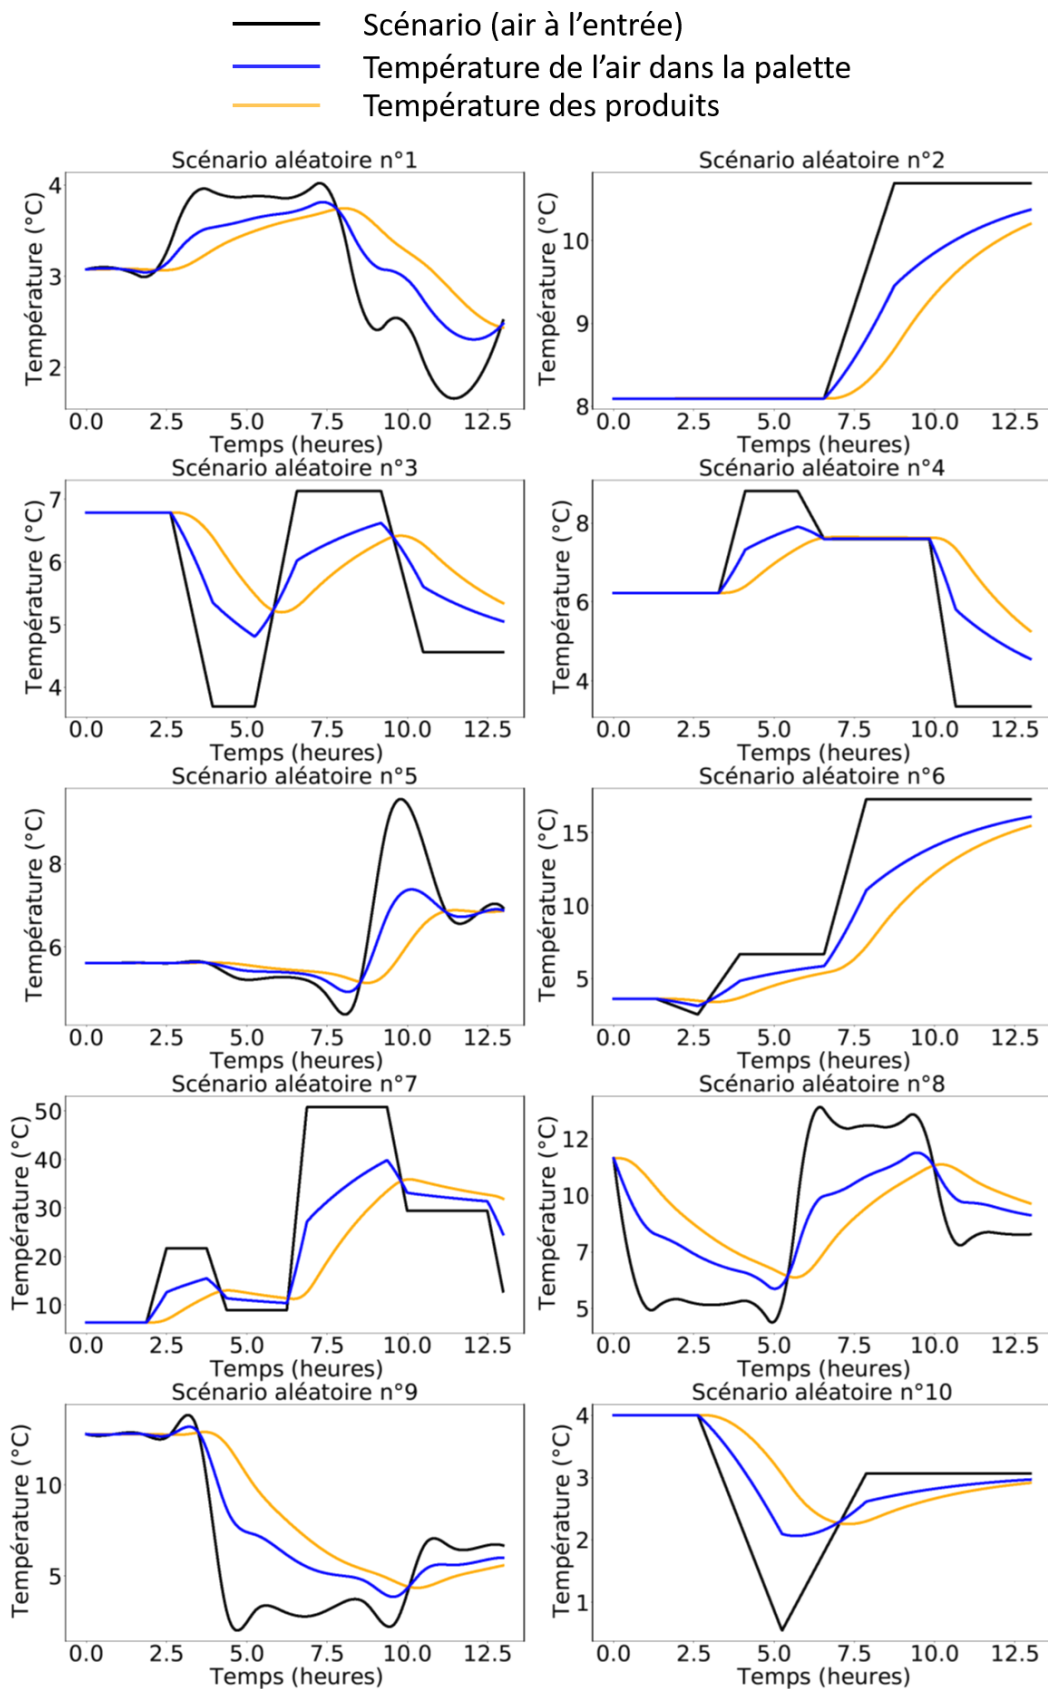
Tirer  $p$  températures uniformément entre 0 et 35 °C  $T_1, \dots, T_p$

Tirer  $p - 2$  indices de temps entre 0 et 12 heures  $t_2, \dots, t_{p-1}$  ( $t_0 = 0$  et  $t_p = 12h$ )

Choisir une interpolation aléatoirement dans la liste [interpolation linéaire, cubique, quadratique]

Interpoler les  $p$  points  $(t_i, T_i)$  pour former le scénario aléatoire  $(t, T_{entree}^{air}(t))$

---

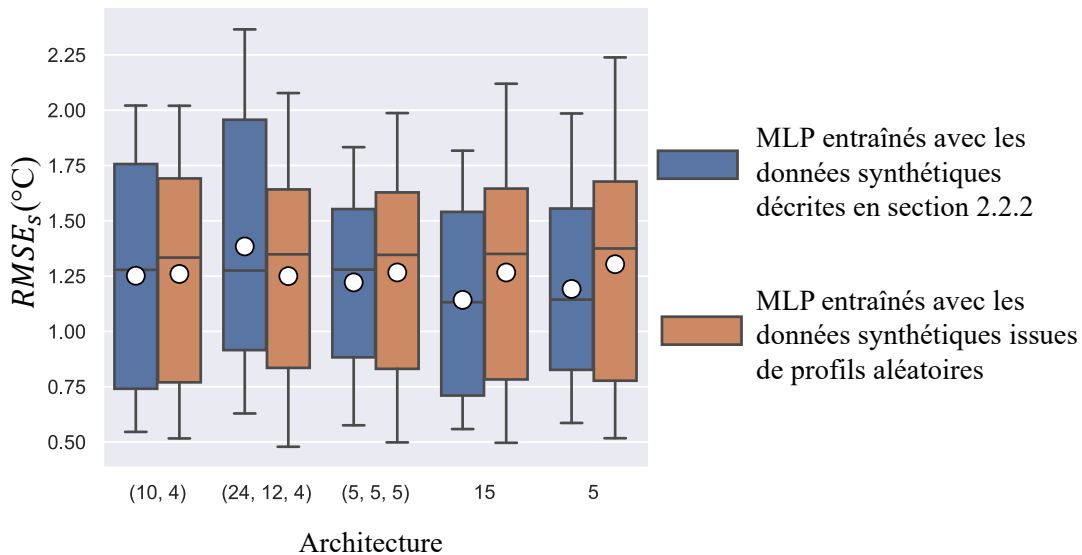


**FIGURE 2.14** – Scénarios de température en fonction du temps générés aléatoirement - Ligne noire : température de l'air à l'entrée de la palette (générée aléatoirement) - Ligne bleue : température de l'air dans la palette (calculée avec le modèle thermique) - Ligne orange : température d'un produit (calculée avec le modèle thermique)



### 2.5.1.5 Impact du choix des scénarios

Pour répondre à la question du choix des scénarios, à savoir si les données synthétiques doivent être générées à partir de scénarios réalistes ou si elles peuvent être générées à partir de scénarios choisis arbitrairement, des NN ont été entraînés sur 10 scénarios aléatoires, et les performances ont été comparées avec ces mêmes NN sur les 10 scénarios réalistes présentés à la section 2.2. Nous avons généré 10 scénarios synthétiques aléatoires afin de pouvoir comparer deux ensembles d'entraînement de même taille. La figure 2.15 présente les performances des NN entraînés avec les données synthétiques décrites dans la section 2.2.2 et les performances des NN entraînés avec des données synthétiques issues de scénarios générés aléatoirement.



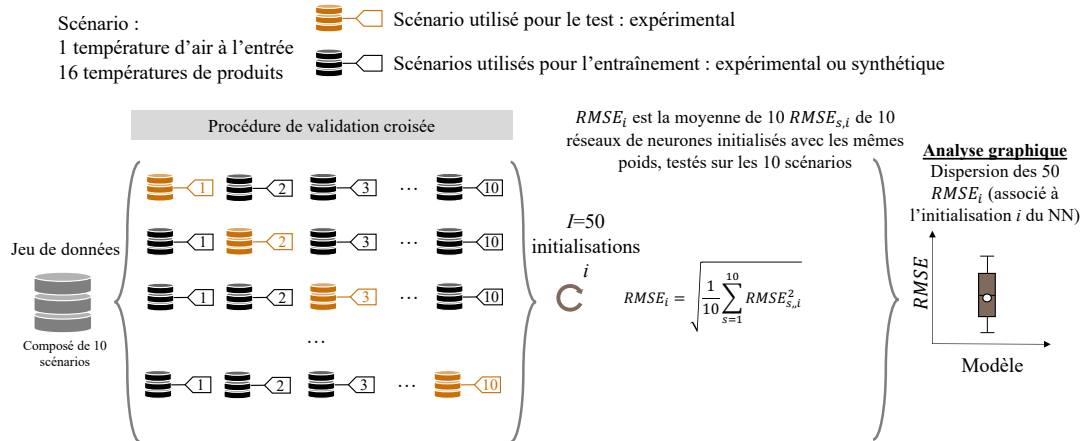
**FIGURE 2.15** – Distribution des  $RMSE_s$  de 5 NN entraînés sur les données synthétiques avec les 10 scénarios décrits dans la section 2.2.2 (bleu) et 10 scénarios générés aléatoirement en suivant l’algorithme 1. Ces résultats ont été obtenus avec un capteur placé au fond de la palette

Les résultats montrent que les NN entraînés sur des données synthétiques générées à partir de scénarios aléatoires ont des performances similaires à celles des NN entraînés sur des scénarios réalistes. Cette observation est intéressante car elle montre que les NN peuvent être entraînés sans informations précises sur les températures de la chaîne du

froid donnée. Ainsi, pour mettre en œuvre la prédiction de la température des produits à l'aide d'un capteur de température sans fil et d'un NN, il n'est pas nécessaire de mener une étude complète sur le terrain pour identifier un scénario représentatif. Seules les caractéristiques de la palette (taux d'ajourage des caisses) et des produits (forme, propriétés thermiques) sont nécessaires pour développer un modèle thermique ou un dispositif expérimental en laboratoire. Il est tout de même important de noter que pour tous les scénarios testés, la vitesse d'air est de  $0.2 \text{ m.s}^{-1}$  pour représenter ce que nous observons souvent dans la pratique. Une étude plus approfondie sur l'impact de la modification de la vitesse d'air sur la prédiction des températures par les NN serait intéressante à réaliser après cette thèse.

## 2.5.2 Performance moyenne sur les 10 scénarios selon plusieurs initialisations

### 2.5.2.1 Impact de données synthétiques supplémentaires



**FIGURE 2.16** – Procédure de validation croisée pour évaluer la performance des modèles sur l'ensemble des 10 scénarios, avec des initialisations différentes - Calcul des  $RMSE_i$

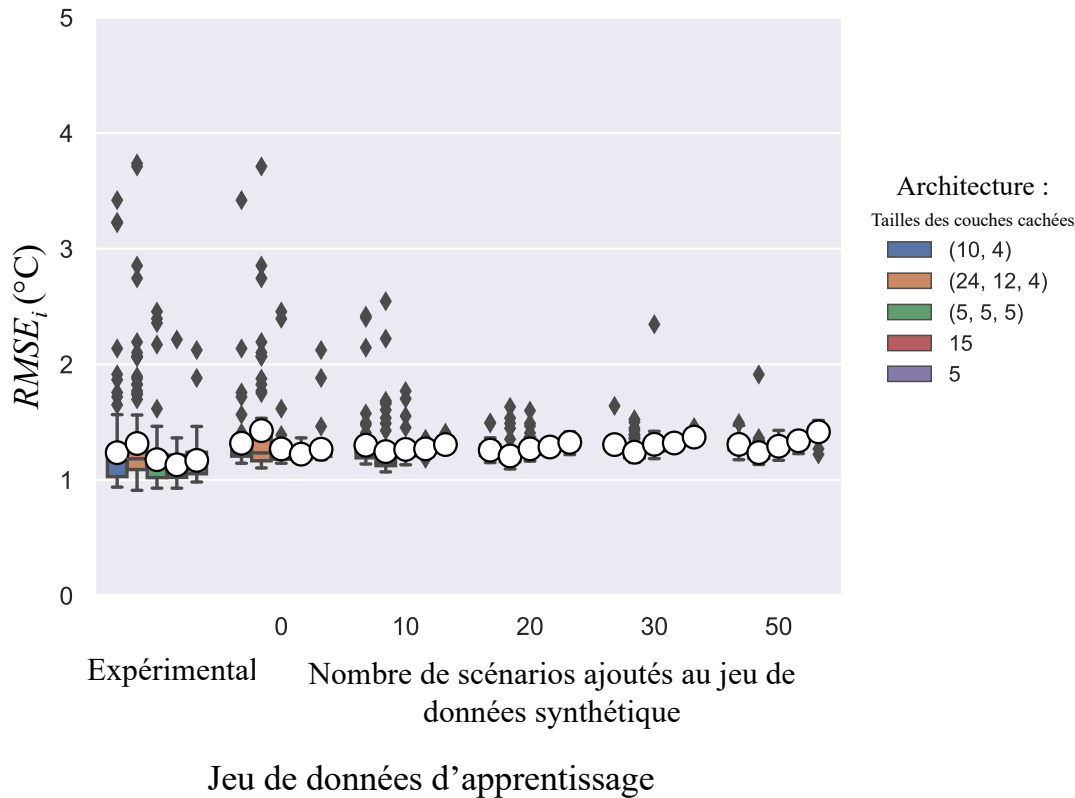
Dans cette section le  $RMSE_i$  est également basé sur le RMSE (voir équation 2.15). La validation croisée LOO (figure 2.10) est traitée pour une graine donnée pour les 10 étapes  $s$ , ce qui donne 10  $RMSE_{s,i}$  (figure 2.16) dont on fait la moyenne.

Ce processus est effectué 50 fois avec 50 graines aléatoires différentes (c'est-à-dire initialisations de NN, brassage de données...), ce qui donne 50  $RMSE_i$  :

$$RMSE_i = \sqrt{\frac{1}{10} \sum_{s=1}^{10} RMSE_{s,i}^2} \quad (2.17)$$

Les résultats correspondants sont présentés à l'aide de boxplots décrivant la distribution des 50  $RMSE_i$  (graine) ; en d'autres termes, la performance moyenne du modèle sur les 10 scénarios, pour 50 initialisations différentes.

Une fois qu'un modèle thermique est développé, il est facile de générer de grands ensembles de données synthétiques à partir de nombreux scénarios synthétiques de la chaîne du froid. Ceci représente le principal avantage des données synthétiques par rapport à la



**FIGURE 2.17** – Impact du nombre de scénarios ajoutés au jeu de données original sur le  $RMSE_i$  (cf. figure 2.16)

génération de données expérimentales.

Avec un grand ensemble de données, la performance du NN pourrait s'améliorer de manière significative, permettant d'atteindre la performance d'un NN entraîné sur des données expérimentales. Dans la figure 2.17, l'impact du nombre de scénarios aléatoires ajoutés au jeu de données original sur le  $RMSE_i$  est présenté, comparé au  $RMSE_i$  obtenu à partir d'un NN entraîné sur des données expérimentales. Globalement, la moyenne des  $RMSE_i$  est similaire pour tous les cas testés (de 0 à 50 scénarios ajoutés au jeu de données original). L'ajout de scénarios synthétiques supplémentaires ne suffira pas à pallier les inconvénients des données synthétiques. Cependant, la variance du  $RMSE_i$  diminue lorsque le nombre de scénarios ajoutés augmente. Ainsi, bien que le nombre de

scénarios n'ait pas d'impact sur la performance globale du  $RMSE_i$ , il permet de réduire l'impact de l'initialisation des poids du NN, réduisant ainsi la variance du modèle final. Cette diminution de la variance est d'autant plus importante que les architectures sont simples. Par exemple, la variance des deux architectures à une couche cachée est déjà faible lorsque seulement 10 scénarios additionnels sont ajoutés. Pour les architectures plus complexes, il est nécessaire d'avoir plus de scénarios pour diminuer la variance. Cela peut être expliqué par le fait que les architectures complexes nécessitent plus de données pour leur entraînement. Des précautions doivent être prises sur le développement du NN lorsque peu de données sont utilisées pour l'entraînement car le NN est sensible à l'initialisation des poids. Il semble également important de prendre des précautions quant au choix de l'architecture, dans le cas où il y a peu de données, il semble plus judicieux d'utiliser des architectures simples à une seule couche cachée car cela permet de diminuer le nombre de scénarios supplémentaires à générer pour réduire la variance du modèle.

## 2.6 Discussion

La principale tâche pour développer des modèles d'apprentissage automatique pour prédire la température des produits est de collecter les données d'apprentissage. Ces données peuvent provenir de plusieurs sources : mesures sur le terrain, expériences en laboratoire, ou données synthétiques issues de modèles thermiques plus ou moins complexes (Loisel et al. [2021]).

Dans ce chapitre, l'impact des données expérimentales et synthétiques sur l'entraînement de modèles d'apprentissage automatique a été évalué. Les NN entraînés sur des données expérimentales ont donné de meilleurs résultats que les NN entraînés sur des données synthétiques.

L'inconvénient des données expérimentales est que leur génération nécessite un investissement matériel et un temps (dans notre cas, pour une seule configuration spécifique, il a fallu 10 jours pour générer des profils de température de 10 scénarios, sans inclure la mise en place du dispositif ou les divers problèmes expérimentaux que l'on a pu ren-

contrer). Aussi, la génération des données expérimentales générées sous des conditions spécifiques (vitesse de l'air, direction de l'air, disposition des produits et des palettes...) peut être limitée. L'utilisation d'un modèle thermique basé sur la physique pour générer des données synthétiques dans de nombreuses conditions apparaît dans ce cas comme une alternative prometteuse mais leur utilisation pose d'autres problèmes comme la méthode d'évaluation de la performance des NN. Comme présenté dans la section 2.5.1.3, l'utilisation de données synthétiques comme données de test conduit à une surestimation des performances du modèle, et, l'ajout de bruit pendant les tests ne suffit pas à surmonter ce problème.

Afin d'améliorer les performances des modèles d'apprentissage automatique entraînés avec des données synthétiques, plusieurs études ont ajouté du bruit aux données d'entraînement. En effet, contrairement aux données expérimentales, les données synthétiques ne sont pas bruitées. L'ajout de bruit aux données synthétiques pourrait décrire plus précisément les données expérimentales. Pour évaluer l'impact du bruit sur les performances, une comparaison entre des données synthétiques sans bruit, des données synthétiques avec un écart-type de  $0.1^{\circ}\text{C}$  (correspondant à une incertitude de  $\pm 0.2^{\circ}\text{C}$  du capteur utilisé dans l'expérimentation avec intervalle de confiance de 95% de  $0.2^{\circ}\text{C}$  et  $0.5^{\circ}\text{C}$ ) a été réalisée. Cependant, aucune différence n'a été constatée en termes de performances (résultats non présentés ici). Des travaux approfondis sur cet aspect pourraient être menés afin d'améliorer les modèles entraînés avec des données synthétiques.

Les données de mesure (issues d'expériences en laboratoire ou idéalement de données de terrain) doivent être utilisées comme données de test pour évaluer correctement les performances des NN entraînés avec des données synthétiques. En d'autres termes, les données synthétiques peuvent être utilisées pour entraîner les NN mais les mesures expérimentales doivent être utilisées comme données de test de validation. Il faut noter que les résultats et les conclusions de cette étude ne sont pas généralisables à d'autres applications pour l'instant. Il est nécessaire de poursuivre l'étude de l'effet de l'incertitude des jeux de données d'entraînement sur les performances des NN. En effet, les résultats obtenus avec des modèles plus complexes à plus faible incertitude (par exemple,

des modèles prenant en compte des effets hydrodynamiques plus détaillés du type CFD) pourraient être différents de ceux de cette étude.

Dans l'optique du développement d'un outil de prédiction plus flexible capable de décrire une grande variabilité des configurations rencontrées dans la chaîne du froid, la méthodologie d'apprentissage par transfert pourrait être intéressante. La disponibilité croissante de méthodes d'apprentissage automatique puissantes et efficaces dans un grand ensemble de situations très variables dans la chaîne du froid, s'accompagne d'une demande croissante de données d'apprentissage. Compte tenu de la difficulté de produire des données expérimentales, il pourrait être intéressant d'envisager l'utilisation de l'apprentissage par transfert où l'on part d'un modèle précédemment entraîné avec des données similaires afin d'apprendre un modèle pour une nouvelle tâche, réduisant ainsi le besoin de nouvelles données d'apprentissage.

Il existe de nombreux types de NN. Dans cette étude, des perceptrons multicouches ont été utilisés. Ce choix a été fait comme une première approche car notre configuration était simple (un seul niveau d'une palette) et nos tests préliminaires ont montré de bons résultats en les utilisant. La comparaison des différents types de NN n'entraîne pas dans le cadre de cette thèse. Dans des études ultérieures, se concentrant sur des configurations plus complexes (palette, équipement, ...), d'autres types de NN pourraient être utilisés tels que les RNN qui sont mieux adaptés aux données temporelles (Jaeger [2002]), les réseaux de neurones convolutifs (CNN) qui sont mieux adaptés aux données spatiales (Le Cun et al. [1990]), ou d'autres méthodes combinant les deux (Convolutional Recurrent Neural Networks - CRNN) (Zuo et al. [2015]).

Enfin, ces modèles de prédiction en temps réel de la température pourraient être associés à des algorithmes de détection d'anomalies afin d'alerter les opérateurs lorsque des ruptures de la chaîne du froid se produisent ou sur le point de se produire. Cela permettrait aux opérateurs de prévenir les ruptures de la chaîne du froid en mettant en œuvre des mesures correctives pour réduire la dégradation de la qualité des aliments, assurer la sécurité alimentaire et réduire les pertes.

## Conclusion

Un dispositif expérimental a été mis en place et un modèle thermique a été développé pour générer deux jeux de données de températures de l'air et des produits dans une palette de pommes. L'objectif des travaux présentés dans ce chapitre était de comparer les performances des réseaux de neurones entraînés sur des données expérimentales ou synthétiques. Les principales conclusions sont les suivantes :

1. Les réseaux de neurones entraînés avec le jeu de données expérimentales ont montré de meilleures performances (20 à 40%) par rapport à celui entraîné avec le jeu de données synthétique.
2. La position du capteur à l'intérieur de la palette est un facteur déterminant pour la précision de la prédiction de la température des produits par les réseaux de neurone.
3. Des résultats similaires ont été obtenus avec des modèles entraînés sur des données synthétiques générées à partir de scénarios réalistes et de scénarios aléatoires. Il n'est donc pas nécessaire d'avoir des informations sur la chaîne logistique réelle pour entraîner les modèles.
4. L'augmentation de l'ensemble de données d'entraînement synthétiques avec 10 à 50 scénarios supplémentaires n'a pas amélioré de manière significative la précision du modèle mais a réduit la variance du modèle.





## Chapitre 3

# Modèle de simulation de chaîne du froid fictive

### Introduction

Dans ce chapitre, un modèle permettant de simuler des scénarios temps-température de chaîne du froid a été développé. Une chaîne est une suite de couples de températures-durées de séjour  $(T_i, D_i)$  dans chaque étape  $i$  et une température ambiante externe  $T_{ext}$ . La chaîne étudiée consiste en une palette de produits acheminée du producteur au magasin à travers plusieurs équipements frigorifiques.

L'objectif est de développer des preuves de concept de méthodes de détection des ruptures ou de prise de décision en temps réel. Ces méthodes ont pour but d'améliorer le suivi de la chaîne du froid à partir de la mesure de température de l'air dans une palette. Par exemple, pour tester des méthodes qui consistent à alerter un opérateur en cas de rupture, ou des méthodes plus complètes qui, à la suite d'une alerte, prennent une décision permettant de la corriger.

Des données terrain de distribution de température et de durée de séjour dans un équipement permettant de simuler des circuits logistiques sont disponibles dans la littérature ainsi que des modèles thermiques et qualités spécifiques à différents produits.

Cependant, il est difficile de trouver toutes les données et des modèles nécessaires pour un produit donné. De ce fait, une chaîne du froid *fictive* est simulée, c'est-à-dire que les paramètres utilisés dans chacun des modèles implémentés ne sont pas propres à un produit spécifique. Tous les paramètres de ce modèle étant définis par rapport à ce produit fictif, il sera transposable à la chaîne du froid d'un autre produit. Les paramètres de ce modèle sont inspirés des données d'une chaîne logistique réelle de fruits et légumes. Le modèle développé permet de simuler non seulement l'évolution de la température et de la qualité organoleptique des produits, mais également les consommations énergétiques associées au fonctionnement des procédés frigorifiques.

Les hypothèses simplificatrices suivantes sur le produit et la chaîne du froid étudiée permettent de cadrer cette étude :

- Le produit fictif est un produit de type fruit
- La chaîne logistique dure en moyenne 1/3 de la durée de vie initiale du produit
- La température extérieure  $T_{ext}$  est constante tout le long de la chaîne. De plus, lors des transferts de produit entre deux équipements frigorifiques, la température de l'air dans la palette est égale à la température extérieure.
- La température de l'air à l'intérieur d'un véhicule frigorifique ( $T_m$ ) est toujours inférieure ou égale à la température ambiante extérieure  $T_m \leq T_{ext}$ , car les camions ne chauffent pas<sup>1</sup>.
- La température de l'air dans une palette est considérée homogène et égale à la température de consigne.

Ce chapitre décrit d'abord la construction du modèle logistique, puis du modèle thermique, de consommation énergétique et le modèle qualité. Ensuite, ces modèles sont assemblés pour former le modèle final, qui servira à faire la preuve de concept présentée dans le chapitre 4.

---

1. Dans d'autres pays comme le Canada, certains camions chauffent pour maintenir les produits à une température supérieure à 0°C

### 3.1 Description du circuit logistique de la chaîne du froid étudiée

#### 3.1.1 Enchaînement des étapes

La chaîne est décrite comme une succession discrète d'étapes, allant de l'étape 1 à l'étape 6. Chaque étape correspond à un équipement frigorifique, que l'on appelle un *maillon* (étapes n°1, 3, 5, 6), ou à une *interface* entre deux maillons (étapes n°2 et 4), par exemple lorsque les produits séjournent sur un quai lors d'un transfert d'un équipement à un autre. Pour chaque étape, nous supposons que les lois statistiques de la distribution des temps de séjour du produit et des températures de l'air sont connues.

#### 3.1.2 Durées et températures des étapes

La table 3.1 présente les distributions des variables aléatoires qui décrivent le circuit logistique choisi. On note  $D_1, D_2, D_3, D_4, D_5, D_6$  les variables aléatoires qui décrivent les durées de séjour dans chaque étape de la chaîne. Les durées de chaque étape de la chaîne ont été choisies en s'inspirant d'études terrain, mais de nombreuses autres combinaisons d'étapes et de distributions auraient pu être utilisées. Dans la mesure où notre objectif est d'effectuer une preuve de concept, montrer que pour cette chaîne donnée, les méthodes d'apprentissage peuvent aider à améliorer le suivi de la chaîne du froid serait suffisant.

**TABLE 3.1** – Construction du circuit logistique : lois de distributions

Variable aléatoire	Signification	Loi	Moyenne	Variance
$T_{meteo}$	Température extérieure	$\mathcal{U}(5, 35)$	-	-
$T_1, T_3, T_5, T_6$	Température de consigne de l'équipement $i$	$\Gamma(6, 1)$	6	6
$T_2, T_4$	Température de l'air à l'étape $i$	$T_{meteo}(\omega)$	$T_{meteo}(\omega)$	0
$D_1$	Durée du maillon $i$ (heures)	$\Gamma(180, 0.4)$	3 jours	1.2 jours
$D_2$		$\Gamma(4.375, 0.4)$	1 heure 45	$\approx 45$ min
$D_3$		$\Gamma(120, 0.4)$	2 jours	0.8 jours
$D_4$		$\Gamma(4.375, 0.4)$	1 heure 45	$\approx 45$ min
$D_5$		$\Gamma(90, 0.4)$	1.5 jours	$\approx 14$ heures
$D_6$		$\Gamma(180, 0.4)$	3 jours	1.2 jours

Pour chaque circuit logistique, une température extérieure  $T_{meteo}$  est tirée aléatoirement. Cette température sera utile, d'une part, pour le calcul de la consommation

énergétique (cf. section 3.2), et d'autre part pour fixer la température des étapes aux interfaces. En effet, la température de l'air dans les étapes d'interfaces 2 et 4 ( $T_2$  et  $T_4$ ) ne sont pas réfrigérées et leurs valeurs sont considérées égales à la température extérieure  $T_e$ . On note  $T_1, T_3, T_5, T_6$  les variables aléatoires qui décrivent les températures de l'air de chaque équipement. Elles suivent une loi  $\Gamma(6, 1)$  et sont indépendantes. Les températures de consigne de chaque équipement ont une moyenne de  $6^\circ\text{C}$  et une variance de  $6^\circ\text{C}$ . Cette loi, la valeur moyenne et la variance ont été choisie en se basant sur des données expertes. Il est à noter que ces distributions tiennent compte de l'hétérogénéité des températures au sein d'un même équipement. Ainsi, en tirant cette température au hasard, on tire implicitement une position dans l'équipement. La figure 3.1 montre un exemple de circuit logistique simulé.

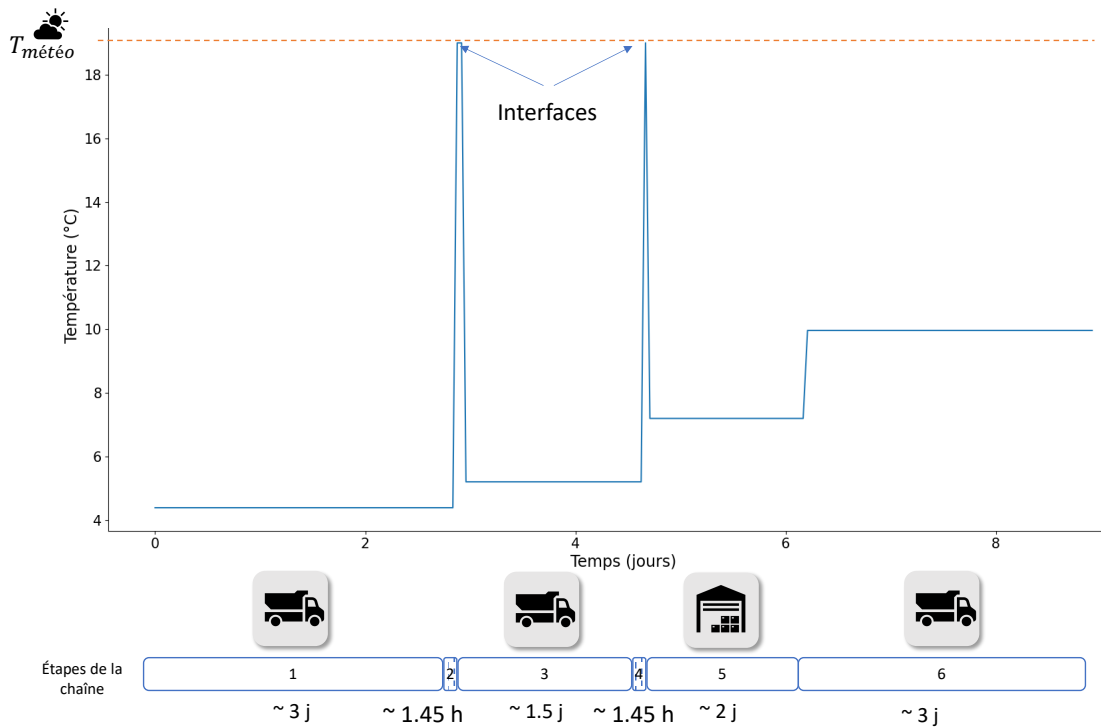


FIGURE 3.1 – Exemple d'un circuit logistique simulé

### 3.1.3 Calcul de la température des produits

Pour simplifier le cas d'étude, seule une zone de produits a été prise en compte dans le calcul de l'évolution de la température des produits, de sorte que tous les produits étudiés subissent la même évolution de température. Les produits sont supposés avoir une forme sphérique avec une résistance interne non négligeable par rapport aux échanges par convection ( $Bi = hD/\lambda > 0.1$ , où  $D$  est le diamètre moyen de produits). Les échanges par rayonnement sont, quant à eux, négligés. Une solution analytique existe pour déterminer l'évolution de la température des produits, mais une bonne approximation peut être obtenue en considérant que la résistance interne est proche de  $R/4/\lambda$  et avec une résistance de transfert convectif de  $1/h$  (van der Sman [2003]). L'évolution de la température moyenne des produits est estimée par l'équation suivante :

$$mCp^{prod} \frac{dT^{prod}(t)}{dt} = \frac{1}{\frac{1}{h} + \frac{R}{4\lambda}} S(T^{air}(t) - T^{prod}(t)) \quad (3.1)$$

Où

- $m$  est la masse du produit [kg]
- $S$  est la surface d'échange entre le produit et l'air pour un produit [m<sup>2</sup>]
- $Cp^{prod}$  est la capacité thermique du produit [J kg<sup>-1</sup> K<sup>-1</sup>]
- $\lambda$  est la conductivité thermique [W m<sup>-1</sup> °C]
- $h$  est le coefficient d'échange convectif [W m<sup>-2</sup> K<sup>-1</sup>]
- $T^{prod}(t)$  est la température moyenne du produit au temps  $t$  [°C]
- $T^{air}(t)$  est la température de l'air au temps  $t$  [°C]

## 3.2 Calcul du coût énergétique

L'énergie dépensée pour la réfrigération des produits est calculée pour une palette de produit, qui passe d'équipements en équipements tout au long de la chaîne du froid. Le calcul du coût énergétique prend en compte l'énergie nécessaire pour refroidir les produits, et pour les maintenir au frais contre des déperditions thermiques par les parois

de l'équipement. L'énergie associée à la consommation de carburant pour le transport, ou l'énergie dépensée par les ventilateurs pour brasser de l'air dans la chambre froide ou dans le véhicule frigorifique n'est prise en compte. Les équations ci-dessous présentent le bilan énergétique de chaque équipement :

- Charge thermique associée au refroidissement des produits :

$$Q_c = m \times C_p^{prod} \times (T^{prod}(t_0) - T^{prod}(t_{end}))[\text{J}] \quad (3.2)$$

- Charge thermique associée aux déperditions par les parois

$$P = K \times S_{eq} \times (T^{ext} - T^{th})[\text{W}] \quad (3.3)$$

- Coefficient de performance (Carnot) :

$$COP = \frac{T_{cold}}{T_{hot} - T_{cold}} \quad (3.4)$$

- $T_{cold}$  est la température de source froide ( $T_{th} - 10$  [K])
- $T_{hot}$  est la température de source chaude ( $T_{ext} + 10$  [K]) On considère ici que les températures de pincement sur le condenseur et l'évaporateur du système frigorifique sont constants.
- Coût énergétique associée à la consommation électrique de la machine frigorifique

$$Conso_e = \frac{Q_c + m/M_{load} \times P \times \delta t}{\eta COP}[\text{J}] \quad (3.5)$$

Où

- $T^{th}$  est la température du thermostat (température de consigne de l'équipement réglée par l'opérateur)
- $m$  est la masse des produits [kg]
- $C_p^{prod}$  est la capacité thermique du produit [ $\text{J kg}^{-1} \text{°C}^{-1}$ ]
- $T^{ext}$  est la température de l'air ambiante à l'extérieur [K]

- $T^{prod}(t_0)$  et  $T^{prod}(t_{end})$  sont respectivement les températures des produits à l'entrée et à la sortie d'un équipement. [K]
- $K$  est le coefficient de transmission thermique global de l'équipement, fixé à une valeur moyenne de  $0.5 \text{ [W m}^{-2} \text{ K}^{-1}]$
- $S_{eq}$  est la surface de l'équipement [ $\text{m}^2$ ]

Ces équations montrent que le coût énergétique est une fonction de la température des produits à leur arrivée et sortie d'un équipement ( $T^{prod}(t_0)$  et  $T^{prod}(t_{end})$ ), de la température extérieure ( $T_{ext}$ ) et de la température du thermostat ( $T^{th}$ ). Il est à souligner que  $T_{ext}$  et  $T^{th}$  sont des températures d'air mesurées en pratique, ceci n'est pas toujours le cas pour  $T^{prod}(t_0)$  et  $T^{prod}(t_{end})$ . En effet, même si la température des produits peut être mesurée lors de la réception d'une cargaison, ce contrôle n'est ni systématique, ni effectué pour tous les produits.

### 3.3 Évolution de la qualité des produits

#### 3.3.1 Modèle qualité

Le calcul de l'évolution de la qualité organoleptique des produits permet de déterminer si, à la fin de la chaîne, un large pourcentage de produits reste éloigné des valeurs critiques de qualité. Les valeurs critiques de qualité étant le seuil acceptable par le consommateur et les différents intervenants de la chaîne du froid. Plusieurs modèles de qualité existent dans la littérature, ceux-ci permettent de modéliser plusieurs indicateurs de qualité tels que la vitamine C, la croissance microbienne, la perte d'eau ou même plusieurs indicateurs combinés. De plus, pour chaque indicateur qualité, il existe des seuils d'acceptabilité. Dans cette étude, où le produit d'intérêt est fictif, un modèle de qualité "générique" sera proposé, basé les hypothèses suivantes :

1. Le produit étudié est de type fruit
2. L'évolution de la qualité du produit est décrite par les équations d'Arrhenius
3. Les réactions chimiques ou biochimiques de la qualité du produit sont d'ordre 0



et 1.

4. Le produit a une durée de vie de  $N$  jours s'il est conservé à sa température de référence  $T_{ref}$  [K]
5. Le produit a une durée de vie de  $N/2$  jours s'il est conservé à  $T_{ref} + 10$  [K] (Cooksey [2008])
6. le seuil critique sur la qualité est  $2/3$  de la durée de vie initiale du produit

Ces hypothèses ont été choisies, car elles correspondent à des hypothèses communes à plusieurs fruits et légumes.

Soit  $A$  l'indicateur qualité du produit fictif. On suppose qu'au début de la chaîne la qualité initiale  $A_0$  est maximale, c'est-à-dire 100%. Son évolution en fonction du temps est décrite par l'équation d'Arrhenius :

$$-\frac{dA}{dt} = kA^n \quad (3.6)$$

Où  $k$  est la constante de la cinétique [ $s^{-1}$ ],  $n$  est l'ordre de la réaction qui détermine si le changement de l'indicateur qualité  $A$  en fonction du temps dépend de lui-même. La réaction chimique étant d'ordre 0, 3.6 peut être intégrée :

$$A(t) = A_0 - kt \quad (3.7)$$

Où  $A_0$  est la qualité initiale du produit.

La dépendance temporelle de  $k$  souvent décrite par une relation d'Arrhenius :

$$k(T) = k_0 e^{\frac{-E_a}{RT}} \quad (3.8)$$

- $T$  : température [K]
- $A$  : indicateur de qualité [%]
- $R$  : constant de gaz parfait  $8.31 \text{ J mol}^{-1} \text{ K}^{-1}$
- $E_a$  : Énergie d'activation [ $\text{J mol}^{-1}$ ]
- $t$  : temps [s]

D'après l'hypothèse 3 : le produit a une durée de vie de  $N$  jours quand il est conservé à la température de référence  $T_{ref}$  :

$$1 - k(T_{ref})N = 0 \quad (3.9)$$

$$1 - k(T_{ref} + 10)\frac{N}{2} = 0 \quad (3.10)$$

Ainsi, pour une durée de vie  $N$  donnée et avec les équations définies en 3.6, on peut calculer explicitement  $k_0(N)$  et  $E_a(N)$  :

$$k_0(N) = \frac{1}{N} \frac{T_{ref} + 10}{T_{ref}} \quad (3.11)$$

$$E_a(N) = -\frac{-R \times \ln(2)}{\frac{1}{T_{ref} + 10} - \frac{1}{T_{ref}}} \quad (3.12)$$

### 3.3.2 Choix de la durée de vie initiale du produit

La chaîne logistique construite dure en moyenne 9 jours et 18 h 30. D'après des données expertes, les chaînes logistiques de fruits et légumes durent approximativement 1/3 de la durée de vie des produits. Les produits de cette chaîne devraient avoir une durée de vie de 29 jours à la température de référence  $T_{ref}$ .

### 3.3.3 Variabilité biologique du produit

La durée de vie d'un produit n'est pas identique d'un produit à l'autre. Deux produits soumis à la même température ne se dégradent pas à la même vitesse. Dans la littérature, il existe des lois distributions des paramètres  $k_0$  et  $E_a$  qui modélisent cette variabilité. Pour inclure la variabilité biologique on considère que la durée de vie initiale  $N_{init}$  est une variable aléatoire qui suit une loi normale  $\mathcal{N}(29, 1.5)$ .

### 3.3.4 Label qualité

Selon le Chapitre 1, pour les produits dont la température est recommandée, comme c'est le cas des fruits, une rupture est une élévation de température qui impacte la qualité du produit, c'est-à-dire que le produit ne respecte plus les attentes du consommateur. On peut supposer que puisque la durée de la chaîne est de  $1/3$  de la durée de vie du produit, les produits sont attendus avec une durée de vie restante supérieure ou égale à  $2/3$ . Ainsi, on définit qu'une cargaison arrive en *bon* état si les produits ont une durée de vie restante supérieure ou égale à  $2/3$ . La durée de vie initiale d'un produit est de 100%. Ensuite, grâce à la durée de vie initiale  $N_j$  de chaque produit en jours, on calcule  $k_0$  (Eq. 3.11) et  $E_a$  (Eq. 3.12). Le modèle qualité calcule donc la durée de vie restante du produit (en %).

On note  $RSL_j(t)$  (Remaining Shelf Life) cette durée de vie restante au temps  $t$  :

$$RSL_j(t) = 1 - \int_0^t k(T_{prod}(s)) ds \quad (3.13)$$

Ainsi, on définit  $Qual(\mathbf{x})$  le label qualité :

$$Qual(\mathbf{x}) = \begin{cases} ok & \text{si } \frac{1}{100} \sum_{j=1}^{100} \mathbb{1}_{RSL_j(t_{end}) > 2/3} > 90 \\ -ok & \text{sinon} \end{cases} \quad (3.14)$$

## 3.4 Intégration des modèles logistique, thermique, de consommation énergétique et de qualité

Sur la figure 3.2, on peut voir les différentes étapes de simulation, composées d'un module de simulation de circuit logistique, un modèle thermique, un modèle de consommation énergétique et un modèle qualité. Pour construire chaque scénario de la chaîne du froid, la simulation se déroule de la façon suivante :

1. La température extérieure ( $T_{ext}$ ) est tirée aléatoirement suivant une loi uniforme en considérant la température minimale de  $5^\circ\text{C}$  et maximale de  $35^\circ\text{C}$  ( $T_{ext} \sim \mathcal{U}([5, 35])$ )

2. Pour chaque étape  $i$ , on tire aléatoirement les durées de séjours  $D_i$  de produit et les températures de l'air  $T_i$  des équipements. Cette étape donne la température de l'air en fonction du temps pour la totalité du circuit logistique.
3. Le modèle thermique zonal permet de calculer la température des produits en fonction du temps.
4. Le modèle de consommation énergétique, qui prend comme paramètre d'entrée la température de l'air autour de la palette, la température des produits, la température extérieure et un paramètre  $K$  (niveau d'isolation d'équipement), calcule la consommation énergétique de l'ensemble des équipements.
5. Ensuite, le modèle qualité calcule les durées de vies restantes des produits ( $RSL_j$ , Remaining Shelf Life, en %) des 100 produits, qui dépendent de leur durée de vie initiale  $N_j$ , tirée aléatoirement.

## Conclusion

Dans ce chapitre, un modèle de simulation de scénarios de chaîne du froid a été développé. Il simule une chaîne du froid fictive pour une palette de 100 produits sphériques de type fruit. La qualité des produits au fil du temps est calculée en tenant compte d'une variabilité biologique, ce qui fait que les qualités des 100 produits ne sont pas identiques en fin de chaîne. Notre approche est en adéquation avec une réalité terrain : deux fruits dans une même palette n'arrivent pas toujours dans le même état, en raison de la variabilité biologique des produits et aussi de l'hétérogénéité de température au sein d'une palette. Les scénarios seront étiquetés  $ok$  ou  $-ok$ , en fonction de la qualité des produits en fin de chaîne. La consommation énergétique est calculée pour chaque scénario. L'ensemble des modèles logistiques, thermiques, de consommation énergétique et de qualité de produit permet une évaluation complète d'une chaîne du froid.

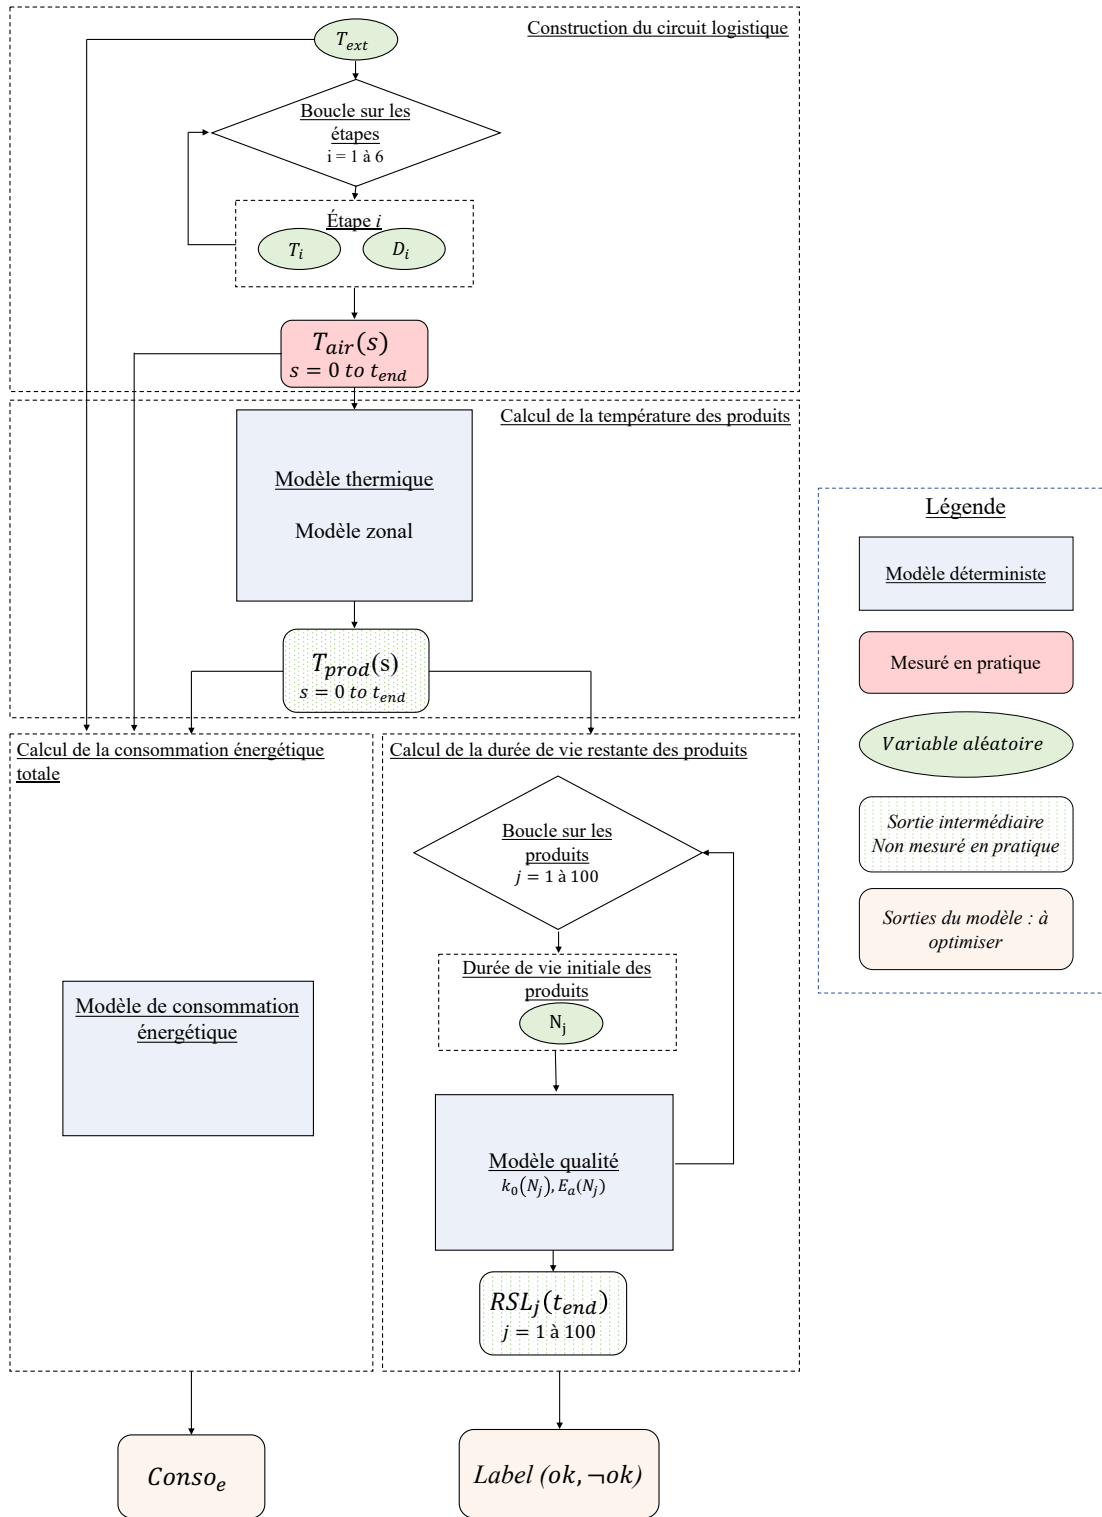


FIGURE 3.2 – Modèle de simulation de chaîne du froid

## Chapitre 4

# Méthodologie de prise de décision en temps réel

La conservation des aliments par le froid permet d'étendre la durée de vie des produits. Parfois, des ruptures peuvent rendre des produits invendables ou inconsommables, et donc gaspillés. Une solution pour réduire ce gaspillage serait d'installer un système capable d'alerter et de baisser la température d'un équipement. Cependant, une telle action a un coût énergétique : des actions fréquentes voir systématiques seraient efficaces, mais auraient un coût élevé. Nous voulons montrer qu'il est possible de réduire le gaspillage et de limiter la consommation énergétique grâce à des critères d'alertes intelligents. En nous basant sur le modèle développé au chapitre 3, nous allons tester différentes politiques de décision.

Ce chapitre présente la démarche du développement de modèles de détection des ruptures de la chaîne du froid ainsi que les prises de décision pour la mise en place de mesures correctives. Nous présentons comme approche de comparaison une méthode de détection présentée dans Hafliðason et al. [2012] basée sur un seuil sur la température, que nous adaptons à la prise de décision en considérant qu'une alerte équivaut à une décision. Ensuite, nous présentons deux méthodes d'apprentissage : une basée sur un classifieur qui prédit si la cargaison arrive en bon ou mauvais état, et une adaptative qui,

avec le même classifieur estime aussi à quel moment agir pour minimiser le coût.

L'originalité de la méthodologie est d'intégrer à la prise de décision la probabilité de l'efficacité de la prise de décision (le fait que le produit arrive dans la qualité souhaitée chez le client) et le coût associé à cette prise de décision.

Le modèle développé au chapitre 3 permet de simuler une chaîne du froid et ainsi de simuler des températures d'air, de produits, des durées de vie et consommation énergétiques. En pratique, comme dans le Chapitre 2, seule la température de l'air dans la palette est mesurée, par un capteur sans fil. On souhaite construire une politique de décision basée sur cette température qui permet de réduire le gaspillage, tout en limitant la consommation énergétique. Dans cette thèse, nous nous intéressons à une politique de décision capable, à l'issue d'une alerte, de baisser la température de consigne d'un équipement frigorifique.

## 4.1 Définitions

Dans cette étude, nous avons défini un certain nombre de termes qui nous ont permis de modéliser les différentes méthodes de détection et de correction de ruptures de chaîne du froid. Plus précisément, chaque politique de décision  $\pi$  prend en entrée un état, noté  $x_m$ , et décide si elle doit ou non prendre une action, notée  $a$ , ou ne rien faire, notée  $-a$ .

### 4.1.1 État

L'état  $x_m$  du système au maillon  $m$  de la chaîne est défini comme un vecteur de données enregistrées par le capteur :

- $m$  : maillon de la chaîne allant du maillon 1 au maillon  $M$
- $T_m$  : Température de l'air mesurée par le capteur sans fil (posé à l'intérieur de la palette)
- $T^{ext}$  : Température de l'air à l'extérieur (météo)
- $\sum_{i=1}^{m-1} D_i$  : Temps écoulé depuis le début de la chaîne
- $\sum_{i=1}^{m-1} D_i \times T_i$  Intégrale temps/température de la température mesurée par le

capteur sans fil

- *équipement* : un booléen l'équipement est frigorifié ou pas

Ces variables ont été choisies car elles sont toutes liées aux sorties à optimiser : la qualité et l'énergie. La température de l'air extérieure  $T^{ext}$  a un impact sur la consommation énergétique : en été, un camion frigorifique consomme plus d'énergie qu'en hiver. La température de l'air dans la palette  $T_m$  au maillon  $m$  a un impact direct sur la température des produits, qui est étroitement liée à l'évolution de leur qualité. L'intégrale de la température de l'air  $\sum_{i=1}^{m-1} D_i \times T_i$  est une donnée souvent utilisée dans l'estimation de la qualité, car la qualité est une fonction de l'intégrale temps température des produits. L'identifiant du maillon  $m$  pourrait aussi être utile car, le nombre de maillons de la chaîne étant supposé connu, l'identifiant du maillon permet d'estimer le temps restant avant d'arriver à destination. Par exemple, si l'intégrale de température est déjà élevée au deuxième maillon, une intervention sera nécessaire, contrairement à la situation où cette même intégrale est observée au dernier maillon. Dans ce cas, aucune intervention ne sera requise. L'*équipement* nous permettra de déterminer si une action est possible.

Dans le chapitre 3, le modèle de chaîne du froid développé suppose plusieurs hypothèses importantes pour la compréhension de la suite de ce chapitre :

- La température de l'air extérieur  $T^{ext}$  est constante sur l'ensemble de la chaîne.
- Le nombre et l'ordre des  $M$  équipements, ou maillons, de la chaîne sont connus. Par exemple, la chaîne sur laquelle nous testons les méthodes comporte 6 étapes, dont 4 réfrigérées (soit 4 maillons,  $M = 4$ ).
- Si une action est lancée, elle est appliquée uniquement dans le maillon courant et pour toute la durée du maillon.



### 4.1.2 Actions, scénarios

On suppose qu'un modèle génératif  $G$  permet de calculer l'état au maillon  $m + 1$  sachant l'état au maillon  $m$  et l'action  $a_m$

$$\begin{aligned} G : \mathcal{S}, \quad \mathcal{A} &\longrightarrow \mathcal{S} \\ \mathbf{x}_m, \quad a_m &\longmapsto \mathbf{x}_{m+1} \end{aligned} \tag{4.1}$$

Avec

- $\mathcal{A} = \{a, \neg a\}$  l'ensemble des actions possibles (agir, ou ne pas agir)
- $\mathcal{S}$  l'ensemble des états possibles

Le modèle  $G$  est le modèle de circuit logistique (modèle de durées de séjour et températures le long d'une chaîne présenté dans le chapitre 3). On appelle un *scénario*, noté  $\mathbf{x}_M$  la suite des couples (état, action)  $\{(x_0, a_0), (x_1, a_1), \dots, (x_M, a_M)\}$  d'une chaîne. Si une action est lancée, elle est appliquée pour la totalité du maillon, c'est-à-dire que la température est baissée pour tout le maillon. À l'issue d'un scénario, les modèles de calcul de coût énergétique (section 3.2) et de qualité (section 4.1.3) permettent de calculer la consommation énergétique  $Conso_e(\mathbf{x}_M)$  et la qualité  $Qual(\mathbf{x}_M) \in \{ok, \neg ok\}$  à la fin de la chaîne.

### 4.1.3 Politique

On définit une *politique* de décision  $\pi$  une fonction qui à un état  $\mathbf{x}_m$  associe une action  $a_m \in \{\neg a, a\}$

$$\begin{aligned} \pi : \mathcal{S} &\longrightarrow \mathcal{A} = \{\neg a, a\} \\ \mathbf{x}_m &\longmapsto a_m \end{aligned} \tag{4.2}$$

où

- $\neg a$  correspond à "ne pas agir"
- $a$  correspond à "agir"
- $\mathbf{x}_M | \pi$  le scénario  $\mathbf{x}_M$  sachant la politique  $\pi$ , si pour tout  $m \in [1, M]$ ,  $a_m = \pi(\mathbf{x}_m)$
- $(\mathbf{x}_M | \pi_{a_m})$  le scénario  $\mathbf{x}_M = \{(x_0, a_0), (x_1, a_1), \dots, (x_M, a_M)\}$  sachant la politique

$\pi_{a_m}(\mathbf{x}_M|\pi_{a_m})$  où

—  $\pi_{a_m}(x_i) = \neg a \ \forall i \neq m$

—  $\pi_{a_m}(x_m) = a_m$

$\mathbf{x}_M|\pi_{a_m}$  est le scénario où l'action  $a_m$  a été prise au maillon  $m$ , et aucune action n'a été prise aux autres maillons.

On définit la politique  $\pi_{\neg a}$  qui n'agit jamais :

$$\begin{aligned} \pi_{\neg a} : \quad \mathcal{S} &\longrightarrow \mathcal{A} \\ x_m &\longmapsto \neg a \end{aligned} \tag{4.3}$$

Le coût énergétique  $C_e(\mathbf{x}_M|\pi)$  d'une politique  $\pi$  est la différence entre la consommation énergétique  $Conso_e(\mathbf{x}_M|\pi)$  (cf. section 3.2) et la consommation énergétique du même scénario sans effectuer aucune action  $Conso_e(\mathbf{x}_M|\pi_{\neg a})$  :

$$C_e(\mathbf{x}_M|\pi) = Conso_e(\mathbf{x}_M|\pi) - Conso_e(\mathbf{x}_M|\pi_{\neg a}) \tag{4.4}$$

La qualité d'une cargaison est donnée par le modèle qualité présenté en section qui à  $\mathbf{x}_M$  attribue  $ok, \neg ok$

$$Qual(\mathbf{x}_M|\pi) \in \{ok, \neg ok\} \tag{4.5}$$

Les calculs du coût énergétique et du gaspillage sont des calculs déterministes, mais calculable uniquement à la fin de la chaîne.

L'algorithme 2 présente le processus utilisé pour tester une politique de décision. En partant d'un état initial  $x_0$ , tant que  $m < M + 1$ , c'est-à-dire tant que la chaîne n'est pas terminée ( $M$  est supposé connu), la politique  $\pi$  prend la décision  $a_m$  à partir de  $x_m$ .  $G$  modélise l'environnement et les interactions de cet environnement avec les actions : il permet de calculer  $x_{m+1}$  au maillon suivant à partir de  $x_m$  et  $a_m$ . À chaque itération, l'état  $x_m$  et l'action  $a_m$  sont gardés en mémoire.

**Algorithme 2** Simulation d'un scénario suivant la politique  $\pi$ 


---

```

 $x_0 = \text{état initial}$ 
 $m = 0$ 
tant que  $m < M + 1$  faire
     $a_m = \pi(x_m)$ 
     $x_{m+1} = G(x_m, a_m)$ 
     $m = m + 1$ 
    save ( $x_m, a_m$ )
fin tant que

```

---

On suppose que si une cargaison arrive en mauvais état, elle est jetée. Le taux de gaspillage associé à une politique de décision  $\pi$  sur  $N$  scénarios est défini :

$$Gasp(\pi) = \frac{1}{N} \sum_i^N [\mathbb{1}_{Qual(x_M^i | \pi) = \neg ok}]$$

On cherche une politique  $\pi$  de décision qui minimise le taux le gaspillage tout en minimisant l'écart entre l'énergie dépensée en suivant la politique  $\pi$  et l'énergie dépensée en suivant la politique  $\pi_{-a}$  qui revient à ne jamais prendre d'actions.

Le coût  $Cost_a$  d'une politique  $\pi$  est défini par :

$$Cost_a(\mathbf{x}_M | \pi) = \underbrace{\alpha_{qualite} \mathbb{1}_{Qual(\mathbf{x}_M | \pi) = \neg ok}}_{\text{Penalite sur la qualite}} + \underbrace{\alpha_{energie} Cost_e(\mathbf{x}_M | \pi)}_{\text{Penalite sur l'energie}} \quad (4.6)$$

Où

- $Cost_e$  est le coût énergétique (calcul déterministe, cf. Eq.4.4).
- $\mathbb{1}$ . est la fonction indicatrice :

$$\mathbb{1}_{Qual(\mathbf{x}_M | \pi) = \neg ok} = \begin{cases} 1 & \text{si } Qual(\mathbf{x}_M | \pi) = \neg ok \\ 0 & \text{sinon} \end{cases} \quad (4.7)$$

Le coût d'une politique  $\pi$  est calculée en fonction de l'état de la qualité à la fin de la chaîne sachant que la politique a été appliquée  $Qual(\mathbf{x}_M | \pi)$  :

- Si  $Qual(\mathbf{x}_M | \pi) = ok$ , on ne paye pas de pénalité sur la qualité
- Si  $Qual(\mathbf{x}_M | \pi) = \neg ok$ , on paye la pénalité sur la qualité  $\alpha_{qualite}$

De plus, à cette pénalité sur la qualité s'ajoute une pénalité sur l'énergie, le coût énergétique de l'action, qui dépend à la fois de la consommation énergétique du scénario qui applique la politique  $\pi$ , mais aussi de la consommation énergétique du même scénario où la politique "ne rien faire" a été appliquée ( $\pi_{-a}$ )  $Cost_e(\mathbf{x}_M|\pi_{a_m})$  pondéré par  $\alpha_{energie}$ .

On suppose  $\alpha_{qualite}$  et  $\alpha_{energie}$  connus. Ces proportions sont déterminées par le prix du produit, le coût du transport et le coût de l'électricité. Dans cette thèse, nous testerons différentes valeurs de  $\alpha_{energie}$  comprises entre 0 et 1, et nous fixerons  $\alpha_{qualite} = 1 - \alpha_{energie}$ .

#### 4.1.4 Évaluation des méthodes : coût moyen

Soient  $\mathbf{x}_M^1|\pi, \dots, \mathbf{x}_M^N|\pi$   $N$  scénarios suivant la politique  $\pi$  générés avec l'algorithme 2. Pour évaluer chaque politique  $\pi$  testée, on calcule empiriquement le coût moyen sur les  $N$  scénarios pour chaque  $\alpha_{energie}$  :

$$\overline{Cost(\pi)}_{\alpha_{energie}} = \frac{1 - \alpha_{energie}}{N} \sum_{i=1}^N \mathbb{1}_{Qual(\mathbf{x}_M^i|\pi)=-ok} + \frac{\alpha_{energie}}{N} \sum_{i=1}^N C_e(\mathbf{x}_M^i|\pi)[J] \quad (4.8)$$

#### 4.1.5 Alertes : différents types d'erreurs

L'optimisation du coût prend en compte le gaspillage et la consommation énergétique. Cependant, d'autres facteurs liés aux alertes pourraient impacter le bon déroulement de la chaîne. Il y a trois types d'erreurs possibles lorsqu'une alerte est lancée : fausses alertes, alertes non détectées et alertes non optimales.

##### 4.1.5.1 Fausse alerte

Une fausse alerte est une alerte qui aurait pu être évitée : même sans l'action, la cargaison serait arrivée en bon état. L'action  $a_m$  est une fausse alerte si :

$$\begin{aligned} Qual(\mathbf{x}_M|\pi_{-a}) &= ok \\ Qual(\mathbf{x}_M|\pi_{a_m}) &= ok \end{aligned} \tag{4.9}$$

#### 4.1.5.2 Alerte non détectée

Une alerte non détectée est une alerte qui aurait pu empêcher la cargaison de se détériorer, mais qui n'a pas été lancée.

$$\begin{aligned} Qual(\mathbf{x}_M|\pi_{-a}) &= \neg ok \\ Qual(\mathbf{x}_M|\pi_{a_m}) &= ok \end{aligned} \tag{4.10}$$

#### 4.1.5.3 Alerte non optimale

Une alerte non optimale est une alerte qui a été lancée mais la cargaison n'est quand même pas arrivée en bon état :

$$Qual(\mathbf{x}_M|\pi_{a_m}) = \neg ok \tag{4.11}$$

Dans le système que nous avons choisi, il est seulement possible de baisser la température et le modèle de qualité n'inclut pas la perte de qualité qui pourrait être liée à une température trop froide. Donc, dans notre cas, si la cargaison est arrivée en mauvais état avec une action, elle serait nécessairement arrivée en mauvais état sans action. Il est à noter qu'avec un modèle qualité qui prend en compte la dégradation des produits exposés à des températures trop froides, ou avec un système d'action capable d'augmenter la température, ce ne serait pas le cas.

#### 4.1.6 Nombre d'actions par maillon

Le nombre d'actions par maillon est intéressant à regarder du point de vue logistique : en effet, rendre les actions possibles dans un maillon nécessite d'équiper ce maillon d'une technologie capable de baisser la température en temps réel. Si un maillon est peu sollicité, c'est-à-dire que peu d'actions sont lancées dans ce maillon, il n'est pas nécessaire de

l'équiper de cette technologie. À l'inverse, si un maillon apparaît comme stratégique, c'est-à-dire qu'il est le plus souvent sollicité, il devient intéressant de l'équiper en priorité. Le nombre total d'actions par maillon est calculé pour chaque politique, sur 700 scénarios.

Dans la suite de ce chapitre nous allons présenter chaque méthode accompagnée des résultats de validation (sur 700 scénarios) : quels paramètres sont sélectionnés pour chaque  $\alpha_{\text{energie}}$  ? Comment se comportent les méthodes : nombre d'actions par maillon, nombre de fausses alertes ? Enfin, nous présenterons une comparaison des 3 méthodes validées sur un nouvel ensemble de test de 700 scénarios.

## 4.2 Méthode à seuil

La méthode de comparaison choisie est la méthode la plus utilisée dans les systèmes WSN. Cette méthode est basée sur le critère d'alerte suivant : si la température mesurée par le capteur (la température de l'air dans la palette) dépasse un seuil prédéfini, une alerte est lancée. Dans ce travail, nous souhaitons prendre la décision de baisser la température de l'équipement. Notre méthode de décision basée sur cette alerte sera la suivante :

$$\pi_{T_{\text{seuil}}}(\mathbf{x}_m) = \begin{cases} a & \text{si } T_m > T_{\text{seuil}} \\ \neg a & \text{sinon} \end{cases} \quad (4.12)$$

Quand la température  $T_m$  du maillon  $m$  dépasse  $T_{\text{seuil}}$ , l'action  $a$  est lancée.

### 4.2.1 Sélection de $T_{\text{seuil}}$ par $\alpha_{\text{energie}}$

10 valeurs de  $T_{\text{seuil}}$  sont testées, entre 6°C (la température de conservation optimale des produits) et 12°C. Pour chaque  $\alpha_{\text{energie}}$  donné,  $\hat{T}_{\text{seuil}}$  qui minimise le coût moyen défini en eq.4.1.4 est sélectionné :

$$\hat{T}_{\text{seuil}}(\alpha_{\text{energie}}) = \arg \min_{T_{\text{seuil}}} \overline{\text{Cost}}_{\alpha_{\text{energie}}}(\pi_{T_{\text{seuil}}}) \quad (4.13)$$

La figure 4.1 montre le seuil sur la température sélectionné en fonction de  $\alpha_{\text{energie}}$ . Plus  $\alpha_{\text{energie}}$  est bas, moins on accorde d'importance à la consommation énergétique et plus le seuil sélectionné est bas. En effet, plus le seuil est bas plus on fait d'actions, et plus les actions sont coûteuses. La température de seuil optimale est donc à définir en fonction du rapport entre le coût des produits et le coût de l'énergie.




FIGURE 4.1 –  $\hat{T}_{\text{seuil}}$  en fonction de  $\alpha_{\text{energie}}$

### 4.2.2 Nombre d’alertes et de fausses alertes

La figure 4.2 montre le nombre d’actions par maillon et par seuil. Aux étapes 2 et 4, aucune action n’est prise, car ils ne concernent pas des équipements frigorifiés (transfert entre deux maillons). Les actions sont réparties de manière égale entre les maillons, ce qui est conforme aux attentes puisque les températures suivent toutes la même loi  $\Gamma(6, 1)$  et sont indépendantes. Plus le seuil est bas (6) plus le nombre d’actions est élevé, et plus le seuil est élevé (12), plus le nombre d’actions est bas.

La figure 4.4 montre le taux de fausses alertes par maillon pour la méthode à seuil. Le taux de fausses alertes est plus élevé dans les deux derniers maillons, ce qui est attendu, car d’autres alertes ont déjà été menées en amont. Une façon de réduire les fausses alertes serait d’interdire les actions dans un des deux derniers maillons ou les deux. Cependant, le nombre de cargaisons en mauvais état risquerait d’augmenter. On remarque finalement qu’un critère basé uniquement sur la température offre assez peu de flexibilité : plus on baisse le seuil de tolérance, plus on augmente la qualité mais mécaniquement on augmente la consommation énergétique.




FIGURE 4.2 – Nombre d’actions par maillon et par  $T_{seuil}$






FIGURE 4.3 – Nombre de fausses alertes par maillon et par  $T_{seuil}$  pour la méthode à seuil




FIGURE 4.4 – Taux de fausses alertes (Nombre de fausses alertes/nombre d'actions par maillon pour la méthode à seuil)

### 4.2.3 Coût moyen d'une action

$$\overline{C_e}(\pi) = \frac{1}{N} \sum_{i=1}^N \text{Conso}_e(\mathbf{x}_M^i | \pi) - \text{Conso}_e(\mathbf{x}_M^i | \pi_{-a}) [J] \quad (4.14)$$

La figure 4.5 montre le coût moyen d'une action par seuil sur la température  $T_{seuil}$ .




FIGURE 4.5 – Coût moyen  $\overline{C_e}$  d'une action par  $T_{seuil}$

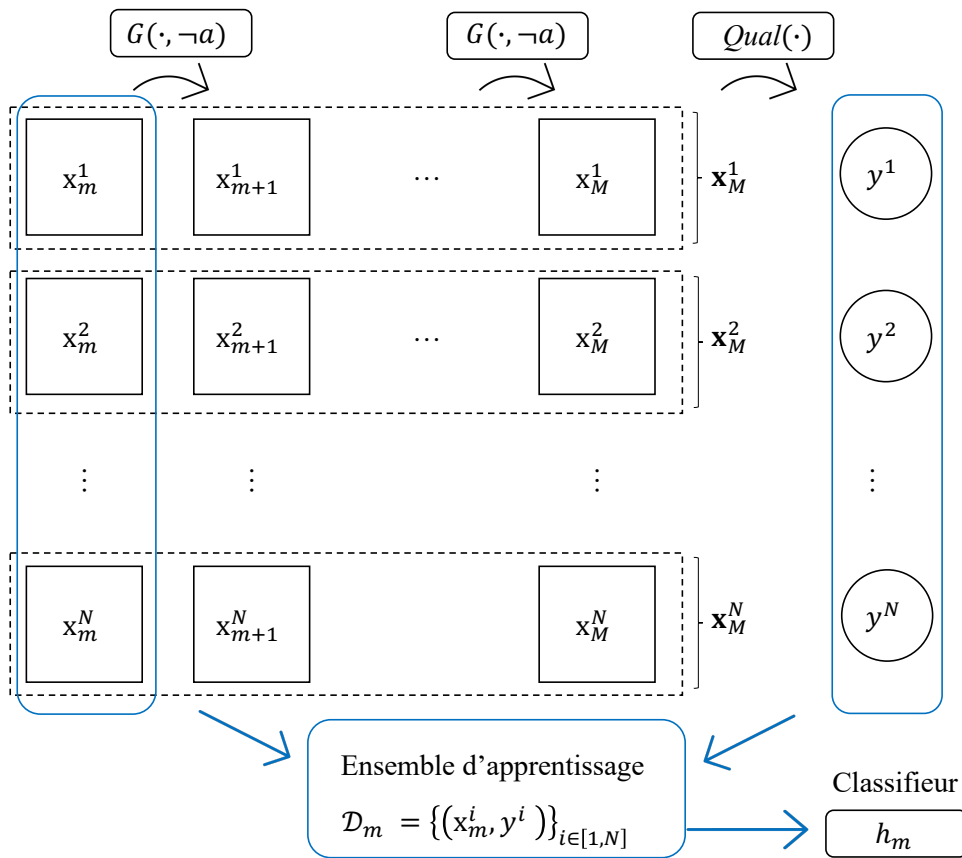
## 4.3 Méthode avec un classifieur $h$

La méthode à seuil ne prend en entrée que la température du maillon courant. Un classifieur pourrait, quant à lui, prendre en entrée l'ensemble des variables qui composent un état  $\mathbf{x}_m$ . En simulant plusieurs scénarios grâce à l'algorithme 2, et la politique  $\pi_{-a}$  sans actions on peut obtenir un ensemble d'apprentissage  $\mathcal{D} = \{(\mathbf{x}_m^i, y^i)\}_{m \in [1:M], i \in [1:N]}$  et une suite d'états labellisés où  $y^i = \text{Qual}(\mathbf{x}_M^i)$  est la qualité des produits en fin de chaîne.

Pour chaque maillon  $m$ , un classifieur  $h_m$  peut être entraîné sur  $\mathcal{D}_m = \{(\mathbf{x}_m^i, y^i)\}_{i \in [1:N]}$ ,  $N$  états dans un maillon  $m$  associés à leurs labels qualité en fin de chaîne.

$$\begin{aligned}
 h_m : \mathcal{S} &\longrightarrow \{ok, \neg ok\} \\
 x_m &\longmapsto h_m(x_m)
 \end{aligned}
 \tag{4.15}$$

La figure 4.6 montre comment l'ensemble d'apprentissage  $\mathcal{D}_m$  est construit. Après avoir simulé  $N$  scénarios  $\mathbf{x}_M^i$ , grâce au modèle générateur  $G$ , les labels  $y^i$  sont calculés grâce à la fonction  $Qual(\cdot)$  définie en 3.14. Ensuite, l'ensemble des états au maillon  $m$   $\mathbf{x}_m^i$  et leurs labels associés  $y^i$  sont assemblés pour former l'ensemble  $\mathcal{D}_m = \{(\mathbf{x}_m^i, y^i)\}_{i \in [1:N]}$ , et le classifieur  $h_m$  est entraîné.



**FIGURE 4.6** – Construction de l'ensemble d'apprentissage  $\mathcal{D}_m$  pour l'entraînement du classifieur  $h_m$ .

On obtient une collection de classifieurs  $\{h_1, \dots, h_M\}$  et la politique de décision  $\pi_h$  consiste, pour un état  $x_m$ , à appliquer le classifieur  $h_m$  qui prédit si la cargaison va

arriver en bon état ( $ok$ ) ou en mauvais état ( $\neg ok$ ). Si la cargaison arrive en mauvais état, la politique décide de lancer une action.

$$\pi_h(\mathbf{x}_m) = \begin{cases} a & \text{si } h_m(\mathbf{x}_m) = \neg ok \\ -a & \text{sinon} \end{cases} \quad (4.16)$$

Des variantes peuvent être obtenues en changeant le seuil du classifieur (probabilité que la cargaison arrive en mauvais état est supérieure à  $s$ ). Pour un classifieur  $h$ , la probabilité  $\mathbb{P}[h_m(\mathbf{x}_m) = ok]$  peut être calculée. La nouvelle politique  $\pi_{h^s}$  obtenue consiste, pour un état  $\mathbf{x}_m$ , à appliquer le même classifieur  $h_m$ , mais cette fois, la politique décide d'agir si la probabilité que la cargaison arrive en mauvais état est supérieure à  $s$ . Par exemple, si  $s = 0.3$ , on prend une décision dès que la probabilité que la cargaison arrive en mauvais état est supérieure à 30%. Le classifieur  $h_m^s(\mathbf{x}_m)$  est défini :

$$h_m^s(\mathbf{x}_m) = \begin{cases} ok & \text{si } \mathbb{P}[h_m(\mathbf{x}_m) = ok] < s \\ \neg ok & \text{sinon} \end{cases} \quad (4.17)$$

Ainsi, on définit  $\pi_{h^s}$  :

$$\pi_{h^s}(\mathbf{x}_m) = \begin{cases} ok & \text{si } h^s(\mathbf{x}_m) = ok \\ \neg ok & \text{sinon} \end{cases} \quad (4.18)$$

Ajuster la valeur de ce seuil permet de rendre la méthode plus ou moins sensible.

Les classifieurs  $h_m$  sont entraînés sur un ensemble d'apprentissage sans actions, générés avec l'algorithme 3.

La méthode classifieur sera testée pour 10 valeurs de seuil sur le classifieur de 0 à 1. La Table 4.1 présente les valeurs utilisées pour apprendre et tester la méthode classifieur.

**Algorithme 3** Construction de l'ensemble d'apprentissage  $\mathcal{D}$  sans action

---

Entrées :

- $N$  Le nombre de scénarios
- $G$  Modèle génératif
- $a$  Valeur de l'action

**for**  $scenario \in [1 : N]$  **faire**

$m = 1$

**tant que**  $m < M + 1$  **faire** ▷ Tant que la chaîne n'est pas terminée

$\mathbf{x}_{m+1} = G(\mathbf{x}_m, -a)$  ▷  $G$  modèle génératif calcule l'état suivant  $\mathbf{x}_{m+1}$

$m = m + 1$

**fin tant que**

$y = Qual(\mathbf{x}_M)$

Sauvegarder  $(\mathbf{x}_1, \dots, \mathbf{x}_M, y)$

**fin for**

---

**TABLE 4.1** – Ensemble des paramètres pour apprendre et tester la méthode classifieur

Notation	Description	Valeurs
$s$	seuil sur le classifieur (cf 4.3)	$\{0.1, 0.2, \dots, 0.9\}$
$N$	taille de l'ensemble d'apprentissage	1000
$N_{val}$	Nombre de scénarios de validation	700

**4.3.1** Sélection de  $s$  par  $\alpha_{energie}$ 

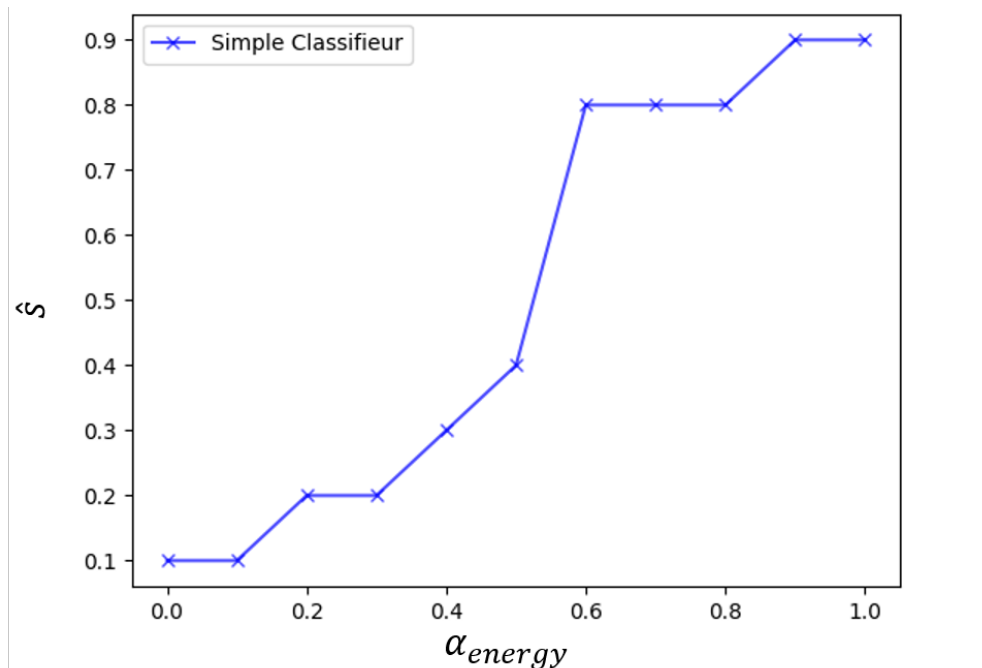
Pour chaque  $\alpha_{energie}$  donné,  $\hat{s}$  le seuil sur le classifieur qui minimise le coût moyen défini en 4.1.4 est sélectionné :

$$\hat{s}(\alpha_{energie}) = \arg \min_s \overline{Cost}_{\alpha_{energie}}(\pi_{h_s}) \quad (4.19)$$

La figure 4.7 montre le seuil  $s$  sélectionné. Plus  $\alpha_{energie}$  est élevé, plus les actions coûtent cher et le seuil sélectionné  $\hat{s}$  est élevé : la politique devient stricte et n'agit que si la probabilité que la cargaison arrive en mauvais état est élevée.

**4.3.2** Nombre d'alertes et de fausses alertes

La figure 4.8 montre le nombre d'actions par maillon pour la politique  $\pi_{h_s}$  en fonction du seuil  $s$  sur le classifieur. Le premier maillon semble légèrement privilégié par rapport aux autres. Ce résultat est attendu, car si une action est menée dès le premier maillon,



**FIGURE 4.7** –  $\hat{s}$  sélectionné pour la méthode classifieur, par  $\alpha_{\text{energie}}$

la probabilité que la cargaison arrive en mauvais état baisse. Si le seuil est bas, par exemple 0.1, une action est presque systématiquement menée dès le premier maillon. En effet, un seuil à 0.1 signifie que si la probabilité que la cargaison arrive en mauvais état est supérieure à 0.1, une action est lancée. Pour les seuils 0.1 et 0.2, le nombre d'actions menées diminue avec l'identifiant du maillon de la chaîne. À l'inverse, pour les seuils supérieurs à 0.3, le nombre d'actions par maillon ne diminue pas strictement en fonction du temps. Ceci est peut-être dû au fait que les classifieurs sont entraînés sur un ensemble d'apprentissage sans actions. Or, pendant le test, les politiques de décisions sont appliquées à chaque maillon, indépendamment des actions menées en amont du scénario testé. De ce fait, la population des états est peut-être différente de la population pendant l'entraînement.

La figure 4.10 montre le nombre de fausses alertes par maillons. On remarque que le nombre de fausses alertes diminue en fonction du maillon. En effet, cela peut être expliqué par le fait que le classifieur, dans les premiers maillons, a une connaissance partielle de




FIGURE 4.8 – Nombre d’actions par maillon pour la politique classifieur  $\pi_h$  par seuil sur le classifieur  $s$

la chaîne et ne prend pas les bonnes décisions.





FIGURE 4.9 – Nombre de fausses alertes par maillon pour la politique classifieur  $\pi_{h_s}$  par seuil sur le classifieur  $s$




**FIGURE 4.10** – Taux de fausses alertes par maillon pour la politique classifieur  $\pi_{h_s}$  par seuil sur le classifieur  $s$

### 4.3.3 Coût énergétique moyen d'une action

La figure 4.11 présente le coût moyen d'une action par seuil sur le classifieur  $s$ . On remarque que le coût moyen d'une action est constant quel que soit le seuil, mais que les actions menées sont en moyenne plus coûteuse que la méthode à seuil basée sur la température. cela s'explique par le fait que la méthode classifieur peut lancer des actions indépendamment de la température actuelle du maillon. C'est-à-dire que même si l'équipement est déjà à une température basse (4 °C), s'il estime que la cargaison va arriver en mauvais état, il effectue une action correctrice et baisse la température de 3 °C. Or, baisser la température d'un équipement déjà froid demande plus d'énergie que baisser la température d'un équipement dont la température est supérieure à 6 °C (dans la méthode à seuil sur la température on n'abaissera jamais la température lorsque celle-ci est supérieure à 6 °C).





**FIGURE 4.11** – Coût moyen  $\overline{C}_e$  d'une action pour la politique classifieur  $\pi_{h_s}$  par seuil sur le classifieur  $s$

#### 4.4 Méthode adaptative

La méthode classifieur fait des erreurs dans les premiers maillons (le nombre de fausses alertes au maillon 1 est le plus élevé). De plus, les actions lancées par le classifieur sont plus coûteuses en énergie que la méthode à seuil : en effet, la méthode à seuil n'agit jamais quand la température est en dessous d'un certain seuil alors que la méthode classifieur peut agir même quand la température est déjà froide. Une politique de décision plus robuste pourrait prendre en compte l'incertitude du classifieur et le coût énergétique d'une action pour décider si la prédiction est fiable, et s'il serait plus judicieux d'attendre la prochaine mesure pour décider. Une méthode, basée sur la même collection de classifieurs que dans 4.3 peut être implémentée de façon adaptative. Achenchabe et al. [2021] optimisent un coût de *mauvaise classification*, ainsi qu'un coût *temporel* pour la classification précoce de séries temporelles. Dans leur cas, le but est de classifier les séries temporelles le plus tôt possible, en minimisant les mauvaises classifications. Par exemple,

classifier si un électrocardiogramme est anormal, si la prédiction est faite suffisamment tôt, peut permettre une meilleure décision. Ces méthodes sont basées sur l'optimisation d'un coût (coût de mauvaise classification et coût temporel). Étant donné un état actuel (dans leur cas, une série temporelle incomplète), les connaissances passées sont utilisées pour estimer les coûts actuels et les coûts à venir. Ensuite, ces coûts sont comparés pour décider si la décision est prise maintenant ou plus tard. Les méthodes développées dans ces travaux supposent deux choses :

1. Gain d'information avec le temps
2. Le coût temporel de reporter la décision est croissant

La première hypothèse semble être vérifiée. En effet, la qualité et l'énergie dépendent de l'historique temps/température. L'attente, du maillon  $m$  au maillon  $m + 1$  permet de gagner des informations sur la chaîne d'approvisionnement, en particulier la température du maillon suivant  $T_{m+1}$ , et la durée du maillon actuel  $D_m$ . Reporter la décision a un coût croissant : en effet, plus une action de baisser la température est tardive, moins elle a de chances d'être efficace. L'originalité de ce cas d'usage par rapport à ceux traités dans les travaux de classification précoce est qu'une décision implique une action capable de changer le futur (la température de consigne), et ainsi de changer le label (la qualité finale du produit).

Les deux méthodes proposées précédemment, les méthodes à seuil sur la température (section 4.2) et les méthodes basées sur un classifieur (section 4.3) optimisent le coût  $\overline{Cost}_{\alpha_{energie}}$ , implicitement, car les paramètres de ces méthodes ( $T_{seuil}$  et  $s$ ) sont choisis de sorte à le minimiser ( $\hat{T}_{seuil}$  et  $\hat{s}$ ). La méthode adaptative présentée dans cette section propose d'optimiser ce même coût, mais explicitement : en estimant en temps réel le coût associé à une action.

#### 4.4.1 Coût d'une action : un compromis entre la qualité et l'énergie

Le coût d'une action  $a_m$  au maillon  $m$  est donné par la somme de la pénalité sur la qualité  $\alpha_{qualite}$  si la cargaison arrive en mauvais état malgré l'action  $a_m$ , et du coût

énergétique de  $a_m$  pondéré par  $\alpha_{energie}$  :

$$Cost_a(\mathbf{x}_M|\pi_{a_m}) = \alpha_{qualite} \mathbb{1}_{Qual(\mathbf{x}_M|\pi_{a_m})=\neg ok} + \alpha_{energie} C_e(\mathbf{x}_M|\pi_{a_m}) \quad (4.20)$$

Cependant, au moment de la décision, dans le maillon  $m$ , il est impossible de calculer ni  $Qual(\mathbf{x}_M|\pi_{a_m})$ , ni  $C_e(\mathbf{x}_M|\pi_{a_m})$ , car la suite de la chaîne n'est pas connue. Nous proposons d'estimer :

- le coût lié à la qualité grâce à un classifieur entraîné à prédire à l'avance si la cargaison va arriver en mauvais état
- le coût lié à l'énergie en estimant sur un ensemble d'apprentissage les coûts énergétiques de diverses actions

Le principe de la méthode adaptative est d'estimer d'une part la qualité finale des produits grâce à un classifieur, mais aussi de tenir compte de la précision du classifieur. En effet, au premier maillon, le classifieur a une connaissance partielle de la chaîne, et risque de se tromper plus souvent.

Soit  $h_m$  un classifieur qui prédit à partir de l'état dans le maillon  $m$  si la cargaison arrive en mauvais état. On note :

$$h_m(\mathbf{x}_m) = \hat{y}_m \quad (4.21)$$

On décide de lancer l'action si et seulement si il prédit que la cargaison va arriver en mauvais état :  $\hat{y}_m = \neg ok$ .

On définit  $d$  la fonction de décision :

$$d(\hat{y}_m) = \begin{cases} a & \text{si } \hat{y}_m = \neg ok \\ \neg a & \text{sinon} \end{cases} \quad (4.22)$$

Pour décider si l'action doit être lancée maintenant ou plus tard, les coûts espérés dans le maillon actuel et dans les maillons suivants sont estimés, grâce à la précision du classifieur par maillon. Si le coût espéré est inférieur dans un maillon suivant, l'action est reportée au prochain maillon. Sinon, l'action est lancée immédiatement dans le maillon

courant.

On définit  $C(x_m)$  le coût de prendre une action au maillon  $m$  :

$$\begin{aligned}
C(x_m) &= \mathbb{E}_{(y, \hat{y}_m) \in \mathcal{Y}^2}^m [Cost_a | x_m] \\
&= \sum_{(y, \hat{y}_m) \in \mathcal{Y}^2} P[y | x_m] P[\hat{y}_m | y, x_m] Cost_a(x_m, y | a_m = d(\hat{y}_m)) \\
&= \sum_{(y, \hat{y}_m) \in \mathcal{Y}^2} P[y | x_m] P[\hat{y}_m | y, x_m] ((1 - \alpha_{energie}) \mathbf{P}[y = \neg ok | x_m, a_m = d(\hat{y}_m)] \\
&\quad + \alpha_{energie} \mathbb{E}[C_e | x_m])
\end{aligned}$$

avec :

- $\mathcal{Y} = \{ok, \neg ok\}$
- $\mathbb{E}_{(y, \hat{y}_m) \in \mathcal{Y}^2}^m [\ ]$  est l'espérance au maillon  $m$
- $\mathbb{E}$  caractérise l'espérance du coût énergétique  $C_e$  de l'action sachant  $x_m$
- $P[y | x_m]$  est la probabilité de la classe  $y$  sachant l'état au maillon  $m$   $x_m$
- $P[\hat{y}_m | y, x_m]$  est la probabilité que le classifieur  $h_m$  prédise  $\hat{y}_m$  alors que le vrai label est  $y$

Si on développe :

$$C(x_m) = \mathbb{E}_{(y, \hat{y}_m) \in \mathcal{Y}^2}^m [Cost_a | x_m] \tag{4.23}$$

$$= P[y = ok | x_m] \mathbf{P}[\hat{y}_m = ok | y = ok, x_m] \times 0 \tag{4.24}$$

$$+ P[y = \neg ok | x_m] \mathbf{P}[\hat{y}_m = \neg ok | y = \neg ok, x_m] \tag{4.25}$$

$$\times \{(1 - \alpha_{energie}) \mathbf{Pr}[y = \neg ok | x_m, a_m] + \alpha_{energie} \mathbb{E}[C_e | x_m]\} \tag{4.26}$$

$$+ P[y = \neg ok | x_m] \mathbf{P}[\hat{y}_m = ok | y = \neg ok, x_m] \times (1 - \alpha_{energie}) \tag{4.27}$$

$$+ P[y = ok | x_m] \mathbf{P}[\hat{y}_m = \neg ok | y = ok, x_m] \times \alpha_{energie} \mathbb{E}[C_e | x_m] \tag{4.28}$$

1. on prédit  $\hat{y} = ok$  et  $y = ok$  (eq 4.24)

- On prédit  $\hat{y} = ok$ , donc on n'agit pas, et à raison car la cargaison arrive en bon état ( $ok$ ) : le coût est nul

2. on prédit  $\hat{y} = \neg ok$  et  $y = \neg ok$  (eq 4.25)
  - On prédit  $\hat{y} = \neg ok$ , donc on agit, et à raison, car la cargaison serait arrivée en mauvais état ( $\neg ok$ )
    - cas 2.1 Si la cargaison arrive en bon état avec cette action : le coût est égal au coût énergétique de l'action  $a_m$  :  $\alpha_{energie} C_e(\mathbf{x}_M, a_m)$  (eq 4.26)
    - cas 2.2 Si la cargaison arrive en mauvais état, même avec cette action : le coût est égal au coût de la mauvaise cargaison + le coût énergétique  $(1 - \alpha_{energie}) + \alpha_{energie} C_e(\mathbf{x}_M, a_m)$  (eq 4.26)
3. on prédit  $\hat{y} = ok$  alors que  $y = \neg ok$ 
  - on prédit  $\hat{y} = ok$  donc on n'agit pas, et la cargaison arrive en mauvais état  $y = \neg ok$ , on paye le coût de la mauvaise cargaison  $(1 - \alpha_{energie})$  (eq 4.27)
4. 4e cas : on prédit  $\hat{y} = \neg ok$  et  $y = ok$ 
  - on prédit  $\hat{y} = \neg ok$  donc on agit, et la cargaison arrive en bon état  $y = ok$  (avec l'action, la cargaison arrive forcément en bon état aussi car on ne peut que baisser la température, la qualité est de fait meilleure) : on paye le coût énergétique  $\alpha_{energie} Cost_a(\mathbf{x}_M)$  (eq 4.28)

Finalement en enlevant le terme nul :

$$C(\mathbf{x}_m) = \mathbb{E}_{(y, \hat{y}_m) \in \mathcal{Y}^2}^m [Cost_a | \mathbf{x}_m] \quad (4.29)$$

$$= P[y = \neg ok | \mathbf{x}_m] \mathbf{P}[\hat{y}_m = \neg ok | y = \neg ok, \mathbf{x}_m] \quad (4.30)$$

$$\times \{(1 - \alpha_{energie}) \mathbf{Pr}[y = \neg ok | \mathbf{x}_m, a_m] + \alpha_{energie} \mathbb{E}[C_e | \mathbf{x}_m]\} \quad (4.31)$$

$$+ P[y = \neg ok | \mathbf{x}_m] \mathbf{P}[\hat{y}_m = ok | y = \neg ok, \mathbf{x}_m] \times (1 - \alpha_{energie}) \quad (4.32)$$

$$+ P[y = ok | \mathbf{x}_m] \mathbf{P}[\hat{y}_m = \neg ok | y = ok, \mathbf{x}_m] \times \alpha_{energie} \mathbb{E}[C_e | \mathbf{x}_m] \quad (4.33)$$

Pour les temps futurs le coût de retarder la prise de décision de  $\kappa$  étapes est donné

par :

$$C_\kappa(\mathbf{x}_m) = \mathbb{E}^{m+\kappa}[Cost_a | \mathbf{x}_m] \quad (4.34)$$

$$= P[y = \neg ok | \mathbf{x}_m] \mathbf{P}[\hat{y} = \neg ok | y = \neg ok, \mathbf{x}_{m+\kappa}] \quad (4.35)$$

$$\times \{(1 - \alpha_{\text{energie}}) \mathbf{Pr}[y = \neg ok | \mathbf{x}_{m+\kappa}, a_{m+\kappa}] + \alpha_{\text{energie}} \mathbb{E}[C_e | \mathbf{x}_{m+\kappa}]\} \quad (4.36)$$

$$+ P[y = \neg ok | \mathbf{x}_m] \mathbf{P}[\hat{y} = ok | y = \neg ok, \mathbf{x}_{m+\kappa}] \times (1 - \alpha_{\text{energie}}) \quad (4.37)$$

$$+ P[y = ok | \mathbf{x}_m] \mathbf{P}[\hat{y} = \neg ok | y = ok, \mathbf{x}_{m+\kappa}] \times \alpha_{\text{energie}} \mathbb{E}[C_e | \mathbf{x}_{m+\kappa}] \quad (4.38)$$


Les coûts futurs  $C_\kappa(\mathbf{x}_m)$  dépendent des états suivants  $\mathbf{x}_{m+\kappa}$ . Cependant, ces états sont inconnus dans le maillon courant. Afin de pouvoir estimer le coût futur  $C_\kappa(\mathbf{x}_m)$ , dès le maillon  $m$ , et ensuite aux maillons  $m + \kappa$ , plusieurs termes doivent être estimés :

1. Les probabilités liées à la précision du classifieur :
  - La probabilité conditionnelle au maillon  $m$  :  $\mathbf{P}[\hat{y} | y, \mathbf{x}_m]$
  - La probabilité conditionnelle au maillon  $m + \kappa$  :  $\mathbf{P}[\hat{y} | y, \mathbf{x}_{m+\kappa}]$
2. Les probabilités liées à l'efficacité d'une action :
  - La probabilité que l'action soit efficace au maillon  $m$  :  $\mathbf{Pr}[y = \neg ok | \mathbf{x}_m, a_m]$
  - La probabilité que l'action soit efficace au maillon  $m + \kappa$  :  $\mathbf{Pr}[y = \neg ok | \mathbf{x}_{m+\kappa}, a_{m+\kappa}]$

## 4.4.1.1 Estimation des probabilités liées à la précision du classifieur

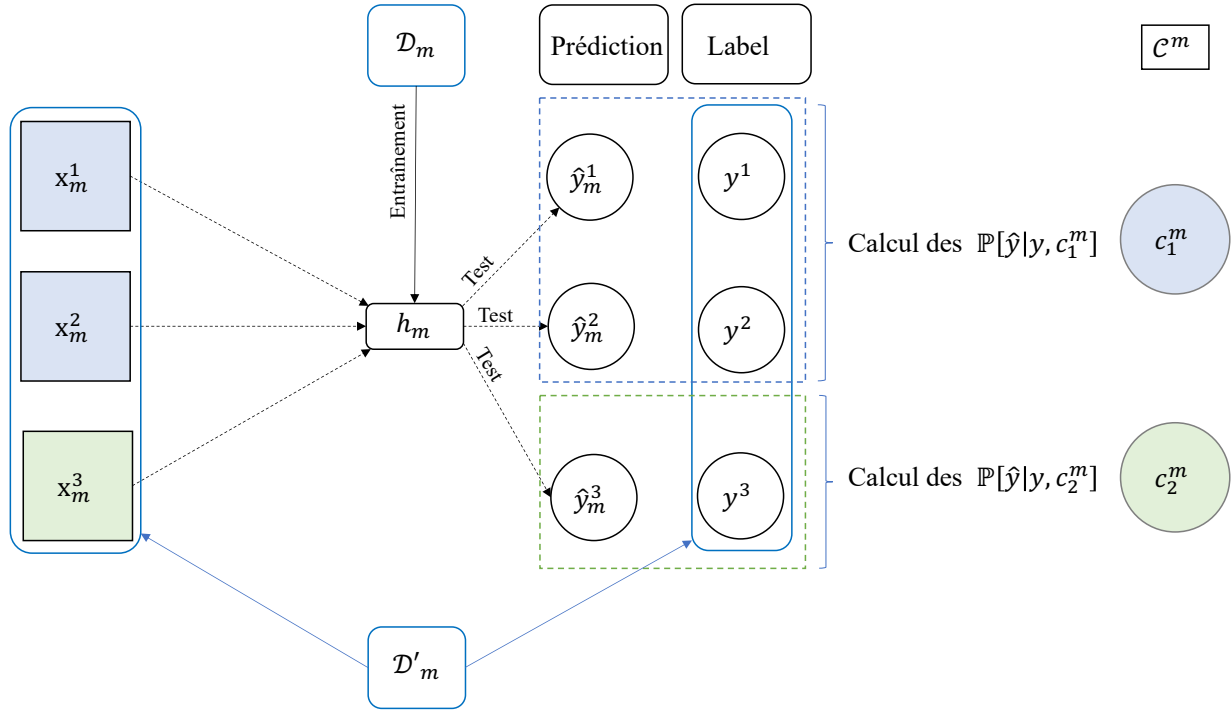
Nous proposons d'estimer la précision du classifieur en le testant sur un nouvel ensemble d'apprentissage  $\mathcal{D}'$ , indépendant de  $\mathcal{D}$ , l'ensemble sur lequel les classifieurs  $h_1, \dots, h_M$  ont été entraînés. Nous proposons d'effectuer un clustering sur les états pour chaque maillon  $m$  de la chaîne. Autrement dit, les états, à chaque maillon  $m$ , peuvent être regroupés pour former des *clusters* d'états qui se ressemblent.

La figure 4.12 présente un schéma du passage de l'ensemble d'apprentissage  $\mathcal{D}'$  à des clusters sur les états de  $\mathcal{D}'$ , avec  $K$  le nombre de clusters égal à 2. Chaque cluster est représenté par une couleur. Il est à noter que les clusters sont différents dans chaque maillon, et donc dans chaque sous-ensemble de  $\mathcal{D}'_m$ . On note  $\mathcal{C}^m = \{c_k^m\}_{k \in [1:K]}$  la collection de  $K$  clusters au maillon  $m$ . Pour chaque nouvel état  $\mathbf{x}_m$  au maillon  $m$ , la probabilité  $\mathbb{P}[c_k^m | \mathbf{x}_m]$  qu'il appartienne à un cluster  $c_k^m$ ,  $\mathbb{P}[c_k^m | \mathbf{x}_m]$  est calculée. Cette probabilité décrit la distance entre l'état mesuré et l'état *moyen* connu du système.



**FIGURE 4.12** – Représentation schématique du passage d'un ensemble d'états à un ensemble de clusters ( $K=2$ )

Avec les clusters obtenus, nous pouvons estimer la précision des classifieurs entraînés sur l'ensemble d'apprentissage  $\mathcal{D}$ . La figure 4.13 illustre comment sont calculées les probabilités  $\mathbb{P}[\hat{y}|y, c_k^m]$ . Pour chaque sous-ensemble  $\mathcal{D}'_m$ , nous testons les classifieurs  $h_m$  (entraînés sur  $\mathcal{D}$ ) et comparons leurs prédictions  $\hat{y}_m^i$  aux vrais labels  $y^i$ . Nous pouvons alors calculer les probabilités conditionnelles par cluster :  $\mathbb{P}[\hat{y}|y, c_k^m]$ .



**FIGURE 4.13** – Représentation schématique de l'estimation de la précision d'un classifieur au maillon  $m$  sur un ensemble d'états de clusters ( $K=2$ )

Ainsi  $\mathbf{P}[\hat{y}|y, x_m]$  est estimé par :

$$\mathbf{P}[\hat{y}|y, x_m] \approx \sum_{c_k^m \in \mathcal{C}^m} P[c_k^m | x_m] \mathbf{P}[\hat{y}|y, c_k^m] \quad (4.39)$$

Concernant les probabilités au maillon  $m + \kappa$ , les probabilités de transition d'un cluster à l'autre, d'un maillon à l'autre sont estimées :

$$P[c_j^{m+\kappa} | c_k^m] \quad (4.40)$$



Avec  $c_k^m \in \mathcal{C}^m$  et  $c_j^{m+\kappa} \in \mathcal{C}^{m+\kappa}$ . Autrement dit, sachant que l'état courant  $m$  est dans le cluster  $c_k^m$ , quelle est la probabilité qu'il soit dans le cluster  $c_j^{m+\kappa}$  au maillon  $m + \kappa$  ?

Ainsi la probabilité est estimée sur  $\mathcal{D}'$  :

$$\mathbf{P}[\hat{y}|y, \mathbf{x}_{m+\kappa}] \approx \sum_{c_k^m \in \mathcal{C}^m} P[c_k^m | \mathbf{x}_m] \sum_{c_j^{m+\kappa} \in \mathcal{C}^{m+\kappa}} P[c_j^{m+\kappa} | c_k^m] \mathbf{P}[\hat{y}|y, c_j^{m+\kappa}] \quad (4.41)$$

#### 4.4.1.2 Estimation des probabilités liées à l'efficacité d'une action

Estimer  $\mathbf{P}[y = \neg ok | x_m, a_m]$  demande, si on veut se baser sur un ensemble d'apprentissage, de générer beaucoup de scénarios, avec de nombreuses combinaisons d'actions, ce qui est très coûteux. En effet, reporter une action, c'est certes considérer qu'on peut la faire au maillon suivant, mais aussi aux maillons d'après, ou même deux maillons après, ou aux trois maillons d'après, et ainsi de suite. Nous proposons de contourner ce problème en supposant que la probabilité que l'action soit efficace  $\mathbf{P}[y = \neg ok | x_m, a_m]$  au maillon  $m$  est linéaire en fonction du maillon et définie en fonction d'un paramètre  $\beta \in [0, 1]$  :

$$\mathbf{P}[y = \neg ok | x_m, a_m] \approx \frac{\beta \times m}{M} \quad (4.42)$$

Le paramètre  $\beta$  correspond à la probabilité que l'action soit efficace si elle est prise uniquement dans le dernier maillon.  $C(x_m)$  est estimé à partir d'un clustering des états, et d'un paramètre  $\beta$  :

$$C(x_m) = \mathbb{E}^m[Cost_a | x_m] \quad (4.43)$$

$$\approx \sum_{c_k^m \in \mathcal{C}^m} P[c_k^m | x_m] \mathbb{E}^m[Cost_a | c_k^m] \quad (4.44)$$

$$= \sum_{c_k^m \in \mathcal{C}^m} P[c_k^m | x_m] \{ \quad (4.45)$$

$$P[y = \neg ok | c_k^m] \mathbf{P}[\hat{y}_m = \neg ok | y = \neg ok, c_k^m] \quad (4.46)$$

$$\times \left\{ (1 - \alpha_{\text{energie}}) \times \frac{\beta \times m}{M} + \alpha_{\text{energie}} \mathbb{E}[C_e | c_k^m] \right\} \quad (4.47)$$

$$+ P[y = \neg ok | c_k^m] \mathbf{P}[\hat{y}_m = ok | y = \neg ok, c_k^m] \times (1 - \alpha_{\text{energie}}) \mathbb{E}[C_e | c_k^m] \quad (4.48)$$

$$+ P[y = ok | c_k^m] \mathbf{P}[\hat{y}_m = \neg ok | y = ok, c_k^m] \times \alpha_{\text{energie}} \mathbb{E}[C_e | c_k^m] \quad (4.49)$$

Où

- $\mathcal{C}^m$  est une collection de clusters au maillon  $m$
- $P[c_k^m | x_m]$  est la probabilité de  $c_k^m$  sachant  $x_m$  que l'on calcule grâce à la distance

de  $\mathbf{x}_m$  au centroid du cluster  $c_k^m$

$C_\kappa(\mathbf{x}_m)$  est estimé par :

$$C_\kappa(\mathbf{x}_m) = \mathbb{E}^{m+\kappa}[Cost_a | \mathbf{x}_m] \quad (4.50)$$

$$\approx \sum_{c_k^m \in \mathcal{C}^m} P[c_k^m | \mathbf{x}_m] \sum_{c_j^{m+\kappa} \in \mathcal{C}^{m+\kappa}} P[c_j^{m+\kappa} | c_k^m] \mathbb{E}^{m+\kappa}[Cost_a | c_j^{m+\kappa}] \quad (4.51)$$

$$= \sum_{c_k^m \in \mathcal{C}^m} P[c_k^m | \mathbf{x}_m] \sum_{c_j^{m+\kappa} \in \mathcal{C}^{m+\kappa}} P[c_j^{m+\kappa} | c_k^m] \{ \quad (4.52)$$

$$P[y = \neg ok | c_k^m] \mathbf{P}[\hat{y}_m = \neg ok | y = \neg ok, c_j^{m+\kappa}] \quad (4.53)$$

$$\times \left\{ (1 - \alpha_{energie}) \times \frac{\beta \times m}{M} + \alpha_{energie} \mathbb{E}[C_e | c_j^{m+\kappa}] \right\} \quad (4.54)$$

$$+ P[y = \neg ok | c_j^{m+\kappa}] \mathbf{P}[\hat{y}_m = ok | y = \neg ok, c_j^{m+\kappa}] \times (1 - \alpha_{energie}) \quad (4.55)$$

$$+ P[y = ok | c_j^{m+\kappa}] \mathbf{P}[\hat{y}_m = \neg ok | y = ok, c_j^{m+\kappa}] \times \alpha_{energie} \mathbb{E}[C_e | c_j^{m+\kappa}] \quad (4.56)$$

Où

- $P[c_j^{m+\kappa} | c_k^m]$  est la probabilité que l'état au maillon  $m + \kappa$  appartienne au cluster  $c_j^{m+\kappa}$  sachant que l'état au maillon  $m$  est dans le cluster  $c_k^m$

#### 4.4.2 Estimation du maillon optimal

Pour chaque scénario  $\mathbf{x}_M$  la politique idéale agirait au maillon optimal  $m_{opt}$  tel que le coût est minimal :

$$m_{opt}(\mathbf{x}_M) = \underset{m}{\operatorname{argmin}} Cost_a(\mathbf{x}_m) \quad (4.57)$$

Cependant, en temps réel, la suite du scénario  $\mathbf{x}_m$  est inconnue, donc on estime le maillon optimal  $m_{opt}$  en minimisant le coût estimé dans les prochains maillons :

$$\hat{m}_{opt}(\mathbf{x}_m) = m + \underset{\kappa}{\operatorname{argmin}} C_\kappa(\mathbf{x}_m) \quad (4.58)$$

L'algorithme 4 présente la simulation d'un scénario en suivant la politique adaptative. Tant que la chaîne n'est pas terminée ( $m < M + 1$ ), on fait appel au classifieur  $h_m$  qui prend en entrée l'état courant  $x_m$ , qui prédit si la cargaison va arriver en bon état. Si la prédiction est " $\neg ok$ ", on calcule les  $\mathbb{P}(c_k^m | x_m)$ , les probabilités d'appartenance aux  $K$  clusters du maillon courant. Ensuite, grâce à ces probabilités, on peut estimer les coûts aux maillons  $m, m + 1, \dots, M$  et le coût optimal estimé  $\hat{m}_{opt}$ . Si le coût optimal estimé  $\hat{m}_{opt} = m$ , soit le maillon courant, l'action est lancée :  $\pi(x_m) = a$ ). Sinon, on ne lance pas d'action :  $\pi(x_m) = \neg a$ ). Ensuite, on passe au maillon suivant  $x_{m+1} = G(x_m, \pi(x_m))$

---

**Algorithme 4** Simulation d'un scénario suivant la politique adaptative

---

```

 $x_0 = initial\_state$ 
 $m = 0$ 
tant que  $m < M + 1$  faire
     $\hat{y}_m = h_m(x_m)$  ▷ Le classifieur prédit si la cargaison sera  $ok$ 
    si  $\hat{y}_m = \neg ok$  alors ▷ Si il prédit  $\neg ok$ 
        for  $k \in [1 : K]$  faire
            Calculer  $\mathbb{P}(c_k^m | x_m)$ 
        fin for
        for  $\kappa \in [0, M - m]$  faire
            Calculer  $C_\kappa(x_m)$ 
        fin for
         $\hat{m}_{opt} = m + \underset{\kappa \in [0, M - m]}{\text{Argmin}} C_\kappa(x_m)$  ▷ On évalue les coûts futurs
        si  $\hat{m}_{opt} = m$  alors ▷ Si le coût minimum est maintenant
             $\pi(x_m) = a$  ▷ On lance l'action
        fin si
    sinon
         $\pi(x_m) = \neg a$  ▷ Si non on reporte l'action
    fin si
     $x_{m+1} = G(x_m, \pi(x_m))$ 
fin tant que

```

---

#### 4.4.3 Entraînement de la méthode adaptative

Pour mettre en œuvre la méthode adaptative, plusieurs choix ont été faits concernant la construction des ensembles d'apprentissage :

- La taille de l'échantillon  $\mathcal{D}$  pour apprendre les classifieur

- La taille de l'échantillon  $\mathcal{D}'$  pour faire le clustering et estimer la précision des classifieurs
- La taille de l'échantillon  $\mathcal{D}^a$  pour estimer le coût énergétique d'une action

De même, des choix ont été faits concernant les modèles d'apprentissage utilisés dans la méthode :

- Les classifieurs
- L'algorithme de clustering, avec le nombre de clusters

Il est possible que de meilleurs résultats puissent être obtenus en utilisant d'autres modèles ou en réglant différemment les paramètres.

---

**Algorithme 5** Construction de l'ensemble d'apprentissage  $\mathcal{D}^a$  contenant des actions

---

Entrées :

- $N$  Le nombre de scénarios
- $G$  Modèle génératif
- $a$  Valeur de l'action

**for**  $scenario \in [1 : N]$  **faire**

$m = 0$

$\mathbf{x}_m = \mathbf{x}_0$

**for**  $k \in [1 : K]$  **faire**

$\mathbf{x}_{k+1}^{am} = G(\mathbf{x}_m, a)$

$\mathbf{x}_{k+1}^{-am} = G(\mathbf{x}_m, \neg a)$

**for**  $i \in [k + 1 : K]$  **faire**

$\mathbf{x}_{i+1}^{am} = G(\mathbf{x}_{k+1}^{am}, a_i = \neg a)$

$\mathbf{x}_{i+1}^{-am} = G(\mathbf{x}_{k+1}^{-am}, a_i = \neg a)$

**fin for**

$y^{-am} = Qual(\mathbf{x}_M^{-am})$

$y^{am} = Qual(\mathbf{x}_M^{am})$

$C_e = Conso_e(\mathbf{x}_M^{am}) - Conso_e(\mathbf{x}_M^{-am})$

Sauvegarder ( $scenario, m, \mathbf{x}_m, y^{-am}, y^{am}, C_e$ )

**fin for**

**fin for**

---

L'apprentissage de la méthode adaptative peut être décrite par l'algorithme 5 et par la figure 4.14.

- Générer un premier ensemble d'apprentissage sans actions  $\mathcal{D} = \{(\mathbf{x}_m^i | \pi_{\neg a}, y^i)\}_{m \in [1:M], i \in [1:N]}$  de taille  $N$  avec l'algorithme 3 qui est utilisé pour entraîner les classifieurs  $h_m$

- Générer un deuxième ensemble d'apprentissage sans actions  $\mathcal{D}' = \{(\mathbf{x}_m^i | \pi_{-a}, y^i)\}_{m \in [1:M], i \in [1:N]}$  de taille  $N$  avec l'algorithme 3
  1. Appliquer un algorithme de clustering pour apprendre les  $K$  clusters  $c_k^m \in \mathcal{C}^m$  d'états pour chaque maillon  $m$
  2. Estimer les probabilités  $P[y|c_k^m] \mathbf{P}[\hat{y}_m | y, c_k^m]$  avec  $c_k^m \in \mathcal{C}^m$
  3. Estimer les probabilités de transitions  $P[c_j^{m+\kappa} | c_k^m]$  avec  $(c_j^{m+\kappa}, c_k^m) \in \mathcal{C}^m \times \mathcal{C}^{m+\kappa}$
- Générer un troisième ensemble d'apprentissage  $\mathcal{D}^a = (i, m, \mathbf{x}_m, y^{-a_m}, y^{a_m}, C_e)_{m \in [1:M], i \in [1:N]}$  contenant des actions  $a_m$  à chaque maillon sur  $N$  scénarios avec l'algorithme 5 :
  1. Estimer  $\mathbb{E}[C_e | c_k^m]$  le coût de l'action par maillon et par cluster empiriquement sur  $\mathcal{D}^a$

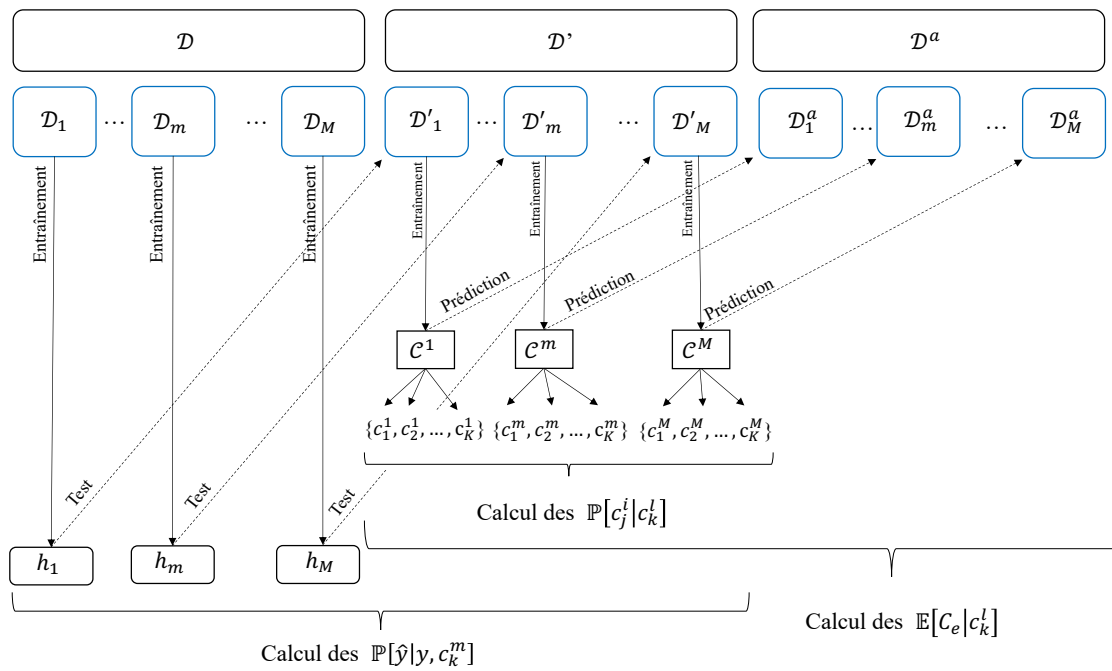


FIGURE 4.14 – Représentation schématique de l'apprentissage de la méthode adaptative

#### 4.4.4 Validation

Afin de tester la méthode adaptative, les choix suivants ont été fait :

**Algorithme 6** Apprentissage de la méthode adaptative

Entrées :

- $M$  ensembles d'apprentissage  $\mathcal{D}_m = \{(\mathbf{x}_m^i | \pi_{-a}, y^i)\}_{i \in [1:N]}$  d'états au maillon  $m$  labellisés
- $M$  ensembles d'apprentissage  $\mathcal{D}'_m = \{(\mathbf{x}_m^i | \pi_{-a}, y^i)\}_{i \in [1:N]}$  d'états labellisés au maillon  $m$
- Un ensemble d'apprentissage  $\mathcal{D}_a = \{(\mathbf{x}_m^i | \pi_{a_m=a}, y^i)\}_{\substack{m \in [1:M] \\ i \in [1:N]}}$  d'états labellisés de

scénarios pour lesquels la politique  $\pi_{a_m=a}$  est appliquée**for**  $m \in \{1, M\}$  **faire**Apprendre sur  $\mathcal{D}_m$  un classifieur  $h_m$ Apprendre un clustering sur les états  $\mathcal{D}'_m$  et garder en mémoire un ensemble  $\mathcal{C}^m = \{c_1, \dots, c_k^m\}$  où chaque  $c_k^m$  est un cluster d'états similaires.**fin for****for**  $m \in \{1, M\}$  **faire****for**  $k \in \{1, K\}$  **faire**Calculer la matrice de confusion  $\mathbb{P}^m[\hat{y}|y, c_k^m]$  (sur  $\mathcal{D}'_m$ )Estimer les probabilités de transitions  $P[c_j^{m+\kappa} | c_k^m]$  avec  $(c_j^{m+\kappa}, c_k^m) \in \mathcal{C}^m \times \mathcal{C}^{m+\kappa}$ (sur  $\mathcal{D}'_m$ )Estimer  $\mathbb{E}[C_e | c_k^m]$  (sur  $\mathcal{D}'$ )**fin for****fin for**

— Choix du classifieur : MLPClassifier (défaut sklearn)

— Choix de l'algorithme de clustering : Kmeans (sklearn)

Les paramètres de la Table 4.2 ont été utilisés.

**TABLE 4.2** – Ensemble des paramètres pour entraîner et valider la méthode adaptative

Notation	Description	Valeurs
$K$	Nombre de clusters	{2, 5, 10}
$s$	seuil sur le classifieur	{0.1, 0.2, ..., 0.9}
$\beta$	probabilité que l'action soit inefficace au dernier maillon	{0.1, 0.2, ..., 0.9, 1}
$N$	taille des ensembles d'apprentissage $\mathcal{D}$ , $\mathcal{D}'$ et $\mathcal{D}^a$	1000
$N_{val}$	Nombre de scénarios de validation	700

Sur  $N_{val}$  scénarios, les politiques adaptatives avec différentes valeurs de  $K, s$  sont testées :  $K$  étant le nombre de clusters, et  $s$  le seuil sur les classifieurs.

$$(\hat{K}, \hat{s}, \hat{\beta})(\alpha_{\text{energie}}) = \arg \min_{(K,s,\beta)} \overline{\text{Cost}}_{\alpha_{\text{energie}}}(\pi_{\text{adapt}}^{K,s,\beta}) \quad (4.59)$$

## 4.5 Test, comparaison des méthodes et interprétation

Pour chacune des méthodes et pour chaque  $\alpha_{\text{energie}}$ , les paramètres qui minimisent le coût sont sélectionnés :

$$\text{Cost}(\pi)_{\alpha_{\text{energie}}} = \min_{\text{args}} \text{Cost}(\pi(\text{args})) \quad (4.60)$$

Avec *args* les paramètres de la méthode.

- Pour Méthode à seuil :  $T_{\text{seuil}}$
- Pour la méthode classifieur :  $s$
- Pour la méthode adaptative :  $K$ ,  $s$  et  $\beta$

Dans la suite de cette section, les résultats seront tous présentés en fonction de  $\alpha_{\text{energie}}$ . Les résultats présentés dans cette section sont des résultats obtenus sur 700 nouveaux scénarios, indépendants des scénarios utilisés pour entraîner ou valider les méthodes. Nous présenterons les résultats en fonction de  $\alpha_{\text{energie}}$ .

Ainsi, on compare les politiques :  $\pi_{\hat{T}_{\text{seuil}}(\alpha_{\text{energie}})}$ ,  $\pi_{\hat{s}(\alpha_{\text{energie}})}$  et  $\pi_{\text{adapt}}^{(\hat{K}, \hat{s}, \hat{\beta})(\alpha_{\text{energie}})}$




### 4.5.1 Coût par méthode et par $\alpha_{\text{energie}}$

La figure 4.15 représente les coûts moyens obtenus pour chaque méthode pour les différentes valeurs de  $\alpha_{\text{energie}}$  testées. Sur cette figure, seuls les  $\alpha_{\text{energie}}$  inférieurs à 0.5 sont représentés. En effet, pour toutes les méthodes, au-delà de 0.5, les méthodes choisissent de ne plus agir.

La politique la plus simple, la politique à seuil sur la température, est la meilleure pour tout niveau de coût de l'énergie, c'est-à-dire pour toute valeur de  $\alpha_{\text{energie}}$ .

La politique classifieur, qui utilise un modèle de classification pour déterminer si une action doit être prise ou non, est la deuxième meilleure politique en termes de coût. Cependant, elle a un coût légèrement plus élevé que la politique à seuil sur la température.


Enfin, la politique adaptative, qui estime le coût d'une décision, a le coût le plus élevé de toutes les politiques étudiées. Cela pourrait être dû au fait que la décision de prendre une action n'a pas été prise ou a été prise trop tard, ce qui a entraîné un coût supplémentaire en énergie. Pour toutes les valeurs de  $\alpha_{\text{energie}} < 0.4$ , les trois méthodes proposées ont un coût inférieur à celui de la politique de ne rien faire  $\pi_{\neg a}$ .



**FIGURE 4.15** – Coût moyen par  $\alpha_{\text{energie}}$  et par politique de décision. En rose la politique  $\pi_{\neg a}$  qui n'agit jamais, en rouge la politique basée sur un seuil  $\pi_{T_{\text{seuil}}}$ , en bleu la politique classifieur  $\pi_{h_s}$  et en vert la politique adaptative  $\pi_{\text{adapt}}$ .

### 4.5.2 Nombre d'actions par méthode et par $\alpha_{\text{energie}}$

La figure 4.16 montre le nombre d'actions par maillon et par  $\alpha_{\text{energie}}$  pour la méthode à seuil sur la température  $\pi_{\hat{T}_{\text{seuil}}(\alpha_{\text{energie}})}$ . Comme précédemment observé pendant la phase de validation (cf. section 4.2.2), le nombre d'actions est équitablement réparti entre les maillons et dépend de  $\alpha_{\text{energie}}$  : plus  $\alpha_{\text{energie}}$  est faible, moins le coût énergétique associé à une action est élevé, et plus le nombre d'actions est élevé. Cette répartition est due à la structure même de notre circuit logistique, où les températures de chaque maillon sont indépendantes et identiquement distribuées.



**FIGURE 4.16** – Nombre d'actions par maillon et par  $\alpha_{\text{energie}}$  pour la méthode à seuil sur la température.

La figure 4.17 montre le nombre d'actions par maillon et par  $\alpha_{\text{energie}}$  pour la méthode à seuil sur le classifieur  $\pi_{\hat{s}}(\alpha_{\text{energie}})$ . Pour la méthode à seuil sur le classifieur, le nombre d'actions décroît avec  $\alpha_{\text{energie}}$ . Plus  $\alpha_{\text{energie}}$  est élevé, moins le coût énergétique associé à une action est élevé, et donc moins le nombre d'actions est élevé. De plus, on remarque que le premier maillon est celui où le plus grand nombre d'actions est pris, quelle que soit la valeur de  $\alpha_{\text{energie}}$ . Cela peut être expliqué par le fait que la méthode agit dès que

le classifieur prédit que la cargaison arrivera en mauvais état : si une action est lancée dès le premier maillon, la probabilité que la cargaison arrive en mauvais état diminue nécessairement.




FIGURE 4.17 – Nombre d’actions par maillon et par  $\alpha_{energie}$  pour la méthode classifieur.

La figure 4.18 montre le nombre d’actions par maillon et par  $\alpha_{energie}$  pour la méthode adaptative. On observe que la méthode ne lance pas d’actions dans le premier maillon de la chaîne pour toutes les valeurs de  $\alpha_{energie}$ . Une des raisons pour lesquelles la méthode adaptative ne prend pas d’actions dans le premier maillon est que le classifieur est imprécis au début de la chaîne. En effet, à ce stade, il ne connaît que la température du premier maillon et la température extérieure. La méthode adaptative semble suggérer qu’il serait plus judicieux d’attendre d’autres mesures avant de prendre une décision.




FIGURE 4.18 – Nombre d’actions par maillon et par  $\alpha_{energie}$  pour la méthode adaptative.

### 4.5.3 Fausses alertes par méthode et par $\alpha_{energie}$

#### 4.5.3.1 Méthode à seuil

La figure 4.19 montre le nombre de fausses alertes par maillon et par  $\alpha_{energie}$  pour la méthode à seuil sur la température  $\pi_{\hat{T}_{seuil}(\alpha_{energie})}$ . Le nombre de fausses alertes augmente après le premier maillon. En effet, si une action a déjà été lancée dans le premier maillon, une deuxième action ne devient pas nécessaire dans les maillons suivants. La figure 4.20 montre le taux de fausses alertes par maillon et par  $\alpha_{energie}$  pour la méthode à seuil sur la température  $\pi_{\hat{T}_{seuil}(\alpha_{energie})}$ . Le taux de fausses alertes par maillon augmente après le premier maillon pour toutes les valeurs de  $\alpha_{energie}$ . Cela signifie que, plus la chaîne avance, plus le nombre de fausses alertes par rapport aux actions lancées augmente. Cela peut être dû au fait que la méthode à seuil sur la température est très stricte et qu’elle lance des actions même lorsque la cargaison est en bon état. Cela peut entraîner un coût supplémentaire lié aux fausses alertes et à l’utilisation inutile de l’énergie. Il serait donc intéressant de revoir la stratégie de seuil choisie pour réduire le nombre de fausses alertes

tout en garantissant la qualité des produits.




FIGURE 4.19 – Fausses alertes par maillon et par  $\alpha_{energie}$  pour la méthode à seuil.




FIGURE 4.20 – Taux de fausses alertes par maillon et par  $\alpha_{energie}$  pour la méthode à seuil.

### 4.5.3.2 Méthode avec un classifieur

La figure 4.21 montre le nombre de fausses alertes par maillon et par  $\alpha_{\text{energie}}$  pour la méthode à seuil sur le classifieur  $\pi_{\hat{s}(\alpha_{\text{energie}})}$ . Comme observé pendant la phase de validation, le nombre de fausses alertes augmente avec le maillon.

La figure 4.22 montre le taux de fausses alertes par maillon pour la méthode à seuil utilisant le classifieur  $\pi_{\hat{s}(\alpha_{\text{energie}})}$ , en fonction de  $\alpha_{\text{energie}}$ . On observe une diminution du taux de fausses alertes avec  $\alpha_{\text{energie}}$ . Cela peut être expliqué par le fait que le seuil du classifieur sélectionné par  $\alpha_{\text{energie}}$  est plus élevé lorsque  $\alpha_{\text{energie}}$  est plus grand, ce qui entraîne une augmentation de la prudence du classifieur et une réduction des fausses alertes. Toutefois, le taux de fausses alertes reste relativement constant en fonction du maillon. On aurait pu s'attendre à ce qu'il diminue avec l'avancée dans la chaîne, car le classifieur a accès à une plus grande partie des informations. Cela peut être dû à deux raisons : soit le classifieur n'est pas assez précis, soit les états utilisés en entrée dans les derniers maillons sont sous-représentés. En effet, le classifieur a été entraîné sur un espace d'états sans actions, ce qui peut être discutable.




FIGURE 4.21 – Fausses alertes par maillon et par  $\alpha_{\text{energie}}$  pour la méthode classifieur.




FIGURE 4.22 – Taux de fausses alertes par maillon et par  $\alpha_{\text{energie}}$  pour la méthode classifieur.

### 4.5.3.3 Méthode adaptative

La figure 4.23 montre le nombre de fausses alertes par maillon et par  $\alpha_{\text{energie}}$  pour la méthode adaptative  $\pi_{\text{adapt}}^{(\hat{K}, \hat{s}, \hat{\beta})}(\alpha_{\text{energie}})$ . On observe que le nombre de fausses alertes diminue avec le temps. La figure 4.24 montre le taux de fausses alertes par maillon et par  $\alpha_{\text{energie}}$  pour la méthode adaptative  $\pi_{\text{adapt}}^{(\hat{K}, \hat{s}, \hat{\beta})}(\alpha_{\text{energie}})$ . On remarque que le taux de fausses alertes diminue légèrement avec l'indice du maillon. Il y a deux raisons possibles à cette diminution :

1. La méthode prend moins de décisions, comme le montre la figure 4.18 surtout pour les valeurs basses de  $\alpha_{\text{energie}}$  (0,0.1,0.2).
2. Le classifieur se trompe moins, comme le suggère le taux de fausses alertes pour les valeurs plus élevées de  $\alpha_{\text{energie}}$  (0.4,0.5).




FIGURE 4.23 – Fausses alertes par maillon et par  $\alpha_{\text{energie}}$  pour la méthode adaptative.






FIGURE 4.24 – Taux de fausses alertes par maillon et par  $\alpha_{\text{energie}}$  pour la méthode adaptative.

#### 4.5.4 Comment améliorer ces méthodes ?

##### 4.5.4.1 Améliorer la précision du classifieur

Nous avons entraîné les classifieurs utilisés dans la méthode classifieur et la méthode adaptative sur un ensemble d'apprentissage qui ne comprenait pas d'actions. Nous avons adopté cette approche car nous partions du principe que, au moment de prendre une décision, l'action n'a pas encore été exécutée et qu'il n'est donc pas nécessaire d'apprendre sur des scénarios qui contiennent des actions. Cependant, en pratique, il est possible que la méthode prenne plusieurs actions au cours d'une chaîne. Cela peut entraîner une modification de la population des états par maillon en fonction des actions prises dans les maillons précédents. Quelques pistes pour améliorer la précision du classifieur :

- Apprendre sur des scénarios qui contiennent des actions
- Choisir un autre classifieur
- Optimiser les paramètres du classifieur utilisé

#### 4.5.4.2 Nombre de clusters par maillon

Le nombre de clusters par maillon est actuellement fixé à  $K$ , mais il pourrait être avantageux de l'adapter en fonction du maillon considéré. En effet, le nombre de clusters devrait refléter de manière plus précise la réalité du maillon. Par exemple, dans le premier maillon, il pourrait être plus judicieux d'avoir un nombre de clusters plus faible que dans le dernier maillon, car il y a moins d'historiques possibles au début de la chaîne.

#### 4.5.4.3 Ajouter une contrainte sur la température

Il a été observé que les méthodes classifieurs et adaptatives ont tendance à prendre des actions coûteuses, car elles ne sont pas soumises à la contrainte de température du maillon. Il pourrait être intéressant de tester ces méthodes en ajoutant cette contrainte afin de vérifier si cela peut améliorer leur performance.

## 4.6 Limites

### 4.6.1 Géométrie du circuit logistique

Le circuit logistique que nous avons construit contient plusieurs biais. Pour commencer, le dernier maillon dure 3 jours : il est, avec le premier maillon, le maillon le plus long. Cela induit plusieurs problèmes avec la méthode adaptative décrite dans ce chapitre. En effet, le dernier maillon est le maillon dans lequel le classifieur est le meilleur, mais aussi, comme il dure plus longtemps que les maillons précédents, le maillon dans lequel une action est la plus efficace, car elle va durer 3 jours. Il faudrait tester cette méthode sur un circuit où tous les maillons durent le même temps, pour voir comment la méthode adaptative se comporte dans ce cas-là.

### 4.6.2 Méthode adaptative

Dans ces travaux, nous avons limité l'espace d'actions à l'option "action" ou "pas d'action". Cependant, il serait possible de concevoir un système plus complexe qui per-

mettrait de baisser la température de manière plus flexible, en choisissant un nombre de degrés différent. De plus, actuellement, il n'est possible de changer la température de consigne qu'au début d'un maillon et pour toute sa durée. En réalité, il pourrait être utile de pouvoir changer la température au cours d'un maillon. Ces tests n'ont pas pu être réalisés en raison de la consommation importante de ressources numériques qu'ils nécessitent. En outre, dans ces travaux, la température d'un maillon est considérée comme constante. Des événements tels que des pannes d'équipement pourraient être intégrés dans les simulations pour rendre le modèle plus réaliste.

De plus, d'autres actions que baisser la température de consigne d'un équipement sont envisageables. Par exemple, réorienter une cargaison vers un circuit plus court : si la cargaison est exposée à des conditions de transport ou de stockage qui risquent de la détériorer, il peut être judicieux de la réorienter vers un itinéraire qui lui permettra d'arriver à destination plus rapidement.

La méthode adaptative peut être testée avec une multitude d'autres choix :

- Choix de l'algorithme de clustering et de la distance utilisée : il existe plusieurs algorithmes de clustering et plusieurs mesures de distance qui peuvent être utilisés pour grouper les données en clusters. En testant différentes combinaisons, il est possible de trouver celle qui convient le mieux aux données et qui donne les meilleurs résultats.
- Choix du classifieur et de ses hyperparamètres : il existe de nombreux classifieurs différents et chacun d'eux a des hyperparamètres qui peuvent être ajustés. En testant différents classifieurs et en optimisant les paramètres de chacun d'eux, il est possible de trouver le modèle qui convient le mieux aux données.
- Nombre de clusters identique pour chaque maillon : actuellement, le nombre de clusters est fixé à chaque maillon. Cependant, il pourrait être intéressant de l'adapter en fonction du maillon considéré, en utilisant un nombre de clusters plus élevé dans les maillons les plus avancés de la chaîne par exemple.
- Entraînement des classifieurs sur des états sans actions : dans ces travaux, les classifieurs ont été entraînés sur des états qui ne comprenaient pas d'actions.

Cependant, il pourrait être discutable de ne pas inclure des états avec des actions dans l'ensemble d'apprentissage, car cela pourrait être utile pour le classifieur de connaître les conséquences des actions prises dans chaque maillon.

Le dernier point concerne la construction même de l'ensemble d'apprentissage utilisé pour entraîner les classifieurs. Actuellement, nous avons supposé que, étant donné qu'au moment de l'action, aucune action n'a encore été prise, les classifieurs pouvaient être entraînés sur un ensemble sans action. Cependant, lors de l'évaluation des politiques de décision, les actions sont lancées indépendamment des actions passées, ce qui signifie qu'il est possible de lancer plusieurs actions sur un même scénario. Par conséquent, la population des états aux maillons qui suivent une ou deux actions pourrait être différente de celle des états sans action. C'est ce que l'on observe lorsque l'on regarde les résultats du nombre d'actions pour la méthode classifieur (ici avec un seuil à 0.5) : le nombre d'actions diminue jusqu'au maillon 2, puis augmente aux maillons 4 et 5. Or, on s'attendrait à ce que le nombre d'actions diminue, étant donné que des actions devraient avoir été lancées plus tôt. Cela pourrait être dû au fait que le classifieur est moins performant sur une population qui a déjà subi des actions, car cette population, dans les deux derniers maillons, est peut-être sous-représentée pendant l'apprentissage.

## Conclusion

Dans ce chapitre, pour le circuit présenté au chapitre 3, nous avons fixé un objectif à atteindre, en supposant que le distributeur puisse définir lui-même le compromis qu'il veut attribuer à la fois à la qualité et à l'énergie. Nous avons ensuite proposé plusieurs politiques de décisions, une basée sur un critère d'alerte simple sur un seuil sur la température. Nous avons aussi présenté deux autres politiques basées sur des méthodes d'apprentissage et définit une méthodologie pour les entraîner. La première méthode, basée sur un classifieur simple et la deuxième dite *adaptative*, qui prend en compte le coût d'une décision.

Les méthodes à seuil et classifieur, optimisent le coût implicitement, car les paramètres des méthodes sont choisis à partir du coût total final de la politique. À l'inverse, pour la politique adaptative, l'optimisation de ce coût est explicite, car au sein même de la méthode ce coût est estimé et minimisé.

Pour toutes les méthodes présentées, le paramètre  $\alpha_{\text{energie}}$  a un impact direct sur le nombre d'actions menées au cours de la chaîne du froid : augmenter  $\alpha_{\text{energie}}$  permet de diminuer le nombre d'actions car il permet d'augmenter le coût énergétique associé à une décision.

L'étude des différentes politiques de décision a montré que la politique la plus simple, la politique à seuil sur la température, est la meilleure en termes de coût pour tout niveau de coût de l'énergie. La politique classifieur arrive en deuxième position, suivie de la politique adaptative, qui a le coût le plus élevé.

Bien que la politique adaptative ait un coût plus élevé que les autres politiques étudiées, il y a des perspectives pour cette méthode. En effet, en utilisant des données de chaînes du froid plus importantes et en améliorant la précision du modèle de classification utilisé, il pourrait être possible de réduire le coût de la politique adaptative et de la rendre plus compétitive par rapport aux autres politiques. En outre, la flexibilité de la politique adaptative, qui s'ajuste en fonction de l'historique de la chaîne, peut être un atout dans certains cas. Ainsi, il y a des perspectives pour cette méthode et il serait

intéressant de poursuivre l'étude de la politique adaptative dans le futur.



## Chapitre 5

# Conclusions et perspectives

Dans ce chapitre, nous détaillons les principales contributions et les conclusions des travaux réalisés. Enfin, nous discutons quelques pistes de travaux futurs.

La production alimentaire mondiale (4547 millions de tonnes) se compose d'environ 40% de produits périssables qui devraient être conservés sous régime de froid, cependant seuls 18% le sont (IIF, 2017). Pour éviter les pertes alimentaires, une réfrigération précoce (dès que possible après la récolte ou la fabrication) et un froid continu jusqu'à la consommation, appelé "Chaîne du froid", sont déterminants. La chaîne du froid est une succession d'opérations qui s'effectuent sous une température dirigée au moyen d'équipements frigorifiques tels que des entrepôts frigorifiques, des transports frigorifiques, des plates-formes logistiques, des meubles frigorifiques de vente et des réfrigérateurs domestiques. Toutefois, il n'y a pas un seul type de chaîne logistique, mais une multitude de combinaisons possibles des différentes étapes. Selon les produits réfrigérés, la température de conservation varie entre 0°C et 8°C. Les basses températures permettent de ralentir le développement des micro-organismes ainsi que les réactions chimiques à l'origine de la dégradation des qualités sensorielles et nutritionnelles.

De nombreuses études de terrain ont constaté des ruptures de la chaîne du froid. Ces ruptures ont plusieurs causes, un thermostat mal réglé, un équipement défaillant, des produits situés dans une zone mal ventilée ou placés en attente dans une zone non



réfrigérée lors d'une livraison. Pour détecter les ruptures dans la pratique, les opérateurs mesurent la température à une ou plusieurs positions d'une palette à un moment donné, par exemple lors de la livraison ou de l'expédition. Cependant, ces mesures locales peuvent ne pas être représentatives de la température d'une palette entière car celle-ci est hétérogène. Par exemple, le produit à l'intérieur d'une palette peut être plus froid qu'un autre situé à la périphérie. Par ailleurs, des mesures à un instant donné ne permettent pas de détecter les ruptures de température antérieures. Les opérateurs peuvent également refuser les produits à réception si ces derniers sont dégradés et ne répondent pas aux critères de qualité attendus. Aujourd'hui, les capteurs de température connectés placés dans les équipements ou dans les palettes permettent de suivre l'évolution la température tout au long de la chaîne du froid. Ces capteurs sont de plus en plus utilisés pour détecter les ruptures en temps réel. Ceci est dû au fait que les capteurs de température sans fil sont de plus en plus abordables. Cependant, ces capteurs mesurent la température de l'air et non la température des produits ni leur qualité. La définition d'une rupture à partir de ces mesures est par conséquent difficile. Dans ce travail, nous avons défini la notion de rupture en fonction de deux grandes catégories de produits : les produits dont la température est réglementée (viandes, poissons), et les produits pour lesquels une température est recommandée (fruits, légumes). De plus, selon ces types de produits, la méthodologie pour détecter une rupture est différente :

- Pour les produits à température réglementée, le but est de déterminer précisément la température de tout le chargement en se basant sur la température mesurée par le capteur.
- Pour les produits à température recommandée, le but est de prédire si les produits seront livrés avec les qualités organoleptiques souhaitées en se basant sur la température mesurée par le capteur. Pour cette catégorie, il est possible de mettre en place des actions correctrices pour garantir la qualité des produits si un problème est détecté, mais il faut aussi tenir compte du coût de ces actions pour optimiser le coût global du système de détection des ruptures.

Pour les produits à température réglementée, par exemple les viandes ou les poissons,

l'objectif est de prédire la température de l'ensemble d'un chargement à partir de la mesure de la température à une ou plusieurs positions. En effet, du fait de la complexité des écoulements et des transferts dans les équipements frigorifiques, la température peut être hétérogène et la mesure à une ou plusieurs positions ne reflète pas forcément la température du chargement dans son ensemble. Plusieurs études ont montré qu'il est possible de prédire la température de tout un chargement à partir d'une mesure à une position donnée en utilisant des techniques d'apprentissage, notamment des réseaux de neurones (NN). Pour entraîner ces NN, ces études ont utilisé soit des données expérimentales, soit des données synthétiques, mais aucune étude n'a comparé l'impact de la source de données (expérimentales et synthétiques) sur l'entraînement des NN. Nous avons comparé les avantages et les inconvénients des deux types de données et souligné les points à prendre en compte lors de l'utilisation de jeux de données synthétiques générés par des modèles thermiques (Loisel et al. [2022]). L'objectif de cette étude était de trouver des moyens pour développer une méthodologie efficace permettant d'entraîner des NN à moindre coût tout en proposant une méthodologie robuste d'évaluation de leurs performances. Il est important de disposer d'une méthode efficace pour entraîner ces NN car les configurations dans la chaîne du froid sont très variées et il serait très coûteux de les entraîner en utilisant des dispositifs expérimentaux. C'est pourquoi l'utilisation de modèles générant des données synthétiques pourrait être intéressante pour produire des données pour des configurations diverses (vitesse d'air, ajourage des cagettes, forme des produits). Les conclusions de cette première étude sont les suivantes :

- Les NN entraînés avec des données expérimentales présentent de meilleures performances que ceux entraînés avec les données synthétiques.
- Les NN entraînés avec des données synthétiques doivent être testés sur d'autres données synthétiques avec précaution au risque de surestimer les performances des NN. L'ajout de bruit aux données n'a pas permis dans notre cas de surmonter les problèmes associés à la surestimation des performances de ces NN.
- Il n'est pas nécessaire de connaître les caractéristiques de la chaîne du froid considérée (variations de température, durée) : des profils aléatoires peuvent être uti-

lisés comme données d'entraînement.

- La génération d'un grand nombre de profils, facilement réalisable pour les données synthétiques, a réduit la variance des NN mais n'a pas amélioré leurs performances.

Une perspective intéressante pour ces travaux serait d'étudier comment l'incertitude des données d'entraînement se propage à l'incertitude des NN, par exemple en générant des données synthétiques avec des modèles thermiques de précision variable. Une autre perspective importante serait de développer une méthode pour évaluer les performances des NN entraînés avec des données synthétiques sans avoir besoin de données expérimentales, afin d'éviter de mettre en place un dispositif expérimental pour chaque configuration.

Pour les produits à température recommandée, malgré l'impact des ruptures de la chaîne du froid sur les pertes et le gaspillage des produits alimentaires, il y a peu d'études qui proposent des méthodes pour les détecter. De plus, il n'existe pas de système permettant de décider quelle action correctrice mettre en place en fonction du coût du produit et du coût de l'action. Nous avons comparé trois systèmes différents pour détecter les ruptures et mettre en place une action correctrice :

- Un système simple basé sur un seuil de température. Si la température dépasse un seuil, la température de consigne de l'équipement est diminuée.
- Une première méthode d'apprentissage basée sur un classifieur. Ce système estime, à partir de la mesure de la température par un capteur, la probabilité du produit à arriver dans les qualités organoleptiques attendues. La température de consigne de l'équipement est réduite si la probabilité que les produits ne parviennent pas à la qualité attendue dépasse un seuil.
- Une seconde méthode d'apprentissage basée sur le même classifieur, mais qui prend en compte la probabilité de l'efficacité de la prise de décision (le fait que le produit arrive dans la qualité souhaitée chez le client) et le coût associé à cette prise de décision.

Ces systèmes ont été testés sur un modèle de simulation de chaîne du froid fictive prenant en compte l'évolution des températures dans une chaîne composée de six étapes,

l'évolution de la qualité organoleptique des produits et les consommations énergétiques des équipements frigorifiques.

Notre étude a permis de déterminer que la politique à seuil sur la température est la meilleure en termes de coût pour tout niveau de coût de l'énergie. Cependant, la politique adaptative, que nous avons formalisée dans le cadre de cette étude, offre également des perspectives intéressantes. En effet, en utilisant des données de chaînes de refroidissement de cargaisons plus importantes et en améliorant la précision du modèle de classification utilisé, il pourrait être possible de réduire le coût de cette politique et de la rendre plus compétitive. Ainsi, il serait judicieux de poursuivre l'étude de cette politique afin de mieux comprendre son potentiel et ses limites.

Plus largement il serait intéressant de tester et de formaliser des méthodes de décision qui tiennent compte d'un espace d'actions plus large, qui dépasse le simple choix entre une action et aucune action. Par exemple, il pourrait être possible de moduler la température de façon plus fine, en prévoyant différentes valeurs de baisse de température. Par ailleurs, il serait bénéfique de pouvoir prendre en compte d'autres actions, comme la réorientation d'une cargaison, lors de la prise de décision. Cela pourrait être bénéfique pour réagir rapidement aux ruptures de la chaîne du froid et éviter que les produits ne soient endommagés ou perdus.



# Bibliographie

- E. Abad, F. Palacio, M. Nuin, A. G. d. Zárate, A. Juarros, J. Gómez, and S. Marco. RFID smart tag for traceability and cold chain monitoring of foods : Demonstration in an intercontinental fresh fish logistic chain. *Journal of Food Engineering*, 93(4) :394–399, Aug. 2009. ISSN 02608774. doi : 10.1016/j.jfoodeng.2009.02.004. URL <https://linkinghub.elsevier.com/retrieve/pii/S0260877409000661>.
- Y. Achenchabe, A. Bondu, A. Cornuéjols, and A. Dachraoui. Early classification of time series : Cost-based optimization criterion and algorithms. *Machine Learning*, 110(6) : 1481–1504, June 2021. ISSN 0885-6125, 1573-0565. doi : 10.1007/s10994-021-05974-z. URL <https://link.springer.com/10.1007/s10994-021-05974-z>.
- AFNOR. NF E18-100, July 2013.
- G. Aiello, G. La Scalia, and R. Micale. Simulation analysis of cold chain performance based on time–temperature data. *Production Planning & Control*, 23(6) :468–476, June 2012. ISSN 0953-7287, 1366-5871. doi : 10.1080/09537287.2011.564219. URL <https://www.tandfonline.com/doi/full/10.1080/09537287.2011.564219>.
- A. Alonso-Hernando, Alonso-Calleja, Carlos, and R. Capita. Effectiveness of several chemical decontamination treatments against Gram-negative bacteria on poultry during storage under different simulated cold chain disruptions. *Food Control*, 34(2) :574–580, Dec. 2013. ISSN 09567135. doi : 10.1016/j.foodcont.2013.05.020.
- A. Ambaw, T. Fadiji, and U. L. Opara. Thermo-Mechanical Analysis in the Fresh Fruit Cold Chain : A Review on Recent Advances. *Foods*, 10(6) :1357, June 2021. ISSN

- 2304-8158. doi : 10.3390/foods10061357. URL <https://www.mdpi.com/2304-8158/10/6/1357>.
- M. H. M. Assogba. IMPACT OF BREAK IN COLD CHAIN ON THE TECHNOLOGICAL AND ORGANOLEPTIC QUALITIES OF ATLANTIC MACKEREL (SCOMBER SCOMBRUS) AND HORSE MACKEREL (TRACHURUS TRACHURUS) IN SOUTH BENIN. *Journal of Microbiology, Biotechnology and Food Sciences*, 8(6) : 1242–1248, June 2019. ISSN 13385178. doi : 10.15414/jmbfs.2019.8.6.1242-1248.
- R. Badia-Melis, J. P. Qian, B. L. Fan, P. Hoyos-Echevarria, L. Ruiz-García, and X. T. Yang. Artificial Neural Networks and Thermal Image for Temperature Prediction in Apples. *Food and Bioprocess Technology*, 9(7) :1089–1099, July 2016. ISSN 1935-5130, 1935-5149. doi : 10.1007/s11947-016-1700-7.
- R. Badia-Melis, J. P. Qian, B. L. Fan, P. Hoyos-Echevarria, L. Ruiz-García, and X. T. Yang. Artificial Neural Networks and Thermal Image for Temperature Prediction in Apples. *Food and Bioprocess Technology*, 9(7) :1089–1099, July 2016. ISSN 1935-5130, 1935-5149. doi : 10.1007/s11947-016-1700-7. URL <http://link.springer.com/10.1007/s11947-016-1700-7>.
- Y. Bouzembrak, M. Klüche, A. Gavai, and H. J. Marvin. Internet of Things in food safety : Literature review and a bibliometric analysis. *Trends in Food Science & Technology*, 94 :54–64, Dec. 2019. ISSN 09242244. doi : 10.1016/j.tifs.2019.11.002. URL <https://linkinghub.elsevier.com/retrieve/pii/S0924224419303048>.
- V. Brenner. *Causes of supply chain disruptions : an empirical analysis in cold chains for food and pharmaceuticals*. Research. Springer Gabler, Wiesbaden, 2015. ISBN 978-3-658-08662-6 978-3-658-08661-9. OCLC : 931763406 tex.ids : brennerCausesSupplyChain2015a, brennerCausesSupplyChain2015b.
- S. Bruckner, A. Albrecht, B. Petersen, and J. Kreyenschmidt. Influence of cold chain interruptions on the shelf life of fresh pork and poultry : Influence of cold chain inter-

- ruptions. *International Journal of Food Science & Technology*, 47(8) :1639–1646, Aug. 2012. ISSN 09505423. doi : 10.1111/j.1365-2621.2012.03014.x.
- P. Chaitangjit and P. Ongkunaruk. The Study of Cold Storage and Temperature Controlled Transportation : A Case Study of a Chain Restaurant in Thailand. *Pamukkale University Journal of Engineering Sciences*, 25(9) :1014–1019, 2019. ISSN 1300-7009. doi : 10.5505/pajes.2019.81231.
- N. Chaomuang, D. Flick, and O. Laguerre. Experimental and numerical investigation of the performance of retail refrigerated display cabinets. *Trends in Food Science & Technology*, 70 :95–104, Dec. 2017. ISSN 09242244. doi : 10.1016/j.tifs.2017.10.007. URL <https://linkinghub.elsevier.com/retrieve/pii/S0924224417303321>.
- N. Chaomuang, O. Laguerre, and D. Flick. Dynamic heat transfer modeling of a closed refrigerated display cabinet. *Applied Thermal Engineering*, 161 :114138, Oct. 2019. ISSN 13594311. doi : 10.1016/j.applthermaleng.2019.114138. URL <https://linkinghub.elsevier.com/retrieve/pii/S1359431119314504>.
- K.-Y. Chen and Y.-C. Shaw. Applying back propagation network to cold chain temperature monitoring. *Advanced Engineering Informatics*, 25(1) :11–22, Jan. 2011. ISSN 14740346. doi : 10.1016/j.aei.2010.05.003.
- K. Cho and Y. Cho. HyperLedger Fabric-Based Proactive Defense against Inside Attackers in the WSN With Trust Mechanism. *Electronics*, 9(10) :1659, Oct. 2020. ISSN 2079-9292. doi : 10.3390/electronics9101659. URL <https://www.mdpi.com/2079-9292/9/10/1659>.
- B. Commere and F. Billard. La chaîne du froid dans l’agroalimentaire. *Techniques de l’ingénieur. Agroalimentaire*, 2 :F3230–1, 2008.
- K. Cooksey. Food packaging, principles and practices, by gordon robertson. crc, taylor and francis : Boca raton, fl, 2006. isbn 0-8493-3775-5 : 550 pages., 2008.



- R. M. Cruz, M. C. Vieira, and C. L. Silva. Effect of cold chain temperature abuses on the quality of frozen watercress (*Nasturtium officinale* R. Br.). *Journal of Food Engineering*, 94(1) :90–97, Sept. 2009. ISSN 02608774. doi : 10.1016/j.jfoodeng.2009.03.006.
- M. Degli Esposti, M. Toselli, C. Sabia, P. Messi, S. de Niederhäusern, M. Bondi, and R. Iseppi. Effectiveness of polymeric coated films containing bacteriocin-producer living bacteria for *Listeria monocytogenes* control under simulated cold chain break. *Food Microbiology*, 76 :173–179, Dec. 2018. ISSN 07400020. doi : 10.1016/j.fm.2018.05.005.
- E. Derens, B. Palagos, and J. Guilpart. The cold chain of chilled products under supervision in France. In *13th World Congress of Food Science & Technology*, page 823, Nantes, France, 2006. EDP Sciences. doi : 10.1051/IUFoST:20060823. URL <http://iufost.edpsciences.org/10.1051/IUFoST:20060823>.
- E. Derens-Bertheau, V. Osswald, O. Laguerre, and G. Alvarez. Cold chain of chilled food in France. *International Journal of Refrigeration*, 52 :161–167, Apr. 2015. ISSN 01407007. doi : 10.1016/j.ijrefrig.2014.06.012.
- M. C. do Nascimento Nunes, M. Nicometo, J. P. Emond, R. B. Melis, and I. Uysal. Improvement in fresh fruit and vegetable logistics quality : Berry logistics field studies. *Philosophical Transactions of the Royal Society A : Mathematical, Physical and Engineering Sciences*, 372(2017) :20130307, June 2014. ISSN 1364-503X, 1471-2962. doi : 10.1098/rsta.2013.0307.
- A. Draganic, I. Orovic, S. Stankovic, X. Zhang, and X. Wang. Compressive sensing approach in the table grape cold chain logistics. In *2017 6th Mediterranean Conference on Embedded Computing (MECO)*, pages 1–4, Bar, Montenegro, June 2017a. IEEE. ISBN 978-1-5090-6742-8. doi : 10.1109/MECO.2017.7977143.
- A. Draganic, I. Orovic, S. Stankovic, X. Zhang, and X. Wang. Compressive sensing approach in the table grape cold chain logistics. In *2017 6th Mediterranean Conference on Embedded Computing (MECO)*, pages 1–4, Bar, Montenegro, June

- 2017b. IEEE. ISBN 978-1-5090-6742-8. doi : 10.1109/MECO.2017.7977143. URL <http://ieeexplore.ieee.org/document/7977143/>.
- S. Duret, H.-M. Hoang, D. Flick, and O. Laguerre. Experimental characterization of airflow, heat and mass transfer in a cold room filled with food products. *International Journal of Refrigeration*, 46 :17–25, Oct. 2014. ISSN 01407007. doi : 10.1016/j.ijrefrig.2014.07.008. URL <https://linkinghub.elsevier.com/retrieve/pii/S0140700714001868>.
- S. Duret, H. Hoang, E. Derens-Bertheau, A. Delahaye, O. Laguerre, and L. Guillier. Combining Quantitative Risk Assessment of Human Health, Food Waste, and Energy Consumption : The Next Step in the Development of the Food Cold Chain? *Risk Analysis*, 39(4) :906–925, Apr. 2019. ISSN 0272-4332, 1539-6924. doi : 10.1111/risa.13199. URL <https://onlinelibrary.wiley.com/doi/abs/10.1111/risa.13199>.
- C. Faullimel, S. Ennahar, D. Aoude-Werner, P. Guterl, and E. Marchioni. DNA Comet Assay for the Detection of Time-Temperature Abuse during the Storage of Poultry. *Journal of Food Protection*, 68(7) :1414–1420, July 2005. ISSN 0362-028X, 1944-9097. doi : 10.4315/0362-028X-68.7.1414.
- R. Ferdousi, M. Rouhi, R. Mohammadi, A. M. Mortazavian, K. Khosravi-Darani, and A. H. Rad. Evaluation of Probiotic Survivability in Yogurt Exposed To Cold Chain Interruption. page 6, 2013.
- D. Frank, Y. Zhang, Y. Li, X. Luo, X. Chen, M. Kaur, G. Mellor, J. Stark, and J. Hughes. Shelf life extension of vacuum packaged chilled beef in the Chinese supply chain. A feasibility study. *Meat Science*, 153 :135–143, July 2019a. ISSN 03091740. doi : 10.1016/j.meatsci.2019.03.006.
- D. Frank, Y. Zhang, X. Luo, X. Chen, G. Mellor, J. Stark, and J. Hughes. Shipping and storage temperature logger datasets for extended shelf life vacuum packaged chilled beef in the Chinese supply chain. *Data in Brief*, 27 :104586, Dec. 2019b. ISSN

23523409. doi : 10.1016/j.dib.2019.104586. URL <https://linkinghub.elsevier.com/retrieve/pii/S2352340919309412>.
- H. W. Freiboth, L. Goedhals-Gerber, F. E. Van Dyk, and M. C. Dodd. Investigating temperature breaks in the summer fruit export cold chain : A case study. *Journal of Transport and Supply Chain Management*, 7(1) :7 pages, May 2013. ISSN 1995-5235, 2310-8789. doi : 10.4102/jtscm.v7i1.99. URL <http://www.jtscm.co.za/index.php/jtscm/article/view/99>.
- Y. Galagan and W.-F. Su. Fadable ink for time–temperature control of food freshness : Novel new time–temperature indicator. *Food Research International*, 41(6) : 653–657, July 2008. ISSN 09639969. doi : 10.1016/j.foodres.2008.04.012. URL <https://linkinghub.elsevier.com/retrieve/pii/S0963996908000926>.
- J. Gao, Y. Si, Y. Zhu, F. Luo, and S. Yan. Temperature abuse timing affects the rate of quality deterioration of postharvest broccoli during different pre-storage stages. *Scientia Horticulturae*, 227 :207–212, Jan. 2018. ISSN 03044238. doi : 10.1016/j.scienta.2017.09.034.
- G. Géczi, P. Korzenszky, and K. Szakmár. Cold chain interruption by consumers significantly reduces shelf life of vacuum-packed pork ham slices. *Acta Alimentaria*, 46(4) : 508–516, Dec. 2017. ISSN 0139-3006, 1588-2535. doi : 10.1556/066.2017.46.4.14.
- M. Giannakourou, K. Koutsoumanis, G. Nychas, and P. Taoukis. Field evaluation of the application of time temperature integrators for monitoring fish quality in the chill chain. *International Journal of Food Microbiology*, 102(3) :323–336, July 2005. ISSN 01681605. doi : 10.1016/j.ijfoodmicro.2004.11.037. URL <https://linkinghub.elsevier.com/retrieve/pii/S016816050500067X>.
- L. L. Goedhals-Gerber and G. Khumalo. Identifying temperature breaks in the export cold chain of navel oranges : A Western Cape case. *Food Control*, 110 :107013, 2018. ISSN 09567135. doi : 10.1016/j.foodcont.2019.107013. URL <https://linkinghub.elsevier.com/retrieve/pii/S0956713519306024>.

- L. L. Goedhals-Gerber, L. Haasbroek, H. Freiboth, and F. E. Van Dyk. An analysis of the influence of logistics activities on the export cold chain of temperature sensitive fruit through the Port of Cape Town. *Journal of Transport and Supply Chain Management*, 9(1) :9 pages, Feb. 2015. ISSN 1995-5235, 2310-8789. doi : 10.4102/jtscm.v9i1.201.
- E. Gogou, G. Katsaros, E. Derens, G. Alvarez, and P. Taoukis. Cold chain database development and application as a tool for the cold chain management and food quality evaluation. *International Journal of Refrigeration*, 52 :109–121, 2015.
- W. Gruyters, P. Verboven, E. Diels, S. Rogge, B. Smeets, H. Ramon, T. Defraeye, and B. M. Nicolai. Modelling Cooling of Packaged Fruit Using 3D Shape Models. *Food and Bioprocess Technology*, 11(11) :2008–2020, Nov. 2018. ISSN 1935-5130, 1935-5149. doi : 10.1007/s11947-018-2163-9. URL <http://link.springer.com/10.1007/s11947-018-2163-9>.
- W. Gruyters, T. Van De Looverbosch, Z. Wang, S. Janssen, P. Verboven, T. Defraeye, and B. Nicolai. Revealing shape variability and cultivar effects on cooling of packaged fruit by combining CT-imaging with explicit CFD modelling. *Postharvest Biology and Technology*, 162 :111098, Apr. 2020. ISSN 09255214. doi : 10.1016/j.postharvbio.2019.111098. URL <https://linkinghub.elsevier.com/retrieve/pii/S092552141930657X>.
- T. Hafliðason, G. Ólafsdóttir, S. Bogason, and G. Stefánsson. Criteria for temperature alerts in cod supply chains. *International Journal of Physical Distribution & Logistics Management*, 42(4) :355–371, May 2012. ISSN 0960-0035. doi : 10.1108/09600031211231335. URL <https://www.emerald.com/insight/content/doi/10.1108/09600031211231335/full/html>.
- H.-M. Hoang, S. Duret, D. Flick, and O. Laguerre. Preliminary study of airflow and heat transfer in a cold room filled with apple pallets : Comparison between two modelling approaches and experimental results. *Applied Thermal Engineering*, 76 :367–381, Feb.

2015. ISSN 13594311. doi : 10.1016/j.applthermaleng.2014.11.012. URL <https://linkinghub.elsevier.com/retrieve/pii/S135943111401000X>.
- J. Huang, Y. Luo, and X. Nou. Growth of *Salmonella enterica* and *Listeria monocytogenes* on Fresh-Cut Cantaloupe under Different Temperature Abuse Scenarios. *Journal of Food Protection*, 78(6) :1125–1131, June 2015. ISSN 0362-028X, 1944-9097. doi : 10.4315/0362-028X.JFP-14-468.
- H. Jaeger. Tutorial on training recurrent neural networks, covering bppt, rtrl, ekf and the " echo state network " approach. 2002.
- S. James and C. James. The food cold-chain and climate change. *Food Research International*, 43(7) :1944–1956, Aug. 2010. ISSN 09639969. doi : 10.1016/j.foodres.2010.02.001. URL <https://linkinghub.elsevier.com/retrieve/pii/S0963996910000566>.
- A. Jofré, M. L. Latorre-Moratalla, M. Garriga, and S. Bover-Cid. Domestic refrigerator temperatures in Spain : Assessment of its impact on the safety and shelf-life of cooked meat products. *Food Research International*, 126 :108578, Dec. 2019. ISSN 09639969. doi : 10.1016/j.foodres.2019.108578.
- O. Laguerre, H. Hoang, and D. Flick. Experimental investigation and modelling in the food cold chain : Thermal and quality evolution. *Trends in Food Science & Technology*, 29(2) :87–97, Feb. 2013. ISSN 09242244. doi : 10.1016/j.tifs.2012.08.001. URL <https://linkinghub.elsevier.com/retrieve/pii/S092422441200163X>.
- O. Laguerre, S. Duret, H. Hoang, and D. Flick. Using simplified models of cold chain equipment to assess the influence of operating conditions and equipment design on cold chain performance. *International Journal of Refrigeration*, 47 :120–133, Nov. 2014. ISSN 01407007. doi : 10.1016/j.ijrefrig.2014.07.023. URL <https://linkinghub.elsevier.com/retrieve/pii/S0140700714002011>.
- Y. Le Cun, O. Matan, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, L. Jacket, and H. S. Baird. Handwritten zip code recognition with multilayer networks.

- In [1990] *Proceedings. 10th International Conference on Pattern Recognition*, volume 2, pages 35–40. IEEE, 1990.
- L. Lecoq, D. Flick, E. Derens, H. Hoang, and O. Laguerre. Simplified heat and mass transfer modeling in a food processing plant. *Journal of Food Engineering*, 171 :1–13, Feb. 2016. ISSN 02608774. doi : 10.1016/j.jfoodeng.2015.09.026. URL <https://linkinghub.elsevier.com/retrieve/pii/S0260877415004306>.
- D. Lemmer and F. J. Kruger. Effect of cold chain breaks on the ripening and quality of 'Hass' avocados. page 11, 2010.
- P. Li, S. Jia, C. Zhou, H. Fang, and C. Chen. Protective role of *Lactobacillus fermentum* R6 against *Clostridium perfringens* in vitro and in chicken breast meat under temperature abuse conditions. *Innovative Food Science & Emerging Technologies*, 41 :117–123, June 2017. ISSN 14668564. doi : 10.1016/j.ifset.2017.03.001.
- J. Loisel, S. Duret, A. Cornuéjols, D. Cagnon, M. Tardet, E. Derens-Bertheau, and O. Laguerre. Cold chain break detection and analysis : Can machine learning help? *Trends in Food Science & Technology*, 112 :391–399, June 2021. ISSN 09242244. doi : 10.1016/j.tifs.2021.03.052. URL <https://linkinghub.elsevier.com/retrieve/pii/S0924224421002442>.
- J. Loisel, A. Cornuéjols, O. Laguerre, M. Tardet, D. Cagnon, O. D. de Lamotte, and S. Duret. Machine learning for temperature prediction in food pallet along a cold chain : Comparison between synthetic and experimental training dataset. *Journal of Food Engineering*, 2022.
- D. C. Love, L. M. Kuehl, R. M. Lane, J. P. Fry, J. Harding, B. J. Davis, K. Clancy, and B. Hudson. Performance of cold chains and modeled growth of *Vibrio parahaemolyticus* for farmed oysters distributed in the United States and internationally. *International Journal of Food Microbiology*, 313 :108378, Jan. 2020. ISSN 01681605. doi : 10.1016/j.ijfoodmicro.2019.108378.

- N. Mai and V. Huynh. Kinetics of Quality Changes of Pangasius Fillets at Stable and Dynamic Temperatures, Simulating Downstream Cold Chain Conditions. *Journal of Food Quality*, 2017 :1–9, 2017. ISSN 0146-9428, 1745-4557. doi : 10.1155/2017/2865185.
- L. Mastrandrea, M. L. Amodio, S. Pati, and G. Colelli. Effect of modified atmosphere packaging and temperature abuse on flavor related volatile compounds of rocket leaves (*Diplotaxis tenuifolia* L.). *Journal of Food Science and Technology*, 54(8) :2433–2442, July 2017. ISSN 0022-1155, 0975-8402. doi : 10.1007/s13197-017-2685-6.
- C. Medà, P., A. i Sero, M., A. Rosell, R., A. Vilas, I., Plaza, L., Gilabert, V., and . . V. nas Almenar. Development of a fresh-cut product based on pears and the subsequent evaluation of its shelf life under commercial conditions and after a cold chain break.
- N. Mellouli, M. Akerma, M. Hoang, D. Leducq, and A. Delahaye. Deep Learning Models for Time Series Forecasting of Indoor Temperature and Energy Consumption in a Cold Room. In N. T. Nguyen, R. Chbeir, E. Exposito, P. Aniorté, and B. Trawiński, editors, *Computational Collective Intelligence*, volume 11684, pages 133–144. Springer International Publishing, Cham, 2019. ISBN 978-3-030-28373-5 978-3-030-28374-2. doi : 10.1007/978-3-030-28374-2\_12. URL [http://link.springer.com/10.1007/978-3-030-28374-2\\_12](http://link.springer.com/10.1007/978-3-030-28374-2_12). Series Title : Lecture Notes in Computer Science.
- M. Merai, D. Flick, L. Guillier, S. Duret, and O. Laguerre. Experimental characterization of airflow inside a refrigerated trailer loaded with carcasses. *International Journal of Refrigeration*, 88 :337–346, Apr. 2018. ISSN 01407007. doi : 10.1016/j.ijrefrig.2018.01.005. URL <https://linkinghub.elsevier.com/retrieve/pii/S0140700718300100>.
- S. Mercier and I. Uysal. Neural network models for predicting perishable food temperatures along the supply chain. *Biosystems Engineering*, 171 :91–100, July 2018a. ISSN 15375110. doi : 10.1016/j.biosystemseng.2018.04.016.
- S. Mercier and I. Uysal. Neural network models for predicting perishable food temperatures along the supply chain. *Biosystems Engineering*, 171 :91–100, July 2018b. ISSN

15375110. doi : 10.1016/j.biosystemseng.2018.04.016. URL <https://linkinghub.elsevier.com/retrieve/pii/S1537511017307808>.
- S. Mercier, S. Villeneuve, M. Mondor, and I. Uysal. Time-Temperature Management Along the Food Cold Chain : A Review of Recent Developments : Food preservation along the cold chain... *Comprehensive Reviews in Food Science and Food Safety*, 16(4) :647–667, July 2017. ISSN 15414337. doi : 10.1111/1541-4337.12269. URL <https://onlinelibrary.wiley.com/doi/10.1111/1541-4337.12269>.
- E. Mohebi and L. Marquez. Application of Machine Learning and RFID in the Stability Optimization of Perishable Foods. page 18, 2014a.
- E. Mohebi and L. Marquez. Application of Machine Learning and RFID in the Stability Optimization of Perishable Foods. Nov. 2014b.
- MonitorMarkTM. Time temperature indicators, providing a visual history of time temperature exposure. <https://multimedia.3m.com/mws/media/2155060/3mtm-monitormarktm-time-temperature-indicators-brochure.pdf>.
- G. Mu, A. Jonsson, A. B. Bergsson, and K. A. Thorarinsdottir. The Effects of Short-Time Temperature Abuse on the Microbial and Sensory Quality of Chilled Saithe ( *Pollachius virens* ) Fillets : Spoilage due to time-temperature abuse... *Journal of Food Science*, 82(11) :2690–2699, Nov. 2017. ISSN 00221147. doi : 10.1111/1750-3841.13926.
- H. Nahor, M. Hoang, P. Verboven, M. Baelmans, and B. Nicolai. CFD model of the airflow, heat and mass transfer in cool stores. *International Journal of Refrigeration*, 28(3) :368–380, May 2005. ISSN 01407007. doi : 10.1016/j.ijrefrig.2004.08.014. URL <https://linkinghub.elsevier.com/retrieve/pii/S0140700704002075>.
- N. Ndraha, H.-I. Hsiao, J. Vljajic, M.-F. Yang, and H.-T. V. Lin. Time-temperature abuse in the food cold chain : Review of issues, challenges, and recommendations. *Food Control*, 89 :12–21, July 2018. ISSN 09567135. doi : 10.1016/j.foodcont.2018.01.027. URL <https://linkinghub.elsevier.com/retrieve/pii/S0956713518300331>.  
tex.ids : ndrahaTimetemperatureAbuseFood2018a.



- N. Ndraha, W.-C. Sung, and H.-I. Hsiao. Evaluation of the cold chain management options to preserve the shelf life of frozen shrimps : A case study in the home delivery services in Taiwan. *Journal of Food Engineering*, 242 :21–30, Feb. 2019. ISSN 02608774. doi : 10.1016/j.jfoodeng.2018.08.010.
- M. C. Nunes, M. Nicometo, J. P. Emond, R. B. Melis, and I. Uysal. Improvement in Fresh Fruit and Vegetable Logistics Quality : Berry Logistics Field Studies. *Philosophical Transactions of the Royal Society A : Mathematical, Physical and Engineering Sciences*, 372(2017) :20130307, June 2014. ISSN 1364-503X, 1471-2962. doi : 10.1098/rsta.2013.0307.
- Odoli Ogombe Cyprian, Kolbrún Sveinsdóttir, Hannes Magnússon, and Emília Martinsdóttir. Application of Quality Index Method (QIM) Scheme and Effects of Short-Time Temperature Abuse in Shelf Life Study of Fresh Water Arctic Char ( *Salvelinus alpinus* ). *Journal of Aquatic Food Product Technology*, 17(3) :303–321, July 2008. ISSN 1049-8850, 1547-0636. doi : 10.1080/10498850802195038.
- D. Onwude, F. Bahrami, C. Shrivastava, T. Berry, P. Cronje, J. North, N. Kirsten, S. Schudel, E. Crenna, K. Shoji, and T. Defraeye. Physics-driven digital twins to quantify the impact of pre- and postharvest variability on the end quality evolution of orange fruit. *Resources, Conservation and Recycling*, 186 :106585, Nov. 2022. ISSN 09213449. doi : 10.1016/j.resconrec.2022.106585. URL <https://linkinghub.elsevier.com/retrieve/pii/S0921344922004207>.
- J. L. O’Sullivan, M. J. Ferrua, R. Love, P. Verboven, B. Nicolai, and A. East. Forced-air cooling of polylined horticultural produce : Optimal cooling conditions and package design. *Postharvest Biology and Technology*, 126 :67–75, Apr. 2017. ISSN 09255214. doi : 10.1016/j.postharvbio.2016.11.019. URL <https://linkinghub.elsevier.com/retrieve/pii/S0925521416306676>.
- A. T. Pham, J. Moureh, and D. Flick. Experimental characterization of airflow within a pallet of product generating heat : Application for cheese product. *Inter-*

- national Journal of Refrigeration*, 106 :89–103, Oct. 2019. ISSN 01407007. doi : 10.1016/j.ijrefrig.2019.06.022. URL <https://linkinghub.elsevier.com/retrieve/pii/S0140700719302828>.
- H. Rediers, M. Claes, L. Peeters, and K. A. Willems. Evaluation of the cold chain of fresh-cut endive from farmer to plate. *Postharvest Biology and Technology*, 51(2) : 257–262, Feb. 2009. ISSN 09255214. doi : 10.1016/j.postharvbio.2008.07.017.
- P. E. Romotowska, M. Gudjónsdóttir, M. G. Karlsdóttir, H. G. Kristinsson, and S. Arason. Stability of frozen Atlantic mackerel ( *Scomber scombrus* ) as affected by temperature abuse during transportation. *LWT - Food Science and Technology*, 83 :275–282, Sept. 2017. ISSN 00236438. doi : 10.1016/j.lwt.2017.05.024.
- L. Ruiz-Garcia, L. Lunadei, P. Barreiro, and I. Robla. A Review of Wireless Sensor Technologies and Applications in Agriculture and Food Industry : State of the Art and Current Trends. *Sensors*, 9(6) :4728–4750, June 2009. ISSN 1424-8220. doi : 10.3390/s90604728. URL <http://www.mdpi.com/1424-8220/9/6/4728>.
- S. P. Sadhu. Effect of cold chain interruptions on the shelf-life of fluid pasteurised skim milk at the consumer stage. *Brazilian Journal of Food Technology*, 21(0), Mar. 2018. ISSN 1981-6723. doi : 10.1590/1981-6723.06417.
- G. A. Salvatore, J. Sülzle, F. Dalla Valle, G. Cantarella, F. Robotti, P. Jokic, S. Knobelspies, A. Daus, L. Büthe, L. Petti, N. Kirchgessner, R. Hopf, M. Magno, and G. Tröster. Biodegradable and Highly Deformable Temperature Sensors for the Internet of Things. *Advanced Functional Materials*, 27(35) :1702390, Sept. 2017. ISSN 1616301X. doi : 10.1002/adfm.201702390. URL <https://onlinelibrary.wiley.com/doi/10.1002/adfm.201702390>.
- A. Sarac, N. Absi, and S. Dauzère-Pérès. A literature review on the impact of RFID technologies on supply chain management. *International Journal of Production Economics*, 128(1) :77–95, Nov. 2010. ISSN 09255273. doi : 10.1016/j.ijpe.2010.07.039. URL <https://linkinghub.elsevier.com/retrieve/pii/S0925527310002835>.

- Sichao Lu and Xifu Wang. Toward an intelligent solution for perishable food cold chain management. In *2016 7th IEEE International Conference on Software Engineering and Service Science (ICSESS)*, pages 852–856, Beijing, China, Aug. 2016. IEEE. ISBN 978-1-4673-9904-3. doi : 10.1109/ICSESS.2016.7883200.
- A. Siti Norashikin, M. Nor Khaizura, and W. Wan Zunairah. Microbiological Quality and Safety of Unfinished UHT Milk at Storage Time-Temperature Abuse. *International Journal of Current Microbiology and Applied Sciences*, 7(03) :2278–2296, Mar. 2018. ISSN 23197692, 23197706. doi : 10.20546/ijcmas.2018.703.268.
- P. Taoukis and T. Labuza. Applicability of Time-Temperature Indicators as Shelf Life Monitors of Food Products. *Journal of Food Science*, 54(4) :783–788, July 1989. ISSN 0022-1147, 1750-3841. doi : 10.1111/j.1365-2621.1989.tb07882.x. URL <https://onlinelibrary.wiley.com/doi/10.1111/j.1365-2621.1989.tb07882.x>.
- J. Thibault, S. Bergeron, and H. W. Bonin. ON FINITE-DIFFERENCE SOLUTIONS OF THE HEAT EQUATION IN SPHERICAL COORDINATES. *Numerical Heat Transfer*, 12(4) :457–474, Dec. 1987. ISSN 0149-5720. doi : 10.1080/10407788708913597. URL <http://www.tandfonline.com/doi/abs/10.1080/10407788708913597>.
- C. Thomas and D. O’Beirne. Evaluation of the impact of short-term temperature abuse on the microbiology and shelf life of a model ready-to-use vegetable combination product. *International Journal of Food Microbiology*, 59(1-2) :47–57, July 2000. ISSN 01681605. doi : 10.1016/S0168-1605(00)00290-7.
- Thompson. cooling METHODS. *University of California Agriculture and Natural Resources*, 3311 :97, 2002.
- P. Undurraga, J. A. Olaeta, and P. Canessa. Effect of Cold Break During Refrigerated Storage on Conservation and Quality of Hass Avocados (Persea Americana Mill.). page 10.

- R. van der Sman. Simple model for estimating heat and mass transfer in regular-shaped foods. *Journal of Food Engineering*, 60(4) :383–390, Dec. 2003. ISSN 02608774. doi : 10.1016/S0260-8774(03)00061-X. URL <https://linkinghub.elsevier.com/retrieve/pii/S026087740300061X>.
- P. Verboven, D. Flick, B. Nicolai, and G. Alvarez. Modelling transport phenomena in refrigerated food bulks, packages and stacks : basics and advances. *International Journal of Refrigeration*, 29(6) :985–997, Sept. 2006. ISSN 01407007. doi : 10.1016/j.ijrefrig.2005.12.010. URL <https://linkinghub.elsevier.com/retrieve/pii/S0140700705002628>.
- S. Wang, X. Liu, M. Yang, Y. Zhang, K. Xiang, and R. Tang. Review of Time Temperature Indicators as Quality Monitors in Food Packaging : Review of Time Temperature Indicators. *Packaging Technology and Science*, 28(10) :839–867, Oct. 2015. ISSN 08943214. doi : 10.1002/pts.2148. URL <https://onlinelibrary.wiley.com/doi/10.1002/pts.2148>.
- W. Wu, P. Cronjé, B. Nicolai, P. Verboven, U. Linus Opara, and T. Defraeye. Virtual cold chain method to model the postharvest temperature history and quality evolution of fresh fruit – A case study for citrus fruit packed in a single carton. *Computers and Electronics in Agriculture*, 144 :199–208, Jan. 2018. ISSN 01681699. doi : 10.1016/j.compag.2017.11.034. URL <https://linkinghub.elsevier.com/retrieve/pii/S0168169917306105>.
- X. Xiao, Q. He, Z. Fu, M. Xu, and X. Zhang. Applying CS and WSN methods for improving efficiency of frozen and chilled aquatic products monitoring system in cold chain logistics. *Food Control*, 60 :656–666, Feb. 2016. ISSN 09567135. doi : 10.1016/j.foodcont.2015.09.012. URL <https://linkinghub.elsevier.com/retrieve/pii/S0956713515301912>.
- W. Xu, Z. Zhang, D. Gong, and X. Guan. Neural Network Model for the Risk Prediction in Cold Chain Logistics. *International Journal of Multimedia and Ubi-*

*quitous Engineering*, 9(8) :111–124, Aug. 2014. ISSN 19750080, 19750080. doi : 10.14257/ijmue.2014.9.8.10.

W. Zeng, K. Vorst, W. Brown, B. P. Marks, S. Jeong, F. Pérez-Rodríguez, and E. T. Ryser. Growth of *Escherichia coli* O157 :H7 and *Listeria monocytogenes* in Packaged Fresh-Cut Romaine Mix at Fluctuating Temperatures during Commercial Transport, Retail Storage, and Display. *Journal of Food Protection*, 77(2) :197–206, Feb. 2014. ISSN 0362-028X, 1944-9097. doi : 10.4315/0362-028X.JFP-13-117.

Z. Zuo, B. Shuai, G. Wang, X. Liu, X. Wang, B. Wang, and Y. Chen. Convolutional recurrent neural networks : Learning spatial dependencies for image representation. pages 18–26, 06 2015. doi : 10.1109/CVPRW.2015.7301268.