

UNIVERSITÉ DU QUÉBEC À MONTRÉAL

ALGORITHMES ET MÉTHODES POUR LA DÉTECTION ET LE TRACKING DES VACHES LAITIÈRES DANS LE
CADRE DE L'ÉTUDE DU BIEN-ÊTRE ANIMAL

MÉMOIRE

PRÉSENTÉ

COMME EXIGENCE PARTIELLE

DE LA MAÎTRISE EN INFORMATIQUE - CONCENTRATION BIOINFORMATIQUE

PAR

CISSE KHALY BÉCAYE BA

FÉVRIER 2026

UNIVERSITÉ DU QUÉBEC À MONTRÉAL
Service des bibliothèques

Avertissement

La diffusion de ce mémoire se fait dans le respect des droits de son auteur, qui a signé le formulaire *Autorisation de reproduire et de diffuser un travail de recherche de cycles supérieurs* (SDU-522 – Rév.12-2023). Cette autorisation stipule que «conformément à l'article 11 du Règlement no 8 des études de cycles supérieurs, [l'auteur] concède à l'Université du Québec à Montréal une licence non exclusive d'utilisation et de publication de la totalité ou d'une partie importante de [son] travail de recherche pour des fins pédagogiques et non commerciales. Plus précisément, [l'auteur] autorise l'Université du Québec à Montréal à reproduire, diffuser, prêter, distribuer ou vendre des copies de [son] travail de recherche à des fins non commerciales sur quelque support que ce soit, y compris l'Internet. Cette licence et cette autorisation n'entraînent pas une renonciation de [la] part [de l'auteur] à [ses] droits moraux ni à [ses] droits de propriété intellectuelle. Sauf entente contraire, [l'auteur] conserve la liberté de diffuser et de commercialiser ou non ce travail dont [il] possède un exemplaire.»

REMERCIEMENTS

Je souhaite exprimer ma profonde gratitude à mon père, Makhète Aboubacar CISSE, qui fut bien plus qu'un parent : un mentor et un ami précieux. Papa, j'espère que ce travail te rendra fier et je m'engage à continuer d'honorer ta mémoire à travers chacun de mes accomplissements. Ma reconnaissance va également à ma mère, Bigue CAMARA, qui n'a cessé de prier pour moi et de m'épauler le long de mon cheminement. Merci à mes frères, Makhete et Cheikh, et à ma belle-sœur, Racky, dont le soutien indéfectible au cours de ces dernières années a été ma force. Sans votre présence, vos encouragements et votre confiance en moi, ce parcours n'aurait pas été possible. Cette réussite vous appartient autant qu'à moi.

Merci également à Junior, qui, au cours de ces derniers mois, a pu m'apporter le courage et la détermination nécessaires à l'achèvement de ce projet.

Je tiens aussi à remercier chaleureusement le Professeur Abdoulaye Baniré Diallo, mon directeur de recherche, pour sa patience, ses conseils éclairés et sa disponibilité tout au long de cette recherche. Ses orientations ont été déterminantes dans l'aboutissement de ce travail. Ma gratitude s'étend aussi à tous les membres du laboratoire de Bioinformatique, notamment Karen, Voncarlos et Thomas, qui ont contribué à ma formation et ont su me guider à travers les différentes étapes de mon cheminement. Je n'oublie pas Abdourahmane, Amanda, Lina, Mamadou, Armand, Aliou, François et bien d'autres, avec qui j'ai partagé les joies et les défis de ces années d'études. Leurs encouragements et notre entraide mutuelle ont rendu ce chemin plus lumineux.

Je te remercie du fond du cœur, Gnagne. Ta patience, ta compréhension et tes encouragements constants ont été un pilier essentiel durant cette aventure académique. Merci d'avoir cru en moi et de m'avoir accompagné avec tant de dévouement dans la réalisation de ce projet.

Enfin, je remercie toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce mémoire.

TABLE DES MATIÈRES

TABLE DES FIGURES	vi
LISTE DES TABLEAUX	viii
ACRONYMES	ix
NOTATION	x
RÉSUMÉ	xi
ABSTRACT.....	xii
INTRODUCTION	1
CHAPITRE 1 CONTEXTE DE L'ÉTUDE	4
1.1 Le bien-être animal.....	4
1.2 Precision Livestock Farming : L'utilisation de la vision par ordinateur dans l'élevage	4
1.3 Définition de l'éthologie	5
1.4 Définition de la vision par ordinateur	7
1.4.1 Les approches d'apprentissage machine pour le tracking	8
1.5 Description des types de données rencontrés en éthologie	9
CHAPITRE 2 REVUE DE LA LITTÉRATURE ET DÉFINITION DE LA PROBLÉMATIQUE	12
2.1 Énoncé de la problématique	12
2.2 État de l'art	13
2.2.1 La détection d'objet	13
2.2.2 Comparaison entre Yolov5 et les versions plus récentes	18
2.2.3 La détection & le suivi d'objets	19
2.2.4 Le suivi d'objets multiples : Tracking.....	20
2.2.5 La re-identification des objets perdus	25

2.3	Les défis de la détection et du suivi d'objet	27
CHAPITRE 3 MÉTHODOLOGIE ET EXPÉRIENCES		31
3.1	Approche méthodologique	31
3.2	Présentation du jeu de données	33
3.3	Traitement des données	35
3.4	Détection des vaches laitières	38
3.4.1	Algorithme 1 pour la détection.....	38
3.4.2	Métriques d'évaluation des performances de la détection.....	40
3.5	Le suivi d'objets multiples.....	43
3.5.1	Algorithme 2 pour le suivi d'objets multiples	44
3.5.2	Métriques d'évaluation des performances du Tracking.....	45
3.5.3	Mesures pour l'étude des comportements et des réseaux sociaux	46
3.5.4	Algorithme 3 pour l'extraction des métriques	48
CHAPITRE 4 RÉSULTATS		51
4.1	Cadre expérimental	51
4.2	Résultats de la détection.....	52
4.3	Résultats du tracking	56
4.4	Résultats des métriques d'analyse des mouvements.....	61
CHAPITRE 5 DISCUSSION ET CONCLUSION		65
ANNEXE A RÉSULTATS DE L'ENTRAÎNEMENT DE LA DÉTECTION PAR YOLOV5		70
ANNEXE B RÉSULTATS EXPÉRIMENTAUX DE LA DÉTECTION ET DU TRACKING		75
BIBLIOGRAPHIE		81

TABLE DES FIGURES

Figure 1.1	Image montrant une vache atteinte de boiterie (Price, 2019)	6
Figure 2.1	Schéma illustrant l'architecture du modèle (Redmon <i>et al.</i> , 2016)	15
Figure 2.2	L'architecture de YOLOv5 (Liu <i>et al.</i> , 2021)	16
Figure 2.3	Schéma représentant le framework de StrongSORT	23
Figure 2.4	Schéma représentant le framework de FastReID (He <i>et al.</i> , 2020)	26
Figure 2.5	Images représentant les problèmes de l'occlusion et des ID switches	29
Figure 3.1	Schéma illustrant les différentes étapes et composantes du pipeline pour la réalisation du projet	32
Figure 3.2	Schéma montrant l'emplacement des différentes caméras extérieurs.....	33
Figure 3.3	Images représentant les différentes caméras : (a) caméra du couloir (OC); (b) caméra placée au milieu de l'enclos (OE); (c) caméra des enclos (OP)	34
Figure 3.4	Schéma montrant l'emplacement des différentes caméras intérieur	34
Figure 3.5	Images représentant les différentes caméras d'intérieur : (a) caméra placée sur les tubes (IP); (b) caméra du mur (IW); (c) caméra du plafond (IC)	35
Figure 3.6	Exemples d'augmentations appliquées aux images : (a) Brightness, (b) Crop, (c) Rotation, (d) Flip	37
Figure 3.7	Matrice de confusion d'un problème de classification.....	41
Figure 3.8	Ration de l'Intersection sur l'Union	42
Figure 4.1	Courbes des différentes métriques obtenues lors de l'entraînement avec en ordonnées les valeurs de métriques en fonction des epochs en abscisse.	53
Figure 4.2	Illustration des résultats de la détection avec YOLOv5 (1)	54
Figure 4.3	Illustration des résultats de la détection avec YOLOv5 (2)	55

Figure 4.4 Image montrant le suivi d'une vache 57

LISTE DES TABLEAUX

Table 2.1	Les paramètres d'entraînement utilisés	17
Table 2.2	Comparaison entre YOLOv5 et des versions plus récentes.....	18
Table 2.3	Les paramètres utilisés pour le suivi multiple d'objets par StrongSORT.....	25
Table 3.1	Différentes augmentation de données appliquées sur notre jeu de données	37
Table 3.2	Comparaison des algorithmes de suivi multi-objets	43
Table 4.1	Les paramètres d'entraînement de Fastreid	51
Table 4.2	Résultat des performances du modèle à travers les epochs d'entraînement	52
Table 4.3	Comparaison des modèles de détection YOLOv5n et YOLOv5l sur les données non augmentées (Simple) et augmentées (Aug.)	53
Table 4.4	Résultats du Tracking avec les coordonnées des boîtes d'encerclement et les scores de confiance de chaque vaches détectées et trackées.....	58
Table 4.5	Comparaison des performances avec différents modèles de TorchReID	59
Table 4.6	Les paramètres d'entraînement de Fastreid	59
Table 4.7	Résultats de la validation du modèle FastReID	60
Table 4.8	Comparaison des performances du modèle FastReID à des seuils d'IoU différents	61
Table 4.9	Analyse des déplacements des vaches : Mesures de distance, de vitesse, et d'accélération	62
Table 4.10	Tableau des moyennes de distances entre les vaches	63

ACRONYMES

PLF Precision Livestock Farming.

CV Computer Vision.

SORT Simple Online Realtime Tracking.

YOLO You Only Look Once.

mAP Mean Average Precision.

CNN Convolutionnal Neural Network.

ML Machine Learning.

DP Deep Learning.

MOT Multi Object Tracking.

MOTA Multi Object Tacking Accuracy.

MOTP Multi Object Tacking Precision.

HOTA High-Order Tracking Accuracy.

IDs Id switches.

NOTATION

m un mètre.

s une seconde.

m/s un mètre par seconde.

m/s^2 un mètre par seconde au carré.

$pixels$ un pixel.

RÉSUMÉ

L'amélioration du bien-être et de la longévité des vaches laitières représente aujourd'hui un défi majeur pour l'élevage moderne. Cette préoccupation nécessite une compréhension fine des besoins comportementaux et sociaux des bovins, ainsi que le développement d'outils permettant d'évaluer objectivement leur état de bien-être au quotidien. Le bien-être animal est une notion fondamentale de l'élevage et englobe non seulement la santé physique des animaux, mais également leur équilibre psychologique et social. Pour les vaches laitières, cela se traduit par la nécessité de surveiller leurs activités, leurs interactions sociales, leurs habitudes de repos et d'alimentation, autant d'indicateurs révélateurs de leur état de confort ou de stress. Face à cette problématique complexe, nous avons développé une approche technologique innovante permettant de quantifier objectivement l'activité et les comportements sociaux des vaches. Notre méthodologie repose sur l'analyse automatisée d'images pour détecter et suivre individuellement les bovins dans leur environnement naturel. Grâce à des algorithmes de détection d'objets (YOLOv5) appliqués à nos données d'images annotées, nous identifions précisément chaque animal. Ces informations alimentent ensuite un système de suivi (StrongSORT) qui combine les données de mouvement et d'apparence visuelle pour maintenir l'identité de chaque vache au fil du temps. Cette approche nous permet de générer des métriques quantitatives d'activité individuelle et collective, ouvrant la voie à des analyses approfondies des dynamiques sociales au sein du troupeau. Ces données comportementales constituent un socle scientifique robuste pour évaluer le bien-être animal et identifier les facteurs environnementaux ou sociaux qui influencent positivement ou négativement la qualité de vie des vaches. À terme, ces outils d'analyse pourront guider les éleveurs vers des pratiques plus respectueuses du bien-être animal, contribuant ainsi à un élevage plus durable et éthique.

Mots-clés : Bien-être animal, Vision par ordinateur, Apprentissage profond, Vaches laitières, Détection, Tracking, Analyse des réseaux sociaux

ABSTRACT

Improving the welfare and longevity of dairy cows represents a major challenge for modern farming today. This concern requires a detailed understanding of the behavioral and social needs of cattle, as well as the development of tools that can objectively assess their daily well-being. Animal welfare is a fundamental concept in livestock farming, encompassing not only the physical health of the animals but also their psychological and social balance. For dairy cows, this translates into the need to monitor their activities, social interactions, resting, and feeding habits—all key indicators of comfort or stress. In response to this complex issue, we have developed an innovative technological approach to objectively quantify the activity and social behaviors of cows. Our methodology is based on automated image analysis to detect and individually track cattle in their natural environment. Using object detection algorithms (YOLOv5) applied to our annotated image data, we accurately identify each animal. This information is then fed into a tracking system (StrongSORT), which combines motion data and visual appearance features to maintain each cow's identity over time. This approach allows us to generate quantitative metrics of both individual and collective activity, paving the way for in-depth analyses of social dynamics within the herd. These behavioral data provide a robust scientific foundation for assessing animal welfare and identifying environmental or social factors that positively or negatively influence the quality of life of cows. In the long term, such analytical tools could guide farmers toward practices that better respect animal welfare, thereby contributing to more sustainable and ethical farming.

Keywords : Animal welfare, Computer vision, Deep learning, Dairy cows, Detection, Tracking, Social network analysis

INTRODUCTION

L'élevage et la production agricole correspondent aux secteurs les plus importants sur un plan économique relatif à la société et ayant connu une croissance des plus spectaculaires depuis ces dernières décennies. D'après le Gouvernement du Canada, en 2023 seulement, le secteur agroalimentaire et agricole représentait près de 7% du Produit Intérieur Brut, soit 150 milliards de dollars générés et employant environ 2,3 millions de personnes (AAC, 2024). Du fait de son importance capitale dans l'économie et l'alimentation, il est nécessaire de pouvoir améliorer et faciliter le travail des agriculteurs et des éleveurs tout en étant responsables et soucieux des animaux et de l'environnement.

Nous nous intéressons de manière plus précise aux vaches et à la production laitière. En raison de cette dernière, de nombreux scientifiques se sont penchés sur les données liées à l'industrie laitière, tant pour augmenter le rendement laitier (Naghashi *et al.*, 2022), (Naghashi et Diallo, 2022), que pour étendre la longévité et plus généralement la qualité de vie des vaches (Dallago *et al.*, 2024). Ces études fournissent des informations cruciales sur le développement des individus au sein des troupeaux. Mais elles permettraient aussi d'avoir un impact plus significatif sur la prévention de certaines maladies comme la boiterie (Russello *et al.*, 2024), (Karoui *et al.*, 2021) ou la mammite (Tanyildizl et Yildirim, 2019), ou encore pour pouvoir suivre le cycle de gestation (Marques *et al.*, 2024) et l'activité journalière des bovins (Mar *et al.*, 2023).

En conséquence, le délaissement de techniques jugées comme invasives, coûteuses et nécessitant une main-d'œuvre plus importante au profit de techniques plus discrètes et faciles d'accès est préconisé. C'est dans ce cadre que s'inscrit cette recherche, dans le but d'améliorer le bien-être des vaches laitières, mais par la même occasion de rendre le travail des éleveurs et des spécialistes des sciences animales moins laborieux et plus accessible. Plus précisément, ce mémoire cherche à répondre à la question de recherche suivante : *Dans quelle mesure des données vidéo peuvent-elles être exploitées pour identifier automatiquement des variables comportementales mesurables, liées aux mouvements et aux interactions sociales des vaches, dans un contexte réel d'élevage ?*

Afin de répondre à cette question, les sous-objectifs suivants sont poursuivis :

- (i) Concevoir un algorithme de détection robuste permettant d'identifier les vaches dans des environnements d'élevage complexes ;
- (ii) Mettre en place un système de suivi multi-objet assurant une identité persistante des animaux au cours

du temps ;

(iii) Développer un ensemble de métriques quantitatives décrivant les déplacements, les proximités inter-individuelles et certaines interactions sociales ;

(iv) Évaluer la pertinence et les limites de ces métriques pour la qualification du bien-être et du comportement social des vaches.

Un autre aspect très exploré par les chercheurs en sciences animales est l'étude des comportements sociaux, que ce soit à travers la détection des émotions (Uddin *et al.*, 2023) ou par l'analyse des réseaux sociaux au sein d'un troupeau (Marina *et al.*, 2024).

Ainsi, les travaux présentés dans ce mémoire s'inscrivent dans le développement d'une méthodologie de vision par ordinateur visant à améliorer l'évaluation objective et non invasive du bien-être et de la qualité de vie des bovins. L'objectif principal est l'extraction automatique d'indicateurs comportementaux pertinents à partir de données vidéo, permettant d'analyser finement les mouvements, les interactions sociales et la dynamique spatiale des vaches.

Afin de répondre aux objectifs fixés, une méthodologie fondée sur la vision par ordinateur est mise en œuvre. Elle repose sur l'analyse de séquences vidéo acquises en milieu d'élevage et s'articule autour d'un pipeline en plusieurs étapes.

Dans un premier temps, un algorithme de détection d'objets est utilisé pour identifier automatiquement les vaches présentes dans chaque image. Ces détections servent ensuite d'entrée à un système de suivi multi-objets permettant d'attribuer une identité persistante à chaque individu et de reconstruire ses trajectoires spatio-temporelles. À partir de ces trajectoires, des métriques quantitatives liées aux déplacements, à l'activité et aux interactions entre individus sont extraites afin de caractériser la locomotion et le comportement social des vaches. L'ensemble de la méthodologie est évalué à l'aide de métriques standard de détection et de suivi, permettant d'apprécier la robustesse et la pertinence de l'approche proposée.

De ce fait, trois composantes algorithmiques complémentaires furent développées :

- L'algorithme 1 correspond à celui pour la détection ;
- L'algorithme 2 décrit le système de suivi utilisé ;
- L'algorithme 3 présente la génération des différentes métriques quantitatives du bien-être.

Ces algorithmes constituent les outils nécessaires à la construction d'un pipeline cohérent dont la véritable contribution réside dans les indicateurs comportementaux produits et dans la capacité à observer de manière continue et automatisée le comportement individuel et social des vaches.

Les métriques développées permettent notamment d'évaluer les déplacements des bovins, les proximités inter-individuelles et certaines formes d'interactions sociales, offrant ainsi de nouvelles perspectives pour l'analyse du bien-être social et comportemental en élevage laitier. Ce travail vise à poser les bases méthodologiques pour de futures études en sciences animales, en fournissant des outils reproductibles et exploitables pour mieux comprendre les besoins sociaux et comportementaux des bovins.

Le présent mémoire se divise en cinq chapitres distincts :

- Le **chapitre 1** se concentre sur la définition des différents thèmes abordés dans cette recherche, à savoir le bien-être animal, l'élevage de précision et la vision par ordinateur.
- Le **chapitre 2** définit le problème à résoudre et établit les limitations de notre recherche à travers la revue des articles concernant notre sujet et pose la problématique au centre de notre étude.
- Le **chapitre 3** révèle la méthodologie proposée et introduit les approches expérimentales empruntées.
- Le **chapitre 4** concerne la présentation des résultats obtenus.
- Le **chapitre 5** correspond à la discussion et à la conclusion. Il passera en revue les résultats obtenus et nous pourrons ainsi déterminer les performances de notre modèle pour les tâches désignées.

CHAPITRE 1

CONTEXTE DE L'ÉTUDE

Dans ce premier chapitre, nous définirons le bien-être animal, l'agriculture de haute précision et la vision par ordinateur. Nous expliquerons certaines applications de la vision par ordinateur. Puis, nous ferons le lien entre ces trois notions avec notre recherche, notamment grâce à la description des données utilisées lors des expériences.

1.1 Le bien-être animal

Le bien-être animal est une notion clé du secteur de l'élevage (Saeed *et al.*, 2023). C'est un aspect important de la durabilité et du maintien de la production, aussi bien pour le public que pour les producteurs (Ducrot *et al.*, 2024). Il fait référence à l'état dans lequel se trouve l'animal, aussi bien sur sa santé physique que mentale. Le bien-être des vaches laitières est une préoccupation importante, car les vaches peuvent ressentir du stress, de la douleur et de l'inconfort à cause de diverses pratiques de gestion (Linstädt *et al.*, 2024). Ainsi, la production laitière est une industrie aux enjeux multiples. Ces 15 dernières années, au Canada, les normes et restrictions liées à l'aménagement et au bien-être des vaches ont pris une dimension plus importante. Notamment avec la mise en place du Conseil national sur la santé et le bien-être des animaux d'élevage en 2010 (Fraser *et al.*,). En effet, dans le but de rendre la vie des bovins plus agréable et, par la même occasion, de répondre à la pression des consommateurs, les producteurs laitiers ainsi que la communauté scientifique, notamment les éthologues, cherchent des innovations qui contribueraient à ce mouvement.

1.2 Precision Livestock Farming : L'utilisation de la vision par ordinateur dans l'élevage

Des techniques de vision par ordinateur ont vu le jour pour permettre aux producteurs laitiers d'obtenir des informations sur leurs troupeaux (McDonagh *et al.*, 2021), (Ozella *et al.*, 2024), et également pour pouvoir réduire le nombre de personnes et le temps alloué à certaines tâches comme la surveillance des bovins ou encore la détection de la boiterie chez les vaches (Kang *et al.*, 2021), (Russello *et al.*, 2024). Ces approches s'inscrivent dans le cadre de l'élevage de précision, dont l'objectif est d'optimiser la gestion des troupeaux par l'exploitation de technologies numériques et automatisées, capables d'extraire des informations quantitatives pertinentes à partir de données hétérogènes.

La croissance démographique, l'urbanisation et l'augmentation des revenus ont entraîné une hausse notable de la demande de produits laitiers dans le monde, en particulier dans les pays développés. Cependant, la nécessité d'augmenter le rendement des vaches laitières dans un contexte d'épuisement des ressources naturelles, comme l'eau, pose des défis écologiques (Gauly et Ammer, 2020) et économiques importants (Koutouzidou *et al.*, 2022). On assiste à une intensification de l'élevage avec des races spécialisées, un plus grand confinement des animaux dans des batteries d'élevage et des troupeaux plus grands avec des rendements animaux accrus, ce qui entraîne une diminution globale du nombre d'exploitations (Medeiros *et al.*, 2022). Dans ce cadre, la vision par ordinateur constitue un levier technologique majeur, en permettant l'extraction automatisée de descripteurs spatio-temporels, de trajectoires et de métriques comportementales, ouvrant la voie à une évaluation plus fine du bien-être animal et à une meilleure compréhension des dynamiques individuelles et collectives au sein des troupeaux.

Par conséquent, on attend désormais des producteurs laitiers qu'ils répondent en permanence à la demande de produits laitiers de haute qualité qui répondront aux attentes de la société en matière de durabilité environnementale, de bien-être animal et de prix abordables. La vision par ordinateur est également utilisée dans l'agriculture, comme pour la surveillance et le maintien des champs (Jacques *et al.*, 2023), avec notamment des techniques d'études du sol, de mesures d'humidité ou de composition des nutriments présents (Ghazal *et al.*, 2024). Ces applications illustrent le potentiel transversal de la vision par ordinateur pour l'extraction de métriques objectives, renforçant ainsi la pertinence de son utilisation dans le contexte de l'élevage laitier.

1.3 Définition de l'éthologie

L'éthologie, est une discipline fondamentale des sciences animales, qui se consacre à l'analyse comportementale des espèces (Sueur et Pelé, 2023). Cette science a connu une évolution remarquable, marquée par l'intégration d'innovations technologiques et par une transformation des approches relatives au bien-être animal. En permettant de décrypter la perception et les interactions des animaux avec leur environnement, l'étude comportementale constitue un enjeu majeur qui favorise l'émergence de pratiques conciliant performance productive et bien-être dans les systèmes d'élevage (Orihuela, 2021). Les éthologues s'appuient essentiellement sur l'analyse de données visuelles, notamment les enregistrements vidéo. Cette approche méthodologique contribue à élucider la complexité des sociétés animales, à identifier les modèles de communication interspécifiques et à évaluer les capacités cognitives de résolution de problèmes chez différentes

espèces. L'éthologie appliquée s'impose donc comme un instrument stratégique permettant d'identifier et de développer des indicateurs descriptifs du bien-être animal.

Un exemple d'une mesure pour quantifier le bien-être que l'on peut extraire à partir des données est la vitesse de la vache. On peut déterminer à quelle vitesse la vache se déplace le long d'un chemin pré-déterminé. Cette mesure nous fournirait une information utile et significative sur l'activité générale et le niveau de confort de l'animal. En effet, une vache en bonne santé et à l'aise dans son environnement aura tendance à se déplacer régulièrement et avec fluidité, tandis qu'une vache stressée, malade ou limitée par des douleurs pourra présenter des déplacements plus lents, saccadés ou réduits (Linstädt *et al.*, 2024).



Figure 1.1 – Image montrant une vache atteinte de boiterie (Price, 2019)

Dans la figure 1.1, la vache présentée est atteinte de boiterie au niveau de sa patte arrière droite. Son allure et sa vitesse seront faibles et ralenties. Ceci est un exemple d'altération locomotrice observable chez les bovins (Higaki *et al.*, 2024), pouvant être détectée par les mesures de vitesse, permettant ainsi d'identifier précocement des troubles de santé et d'optimiser le bien-être animal au sein du troupeau.

Ainsi, l'analyse de la vitesse, combinée à d'autres paramètres tels que la distance parcourue, l'accélération ou encore la distance entre deux vaches, permettrait de dresser un profil comportemental et d'identifier rapidement des anomalies indiquant un problème potentiel de bien-être. Cette approche quantitative offre également la possibilité de suivre l'évolution du comportement des vaches au fil du temps et d'évaluer l'impact des changements dans leur environnement ou dans les pratiques de gestion.

Ce projet de recherche consiste à utiliser clairement les techniques de vision par ordinateur pour pouvoir détecter et suivre des vaches laitières, en vue d'améliorer leur bien-être. Le but étant d'obtenir le plus d'informations sur les vaches de notre troupeau en minimisant l'intervention humaine et l'utilisation de

matériel à des fins d'identification ou de détection des bovins.

1.4 Définition de la vision par ordinateur

La vision par ordinateur (Computer Vision en anglais ou CV) est un sous-ensemble de l'intelligence artificielle qui a pour objectif l'utilisation des données médias telles que des images ou des vidéos dans le but de pouvoir reconnaître et identifier des motifs contenus dans les données visuelles. Pour ainsi pouvoir répliquer la capacité visuelle de l'œil humain (Rasche, 2019).

Cependant, lorsqu'elle est appliquée à l'élevage, elle dépasse la simple interprétation d'images et devient un outil essentiel pour l'analyse du bien-être animal. Grâce à l'association avec l'apprentissage profond, elle permet de détecter, suivre et reconnaître de manière automatisée les vaches au sein d'un troupeau, afin de capturer des métriques comportementales clés telles que la locomotion, la posture, l'alimentation ou le repos. Ces indicateurs sont cruciaux pour l'évaluation de la santé et la détection précoce de troubles, comme la boiterie, qui se traduit par une modification mesurable de la vitesse, de la démarche et de l'allure.

Les techniques de vision par ordinateur mobilisées incluent la détection d'objets pour identifier les animaux, la segmentation pour analyser la morphologie et la posture, ainsi que le suivi multi-objets pour suivre leurs déplacements dans le temps. L'intégration de l'apprentissage profond (Chai *et al.*, 2021), notamment les réseaux de neurones convolutifs (CNN) pour l'extraction de caractéristiques visuelles et les architectures séquentielles (RNN, LSTM, Transformers) pour la dynamique temporelle, permet une analyse fine et robuste des comportements. Ces approches automatisées contribuent ainsi à transformer les données visuelles brutes en indicateurs quantitatifs et objectifs du bien-être animal, ouvrant la voie à une gestion plus intelligente et durable des élevages.

L'utilisation de l'**apprentissage machine** (Khan et Al-Habsi, 2020), permet d'améliorer significativement la capacité des systèmes à interpréter et à comprendre des données visuelles. Lorsqu'ils sont associés, ces deux domaines permettent aux ordinateurs d'avoir de meilleures aptitudes pour l'interprétation et la prédiction des données. Par exemple, la vision par ordinateur à elle seule peut interpréter et extraire de manière indépendante des informations à partir de la vidéo, l'apprentissage automatique ajoute une fonction prédictive aux données traitées. Ils permettent de résoudre des problèmes plus complexes, notamment dans l'extraction et le traitement de caractéristiques dans la vision par ordinateur. Les stratégies d'apprentissage automatique couramment employées en vision par ordinateur comprennent l'apprentissage super-

visé, non supervisé et semi-supervisé. Les algorithmes les plus utilisés sont les réseaux de neurones, le clustering k-means et les machines à vecteurs de support (SVM). Plus précisément, les SVM constituent un sous-domaine de l'apprentissage automatique supervisé, souvent utilisés dans les tâches de classification. Les réseaux de neurones, en particulier les réseaux de neurones convolutifs (CNN), sont largement utilisés pour la reconnaissance et la classification d'images. En résumé, l'apprentissage automatique fournit la puissance analytique et prédictive qui transforme les données visuelles brutes en informations significatives, rendant les systèmes de vision par ordinateur plus intelligents, adaptables et capables de relever un large éventail de défis du monde réel.

La vision par ordinateur permet ainsi de réaliser de nombreuses tâches comme :

- la **segmentation** qui correspond à la division d'objets au sein d'images ou de vidéos (Shreya M. Shelke *et al.*, 2023) ;
- la **reconnaissance d'objet**, qui est un terme général pour décrire la détection, la classification et la localisation d'objets dans une image donnée (Rasche, 2019) ;
- le **tracking** ou le **suivi d'objet** correspond au retracement précis d'un ou plusieurs objets dans une scène donnée (Rasche, 2019) ;
- ou encore dans la **reconnaissance de motifs** qui se concentre sur la reconnaissance d'objets en transformant les images pour obtenir une meilleure qualité et permettre une bonne interprétation. (Shreya M. Shelke *et al.*, 2023).

1.4.1 Les approches d'apprentissage machine pour le tracking

Le suivi d'objets constitue l'un des défis majeurs de la vision par ordinateur appliquée au bien-être animal, car il nécessite non seulement la détection initiale des individus mais aussi la conservation cohérente de leur identité au fil du temps, malgré les occlusions ou les interactions sociales. Les approches modernes qui reposent sur l'apprentissage machine, combinent généralement des détecteurs d'objets profonds tels que YOLO ou Faster R-CNN avec des modules de suivi multi-objets comme DeepSORT ou StrongSORT. Ces modèles exploitent des paramètres variés tels que le seuil de confiance de détection, l'Intersection over Union (IoU) pour l'association des boîtes, ou encore des embeddings visuels issus de réseaux de ré-identification pour distinguer des individus morphologiquement proches.

L'entraînement et l'optimisation de ces modèles de suivi d'objets reposent sur des hyperparamètres clés.

- L'**optimiseur Adam** (pour Adaptive Moment Estimation en anglais) est utilisé, car il combine les avan-

tages de la descente de gradient avec des ajustements adaptatifs de la vitesse d'apprentissage pour chaque paramètre, ce qui accélère et stabilise la convergence.

- Une **epoch** correspond à un passage complet de l'algorithme d'apprentissage sur l'ensemble des données d'entraînement, c'est-à-dire une itération.
- Le **batch size** désigne le nombre d'exemples traités simultanément avant la mise à jour des paramètres du modèle : un batch de grande taille stabilise l'apprentissage mais demande plus de mémoire, tandis qu'un batch réduit favorise la généralisation au prix d'une convergence plus lente.
- Enfin, le **taux d'apprentissage** (learning rate en anglais) contrôle l'ampleur des mises à jour des poids du réseau : un réglage trop élevé peut empêcher la convergence, tandis qu'un taux trop faible ralentit fortement l'entraînement.

L'ajustement (fine-tuning en anglais) de ces hyperparamètres, ainsi que l'adaptation des modèles préentraînés aux données spécifiques, sont des étapes cruciales pour améliorer la robustesse et la précision du suivi. Cette capacité d'adaptation par transfert d'apprentissage et optimisation paramétrique confère aux approches d'apprentissage machine une flexibilité essentielle pour répondre aux contraintes variées des environnements d'élevage réels.

La vision par ordinateur est un domaine en plein essor, que l'on retrouve dans de plus en plus de secteurs (Cernadas, 2024). On peut notamment citer l'**industrie automobile** avec la recherche et le développement de véhicules autonomes (Kanchana *et al.*, 2021), la **robotique** pour la perception de l'environnement et de la détection des objets par les robots (Shi *et al.*, 2025)), la **médecine** et la **santé** pour l'amélioration du traitement des patients (Javaid *et al.*, 2024) ou encore, comme dans notre cas, l'**industrie agricole** (Ghazal *et al.*, 2024) et de l'**élevage** (Petrovic *et al.*, 2023).

1.5 Description des types de données rencontrés en éthologie

Les éthologues s'appuient sur différentes catégories de données pour mener leurs recherches, allant de l'observation brute à la structuration des informations. Les données multimédias constituent la base principale, exploitées notamment via l'outil Observer (Zimmerman *et al.*, 2008), qui permet la création de séries temporelles retraçant l'évolution comportementale des vaches. Ces observations sont ensuite annotées et organisées en bases de données structurées, au sein desquelles les éthogrammes définissent un répertoire précis de comportements. L'intégration d'ontologies offre par ailleurs un cadre conceptuel permettant de relier chaque comportement à une définition claire et à ses relations avec d'autres comportements, renfor-

çant la cohérence des analyses.

Dans ce contexte, l'acquisition et l'organisation des données s'avèrent cruciales pour la réussite des travaux menés. L'utilisation de la vision par ordinateur nous oriente vers l'exploitation de contenus visuels, principalement les vidéos des animaux, qui garantissent une observation dynamique et riche. La réduction des occlusions y joue un rôle essentiel afin de limiter les erreurs de détection et de suivi. Bien que plusieurs bases de données portant sur les vaches frisonnes existent déjà, nous avons choisi de constituer notre propre corpus expérimental, constitué de vidéos capturées directement auprès de notre troupeau. Ainsi, les données mobilisées se déclinent en plusieurs catégories :

- **Contenus visuels :**
 - Séquences vidéo pour analyser les déplacements, les interactions sociales et les comportements en mouvement.
 - Images pour l'examen morphologique et la vérification ponctuelle de comportements spécifiques.
- **Données temporelles (The Observer) :**
 - Informations chronologiques documentant la fréquence, la durée et l'enchaînement des comportements.
 - Modélisation des transitions comportementales au fil du temps (transition position allongée et debout par exemple).
- **Annotations et base de données d'observations :**
 - Marquage manuel ou partiellement automatisé des comportements.
 - Structuration en bases annotées facilitant les comparaisons inter-individuelles et inter-conditions.
- **Éthogrammes :**
 - Répertoire organisé des comportements identifiés (repos, déplacement, prise alimentaire, interactions sociales, boiterie, etc.).
 - Standard commun pour uniformiser les observations et optimiser les traitements statistiques.
- **Ontologies comportementales :**
 - Normalisation des définitions comportementales et de leurs relations structurelles.
 - Modèle conceptuel intégrant l'ensemble des données (annotations, éthogrammes, séries temporelles) pour assurer leur cohérence sémantique.

Dans cette section, nous avons défini les notions du bien-être, de la vision par ordinateur et de l'élevage de précision. Nous avons établi le lien entre ces deux concepts, sur lequel se base notre recherche, c'est-à-dire

l'utilisation de la vision par ordinateur pour permettre la détection et la localisation des bovins. Ceci nous permettra d'avoir des informations sur l'identité et l'activité des vaches. Nous avons également fait une brève description des données requises pour notre étude. Le chapitre suivant posera les limites du projet en définissant la problématique et permettra aussi d'avoir une idée des différents travaux et approches qui furent explorés.

CHAPITRE 2

REVUE DE LA LITTÉRATURE ET DÉFINITION DE LA PROBLÉMATIQUE

Le second chapitre de ce mémoire présente la problématique abordée dans ce projet, mais fait également un survol de la littérature concernant les travaux réalisés dans ce contexte d'étude.

2.1 Énoncé de la problématique

Depuis plusieurs années, les chercheurs en sciences animales de la Chaire Well-E collectent un volume important de données vidéos documentant le comportement des vaches laitières. Ces données, acquises à l'aide de caméras fixes installées en milieu d'élevage, constituent la principale source d'information pour l'analyse comportementale des bovins. En effet, l'analyse du comportement des bovins repose sur une observation systématique effectuée à l'aide de caméras qui collectent les informations requises pour l'étude. La durée de ces observations varie considérablement : certaines expériences pouvant se prolonger pendant des jours, des semaines ou même plusieurs mois. Ces observations sont très souvent réalisées sur un grand nombre de sujets. Cette configuration expérimentale engendre une quantité considérable de données visuelles, rendant leur analyse manuelle particulièrement complexe. Ces données vidéo sont exploitées par les éthologues afin d'identifier, de quantifier et de catégoriser les comportements observés. Ils répertorient tous ces comportements dans un éthogramme qui consiste en une table où l'on retrouve tous les comportements et les activités observées chez un animal. Ce travail permet de développer des méthodes visant à améliorer leur bien-être. Toutefois, cette analyse repose encore largement sur un travail manuel, chronophage et fastidieux. Dans le cadre spécifique de l'analyse de la locomotion, l'évaluation du bien-être et de l'état de santé des vaches nécessite l'extraction de plusieurs métriques quantitatives issues de leurs déplacements. Parmi ces indicateurs figurent notamment la vitesse de déplacement, les variations d'accélération, les distances parcourues, ainsi que des mesures spatio-temporelles dérivées des trajectoires individuelles. L'extraction automatique de telles métriques à partir de données vidéo constitue dès lors un enjeu central.

Dans ce contexte, la problématique de ce mémoire peut être formulée comme suit : **Comment exploiter des séquences vidéo de vaches laitières pour extraire automatiquement, de manière non invasive, des métriques de locomotion et de mouvement pertinentes pour l'évaluation objective du bien-être animal ?**

Le recours à des techniques de vision par ordinateur apparaît comme une solution prometteuse, offrant la possibilité de produire des mesures continues et reproductibles, capables de détecter précocement des

anomalies de locomotion, telles que la boiterie, ou d'autres troubles affectant la santé et le bien-être des animaux.

2.2 État de l'art

De nos jours, un troupeau de vaches se compte en centaines voire en milliers. De ce fait, il est important d'avoir des informations régulières sur toutes les vaches pour pouvoir suivre leur santé, l'avancement de leur gestation ou d'autres paramètres qui jouent sur leur bien-être. L'utilisation de puces RFID (Radio Fréquence Identification), d'étiquettes sur les oreilles (Stankovski *et al.*, 2012) de GPS, ou encore de colliers d'identification, sont des techniques, bien qu'utiles, mais très coûteuses, du fait de la nécessité des équipements et invasives pour les animaux. Ainsi, l'utilisation de la vision par ordinateur et du Deep Learning (DL) permettrait de détecter les vaches, les identifier et de pouvoir suivre leurs mouvements au sein du troupeau ou lorsqu'elles sont seules (Tiwari *et al.*, 2021). Une distinction entre la détection et l'identification est nécessaire.

De nombreux jeux de données sur les vaches frisonnes existent à ce jour comme **OpenCows2020** mis en place par (Andrew *et al.*, 2021) et qui se composent d'une multitude d'images d'extérieur et d'intérieur, capturées respectivement par un drone et des caméras fixées. Une partie est alors utilisée pour la détection des vaches et l'autre pour l'identification. On note également celui élaboré par (Lennox *et al.*, 2022). Le jeu de données comprend 3 054 identités uniquement pour l'entraînement et la validation et plus de 3 700 autres identités uniques pour le test, obtenu sur quatre fermes différentes. Ou encore, MultiCamCows2024 (Yu *et al.*, 2025), qui est l'un des plus larges jeux de données spécifiques aux vaches frisonnes établis, avec 101 329 images provenant de 90 vaches.

En vision par ordinateur, le processus d'extraction d'informations s'articule autour de trois phases successives : la détection de mouvement (ou motion detection en anglais), la ré-identification des objets, et le suivi multi-objets. Notre revue de littérature s'organise en suivant cette séquence méthodologique.

2.2.1 La détection d'objet

En 2023, (Naik *et al.*, 2023) et (Waldmann *et al.*, 2023) se sont focalisés sur l'estimation de la posture et le suivi sur des pigeons. D'autres modèles, basés sur différents animaux, existent. On peut ainsi citer l'étude réalisée par (Wang *et al.*, 2022) sur les cochons. Leur modèle a obtenu des résultats de suivi de 91,41%

pour le MOTA et de 88,33% pour l'IDF1. Les auteurs de (Tan *et al.*, 2022) travaillent avec différentes espèces comme des chats léopards, des vaches, des porte-musc (cerfs) ou encore des renards rouges. Pour pouvoir réaliser une détection à haute performance de ces animaux et ce, à différents instants de la journée. De plus, comme mentionné par (Bonneau *et al.*, 2020), le suivi d'animaux en extérieur est plus complexe qu'à l'intérieur et soulève des challenges comme la baisse de la sensibilité des méthodes de suivi, les conditions d'éclairage aléatoires, l'angle des caméras et leurs perspectives ou encore la complexité de l'arrière-plan. Ces facteurs ne sont pas négligeables et pourraient affecter les résultats de la détection et du suivi des vaches. Pour limiter ces contraintes liées aux milieux plus complexes, des outils comme Argos (Ray et Stopfer, 2022) ont vu le jour.

(Hao *et al.*, 2023) proposent un modèle de détection basé sur YOLOv5 combiné à une stratégie d'EMA (Exponential Moving Average en anglais), permettant l'identification de trois parties anatomiques des vaches : la tête, le corps et les membres. Leur approche obtient des performances supérieures à celles d'autres versions de YOLO (v3, v4 et YOLOv5 sans EMA), ainsi qu'à des modèles de référence tels que SSD et Faster R-CNN. Les résultats rapportés montrent des valeurs de précision, de rappel, de score F1 et de mAP atteignant respectivement 94,8%, 90,3%, 92,5% et 95,1%.

L'augmentation des données est une étape cruciale lors de la constitution du jeu de données et pour la détection comme montré par (Li *et al.*, 2024). Ils ont ainsi appliqué huit techniques d'augmentation sur leurs échantillons, comme notamment des rotations, des flips, des variations de la clarté et du bruit. Ce qui a permis d'agrandir la taille du jeu de données par un facteur huit.

2.2.1.1 Définition de la détection

La détection est un travail très important qui utilise les réseaux neurones (YOLO, SSD ou encore R-CNN) dans le but de localiser/repérer et de classer un objet sur une image ou dans une vidéo. En vision par ordinateur, c'est une tâche capitale que l'on va retrouver dans une multitude d'applications comme dans le domaine médical, le domaine des véhicules autonomes ou encore le domaine de la surveillance publique. Il existe deux approches pour faire de la détection d'objet : l'apprentissage machine (Machine Learning) et l'apprentissage profond (Deep Learning). Le choix de la méthode la plus appropriée dépend de l'application et du problème que l'on cherche à résoudre, mais aussi des ressources dont nous disposons comme les GPU et les données (images entraînées annotées).

Ainsi, l'utilisation d'une approche basée sur l'apprentissage profond tend à avoir un meilleur résultat en présence d'un important jeu de données (images) et le nombre de GPUs, quant à lui, diminue en fonction du temps nécessaire pour entraîner le modèle. Tandis que pour l'approche basée sur l'apprentissage machine, la sélection des caractéristiques (feature selection) d'un objet se fera manuellement comparée à l'apprentissage profond. Parmi les techniques utilisées, on peut citer les SVMs (Support Vector Machine en anglais) ou l'algorithme Viola-Jones pour la détection des visages humains et de la région haute du corps.

Les réseaux de type CNN, et plus particulièrement les approches R-CNN, appartiennent à la catégorie des méthodes de détection à deux niveaux, privilégiant généralement une précision élevée. À l'inverse, les méthodes à un seul niveau, telles que YOLO ou SSD, sont conçues pour optimiser la vitesse d'inférence, c'est-à-dire le temps nécessaire au modèle pour traiter une entrée. Une vitesse d'inférence plus élevée permet ainsi un traitement plus rapide des données, ce qui constitue un avantage important pour les applications en temps réel. Notre travail se base sur l'utilisation de l'approche par apprentissage machine, plus précisément en utilisant YOLO. Bien qu'il s'agisse d'un CNN, YOLO est un modèle à un niveau.

2.2.1.2 L'utilisation de l'outil YOLO pour la détection

L'outil YOLO ("You Only Look Once" en anglais) est un système de détection d'objet en temps réel, où la détection est traitée comme un problème de régression linéaire et non comme une tâche de classification (Redmon *et al.*, 2016).




Figure 2.1 – Schéma illustrant l'architecture du modèle (Redmon *et al.*, 2016)

Son architecture, comme montrée sur la Figure 2.1, est la suivante : 24 couches de convolution, quatre

couches de "pooling" maximum et deux couches complètement connectées. L'image passée en entrée est d'abord redimensionnée avant d'être passée au réseau à convolution. La fonction d'activation utilisée ici est **ReLU**, sauf pour la dernière couche qui utilise une fonction d'activation linéaire. Des techniques comme le "dropout" ou la normalisation de lot y sont directement intégrées et permettent de régulariser le modèle et "l'overfitting". La détection d'objets permise par YOLO est rapide et précise.

Cependant, elle comporte des limites, notamment au niveau spatial et sur la prédiction des boîtes d'encerclement, car chaque cellule ne peut prédire que deux boîtes à la fois et ne peut contenir qu'une seule classe. Il y a donc une limitation du nombre de prédictions d'objets à proximité. Et le modèle reconnaît aussi difficilement les petits objets.

YOLO reste quand même un outil performant et dont l'application est retrouvée dans divers domaines tels que l'agriculture, la santé ou même la sécurité routière (Ali et Zhang, 2024). Ainsi, on présente en entrée les images annotées et augmentées, s'il y a lieu, à l'algorithme YOLO et l'entraînement de l'algorithme va, quant à lui, permettre d'apprendre à reconnaître l'objet que l'on cherche à détecter. On emploie ensuite une validation croisée pour s'assurer que notre modèle fonctionne comme il se doit.




Figure 2.2 – L'architecture de YOLOv5 (Liu *et al.*, 2021)

Version V5 : La version 5 de YOLO a vu le jour en juin 2020. Elle possède une architecture qui se base sur le réseau de neurones à convolution dit CSPDarknet53 tout comme son prédécesseur (YOLOv4). Le modèle comprend 5 tailles : nano, small, medium, large et extra-large. L'une des améliorations majeures par rapport aux autres versions est l'ajout d'une couche de focus au profit des trois premières couches. Cette nouveauté permet, dans un premier temps, de réduire le nombre de couches et le nombre de paramètres, mais aussi d'augmenter la vitesse d'entraînement sans impacter la mAP. Comme montré dans la Figure 2.2, la version v5 de YOLO se compose de 3 parties, avec, en premier lieu, le backbone CSPDarknet, qui permettra d'effectuer l'extraction des caractéristiques. Ensuite, le neck est constitué par un PANet (Path Aggregation Network en anglais), qui, en utilisant les résultats de la couche précédente, réalisera la fusion de ces mêmes caractéristiques. Et le Head qui comprend les couches de YOLO (Liu *et al.*, 2021).

Ainsi, les données en entrée correspondent aux images, qui, une fois passées par les trois couches du modèle de détection YOLOv5, vont nous donner en sortie les vaches détectées entourées d'une boîte d'encerclement, mais aussi d'un score de confiance avec lequel la vache est détectée. L'entraînement de l'algorithme s'est fait avec deux méthodes d'optimisation : **Adam** et **SGD** (pour Stochastic Gradient Descent). L'optimiseur **Adam** dépend moins du taux d'apprentissage et ainsi produit des estimations de gradient plus précises, tandis que l'optimiseur **SGD** a une capacité de généralisation plus importante et possède aussi une rapidité et une efficacité computationnelle supérieures à celles de l'optimiseur **Adam**.

L'ajustement du modèle est une étape cruciale, comme le montre (Zheng et Qin, 2023), pour accélérer la convergence. Ainsi, les paramètres utilisés pour l'entraînement de la détection sont présentés sur le Tableau 2.1 :

Paramètre	Valeur
Number of epoch	250
Batch size	16
Image size	640x640
Initial learning rate	0.01
Final learning rate	0.001
Weight decay	0.0005
Momentum	0.937

Table 2.1 – Les paramètres d'entraînement utilisés

Le nombre d'épochs correspond au nombre d'itérations d'entraînement. Le *batch size* correspond à la taille de l'échantillon, dans notre cas le nombre d'images traitées simultanément. La dimension de l'image est définie par le paramètre *image size*, est de 640x640 pixels (Hauteur x Largeur). Ce redimensionnement permet au modèle d'être plus rapide tout en utilisant moins de mémoire. On note que deux taux d'apprentissage sont possibles. Le taux d'apprentissage initial (lr0) est un hyperparamètre important qui s'assure de la vitesse et de la stabilité de l'entraînement en contrôlant la taille du pas au début. Et le taux d'apprentissage final (lrf) détermine le taux d'apprentissage minimum à la fin de notre entraînement.

Pour ce qui est des métriques d'évaluation pour la détection, comme présenté par (Zheng et Qin, 2023) et (Higaki *et al.*, 2024), on a l'exactitude, la précision, le rappel, le score F1 et le mAP. Ils permettent d'évaluer à quel point le modèle reconnaît les caractéristiques d'une vache.

2.2.2 Comparaison entre Yolov5 et les versions plus récentes

Version	mAP (indicatif)	Vitesse / Latence	Complexité	Remarques principales
YOLOv5	28-50%	Rapide	Faible à modérée	Version stable, largement utilisée, écosystème mature
YOLOv7	51-53%	Très rapide	Modérée	Améliorations architecturales, meilleures performances sur COCO
YOLOv8	37-53%	Rapide	Modérée à élevée	Architecture moderne, tête décorrélée, meilleure précision globale

Table 2.2 – Comparaison entre YOLOv5 et des versions plus récentes

Dans le Tableau 2.2, on voit que bien que des versions plus récentes de YOLO (telles que YOLOv7 et YOLOv8) proposent des améliorations substantielles en précision et en efficacité sur certains jeux de données modernes, plusieurs raisons motivent le choix de YOLOv5 pour ce mémoire.

YOLOv5 est une version largement éprouvée dans la littérature et dans des projets appliqués, offrant une implémentation robuste et bien documentée. L'abondance de travaux antérieurs qui utilisent YOLOv5 facilite la comparaison des résultats et la reproductibilité scientifique.

YOLOv5 bénéficie d'un écosystème développé, avec de nombreux outils standardisés pour l'annotation, l'entraînement et l'évaluation des modèles. Ceci réduit les risques liés aux bugs d'implémentation et aux

incompatibilités, ce qui est particulièrement important dans un contexte de recherche appliquée où la reproductibilité est cruciale.

Les variantes de YOLOv5 (nano, small, medium, etc.) offrent une gamme de modèles bien calibrés pour différents niveaux de ressources matérielles (de machines locales à des serveurs GPU), ce qui permet une optimisation fine entre précision et rapidité selon les besoins de l'étude.

Dans le contexte de détection d'animaux dans des séquences vidéo d'élevage, les performances de YOLOv5 (en termes de précision et de vitesse d'inférence) sont jugées adéquates pour capturer les vaches dans différents environnements vidéo sans nécessiter d'architecture plus complexe qui pourrait augmenter les coûts de calcul ou compliquer l'intégration dans une chaîne de traitement automatisée. De plus, YOLOv5 est réputé pour sa rapidité d'inférence et sa robustesse, ce qui est un atout dans des pipelines temps réel ou quasi-temps réel (Ultralytics, 2025).

En résumé, alors que YOLOv7 et YOLOv8 introduisent des innovations architecturales et des gains mesurables en précision dans certains benchmarks, YOLOv5 reste un choix pertinent dans le cadre de ce mémoire en raison de sa stabilité, de son écosystème mature, de sa flexibilité et de sa compatibilité avec les contraintes pratiques de l'application envisagée. Ce choix est particulièrement justifié lorsque l'objectif est d'intégrer le modèle dans une chaîne de traitement reproductible, robuste et bien supportée, plutôt que d'exploiter à tout prix les dernières architectures expérimentales (Ultralytics, 2025).

2.2.3 La détection & le suivi d'objets

L'estimation de la posture est aussi une technique très répandue, qui consiste à l'utilisation de points clés positionnés sur le corps des animaux sur une image, dans le but de recueillir des informations sur sa posture. Dans certains cas, ces informations pourraient également permettre de réaliser la détection et le suivi des animaux, comme ainsi fait par (Graving *et al.*, 2019). DeepPoseKit permet, grâce à la localisation de ces points clés, de suivre les mouvements des mouches.

Les auteurs (Higaki *et al.*, 2024) utilisent la même technique cette fois sur des vaches. Ils établissent 25 points clés positionnés sur toutes les articulations de l'animal. Et ils parviennent à obtenir 17 variables de mobilité. Un exemple encore plus concret est celui de DeepLabCut par (Lauer *et al.*, 2022). Si des occlusions apparaissent et que le suivi est interrompu, l'algorithme permet de remettre ensemble les différents mor-

ceaux du suivi(ou tracklets) d'un même individu. Bien que ces travaux aient été principalement menés sur de petits mammifères (souris, marmosets) ou des poissons, les principes méthodologiques sous-jacents, fondés sur l'estimation de points clés et l'apprentissage de configurations articulaires, sont indépendants de l'espèce étudiée. Ainsi, sous réserve de données annotées de qualité et d'une adaptation aux contraintes spécifiques liées à la taille, aux occlusions et aux postures des animaux, ce type d'approche apparaît transposable à l'étude d'animaux de plus grande taille, tels que les bovins.

(Bewley *et al.*, 2016) montrent l'importance de la qualité de la détection pour obtenir de bonnes performances de suivi. Selon eux, un système de détection adapté pourrait augmenter les résultats de suivi de plus de 18,9%. Leur approche consiste en l'association d'un filtre Kalman et d'un algorithme hongrois, utilisés respectivement pour la prédiction du mouvement et l'association des données. Ils ont comparé différentes méthodes de détection avec SORT. Cependant, ils ne se concentrent que sur le suivi d'objets en temps réel et ainsi, de nombreux facteurs ne sont pas pris en compte, notamment les occlusions et la ré-identification des objets.

2.2.4 Le suivi d'objets multiples : Tracking

La version améliorée de SORT correspond à DeepSORT montrée dans (Wojke *et al.*, 2017). Les différences majeures sont au niveau de la métrique d'association, du traitement des occlusions et des métriques de performances. Ainsi, DeepSORT comprend une métrique d'association profonde qui permet, grâce à un CNN, de réduire les permutations d'identités et d'augmenter les performances de suivi en cas d'occlusions. Les limitations au niveau des occlusions sont contournées par la combinaison d'informations de mouvement et d'apparence pour pouvoir suivre et maintenir l'identité des objets obstrués sur de plus longues périodes de temps.

Et enfin, en 2022 (Du *et al.*, 2023) présente une version améliorée de DeepSORT avec StrongSORT. Ce modèle est structuré de manière similaire à DeepSort avec deux parties clés : le mouvement et l'apparence. Le modèle d'intégration utilisé ici permet de prendre en compte la re-identification des objets, c'est-à-dire qu'il permet de distinguer les différents objets en fonction de leur apparence. En ce qui concerne le traitement des occlusions, plusieurs techniques sont intégrées au modèle, comme par exemple le GSI (Gaussian-Smooth Interpolation), des techniques robustes d'association ou encore la réduction des faux négatifs. Ces améliorations renforcent les performances du modèle.

Une autre approche pour réaliser le suivi d'objets multiples est celle à travers le filtre Kalman présenté dans (Siriani *et al.*, 2022). Sur lequel se base SORT (Parmiggiani *et al.*, 2023) ou encore ByteTrack. Le filtre Kalman est une méthode probabiliste, qui va utiliser la position mesurée d'un objet pour estimer plus précisément la position de cet objet. Cependant, il est à relever qu'il ne permet pas d'obtenir de bonnes trajectoires sur des objets non linéaires (Bello *et al.*, 2021) .

2.2.4.1 Définition du Tracking

Le **suivi d'objet** ou **tracking** est une tâche d'apprentissage profond où l'algorithme utilise des résultats de détection obtenus au préalable pour pouvoir suivre les mouvements et la trajectoire de ces objets détectés, à travers différents angles de capture. En conséquence, le suivi d'objet ne peut pas être fait sans la détection d'objets. On distingue deux possibilités pour le suivi d'objet. Le suivi basé sur des **images** ou celui basé sur les **vidéos**.

Le premier suivi d'objet se fait sur une image figée en deux dimensions et le suivi est réalisé de manière continue au fur et à mesure que l'objet se déplace. Ainsi, cette méthode est très utile pour des jeux de données contenant des images très contrastées, asymétriques ou avec beaucoup de différences. Le second type, également le plus répandu, concerne le suivi en temps réel à partir de séquences vidéo. Cette approche consiste à estimer, pour chaque image successive, la position future des objets en s'appuyant sur les informations spatiales et temporelles extraites des images précédentes. On distingue par ailleurs le suivi d'un objet unique du suivi multi-objets, selon le nombre d'entités à analyser simultanément. (Du *et al.*, 2023).

Nous sommes intéressés par le suivi multiple d'objets, qui est plus adapté pour notre cas de figure. L'une des applications majeures du suivi est lors du suivi des personnes au sein d'environnements à très forte densité. De ce fait, il existe de nombreux jeux de données qui ont été développés dans le but de pouvoir réaliser le MOT dans un environnement peuplé. Mais on retrouve aussi des jeux de données spécifiques à certains animaux pour pouvoir suivre les mouvements de ces derniers dans des environnements parfois plus complexes.

Malgré tous ces avantages, nous nous heurtons toujours à deux problèmes considérables que sont l'occlusion et la permutation de l'identité. C'est pourquoi nous avons décidé d'utiliser l'algorithme de suivi StrongSORT, car il permet de minimiser au maximum ces occurrences.

2.2.4.2 L'utilisation de StrongSORT pour le Tracking

Il existe une multitude d'algorithmes pour le suivi de trajectoire. Cependant, comme mentionné ci-dessus, nous avons utilisé StrongSORT comme algorithme principal pour réaliser le MOT. Cet algorithme présente plusieurs avantages, notamment des performances améliorées en suivi multi-objets, StrongSORT constituant une version améliorée de DeepSORT intégrant des modules plus avancés pour l'extraction et l'intégration des représentations d'apparence (*embedding* en anglais). On a également l'intégration d'algorithmes dits de poids léger comme le GSI (Gaussian-Smoothed Interpolation) et le ALink (Appearance-Free Link model) qui permettent respectivement de résoudre le problème des détections manquantes et d'effectuer une association globale dans le MOT sans compter sur des informations d'apparence. Ou encore une meilleure vitesse et une amélioration de la précision. Avec une vitesse d'inférence allant de 1,7 à 7,1 ms par image sur le benchmark MOT17. Ainsi, tous ces nouveaux éléments permettent à StrongSORT de pouvoir adresser les problèmes liés au MOT, notamment les associations et les détections manquantes.

En dépit de ces nouvelles intégrations, l'algorithme possède encore des limitations et se heurte au même problème que ses prédécesseurs. On a donc une vitesse d'inférence qui est relativement faible, malgré le fait qu'elle soit améliorée. Concernant les mesures de performances, les valeurs de IDF1 et de HOTA sont satisfaisantes, tandis que celles de MOTA sont légèrement en baisse. Ceci est dû à la présence de trop de détections manquantes, qui sont elles-mêmes causées par un seuil élevé sur le score de détection. Et enfin, bien qu'il soit efficace pour la restauration des associations manquantes, l'algorithme ALink rencontre des problèmes de fausses associations. Et ainsi, il n'arrive pas à restituer les trajectoires d'identification en tracklets distincts.

Pour résoudre ce problème, nous avons intégré une étape de post-processing qui consiste en la restitution du trajet complet de l'objet par association bout à bout des tracklets.

La Figure 2.3 montre les différents composants de la structure de l'algorithme. Pour la détection, StrongSORT utilise **YOLOX-X** qui est beaucoup plus avancé comparé au détecteur R-CNN rapide utilisé par DeepSORT. Ce changement permet d'obtenir une meilleure précision et vitesse pour la détection d'objets qui s'avère être crucial pour un tracking efficace. L'extraction des caractéristiques plus discriminatives se fait grâce à **BoT**, qui va permettre de renforcer la qualité de correspondance entre les objets suivis et leurs tracklets. Pour réactualiser l'état des apparences, StrongSORT possède un **EMA** (Exponential Moving Average) qui va permettre de réduire le bruit et d'augmenter la précision globale du suivi d'objet. Ensuite, pour prendre




Figure 2.3 – Schéma représentant le framework de StrongSORT

en compte le mouvement des caméras, on a un **ECC** (Enhanced Correlation Coefficient). Cette technique aligne les images en estimant la rotation et la translation globale, ceci permet d'avoir un suivi maintenu avec précision sur toutes les images. On note également l'ajout d'un **filtre Kalman**, qui accorde l'amélioration de la précision du positionnement des objets suivis. Et enfin, au lieu du "matching" en cascade employé par DeepSORT, on a ici un **matching dit "vanille"** (*Vanilla Matching*) qui favorise une correspondance supérieure entre les objets détectés et leurs tracklets.

StrongSORT possède des paramètres qui vont permettre d'améliorer les performances du modèle. On distingue trois catégories de paramètres :

— Les paramètres de re-identification et d'association :

1. Le **modèle de re-identification** (RE-ID) utilisé, qui ici est *osnet_x1_0_msmt17.pt*, est un modèle pré-entraîné sur MSMT17 provenant du modèle zoo développé par (Zhou et al., 2021)
2. Pour contrôler la balance entre les mouvements et l'apparence, on initialise **MC_LAMBDA**. Plus la valeur est proche de 1 et plus on a de poids au mouvement. Et inversement, plus la valeur est proche de 0 et plus on a de poids au niveau de l'apparence (Re-ID). Une valeur 0.9 signifie que 90% du matching est basé sur le mouvement, 10% sur l'apparence.
3. La **MAX_DISTANCE** est la distance maximale entre deux vecteurs pour s'assurer qu'ils correspondent. Plus cette valeur est basse, plus le matching d'apparence est strict. Mais aussi, une réduction de cette valeur peut limiter les erreurs d'identification (ID switches).
4. La **distance maximale d'IoU** entre les boîtes pour une association. Si la boîte d'un suivi et d'une

détection a une IoU inférieur 0.7, elles ne seront pas associées. Cette distance permet de contrôler la sensibilité spatiale de l'appariement.

— Les paramètres de la gestion du tracking :

1. Le **MAX_AGE** est le nombre maximal de frames pendant lesquelles une piste peut exister sans nouvelle détection. Si un objet est temporairement masqué ou non détecté, il peut rester actif jusqu'au nombre défini de frames.
2. Le **N_INIT** correspond au nombre minimum de détections consécutives pour confirmer un nouveau track. Il permet d'éviter de confirmer des faux tracks (fausses détections ponctuelles). 3 signifie qu'un objet doit être détecté dans 3 frames consécutives pour être considéré comme réel.
3. Le **NN_BUDGET** est la taille maximale de la mémoire des caractéristiques d'apparence (Re-ID) pour chaque piste. Ainsi, 300 signifie qu'on garde les 300 derniers caractéristiques pour chaque objet.
4. Et on a également le **EMA_ALPHA** qui est le coefficient de lissage exponentiel pour mettre à jour l'embedding d'apparence d'un track. Une valeur de 0.8 signifie que les nouvelles observations ont un poids de 20%, les anciennes 80%. Ce paramètre stabilise l'apparence d'un objet en cas de légères variations visuelles.

— Les paramètres optionnels comme celui de la compensation du mouvement de la caméra. L'**ECC** quand il est activé permet de réduire l'impact du mouvement de la caméra et corrige les trajectoires des objets lors d'éventuels mouvements.

Ainsi, les paramètres de StrongSORT utilisés lors de notre suivi d'objet sont les présentés dans le Tableau 2.2.

Les métriques d'évaluation des performances pour le suivi d'objet sont diverses. Lors de leur étude sur la surveillance individuelle de vaches, (Fuentes *et al.*, 2023) évaluent les capacités du suivi grâce aux métriques suivantes : le HOTA (High-Order Tracking Accuracy), le MOTA (Exactitude pour le suivi d'objets), le MOTP (Précision pour le suivi d'objets) et l'IDF1 (identification). L'importance de pouvoir visualiser les mouvements des vaches est soulignée par (De Castro *et al.*, 2025) grâce au développement de leur interface AnimalMotionViz. Elle permet ainsi d'obtenir une carte de pression thermographique de l'emplacement des vaches sur une vidéo dans un espace pré-défini.

Paramètre	Valeur
REID_CKPT	osnet_x1_0_msmt17.pt
MC_LAMBDA	0.9
MAX_DIST	0.25
MAX_IOU_DISTANCE	0.7
MAX_AGE	120
N_INIT	3
NN_BUDGET	300
EMA_ALPHA	0.8
ECC	True

Table 2.3 – Les paramètres utilisés pour le suivi multiple d'objets par StrongSORT

2.2.5 La re-identification des objets perdus

Concernant la re-identification, l'usage du Deep Learning permet d'obtenir les meilleurs résultats en termes de précision. C'est un sujet fortement appliqué chez les humains et l'on possède à ce jour, diverses bases de données pour la re-identification chez les humains et les objets, telles que les jeux de données Model Zoo (Zhou *et al.*, 2021) ou de COCO (Bansal *et al.*, 2021). Un modèle efficace devrait extraire et apprendre les caractéristiques des objets.

Ainsi, de nombreuses études, comme celle réalisée dans (Andrew *et al.*, 2017) qui utilise les réseaux de neurones à convolution (CNN) couplés à un LSTM (Long Short-Term Memory) et obtiennent ainsi un LRCN (Long-term Recurrent Convolutional Network) pour pouvoir localiser et identifier de manière unique les vaches présentes au sein d'un troupeau. Les auteurs ont ainsi utilisé des vidéos capturées par des drones et donc des images qui montrent la face dorsale des animaux. Leur système est basé sur les motifs et patrons que l'on retrouve sur le pelage des animaux. En effet, cet attribut constitue une caractéristique biométrique unique chez chaque individu. Bien qu'ils aient obtenu une précision de 99,3% avec leurs données, une telle approche n'est réalisable qu'à condition que le pelage de tous les individus d'un troupeau soit différent. Cependant, le travail de (Myat Noe *et al.*, 2023) réalisés sur un troupeau de vaches entièrement noires, donc non différenciables de par leur pelage, montrent la nécessité d'une approche basée sur une autre caractéristique. Toujours dans la re-identification, (Schneider *et al.*, 2020), grâce au Deep Learning, font la comparaison de 2 réseaux de comparaison de similarité : Siamese et Triplet-Loss sur 5 espèces différentes.

La possibilité de mettre en place une base de données de l'identité de chaque vache est aussi envisagée dans certains travaux comme par exemple par (Chen *et al.*, 2022). Leur modèle de détection basé sur un Faster R-CNN et un NASNET-A, permet d'obtenir uniquement le visage des vaches, qui est ensuite passé au modèle de reconnaissance, ResNet-50, pour obtenir un jeu de données du visage des vaches. Une approche similaire est faite par (Bergamini *et al.*, 2019) avec une identification et une ré-identification des vaches à partir de leur visage. Dans ce même contexte s'inscrit l'utilisation de la queue de la vache comme base pour le suivi d'objet. Cette approche fut appliquée par (Huang *et al.*, 2023). La queue étant un indicateur majeur de la vache, elle apporte des informations supplémentaires sur l'identité de la vache, comme son comportement, ses activités ou bien sa localisation.

2.2.5.1 FastReID pour la re-identification

FastReID est un outil qui permet l'entraînement, l'évaluation et le "finetuning" d'un modèle de re-identification (He *et al.*, 2020). En se basant sur PyTorch, FastReID est flexible, rapide et permet d'obtenir une précision élevée. C'est le modèle le plus adapté à notre cas, car il est facile à ajuster sur les vaches, il possède plusieurs "backbones" comme ResNet50, ResNeXt ou encore Swin Transformer et il est déjà intégré dans certains systèmes de suivi d'objet comme StrongSORT.




Figure 2.4 – Schéma représentant le framework de FastReID (He *et al.*, 2020)

Son architecture est présentée par la Figure 2.4. Les images en entrée vont être redimensionnées et subir une étape d'augmentation de données. C'est l'étape de **pré-processing**. Ceci permettra de diversifier le jeu de données et d'augmenter la robustesse de la représentation des caractéristiques. On passe ensuite au **backbone**, comme ResNet. L'étape d'**agrégation** consiste à rassembler les différentes caractéristiques

généérées par le backbone en une caractéristique globale, et ce grâce à des méthodes de pooling. Les images arrivent enfin, au niveau du **Head**, où le vecteur global précédemment généré pourra être transformé. On distingue trois principales variantes de modules de sortie (head) : le **textbfhead** linéaire qui est le plus simple avec une seule couche de décision, le **textbfBN head** qui se compose d'une couche de "Batch Normalization" et d'une couche de décision, et enfin le **textbfhead** de réduction qui est le plus complexe. Il comprend une couche d'opération "**Conv(1x1)+BN+ReLU+Dropout**", une couche de réduction et la couche de décision. Une fois arrivé à cette étape finale, notre modèle sera prêt pour l'entraînement et la prise de décision (He *et al.*, 2020).

Ainsi, l'intégration de FastReID à notre système de suivi permettrait d'avoir de meilleures performances, notamment avec la conservation de l'identité des objets détectés le long de la vidéo. On veut s'assurer que les IDs prédits soient corrects et qu'ils soient bien maintenus. Ce qui permettrait également de réduire le nombre de ID switches.

2.3 Les défis de la détection et du suivi d'objet

Dans le MOT, les défis auxquels nous nous heurtons toujours sont l'occlusion des objets et la non-conservation de l'identité des objets. Dans les travaux comme celui présenté dans (Myat Noe *et al.*, 2023) où les vaches étant entièrement noires, des problèmes se posent notamment avec la différenciation des caractéristiques.

2.3.0.1 L'occlusion

Dans notre cas, l'**occlusion** a lieu lorsqu'une vache est partiellement ou entièrement obstruée, rendant ainsi sa détection et son suivi compliqués pour le système de suivi (Aye *et al.*, 2022). Il pose un défi significatif lors de la détection et du suivi des objets (Al Jaber *et al.*, 2023), (Ravoor et T.S.B., 2020), en interférant avec la précision et en augmentant de manière considérable le nombre de faux positifs, car les objets obstrués rajoutent une complexité dans la résolution de ces tâches. Ainsi, lorsqu'un objet mobile est obstrué, la discontinuité au niveau de la détection est due au fait que l'apparence de l'objet (ses caractéristiques) n'est plus reconnue par le modèle (Yazdi et Bouwmans, 2018).

Pour y remédier, de nombreux travaux furent menés. Ils se basent dans un premier temps sur les modèles d'apparence et de motion renforcés dans le but d'avoir un matching, c'est-à-dire une correspondance des caractéristiques, supérieure. Par exemple, StrongSORT incorpore dans son architecture un filtre Kalman

NSA qui est plus adapté aux détections de faible qualité et au bruit. Ces modifications permettent d'avoir de meilleures performances du suivi d'objet et une meilleure gestion des occlusions (Sim et Cho, 2025). (Hao *et al.*, 2025) intègre une amélioration du filtre Kalman et de la phase de détection mais aussi un module de rematching. Ce qui rend possible la diminution des occlusions et par la même occasion la réduction du nombre d'ID switch.

2.3.0.2 ID switch : La permutation de l'identité

La permutation de l'identité est une conséquence directe de l'occlusion. Il se produit lorsque le système de suivi assigne de manière incorrecte un nouveau numéro d'identité à un objet qui a déjà été tracké ou lorsqu'il réassigne un numéro d'identification déjà utilisé à un objet (Aye *et al.*, 2022). Étant donné que nous travaillons avec des vaches, qui sont des objets mobiles et parfois similaires, c'est un défi auquel nous nous attendons à faire face. Plus ce nombre est élevé et plus la qualité du suivi d'objet se verra amputée, notamment à travers les métriques comme le mAP ou le rank-1 qui sont directement impactées par celui-ci (Dubourvieux *et al.*, 2023).

Pour réduire le nombre de permutations de l'identité, les approches de base consistent à rendre plus robuste le jeu de données. Cependant, ces méthodes visent à réduire le nombre d'ID switches et non pas à les corriger lorsqu'elles apparaissent. Ainsi, (Huang *et al.*, 2025) propose la méthode '**unfctrack**' pour identifier et corriger les permutations. Il se compose de trois parties : l'IDSD (pour ID-switch Detection) qui se charge de détecter quand un ID switch se produit. L'IDSR (pour ID-switch Rectification) qui est le module qui s'occupe de restaurer les boîtes de détection correctes. Et enfin l'AMI (pour Ambiguous Match Improvement en anglais) qui aborde les problèmes au niveau du matching qui peuvent mener aux ID switches.

La Figure 2.5 illustre ces deux problèmes. Dans la première image, Figure 2.5(a), on voit une vache identifiée comme la vache numéro 1 détectée et trackée de manière correcte. Ensuite, dans la Figure 2.5(b), arrive la seconde vache juste derrière qui est obstruée par la vache numéro une donc n'est pas détectée. Cependant, l'occlusion affectant le suivi, l'identité de la vache numéro une n'est pas conservée. On a une permutation de l'identité de 1 à 3. Enfin arrive la troisième vache, dans la Figure 2.5(c). Mais cette fois-ci, la vache numéro une a retrouvé son numéro d'identification initial, la seconde vache étant toujours obstruée par la première, elle n'est pas détectée et la troisième vache est identifiée par le numéro trois.



Figure 2.5 – Images représentant les problèmes de l'occlusion et des ID switches

Une autre solution à ces deux problèmes serait un modèle de re-identification efficace. En effet, une bonne re-identification des objets détectés et suivis diminuerait l'occurrence des occlusions et des ID switches. Ou encore, l'intégration d'un algorithme de smoothing après l'exécution de ces tâches, qui se chargerait de réassigner les trajectoires perdues en les fusionnant avec celles ayant le plus grand taux de similitude. C'est-à-dire que lorsque l'on a des gaps dans la détection avec la disparition et la réapparition d'une vache avec un nouveau numéro d'identité, si la proximité spatiale entre la fin de l'ancienne trajectoire et le début de la nouvelle est petite dans la continuité des frames, on va assumer qu'il s'agit de la même vache. On va donc lui réassigner son ancien numéro d'identification.

Une architecture similaire à celle de (Lee *et al.*, 2023) ou encore (Myat Noe *et al.*, 2023) est notable pour de nombreux travaux. Elle se caractérise notamment par le modèle YOLOv5 pour la détection et par un algorithme de suivi de type SORT, DeepSORT, StrongSORT ou ByteTrack pour le MOT.

Et enfin, on note que l'apprentissage profond s'avère également utile pour d'autres applications en agriculture et en élevage de précision. Comme pour la détection de la boiterie (Karoui *et al.*, 2021) au sein d'un troupeau, pour l'amélioration du rendement des vaches (Frasco *et al.*, 2020) ou bien d'une manière plus

générale pour l'amélioration des conditions de vie et de la longévité des bovins (Dallago *et al.*, 2024).

Ainsi, dans ce chapitre, nous avons défini la problématique à laquelle nous allons essayer de répondre : *Est-il possible d'extraire automatiquement des variables utiles pour la qualification du bien-être à partir de nos données ?* Nous avons également présenté les principaux travaux réalisés sur le sujet de la détection, de la ré-identification et du suivi d'animaux. Pour réaliser ces tâches, nous allons respectivement utiliser YOLO pour la détection, FastReID pour la ré-identification et StrongSORT pour le suivi. Le chapitre suivant se concentrera sur l'élaboration de l'approche méthodologique et présentera le jeu de données utilisé pour réaliser les expériences.

CHAPITRE 3

MÉTHODOLOGIE ET EXPÉRIENCES

Ce chapitre a pour but de décrire la méthodologie, les données utilisées et la mise en place des expériences réalisées et du plan d'expérimentation.

3.1 Approche méthodologique

Notre but étant d'extraire des métriques relatives au bien-être animal et de faciliter le travail des éthologues, nous allons ainsi mettre en place un système d'apprentissage profond de détection et d'identification de vaches, mais également l'évaluation d'une nouvelle approche pour permettre le suivi des vaches à l'aide de la vision par ordinateur. Nous avons décidé d'ajouter une partie sur les mesures du suivi d'objet. En plus d'utiliser les mesures déjà existantes pour évaluer les performances du suivi, nous avons défini et établi de nouvelles mesures basées sur le suivi des vaches pour permettre d'avoir des informations supplémentaires sur les vaches et leurs activités.

Une fois les vidéos collectées, la première étape au niveau de la Figure 3.1 correspond au traitement de ces vidéos et images. On va donc réaliser une annotation manuelle de toutes les images, où on va entourer à l'aide d'une boîte d'encerclement toutes les vaches d'intérêt présentes sur une image. Lorsque cette étape est faite, on passe à celle d'augmentation des données, qui va nous permettre d'accroître et de diversifier la taille de notre jeu de données, mais par la même occasion d'améliorer notre précision. Pour ce faire, nous appliquons diverses transformations sur les images, telles que le recadrage, la rotation, les retournements, ainsi que des modifications de la saturation, de la luminosité ou de l'ajout de bruit. Ensuite, on réalise la détection des vaches d'intérêt grâce à la version v5 de YOLO, qui correspond à notre détecteur. Le modèle sera entraîné à identifier une vache avec une certaine précision. Le résultat obtenu sera utilisé pour faire le suivi des bovins avec StrongSORT, qui est un algorithme de suivi d'objet. Cet algorithme permet de faire l'extraction des caractéristiques ainsi que leur actualisation, aussi de réaliser un matching entre les frames pour s'assurer de la continuité dans le suivi des trajectoires. Le résultat final obtenu est une vidéo avec les vaches détectées et identifiées avec un numéro d'identification unique, plus un tracé qui représente le trajet parcouru par ces dernières.




Figure 3.1 – Schéma illustrant les différentes étapes et composantes du pipeline pour la réalisation du projet

3.2 Présentation du jeu de données

Les jeux de données exploités lors des expériences correspondent à des vidéos capturées sur le site de la ferme du campus McDonald's de l'université McGill. Les vidéos montrent des vaches à l'étable, en train de marcher le long d'un couloir ou en extérieur. (Sur certaines vidéos, les vaches interagissent avec des objets d'éveil ou non.) Ces vaches sont de la race Holstein ou vaches frisonnes. C'est l'une des races bovines les plus célèbres et répandues au monde. Elles sont principalement élevées pour la production de lait et peuvent ainsi produire jusqu'à 12 000 litres de lait par lactation, qui dure environ 350 jours au Québec et qui est alternée par une période dite sèche d'environ 64 jours durant laquelle la vache ne produit pas de lait (Dallago *et al.*, 2021).




Figure 3.2 – Schéma montrant l'emplacement des différentes caméras extérieures

Trois types de caméras sont utilisées en extérieur, comme montré dans la Figure 3.2, qui constituent une partie de la base de données et c'est à partir de ces trois angles de capture que notre modèle a été entraîné.

- Les caméras du couloir extérieur (OC pour « outdoor corridor ») qui capturent le trajet effectué par les vaches lorsqu'elles quittent la ferme pour se rendre jusqu'au premier enclos (Paddock 1).
- Les caméras des enclos (OP pour « outdoor paddock ») sont placées de façon à obtenir une vue d'ensemble de l'espace et on y voit les vaches par groupe de trois interagissant entre elles.
- Et enfin, les caméras placées au milieu des enclos (OE pour « outdoor enrichment »). Elles capturent l'enrichissement des vaches par l'interaction de ces dernières avec des objets comme, par exemple, des grattoirs.




Figure 3.3 – Images représentant les différentes caméras : (a) caméra du couloir (OC) ; (b) caméra placée au milieu de l'enclos (OE) ; (c) caméra des enclos (OP)




Figure 3.4 – Schéma montrant l'emplacement des différentes caméras intérieur

L'autre partie de la base de données est constituée des images provenant des vidéos des vaches à l'intérieur de la ferme, comme montré sur la Figure 3.4 ci-dessus. Là aussi, nous possédons trois angles de capture différents. Nous avons les caméras placées sur les tubes (IP pour « Inside Pipes ») où l'on pourra observer entre cinq et sept vaches simultanément. Elles sont généralement debout en train de ruminer, mais peuvent aussi être assises. Le second angle correspond aux caméras positionnées sur le mur (IW pour « Inside Wall »). Un angle qui va permettre d'avoir une précision sur une vache à la fois et de plus près. Et le dernier angle correspond aux caméras accrochées au plafond (IC pour « Inside Ceiling ») où l'on voit le couloir qui sépare les deux rangées d'étables. On y observe également les vaches qui empruntent le couloir une fois revenues de l'extérieur.



Figure 3.5 – Images représentant les différentes caméras d'intérieur : (a) caméra placée sur les tubes (IP) ; (b) caméra du mur (IW) ; (c) caméra du plafond (IC)

Avec ces différents angles et environnements, le jeu de données sera varié et prend en considération des éclairages et des backgrounds différents, mais aussi des positions des vaches diverses. De cette manière, le modèle proposé pourra reconnaître une vache sous différentes postures et dans différents lieux avec une meilleure exactitude.

3.3 Traitement des données

Une fois les différentes vidéos obtenues, nous avons réalisé une extraction d'images. À chaque 30 images, une image est enregistrée. Le but de cette étape est de réduire la quantité de données tout en conservant une séquence représentative d'images de la vidéo. On obtient donc un fichier avec 1115 images provenant de tous les angles de capture possibles. Soit 871 images provenant de l'intérieur de la ferme et 244 images prises en extérieur.

Suite à cette étape, nous procédons à l'annotation manuelle des images à partir de l'outil **Roboflow** (Roboflow,), qui est un logiciel gratuit pour la vision par ordinateur et qui permet aussi l'exportation du jeu de données une fois traité en un format adéquat. L'annotation se fait sur toutes les 1115 images et comporte un label unique, à savoir le corps de la vache (Ravoor et T.S.B., 2020). Une **boîte d'encerclement** ou «**bounding box**» spécifique au label entoure la partie identifiée chez l'animal. De ce fait, sur une image comprenant trois vaches, nous aurons distinctement trois boîtes d'encerclement pour le corps de chacune des trois vaches.

Une fois l'annotation faite, on applique de l'augmentation sur les nouvelles images. L'augmentation de données permet d'accroître de manière artificielle la quantité de données. Les données augmentées sont dé-

rivées des données originales auxquelles on ajoute des transformations mineures géométriques et de l'espace colorimétrique, qui vont permettre d'augmenter la taille et la diversité de l'ensemble d'apprentissage. En dépit de tous ces avantages, l'augmentation de données possède des limites et peut être à l'origine du renforcement de biais déjà présents au niveau des données originales. Parmi ces augmentations, on peut citer :

- Les rotations correspondent à des retournements d'images selon différents degrés (90° , 180°). C'est une transformation intéressante si le modèle s'attend à identifier des objets qui sont orientés selon un certain angle ;
- Les flips correspondent à un retournement total de l'image ;
- Les recadrements (crops) sont utilisés pour réduire la taille d'une image et permettre ainsi au modèle de mieux apprendre à reconnaître des objets qui ne sont présents que partiellement.
- La saturation se traduit par la vibrance ou l'intensité des couleurs présents dans une image. Une variation de la saturation peut s'avérer efficace si les conditions d'éclairage varient dans notre environnement d'intérêt.
- La variation de la clarté (brightness) joue sur la balance entre les zones lumineuses et sombres présentes sur l'image. Cela correspond à l'ajustement de la tonalité.
- Le bruit (random noise) correspond à l'ajout d'une couche de pixels (noir et blanc) sur l'image dans le but de la rendre plus floue. C'est une technique intéressante à utiliser si les images sont initialement un peu floues.

Au niveau de la figure 3.6, on peut apercevoir différentes augmentations appliquées sur les données brutes. L'éclat de la lumière est notamment modulé en faisant varier la luminosité, sur les dimensions des images en réalisant des crops et on applique des flips, ainsi que des rotations à les images annotées.




Figure 3.6 – Exemples d’augmentations appliquées aux images : (a) Brightness, (b) Crop, (c) Rotation, (d) Flip

Le tableau 3.1 présente les différentes augmentations appliquées sur les données originales et leurs valeurs.

Type d’augmentation	Valeur d’augmentation
Flip	Horizontal
Rotation	90°
Crop	Minimum Zoom, 24% Maximum Zoom
Saturation	Entre -25% et +25%
Brightness	Entre -22% et +22%
Noise	Jusqu’à 0.89% des pixels

Table 3.1 – Différentes augmentation de données appliquées sur notre jeu de données

On passe de 1115 initialement à 2676 images au total et les données sont ensuite réparties en 3 catégories, à savoir l’entraînement (2340 images – 87%), la validation (203 images – 8%), et le test (133 images – 5%). On obtient aussi un fichier intitulé « data.yaml » qui récapitule toutes les informations du jeu de données. Avec en premier lieu, le lien Roboflow vers notre jeu de données, le chemin d’accès des trois fichiers mentionnés ci-dessus. Et enfin, on a le nombre de classes et les labels utilisés pour décrire les classes. L’obtention de

ces 4 éléments conclut l'étape de prétraitement des données, de l'extraction des images à partir des clips vidéo jusqu'à l'annotation et l'augmentation de ces mêmes images. Une fois cette étape réalisée, on peut ensuite passer à l'entraînement de notre modèle de détection.

3.4 Détection des vaches laitières

Pour la détection, YOLO s'avère être une référence en vision par ordinateur. C'est une étape cruciale au sein de l'approche proposée et qui influencera le reste des expériences. Elle dépend grandement de la qualité et de la taille du jeu de données, d'où l'importance que ce dernier soit divers et bien adapté à la tâche que l'on veut réaliser. La version v5 de YOLO, de par son architecture, permettra ainsi d'avoir une détection rapide et de haute précision (Guo *et al.*, 2023). En entrée, l'algorithme reçoit un clip vidéo d'une longueur variant de 30 secondes à trois minutes. Et l'algorithme nous retourne cette même vidéo avec des boîtes d'encerclement autour des vaches détectées durant cette période. De plus, le niveau de confiance de la détection est disponible pour chaque frame. C'est pourquoi, tout au long de la vidéo, cette valeur de confiance change.

3.4.1 Algorithme 1 pour la détection

Le pseudo-code suivant explique le fonctionnement de la détection faite par YOLOv5.

Cet algorithme résume les différentes étapes de la détection d'objets dans une vidéo à l'aide de YOLOv5. Après l'initialisation du modèle pré-entraîné, chaque frame de la vidéo est prétraitée et soumise à l'inférence du modèle. Les prédictions sont ensuite filtrées pour éliminer les doublons, puis chaque objet détecté est annoté avec sa boîte de délimitation et son label. Enfin, les frames annotées sont sauvegardées ou affichées pour visualisation.

Algorithm 1 Détection d'objets avec YOLOv5

Require: vidéo

Ensure: vidéo annotée avec boîtes de détection

- 1: **Initialiser** le modèle YOLOv5 avec des poids pré-entraînés
 - 2: **for** chaque frame extraite de la vidéo **do**
 - 3: Charger l'image et la convertir en tenseur
 - 4: Normaliser les valeurs de pixels (0-1)
 - 5: Effectuer l'inférence avec YOLOv5
 - 6: Récupérer les prédictions (boîtes, classes, scores de confiance)
 - 7: Appliquer Non-Maximum Suppression (NMS) pour supprimer doublons
 - 8: **for** chaque objet détecté **do**
 - 9: Extraire coordonnées de la boîte (x_1, y_1, x_2, y_2)
 - 10: Associer la probabilité de détection (confiance)
 - 11: Identifier la classe (ex. vache)
 - 12: Dessiner la boîte et le label sur la frame
 - 13: **end for**
 - 14: Sauvegarder ou afficher la frame annotée
 - 15: **end for**
-

3.4.2 Métriques d'évaluation des performances de la détection

En apprentissage machine, il existe des mesures qui permettent d'évaluer la performance du modèle. Pour quantifier le niveau de détection, on utilise ces mêmes métriques. Parmi ces mesures, on peut citer l'exactitude (accuracy en anglais), la précision, le rappel (Recall en anglais), le score F1 ou encore la moyenne de précision (mAP). Avant de définir ces différentes métriques, faisons un rappel des valeurs de vrai positif et négatif et de faux négatif et positif. Soit l'exemple suivant (N.B., 2019), qui consiste à classier si une personne est enceinte ou non. Il existe ici quatre cas de figure :

- Le patient est une femme et est enceinte. Il s'agit ici d'un vrai positif (TP pour « True Positive »);
- Le patient est une femme et n'est pas enceinte, ce cas correspond à un vrai négatif (TN pour « True Negative »);
- Le patient est une femme enceinte mais le docteur lui annonce qu'elle ne l'est pas. Il s'agit ici d'un faux négatif (FN pour « False Negative »);
- Le patient est un homme et le docteur lui annonce qu'il est enceint, on parle ici d'un faux positif (FP pour « False Positive »).

Les seules valeurs que l'on désire obtenir sont les vrais positifs et les vrais négatifs. Cependant, dû à des erreurs de classification, on se retrouve aussi avec des faux positifs et des faux négatifs. De cette manière, en utilisant un algorithme d'apprentissage machine pour prédire ces résultats sur un nombre n de patients, on a deux notions clés qui sont celles des vrais labels et celles des labels prédits, comme illustré sur la figure 3.7.




Figure 3.7 – Matrice de confusion d'un problème de classification

L'exactitude représente le nombre de classifications qui sont correctes sur toutes celles qui ont été faites. Ainsi, elle se calcule selon la formule suivante :

$$Exactitude = \frac{TN + TP}{TN + FP + TP + FN} \quad (3.1)$$

La précision nous donne la proportion de vrais positifs sur le total des positifs prédits par le modèle, c'est-à-dire :

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

Le rappel (ratio de vrais positifs) correspond au véritable taux de vrais positifs, c'est-à-dire le nombre de vrais positifs sur le nombre de vrais positifs plus celui des faux négatifs :

$$Rappel = \frac{TP}{TP + FN} \quad (3.3)$$

Le score F1 est une mesure qui combine la précision et le rappel, et se calcule de la manière suivante :

$$F1Score = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (3.4)$$




Figure 3.8 – Ration de l'Intersection sur l'Union

Et enfin la moyenne de précision (Mean Average Precision en anglais), c'est-à-dire mAP correspond à la moyenne de chaque classe, chaque label contenu dans notre jeu de données et basée sur les prédictions de notre modèle. En ce qui concerne la détection d'objet, on utilise l'IoU ou (Intersection over Union) pour calculer la mAP. L'IoU est une mesure qui évalue le chevauchement entre deux boîtes d'encerclement. On a ainsi une boîte vraie, où se trouve exactement l'objet sur l'image et une boîte de prédiction, où se trouve l'objet détecté selon le modèle. Il se calcule par la division de l'aire de chevauchement sur celle de l'aire d'union qu'il existe entre les deux boîtes. En général, une IoU supérieure à 0.5 veut dire que l'on a un succès, sinon on a un échec. Ainsi, dans la Figure 3.8(a), il y a une vache entourée de deux boîtes d'encerclement. Celle en bleu correspond à celle que l'on aura annotée manuellement, à notre vraie boîte. Tandis que celle en noir correspond à celle que l'on obtient avec notre algorithme.

Ainsi, la mAP se calcule en se basant sur l'équation (3.5). Avec AP_k qui représente la moyenne de précision de la classe k et n qui est le nombre de classes. La notation **mAP@[0.5]** signifie que la mAP a été calculée avec un seuil d'IoU de 0,5.

$$mAP = \frac{1}{n} \sum_{k=1}^n AP_k \quad (3.5)$$

3.5 Le suivi d'objets multiples

Une fois l'évaluation de la **détection** faite, on passe au **suivi**. L'objectif est d'obtenir un suivi de qualité, avec un nombre d'ID switches minimum et donc une bonne conservation de l'identité des bovins. Ainsi, StrongSORT apparaît comme un choix privilégié parmi les divers systèmes de suivi d'objets disponibles. Il se démarque notamment par l'intégration d'un modèle de re-identification puissant (souvent basé sur FastReID) pour reconnaître un objet même après une occlusion ou une disparition temporaire, ce qui permet d'avoir des trajectoires plus complètes et cohérentes. Contrairement à SORT ou DeepSORT, StrongSORT utilise des embeddings visuels qui permettent de réassocier les objets perdus, même sur de longues périodes ou dans des vidéos complexes. Et surtout, il se combine très bien avec YOLOv5 pour des performances en temps réel. Au final, ces avantages permettent une amélioration des métriques de suivi comme le MOTA, l'IDF1, et le HOTA, qui s'en trouvent souvent améliorés par rapport aux versions précédentes (DeepSORT ou SORT), surtout en présence de nombreux objets semblables. Le tableau 3.2 établit la comparaison entre les différents systèmes de suivi d'objets SORT, DeepSORT et StrongSORT.

Critère	SORT	DeepSORT	StrongSORT
Gestion des ID	Faible	Moyenne	Excellente
Re-identification	Aucune	Présente (basique)	Avancée (FastReID)
Résistance aux occlusions	Faible	Moyenne	Élevée
Stabilité des trajectoires	Fragmentée	Moyenne	Fluide
Qualité des embeddings	-	Faible à moyenne	Élevée (apprentissage supervisé)
Personnalisation du modèle Re-ID	Non supporté	Limitée	Facile
Performance en temps réel	Très rapide	Moyenne	Bonne (optimisée)
Facilité d'intégration	Simple	Relativement simple	Modulaire (YOLO, YAML)
Compatibilité avec YOLO	Oui	Oui	Optimale
Performances (MOTA, IDF1, HOTA)	Basses à moyennes	Moyennes	Élevées

Table 3.2 – Comparaison des algorithmes de suivi multi-objets

3.5.1 Algorithme 2 pour le suivi d'objets multiples

L'algorithme suivant détaille l'implémentation du système de suivi d'objets multiples.

Algorithm 2 Suivi multi-objets avec YOLOv5 et StrongSORT

Require: vidéo

Ensure: vidéo avec suivi multi-objets et trajectoires persistantes

- 1: **Initialiser** YOLOv5 pour la détection d'objets
 - 2: **Initialiser** StrongSORT avec modèle de ré-identification (ReID)
 - 3: **Créer** une liste de trajectoires vides
 - 4: **for** chaque frame extraite de la vidéo **do**
 - 5: Détecter les objets avec YOLOv5
 - 6: Convertir boîtes en format (x, y, w, h) avec confiances et classes
 - 7: Mettre à jour StrongSORT avec ces informations
 - 8: StrongSORT assigne un ID unique à chaque objet détecté
 - 9: Récupérer les résultats : boîtes, IDs, classes
 - 10: **for** chaque objet suivi **do**
 - 11: Dessiner la boîte et afficher son ID
 - 12: Mettre à jour la trajectoire (liste de positions passées)
 - 13: Dessiner la trajectoire de l'objet (ligne de mouvement)
 - 14: **end for**
 - 15: Sauvegarder ou afficher la frame avec suivi et trajectoires
 - 16: **end for**
-

L'**algorithme de suivi multi-objets** combine YOLOv5 pour la détection et StrongSORT pour l'association d'objets et la ré-identification. Après l'initialisation du modèle de détection et du modèle ReID, chaque frame de la vidéo est traitée : les objets sont détectés avec YOLOv5 et convertis au format (x,y,w,h) avec leurs classes et scores de confiance. StrongSORT met ensuite à jour l'état des objets détectés, attribue un ID unique à chaque objet et maintient la liste des trajectoires passées. Pour chaque objet suivi, la boîte d'encerclement et l'ID sont dessinés sur la frame, et sa trajectoire est visualisée sous forme de ligne de mouvement. Enfin, les frames annotées avec le suivi et les trajectoires sont sauvegardées ou affichées pour visualisation.

3.5.2 Métriques d'évaluation des performances du Tracking

Pour mesurer la performance de notre algorithme de suivi, nous avons à notre disposition des métriques, pour s'assurer de la qualité du suivi des objets (Luo *et al.*, 2024). Le MOTA et le MOTP sont des mesures respectives de l'exactitude par image et de la précision des boîtes d'encerclement dans le cadre du suivi multiple d'objets (Han *et al.*, 2023).

Le MOTA correspond à la capacité du *tracker* à suivre un objet et à conserver sa trajectoire. Il est calculé par la formule suivante :

$$MOTA = 1 - \frac{\sum FN_t + FP_t + IDSW_t}{\sum_t GT_t} \quad (3.6)$$

Le MOTP peut être défini comme la précision de localisation du détecteur. Il est calculé comme suit :

$$MOTP = \frac{\sum_{i,t} d_t^i}{\sum_t c_t} \quad (3.7)$$

Cependant, ces deux mesures ne prennent pas en compte les changements d'identité, c'est-à-dire quand un identifiant est remplacé par un nouvel identifiant. Ainsi, on introduit une nouvelle métrique notée IDF1 pour mesurer le changement d'identité. Il calcule la stabilité du tracker comme montré avec l'équation (3.8).

$$IDF1 = \frac{2 * IDTP}{2 * IDTP + IDFP + IDFN} \quad (3.8)$$

Le HOTA (High-Order Tracking Accuracy) est un index qui calcule l'exactitude du suivi et qui mesure la performance du tracker pour le suivi multiple d'objets de manière plus globale et en prenant en compte le score de la détection et celui de l'association. De ce fait, on s'assure de la stabilité/de l'équilibre de ces deux scores (Zheng *et al.*, 2023), (Luiten *et al.*, 2021). Ce score se calcule selon l'équation (3.9) :

$$HOTA = \sqrt{DetA * AssA} = \sqrt{\frac{\sum_{C \in TP} A(c)}{TP + FN + FP}} \quad (3.9)$$

De plus, $A(c)$ présenté par l'équation (3.10) représente la précision de l'association :

$$A(c) = \frac{TPA(c)}{TPA(c) + FPA(c) + FNA(c)} \quad (3.10)$$

Pour conclure, les métriques qui reflètent le mieux la stabilité du suivi sont le HOTA, l'IDF1 et le nombre d'ID switches. Le HOTA mesure de manière conjointe l'association. Donc la stabilité de l'identité et la précision de la détection. L'IDF1 représente la précision de la préservation de l'identité en fonction du temps. Cet indice se charge de la balance entre les faux positifs, les faux négatifs, et les ID switches. Ainsi, une grande valeur de l'IDF1 traduit une meilleure stabilité du suivi des identités. Et le nombre d'ID switches évalue le nombre de fois où l'identité assignée à une vache change tout au long des frames. Plus ce chiffre est bas, plus l'équilibre de l'identité est bon.

Le MOTA vis principalement les erreurs au niveau de la détection et ne traite pas correctement les ID switches. Le MOTP, de son côté, évalue la localisation précise d'un objet suivi, c'est-à-dire à quel point sont similaires les boîtes d'encerclement prédites à celles du ground truth. Il ne prend pas en compte la consistance de l'identité d'un objet le long des frames.

3.5.3 Mesures pour l'étude des comportements et des réseaux sociaux

En plus des métriques classiques, nous avons mis en place des mesures à partir des résultats du suivi pour pouvoir obtenir des informations sur les comportements des objets détectés. Ces résultats pourront être utilisés pour une étude sur l'analyse des comportements et des réseaux sociaux.

En effet, la mesure des émotions est une thématique récurrente et très importante en science animale, notamment pour l'étude du comportement et des relations des animaux. Ainsi, (Uddin *et al.*, 2023) met en place trois types de métriques. Les métriques **physiologiques** qui sont basées sur des indicateurs physiques comme la température corporelle ou la concentration sanguine de cortisol. Les métriques du **comportement** comme la vitesse de déplacement des vaches ou la réaction de l'animal face à l'approche d'une personne humaine. Et enfin, les mesures liées à la productivité et à la qualité du lait produit par les vaches. De la même manière, les auteurs (Ren *et al.*, 2021) dans leur étude sur l'analyse des comportements, établissent des mesures de l'interaction sociale entre deux ou plusieurs individus. On peut ainsi citer la proximité spatiale entre deux vaches, avec un contact physique ou non. Ce dernier peut d'ailleurs être doux (simple toucher, léchage, etc.) ou plus agressif (coup de tête, pressage, etc.).

L'utilisation de la vision par ordinateur permettrait d'avoir des informations plus correctes sur la vie des bovins et ainsi de pouvoir prendre des décisions plus précocement et d'optimiser la qualité de vie et le bien-être des vaches laitières. D'après (Benaissa *et al.*, 2023) et (Da Silva Santos *et al.*, 2023), une meilleure compréhension du comportement des animaux d'élevage est primordiale pour un maintien de leur santé,

de la productivité et du bien-être général au sein du troupeau.

Le calcul de ces métriques se fait grâce à l'utilisation des coordonnées des boîtes d'encerclement obtenues. Ainsi, ces mesures ne sont que des estimations et sont très dépendantes de la qualité des résultats du suivi. Une fois la trajectoire déterminée, on peut en déduire la **distance parcourue**, la **vitesse**, l'**accélération** mais aussi la **distance entre deux vaches**. On peut également générer une **carte thermique** pour visualiser les endroits où les vaches passent le plus de temps.

La distance parcourue correspond à la distance totale cumulative faite par une vache et prend ainsi en compte toutes les positions de la vache sur toutes les images suivies. Cette distance en **pixels** est représentée par l'équation (3.11). Alors qu la distance en **mètre** est montrée par l'équation (3.12) :

$$\text{Distance (pixels)} = \sum_{i=1}^{n-1} \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (3.11)$$

$$\text{Distance Totale (mètres)} = \frac{\text{Distance (pixels)}}{\text{Average PPI}} * 0.0254 \quad (3.12)$$

Dans l'équation (3.12), le 0,0254 est un facteur de conversion pour passer des pouces en mètres. En effet, 1 pouce est égal à 0.0254 mètres. Ainsi, la distance des vaches est d'abord calculée en pixels, puis convertie en pouces en utilisant le PPI (Pixels Per Inch). La distance en mètres est trouvée en multipliant par 0.0254 pour convertir les pouces en mètres.

La vitesse moyenne de la vache sur une période t donnée, nous renseigne sur l'allure moyenne de la vache et potentiellement sur le type d'activité qu'exerce cette dernière. On la calcule selon l'équation (3.13). Cependant pour la calculer, il faut d'abord déterminer le temps écoulé qui est représenté par l'équation (3.14) :

$$\text{Vitesse moyenne (m/s)} = \frac{\text{Distance totale parcourue (m)}}{\text{Temps écoulé (s)}} \quad (3.13)$$

$$\text{Temps écoulé (s)} = \frac{\text{Dernière image} - \text{Première image}}{\text{FPS}} \quad (3.14)$$

L'accélération montre la variation de la vitesse en fonction du temps. Si la valeur est positive, cela veut dire que la vache augmente sa vitesse de déplacement (dans le sens du mouvement observé). Si elle est négative, c'est-à-dire qu'on a une décélération et la vitesse de la vache diminue. Et enfin, cette valeur peut être nulle et cela veut dire que la vache se déplace à une vitesse constante. L'accélération se calcule selon la formule suivante :

$$\text{Accélération}(m/s^2) = \frac{v(t + \Delta t) - v(t)}{\Delta t} = \frac{dv(t)}{dt} \quad (3.15)$$

Pour la distance entre deux vaches, c'est essentiellement la distance euclidienne que l'on calcule pour chaque image. Il suffit ensuite d'utiliser la formule définie en (3.14) pour la convertir en mètres. La formule est la suivante :

$$\text{Distance (pixels)} = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (3.16)$$

En ce qui concerne les cartes thermiques, elles fournissent des informations comme les lieux les plus fréquentés par les bovins ou encore les potentielles interactions entre eux.

3.5.4 Algorithme 3 pour l'extraction des métriques

Cet algorithme permet d'extraire les métriques de mouvement à partir des trajectoires de chaque vache détectée et suivie. À partir d'un fichier CSV contenant les boîtes englobantes et les identifiants d'objets, les positions sont regroupées par vache et triées selon l'ordre des frames. Pour chaque paire de positions consécutives, la distance parcourue est calculée, convertie en mètres, et utilisée pour déterminer la vitesse instantanée. La distance totale et la vitesse moyenne de chaque vache sont ensuite calculées, ainsi que l'accélération et l'accélération moyenne à partir des variations de vitesse. Enfin, toutes ces métriques sont enregistrées dans un fichier texte pour analyse ultérieure.

Algorithm 3 Analyse de trajectoires et calcul de métriques de mouvement

Require: fichier CSV contenant les boîtes englobantes avec coordonnées et métadonnées

Ensure: métriques de mouvement (distance, vitesse, accélération) par vache

```
1: Initialiser fps = 30, cow_trajectories = dictionnaire vide
2: Lire "bounding_boxes.csv" et regrouper les coordonnées par cow_id
3: Trier chaque trajectoire par numéro de frame
4: for chaque vache do
5:     for chaque paire de positions consécutives do
6:         Calculer distance en pixels puis convertir en mètres
7:         Calculer vitesse = distance / temps_entre_frames
8:         Accumuler distance_totale
9:     end for
10:    Calculer accélérations à partir des variations de vitesse
11:    Calculer vitesse_moyenne = distance_totale / temps_total
12:    Calculer accélération_moyenne
13: end for
14: Écrire résultats dans "metrics.txt"
```

Le suivi a été principalement réalisé sur une vidéo complexe d'une durée de 110 secondes, soit 1 minute et 50 secondes. On y voit apparaître 10 vaches le long du corridor qui relie la ferme et l'espace extérieur divisé en paddocks. Il s'agit exactement de la caméra OC1 comme montré sur la Figure 3.2. Nous avons choisi cette vidéo car elle constitue un bon indicatif pour évaluer la performance de notre modèle, mais également car elle nous permettra de calculer les métriques que nous avons définies et établies de la manière la plus optimale.

Dans ce chapitre, nous avons traité l'approche méthodologique et expérimentale que nous avons suivie. De plus, nous avons montré les différents outils utilisés pour réaliser les expériences, ainsi que des mesures utilisées pour quantifier la performance des modèles. Le chapitre qui suivra exposera résultats obtenus et fera également l'interprétation de ses résultats.

CHAPITRE 4

RÉSULTATS

Le chapitre quatre aborde les résultats obtenus pour la détection des vaches. Et ceux obtenus lors du suivi d'objet multiple des vaches à partir des résultats de la détection.

4.1 Cadre expérimental

Les expériences de détection et de suivi ont été faites sur le cluster de calcul haute performance Calcul Canada. La totalité des algorithmes utilise **Python**(version 3.10.2) comme langage de programmation. Les principales bibliothèques utilisées sont : OpenCV (version 4.8.0) pour la vision par ordinateur, NumPy (1.25.2) pour les calculs, Torch (version 2.0.1) et Pandas (version 2.2.3). Le framework de l'apprentissage profond se base sur les packages Ultralytics, YOLOv5, FastReID et StrongSORT-YOLO.

Pour la détection, on utilisera 2340 images pour l'entraînement de notre modèle. Les images proviennent de six caméras, trois extérieures et trois intérieures. Le tableau 4.1 montre les différents paramètres utilisés lors de la détection.

Paramètre	Valeur
Number of epochs	250
Batch size	16
Image size	640x640
Initial learning rate	0.01
Final learning rate	0.001
Weight decay	0.0005
Momentum	0.937

Table 4.1 – Les paramètres d'entraînement de Fastreid

Cette section présente les résultats obtenus selon trois axes principaux.

- Premièrement, nous exposerons les performances obtenues par notre modèle YOLOv5 lors de la détection sur la vidéo d'étude, en détaillant les métriques d'évaluation du modèle.
- Deuxièmement, nous analyserons les résultats du suivi d'objets générés par le système StrongSORT.

- Troisièmement, nous présenterons les différents indicateurs de bien-être que l'approche expérimentale proposée nous a permis de calculer.

Deuxièmement, nous analyserons les résultats du suivi d'objets généré par le système StrongSORT. Troisièmement, nous présenterons les différents indicateurs de bien-être que notre approche expérimentale nous a permis de calculer.

4.2 Résultats de la détection

La figure 4.1 et le tableau 4.2 montrent les résultats des métriques d'évaluation obtenus suite à notre entraînement. Sur les différentes courbes, on a sur l'axe des abscisses les différentes epochs et sur celui des ordonnées les valeurs des variables calculées. Ce dernier a été fait sur 250 epochs et l'on constate que les valeurs de précision et de recall sont très élevées. On note qu'au cours de l'entraînement, les valeurs de box_loss et d'obj_loss diminuent à mesure que les périodes d'apprentissage et de validation progressent. De plus, la précision, le rappel et le mAP augmentent à mesure des epochs.

Epoch	mAP@0.5	mAP@0.5 :0.95	recall	precision	val box loss	val obj loss
10	0.91834	0.53992	0.85799	0.87174	0.0070297	0.0006942
50	0.95889	0.75749	0.8986	0.91917	0.0071841	0.0056065
100	0.96403	0.782	0.91044	0.91404	0.0066911	0.0054284
200	0.96392	0.7950	0.89572	0.9329	0.006344	0.0055287
250	0.96323	0.79711	0.91024	0.91807	0.0063139	0.0056168

Table 4.2 – Résultat des performances du modèle à travers les epochs d'entraînement




Figure 4.1 – Courbes des différentes métriques obtenues lors de l'entraînement avec en ordonnées les valeurs de métriques en fonction des epochs en abscisse.

Nous avons d'abord commencé par les modèles nano de YOLOv5 car ils permettent d'avoir une haute performance pour la détection d'objet. Cependant, la précision obtenue est moins bonne que celle obtenue avec des modèles plus grands comme les modèles large (YOLOv5l) et extra (YOLOv5x). Une fois l'entraînement fait, la validation a été faite sur les données simples et celles augmentées. Ainsi, dans le tableau 4.3, on retrouve toutes les métriques définies dans la partie 3.4.3. À savoir la mAP, la précision, le rappel et le score F1.

YOLO	Données	mAP@0.5	mAP@0.5 :0.95	Precision(%)	Recall(%)	F1-score(%)	Temps(ms)
v5n	Simple	85.2	74.4	83.1	82.0	82.5	1.8
v5n	Aug.	94.5	77.6	89.7	89.1	89.4	1.8
v5l	Aug.	95.4	80.3	91.0	87.2	89.0	1.8

Table 4.3 – Comparaison des modèles de détection YOLOv5n et YOLOv5l sur les données non augmentées (Simple) et augmentées (Aug.)

YOLOv5n obtient un mAP@0.5 de 85,2% et un mAP@0.5 :0.95 de 74,4% sur les données brutes, et de 94,5% et 77,6% respectivement sur les données augmentées. De même, les valeurs de précision, de recall et du score F1 sont de l'ordre de 82 à 83%. On obtient une vitesse d'inférence rapide de 1,8 ms. Grâce à sa concep-

tion à une étape, il excelle dans la détection de petits objets, qui prédit directement les emplacements et les classifications des objets. Le modèle YOLOv5l performe lui aussi très bien. On observe le même temps d'inférence et une augmentation du mAP@0.5 de 95,4% et du mAP@0.5 :0.95 à 80,3%. On note aussi une précision à 91%, un recall à 87,2% et un score F1 de 89%. Bien que YOLOv5 montre des performances prometteuses, il est noté que ses performances se dégradent dans des conditions réelles complexes, telles que des éclairages variés, des occlusions, des ID switches et des variations de pose comme on peut le retrouver dans notre vidéo, avec les dix vaches.




Figure 4.2 – Illustration des résultats de la détection avec YOLOv5 (1)

La figure 4.2 illustre le meilleur cas de figure, celui que nous cherchons à obtenir tout au long de la vidéo. On y voit trois vaches, qui sont toutes détectées et donc encerclées d'une boîte munie du score de confiance avec lequel la vache est détectée durant ce frame.

A l'instar de la figure 4.3, où nous pouvons voir l'un des problèmes évoqués plus tôt qui est l'occlusion. En effet, sur les cinq vaches présentes à cet instant t dans la vidéo, seulement trois sont correctement détectées. Une fois sortie de l'habitable, les vaches traînent un peu au niveau de la porte, ce qui crée une agglomération. Ainsi, par ordre de sortie, la première vache se retrouve à obstruer la seconde vache et ainsi de suite. De plus, on observe 4 boîtes d'encerclement à cause d'une erreur de détection. Ici, un des équipements de la ferme est détecté comme une vache.



Figure 4.3 – Illustration des résultats de la détection avec YOLOv5 (2)

4.3 Résultats du tracking

Nous avons cinq paramètres à prendre en compte lors des expériences :

- **yolo-weights** correspond au modèle YOLO utilisé pour la détection des objets. Dans toutes les expériences, nous utilisons notre modèle *best.pt*, entraîné et validé précédemment.
- **strong-sort-weights** représente le modèle de ré-identification utilisé par l'algorithme StrongSORT pour associer les identités d'un objet au fil des frames. Ce modèle permet d'améliorer la cohérence du suivi, notamment en cas d'occultation temporaire ou de chevauchement d'objets.
- **config-strongsort** fait référence au fichier de configuration contenant les paramètres spécifiques que l'on souhaite appliquer au suivi, tels que les seuils de distance (MAX_DIST), le nombre de détections nécessaires à la confirmation d'un track (N_INIT), ou encore le nombre de features pour maintenir un track (NN_BUDGET). On y retrouve également le modèle de ré-identification utilisé.
- **conf-thres** est le seuil minimum de confiance à partir duquel les vaches seront détectées. Une détection en dessous de ce seuil est ignorée, afin de limiter les fausses détections dues à une faible probabilité.
- **iou-thres** est le seuil utilisé pour l'association entre les boîtes englobantes d'une frame à l'autre. Si l'IoU entre une détection actuelle et une précédente est supérieur à ce seuil, elles sont considérées comme représentant le même objet. Ce paramètre est crucial pour assurer un suivi précis et éviter les erreurs d'association.



Figure 4.4 – Image montrant le suivi d'une vache

Dans la figure 4.4, on voit une vache numérotée "14" avec une ligne de suivi (*tracking line* en anglais) au centre de sa boîte d'encerclement et qui retrace le parcours de la vache depuis qu'elle a été détectée. Cette ligne permet de visualiser la trajectoire de l'animal au fil du temps et illustre la capacité du système à suivre les déplacements de la vache. Elle constitue donc un indicateur visuel de la qualité du suivi et met en évidence la continuité des trajectoires, ce qui est essentiel pour l'analyse comportementale.

En parallèle de l'exécution du suivi, on obtient notre fichier csv et l'on s'aperçoit qu'il y a un saut au niveau de l'attribution des numéros d'identification. On peut spéculer que ceci est dû à une occlusion, qui causera à une vache de ne pas être détectée et donc pas trackée. Dans le Tableau 4.4 est exposé un extrait des résultats pour les frames 588 à 594. Pour ces 7 frames, on a 3 vaches détectées. Soit les vaches numérotées 1, 3 et 5. On y retrouve les coordonnées de leurs boîtes respectives, le niveau de confiance avec lequel les vaches sont détectées dans chaque frame et les coordonnées du centre des boîtes d'encerclement.

N°Frame	Cow ID	x1	y1	x2	y2	Confidence	Coordonnées centre	PPI Width	PPI Height
588	1	2417.0	335.0	2606.0	552.0	0.919	(2511.5; 443.5)	7.56	3.338
588	3	2261.0	515.0	2614.0	1108.0	0.757	(2437.5; 811.5)	14.12	9.123
588	5	2645.0	384.0	2803.0	684.0	0.501	(2724.0; 534.0)	6.32	4.615
589	1	2418.0	337.0	2606.0	553.0	0.919	(2512.0; 445.0)	7.52	3.323
589	3	2256.0	519.0	2616.0	1111.0	0.761	(2436.0; 815.0)	14.4	9.108
590	1	2421.0	344.0	2640.0	578.0	0.914	(2530.5; 461.0)	8.76	3.6
590	3	2255.0	522.0	2615.0	1113.0	0.672	(2435.0; 817.5)	14.4	9.092
590	5	2639.0	376.0	2804.0	683.0	0.664	(2721.5; 529.5)	6.6	4.723
591	1	2423.0	341.0	2642.0	571.0	0.924	(2532.5; 456.0)	8.76	3.538
591	3	2254.0	522.0	2613.0	1116.0	0.693	(2433.5; 819.0)	14.36	9.138
591	5	2651.0	384.0	2802.0	685.0	0.579	(2726.5; 534.5)	6.04	4.631
592	1	2425.0	354.0	2644.0	593.0	0.904	(2534.5; 473.5)	8.76	3.677
592	3	2255.0	524.0	2613.0	1119.0	0.727	(2434.0; 821.5)	14.32	9.154
592	5	2653.0	379.0	2800.0	684.0	0.611	(2726.5; 531.5)	5.88	4.692
593	1	2432.0	354.0	2648.0	614.0	0.917	(2540.0; 484.0)	8.64	4.0
593	3	2257.0	533.0	2614.0	1124.0	0.642	(2435.5; 828.5)	14.28	9.092
593	5	2646.0	385.0	2802.0	681.0	0.556	(2724.0; 533.0)	6.24	4.554
594	1	2443.0	364.0	2662.0	660.0	0.911	(2552.5; 512.0)	8.76	4.554
594	3	2250.0	538.0	2616.0	1125.0	0.624	(2433.0; 831.5)	14.64	9.031
594	5	2643.0	396.0	2802.0	683.0	0.571	(2722.5; 539.5)	6.36	4.415

Table 4.4 – Résultats du Tracking avec les coordonnées des boîtes d'encerclement et les scores de confiance de chaque vaches détectées et trackées

C'est grâce à ce même fichier csv que nous calculerons les performances de notre modèle. C'est précisément en utilisant les coordonnées des boîtes prédites par le système et en les comparant avec celles annotées manuellement, c'est-à-dire notre **ground-truth**, que nous pourrions obtenir les mesures sur la précision et la qualité de notre suivi.

4.3.0.1 Résultats tracking avec TorchReID

Nous avons aussi fixé les seuils de confiance et d'IoU à 0.5 pour toutes les expériences. Nous avons mené trois expériences en utilisant comme modèle de ré-identification celui intégré par défaut à StrongSORT, c'est-à-dire Torchreid avec des modèles différents. Ainsi, dans le tableau 4.5 présenté ci-dessous, nous pouvons observer les résultats de suivi obtenus avec les modèles osnet de Torchreid. On accorde une grande importance au nombre de permutations car il atteste de la conservation de l'identité et du bon suivi des vaches. Les trois modèles performant de manière similaire, avec un MOTA d'environ 62%, une MOTP de 77%, un IDF1 de 79%, et un HOTA de 65-66%. La principale différence se présente au niveau du nombre d>ID switches qui est de 17 pour le modèle osnet_x1_0_pretrained et respectivement de 21 et 24 pour les modèles *cross_domain* et *same_domain*.

Modèle OSNET	ID switches	MOTA	MOTP	IDF1	HOTA
osnet_x1_0_pretrained	17	62.37	77.48	79.38	65.91
osnet_x1_0_cross_domain	21	62.62	77.49	79.50	66.10
osnet_x1_0_msmt17_same_domain	24	62.68	77.48	79.53	66.16

Table 4.5 – Comparaison des performances avec différents modèles de TorchReID

4.3.0.2 Résultats de la re-identification

Lors de l'entraînement du modèle FastReID, nous avons essayé différentes combinaisons de paramètres pour obtenir les résultats les plus optimaux.

Paramètre	Valeur
Number of epochs	400
Batch size	64
Image size	224x128
Base learning rate	0.00035
RERANK	Enabled
CLS_LAYER	ArcSoftmax

Table 4.6 – Les paramètres d'entraînement de Fastreid

De ce fait, nous avons décidé d'entraîner notre modèle sur 400 epochs, pour qu'il puisse apprendre et reconnaître des motifs plus complexes. C'est un nombre assez grand, mais adéquat en raison de la taille de notre jeu de données. La taille du batch (échantillon) est de 64, ce qui permet un entraînement plus rapide et un bon équilibre entre la vitesse et la stabilité. Le taux d'apprentissage est fixé à 0.00035, ce qui est standard pour le fine-tuning ou pour les modèles de re-identification. Le RERANK est utilisé après l'entraînement durant l'inférence. Son utilisation permet d'améliorer la précision du grade final (mAP, Rank-1). Le paramètre ArcSoftmax fait référence au head de classification utilisé durant l'entraînement. Il permet une meilleure discrimination des caractéristiques. Ce qui représente une étape cruciale pour la re-ID des vaches. Et contribue à la généralisation et au boost des métriques du Rank-1 et du mAP.

Dataset	Rank-1	Rank-5	Rank-10	mAP	mINP	metric
cows_test	59.85	63.23	66.42	42.10	14.36	50.97

Table 4.7 – Résultats de la validation du modèle FastReID

Une fois l'entraînement fait, on réalise une validation des résultats, comme présentés dans le Tableau 4.7. Le Rank-1 est à environ 60%, cela veut dire que l'identité correcte est récupérée comme match principal à hauteur de 60%. On obtient un mAP (Mean Average Precision) de 42%, ce qui renseigne sur la qualité de la correspondance. Ainsi, une faible valeur de mAP suggère qu'il y a beaucoup de faux positifs. Le mINP correspond au Mean Inverse Negative Penalty et indique la difficulté d'avoir de bons matchs à un grand rank. Notre valeur, 14%, est en dessous de celle attendue qui est d'environ 20%. Et enfin, la valeur metric (50.97%) est la moyenne entre le rank-1 et le mAP.

4.3.0.3 Résultats du tracking avec FastReID

On utilise ensuite notre résultat de re-identification dans notre système de suivi d'objets. Cette fois, avec des variations du seuil d'IoU. Au niveau du Tableau 4.8, pour le IoU à 0.3, on a un nombre de faux positifs de 590, ce qui est relativement bas. Et on obtient des valeurs élevées des métriques d'évaluation. Le MOTA est à 69%, le MOTP à 74%, notre IDF1 est à 83%, et le HOTA est à 71%. Cependant, on a un nombre d>ID switches de 65. C'est plus de deux fois celui que l'on obtient avec l'IoU à 0.5 et 5 fois de plus que celui avec l'IoU à 0.3. Pour l'IoU à 0.5, nous obtenons un MOTA de 62.62%, ce qui suggère que notre nombre de faux positifs, bien que plus grand que celui obtenu précédemment, est assez faible, soit 915. Notre MOTP est très élevé, 77.49%, les bounding boxes sont donc détectées avec une grande et bonne précision. On constate que,

bien qu'ayant un plus grand nombre d'ID switches que les autres modèles, notre modèle basé sur FastReID obtient une valeur élevée d'IDF1, de 79.28%, ce qui suggère que le modèle proposée arrive à maintenir avec un grand succès l'identité des vaches détectées et suivies. Ce résultat sous-entend une consistance dans la préservation de l'identité. Et enfin, lorsque l'on augmente le seuil d'loU, on observe une baisse importante du MOTA qui passe à 27%. Le MOTP est très élevé mais étant donné que le nombre de faux positifs est lui aussi très grand, environ 2500, cela suggère que les vaches ne sont pas correctement détectées. Et on note aussi que le nombre d'ID switches est le plus faible mais pour autant l'IDF1 est le plus faible avec une valeur de 60%.

Modèle fastreid_model_best	Nombre de FP	ID switches	MOTA	MOTP	IDF1	HOTA
loU = 0.3	590	65	69.06	74.34	83.60	71.30
loU = 0.5	915	30	62.62	77.49	79.28	65.84
loU = 0.7	2489	13	27.35	82.81	60.20	43.15

Table 4.8 – Comparaison des performances du modèle FastReID à des seuils d'loU différents

Ainsi, on remarque que plus l'on augmente le seuil d'loU, plus le nombre de permutations d'identité augmente. Et en parallèle, cela fait diminuer la valeur de l'IDF1, donc le bon maintien de l'identité lors du suivi de vaches. Ainsi, on va privilégier le résultat obtenu avec l'loU établi à 0.5, en raison de son équilibre entre le nombre d'ID switches et la valeur de l'IDF1. Le fait d'obtenir des résultats similaires entre FastReID et TorchReID pour le même seuil d'loU est plutôt rassurant, car cela prouve : une implémentation correcte de notre entraînement, une reproductibilité des résultats entre les frameworks et que les hyperparamètres et la configuration utilisés sont appropriés.

4.4 Résultats des métriques d'analyse des mouvements

En exploitant le fichier des coordonnées des boîtes englobantes, nous avons pu extraire diverses métriques liées aux déplacements des bovins tout au long de la séquence vidéo. Parmi les 10 individus présents dans l'enregistrement, 9 ont été détectés et suivis avec succès. La complexité inhérente à cette séquence a engendré la perte d'un individu, probablement due à des phénomènes d'occlusion et à une permutation d'identités où deux vaches se sont vues attribuer le même identifiant, résultant en l'exclusion de l'une d'entre elles du suivi. De cette manière, dans le tableau 4.9, nous obtenons les mesures de distance parcourue, de vitesse et d'accélération pour 9 vaches au lieu de 10.

Cow ID	Distance parcourue (m)	Vitesse (m/s)	Accélération (m/s ²)
1	40.53	0.59	-0.28
3	26.68	0.46	0.06
5	13.04	0.60	0.16
6	11.54	0.75	1.46
9	29.09	0.38	0.02
12	2.60	1.81	3.47
14	19.01	0.64	0.20
16	18.84	0.80	0.15
18	13.84	0.78	0.24

Table 4.9 – Analyse des déplacements des vaches : Mesures de distance, de vitesse, et d'accélération

La distance du couloir emprunté par les bovins dans la vidéo est d'environ une quinzaine de mètres. Et étant donné que les vaches sont des animaux qui se déplacent assez doucement et à une vitesse constante, l'accélération est nulle pour la plupart d'entre elles. On peut supposer que les variations observées sont probablement dues à des boosts soudains ou à des reprises de leur trajectoire suite à un arrêt. Et l'inconsistance au niveau des mesures de distance est causée par les occlusions et les ID switches.

Vache 1	Vache 2	Moy. Distance (m)
1	3	1.31
1	5	0.83
1	6	0.87
1	9	1.26
3	5	1.25
3	6	1.57
3	9	0.83
5	6	1.23
5	9	1.97
6	9	0.60
9	12	0.42
9	14	1.90
9	16	0.75
9	18	1.02
12	14	0.20
14	16	0.83
14	18	0.72
16	18	0.47

Table 4.10 – Tableau des moyennes de distances entre les vaches

Le tableau 4.10 présente la moyenne de distance entre deux vaches le long de la vidéo. Par exemple, on voit que les vaches numérotées 1 et 3 ont une distance moyenne de 1.31 mètres. Ce qui pourrait être qualifié de relativement distant, tandis que les vaches 12 et 14 ont une distance moyenne de 20 cm tout au long de la vidéo, ce qui est quand même très proche. Cette distance pourrait faire l'objet d'une interprétation plus poussée et servir d'indicatif sur les relations inter-individus.

Il convient de noter que ces expérimentations, si elles étaient conduites sur des séquences vidéo moins complexes, comportant un nombre réduit d'individus et donc moins d'occlusions et de permutations d'identité, permettraient d'obtenir des performances significativement supérieures.

Ce chapitre a exposé les résultats des expérimentations ainsi que leur analyse critique. Bien que notre système de détection et de suivi multi-objets ait permis de conduire les expériences avec un succès relatif, des améliorations demeurent nécessaires. Les perspectives d'optimisation et les axes de développement futurs seront abordés dans le chapitre suivant consacré à la discussion.

CHAPITRE 5

DISCUSSION ET CONCLUSION

En conclusion, les expérimentations réalisées ont permis d'extraire les métriques qui peuvent être utilisées pour le bien-être animal. En s'appuyant sur le modèle de détection et de suivi appliqué aux vaches laitières, nous sommes capables de déterminer des indicateurs comme la distance parcourue par les vaches, leur vitesse et les variations de cette dernière. L'algorithme YOLO a fait preuve d'une remarquable précision pour localiser les animaux dans les séquences vidéo, tandis que StrongSORT a assuré un suivi temporel cohérent. Toutefois, notre système reste confronté à des enjeux techniques majeurs, notamment la résolution des occultations entre animaux et la stabilité de l'attribution des identifiants lors du suivi. En somme, ce travail confirme le potentiel de l'intelligence artificielle et de la vision par ordinateur dans le suivi automatisé des animaux d'élevage, tout en soulignant les pistes d'amélioration nécessaires pour franchir un nouveau cap vers des systèmes robustes, généralisables et applicables en conditions réelles.

L'approche proposée dans ce travail repose en premier lieu sur un système de détection performant, fondé sur le modèle YOLOv5. Ce modèle de détection d'objets en temps réel s'est imposé dans la littérature récente comme une solution de référence en raison de son équilibre entre précision, vitesse d'exécution et légèreté du modèle. Dans notre étude, YOLOv5 a été entraîné sur un jeu de données annoté spécifiquement pour le suivi des vaches laitières en contexte réel. L'application de techniques d'augmentation de données, telles que la rotation, la variation de luminosité ou encore la variation du bruit, a permis de générer des échantillons synthétiques variés. Cette diversité a renforcé la capacité du modèle à généraliser face aux changements de perspective, d'échelle ou d'éclairage, très fréquents dans les environnements agricoles.

Le modèle YOLOv5 proposé atteint des performances élevées avec les données augmentées. On rappelle que YOLOv5n obtient un mAP de 94,5%, une précision de 89,7% et un rappel de 89,1%. Pour YOLOv5l, nous obtenons un mAP à 95,4% pour un score-F1 d'environ 89%, avec un temps d'inférence de 1,8 ms, confirmant l'apport de l'augmentation de données et du modèle plus large sur les données. Ces niveaux se situent dans l'ordre de grandeur des études récentes. Par exemple, (Hao *et al.*, 2023) rapporte des mesures de précision de 94,8%, de rappel de 90,3%, un score-F1 de 92,5% et un mAP de 95,1% avec un YOLOv5 amélioré (EMA). Les écarts observés en conditions réelles (occlusions, arrière-plans complexes) dans notre vidéo d'évaluation expliquent les difficultés que nous rencontrons.

Les résultats expérimentaux indiquent que YOLOv5 parvient à détecter efficacement les vaches dans la majorité des scènes, tout en maintenant un temps d'inférence compatible avec les exigences du traitement en temps réel. Cependant, malgré ces points forts, certaines limites persistent, notamment dans le cas de scènes complexes comprenant des occlusions, des chevauchements ou des objets partiellement visibles. Ce type de défi est courant dans les troupeaux denses, où les vaches peuvent se masquer partiellement les unes des autres. Par ailleurs, les erreurs de détection dans des cas de mouvements rapides, de chevauchements prolongés ou de conditions de faible luminosité restent un facteur limitant, impactant par conséquent la qualité du suivi global. Pour pallier ces limitations, plusieurs axes d'amélioration sont envisageables. Un premier levier réside dans l'exploration de modèles de détection plus récents, en particulier YOLOv8, qui bénéficie de plusieurs optimisations structurelles (notamment en termes d'attention spatiale et de stratégie d'entraînement). Ces modèles ont montré des gains significatifs en précision sur des benchmarks variés, tout en conservant une rapidité d'exécution compatible avec des déploiements réels. En outre, l'intégration de mécanismes d'ensemblage de modèles (model ensembling) ou de détection multi-échelle plus fine, ainsi qu'une exploitation plus poussée des données temporelles, pourrait permettre de renforcer la robustesse du système face aux cas d'ambiguïté visuelle.

Enfin, une annotation plus fine des données complexes, notamment celles présentant des cas d'occlusion partielle, pourrait contribuer à orienter l'apprentissage du modèle vers des cas difficiles, améliorant ainsi sa résilience sur le terrain.

StrongSORT se révèle être un système de suivi d'objets compétent et très performant pour le suivi des vaches. Cet algorithme repose sur une combinaison efficace entre une détection (basée sur YOLOv5) et un module de ré-identification (FastReID) permettant d'assurer une cohérence des identifiants à travers les différentes frames. Les résultats obtenus mettent en évidence les atouts de StrongSORT, tout en soulignant certaines limites inhérentes à la nature des données ou au paramétrage des modules. Premièrement, l'intégration d'un module de ré-identification constitue une avancée majeure par rapport aux algorithmes de suivi classiques. Celui-ci permet d'améliorer la robustesse de l'association des objets dans le temps, en limitant les erreurs d'ID switches. Dans notre cas d'étude, le nombre de changements d'ID est resté assez bas, démontrant une bonne stabilité du suivi même dans des scènes complexes. Deuxièmement, la précision de localisation moyenne (MOTP) s'est établie à plus de 77%, ce qui atteste de la qualité de la détection initiale et de la cohérence spatiale du suivi. Cette précision est renforcée par la combinaison de YOLOv5 pour la détection et du mécanisme de filtre de Kalman amélioré dans StrongSORT. Troisièmement, l'architec-

ture modulaire de StrongSORT autorise l'intégration aisée de différents modèles de ré-identification, qu'ils soient pré-entraînés (TorchReID) ou entraînés spécifiquement sur notre jeu de données (FastReID). Cette flexibilité a permis d'évaluer l'impact du choix du modèle de ré-identification sur les performances globales du système.

Avec StrongSORT, les expériences avec un IoU de 0,5 donnent des résultats stables et cohérents : MOTA = 62,4–62,7%, MOTP = 77,5%, IDF1 = 79,3–79,5%, HOTA = 65–66%, avec 17 à 24 permutations d'identité selon le backbone OSNet de TorchReID. Ces niveaux sont inférieurs aux meilleurs rapports sur d'autres espèces et contextes contrôlés comme les expériences de (Wang *et al.*, 2022) réalisées sur les porcs : MOTA = 91,41% et IDF1 = 88,33%. Néanmoins, ils restent robustes au vu de la scène test choisie (couloir étroit, 10 vaches, occlusions marquées), et l'on rappelle que l'extérieur et le mouvement de groupe complexifient fortement le suivi multiple d'objet. Ainsi, les résultats obtenus sur les métriques globales (IDF1, HOTA, MOTA) témoignent d'un bon équilibre entre détection, suivi et qualité d'association, rendant StrongSORT particulièrement adapté aux applications de suivi de bétail.

En validation, notre modèle FastReID atteint un Rank-1 = 59,85% et mAP = 42,10% (mINP = 14,36%), ce qui reflète à la fois la difficulté inter-individus (morphologies proches, vues et éclairages homogènes) et la taille du jeu de ré-identification. Intégré au pipeline de suivi, FastReID fournit des performances très proches de TorchReID au seuil d'IoU de 0,5 : MOTA = 62,62%, MOTP = 77,49%, IDF1 = 79,28%, HOTA = 65,84%. Ceci confirme la bonne implémentation et la transférabilité des embeddings. Avec un seuil d'IoU égal à 0,3, l'IDF1 grimpe à 83,60% au prix de davantage d'ID switches (65), tandis qu'à IoU = 0,7 le MOTA chute (27,35%) malgré un MOTP élevé, du fait d'un grand nombre de faux positifs. On note qu'un enrichissement d'un jeu de données spécifiques aux vaches comme OpenCows2020 (Andrew *et al.*, 2021) ou MultiCamCows (Yu *et al.*, 2025) améliore la discrimination et donc le ratio Rank-1/mAP. Ces résultats s'inscrivent dans cette tendance et motivent l'extension du dataset et des vues pour franchir un palier supplémentaire.

Au-delà des performances de détection, de suivi et de ré-identification, les mesures dérivées du mouvement (distances parcourues, vitesses, accélérations, etc.) apportent une valeur ajoutée essentielle à l'évaluation du bien-être animal. En effet, des approches récentes démontrent que des altérations de la locomotion ou une réduction des distances parcourues sont souvent associées à des états de douleur ou de stress, notamment en cas de boiterie (Russello *et al.*, 2024), (Kang *et al.*, 2021), (Karoui *et al.*, 2021). Dans notre étude, l'extraction automatisée de ces indicateurs permet non seulement de quantifier objectivement l'ac-

tivité individuelle et sociale, mais aussi d'identifier les écarts ou anomalies comportementales révélatrices d'un inconfort. Ces mesures dynamiques s'inscrivent ainsi dans une perspective de surveillance continue, offrant aux éleveurs et chercheurs des outils concrets pour relier l'activité motrice aux états de santé et de bien-être, et pour mettre en place des interventions plus précoces et adaptées.

Malgré les performances encourageantes obtenues, plusieurs axes d'améliorations demeurent nécessaires pour renforcer la robustesse et la fiabilité du système.

Tout d'abord, le module de Re-Identification (ReID) entraîné localement avec FastReID n'a pas surpassé de manière significative les modèles génériques de TorchReID. Plusieurs facteurs peuvent expliquer cette limite :

- la taille encore restreinte du jeu de données d'entraînement, qui limite la capacité de généralisation ;
- faible diversité inter-classes, due à la ressemblance morphologique élevée entre individus d'un même troupeau ;
- des conditions d'acquisition homogènes (angles de vue fixes, luminosité constante, arrière-plans similaires) qui réduisent la variabilité des représentations apprises.

Pour pallier ces limites, un enrichissement du jeu de données apparaît essentiel : diversification des vues (multicaméras, différentes hauteurs de prise de vue), variations des conditions lumineuses (jour/nuit, intérieur/extérieur), et intégration d'angles obliques ou arrière. L'application de techniques d'augmentation de données ciblées (occlusions, modification de la lumière ou du contraste, déformation géométrique adaptée aux bovins) pourrait également améliorer la robustesse du modèle face aux situations imprévues.

Ensuite, les paramètres du système de détection et de suivi jouent un rôle crucial dans les performances globales. Les seuils de confiance et d'IOU, mais aussi les hyperparamètres propres au module ReID, influencent directement la précision et la stabilité des trajectoires. Une piste d'amélioration réside dans l'optimisation automatique des hyperparamètres, permettant d'atteindre un optimum global adapté au contexte spécifique des élevages.

Un autre défi majeur concerne la gestion des occlusions prolongées. Lorsqu'une vache est masquée partiellement ou totalement, le système peut interrompre la continuité de son identifiant, entraînant des ruptures de trajectoires et des erreurs d'association. Pour limiter ce problème, plusieurs pistes peuvent être envisagées :

- l'intégration de méthodes contextuelles, exploitant les relations spatiales entre individus (par ex. proximité relative dans le troupeau) ;
- l'utilisation de modèles séquentiels (LSTM, GRU) pour prédire la trajectoire future à partir des déplacements passés ;
- l'exploration de modèles transformer spatio-temporels, plus récents et performants, capables de capturer les dépendances à long terme dans les trajectoires.

À court terme, il serait pertinent d'expérimenter des modèles de détection plus récents tels que YOLOv8 ou ses variantes spécialisées, susceptibles d'améliorer la précision et la robustesse face aux variations d'apparence et aux occlusions partielles. À moyen terme, l'intégration de méthodes de ReID spécialisées pour le domaine agricole, associées à des techniques de filtrage et de correction temporelle avancées (comme des filtres de Kalman étendus, l'ID smoothing), permettrait d'améliorer la stabilité des trajectoires et de réduire le nombre d'erreurs d'identification. Enfin, à plus long terme, l'évolution vers des systèmes multimodaux représenterait une avancée majeure. L'association de la vision par ordinateur avec des capteurs complémentaires (RFID pour l'identification sûre, accéléromètres pour l'analyse de la locomotion, capteurs environnementaux pour contextualiser le comportement) ouvrirait la voie à des approches hybrides, à la fois plus fiables et mieux adaptées aux exigences de la gestion intelligente des troupeaux. Une telle intégration multimodale permettrait non seulement d'améliorer la qualité du suivi, mais aussi d'élargir l'éventail des indicateurs de bien-être accessibles, allant de la locomotion à l'activité métabolique.

ANNEXE A

RÉSULTATS DE L'ENTRAÎNEMENT DE LA DÉTECTION PAR YOLOV5

results

epoch	train/box_loss	train/obj_loss	train/cls_loss	metrics/precision	metrics/recall	metrics/mAP_0.5	metrics/mAP_0.5:0.95	val/box_loss	val/obj_loss	val/cls_loss	x/r/0	x/r/1	x/r/2
0	0.041298	0.018357	0.010221	0.013329	0.48079	0.023051	0.0055449	0.034814	0.0127	0.0087764	0.13274	0.00098117	0.00098117
1	0.031485	0.02056	0.0061649	0.30751	0.55763	0.31483	0.10529	0.021906	0.012303	0.0034098	0.078542	0.0019624	0.0019624
2	0.024638	0.018624	0.0023761	0.43841	0.63069	0.51279	0.22481	0.018582	0.009763	0.0014774	0.024334	0.0029369	0.0029369
3	0.0229	0.017048	0.0014157	0.6579	0.71679	0.73912	0.351	0.017947	0.0088138	0.0010879	0.003306	0.003306	0.003306
4	0.021407	0.016383	0.0011205	0.78558	0.77607	0.84217	0.46214	0.014846	0.0084488	0.00092104	0.003306	0.003306	0.003306
5	0.020154	0.015921	0.00096859	0.75128	0.81566	0.84194	0.4516	0.014285	0.0079883	0.00084277	0.0032946	0.0032946	0.0032946
6	0.019092	0.015164	0.00087948	0.76742	0.79802	0.84522	0.46235	0.013798	0.0076657	0.00076472	0.0032833	0.0032833	0.0032833
7	0.018426	0.01516	0.00082214	0.79207	0.84083	0.88026	0.5058	0.01281	0.0073752	0.00073744	0.003272	0.003272	0.003272
8	0.017891	0.014215	0.00078812	0.83914	0.86059	0.90542	0.52868	0.0127	0.0071721	0.00071554	0.0032606	0.0032606	0.0032606
9	0.017329	0.01468	0.00076291	0.87174	0.85799	0.91834	0.53992	0.012063	0.0070297	0.0006942	0.0032493	0.0032493	0.0032493
10	0.016729	0.014097	0.00073517	0.86031	0.86389	0.91747	0.55954	0.011743	0.0068652	0.00067616	0.003238	0.003238	0.003238
11	0.016383	0.013778	0.00070861	0.85772	0.87486	0.92305	0.55617	0.011663	0.0067636	0.00065659	0.0032266	0.0032266	0.0032266
12	0.015722	0.014033	0.00068135	0.88032	0.88013	0.93123	0.61497	0.010817	0.0066389	0.00065509	0.0032153	0.0032153	0.0032153
13	0.015451	0.013672	0.0006677	0.87641	0.88364	0.9351	0.64037	0.010152	0.0065939	0.00064058	0.0032039	0.0032039	0.0032039
14	0.015103	0.013381	0.00064551	0.87206	0.89133	0.93583	0.64927	0.010034	0.0065124	0.00061424	0.0031926	0.0031926	0.0031926
15	0.015217	0.013486	0.00063729	0.86908	0.88804	0.93725	0.64827	0.0097165	0.0064489	0.00061085	0.0031813	0.0031813	0.0031813
16	0.014656	0.01349	0.00061159	0.87427	0.88584	0.93783	0.64986	0.010054	0.0063727	0.00059136	0.0031699	0.0031699	0.0031699
17	0.014631	0.013363	0.00060154	0.87904	0.88804	0.94094	0.66902	0.0094273	0.0063368	0.00058255	0.0031586	0.0031586	0.0031586
18	0.014325	0.01317	0.00059295	0.87827	0.88584	0.94095	0.66779	0.0095289	0.0062561	0.00056747	0.0031473	0.0031473	0.0031473
19	0.014178	0.013376	0.00058332	0.88021	0.88474	0.93965	0.67893	0.0094793	0.0062288	0.00055133	0.0031359	0.0031359	0.0031359
20	0.013831	0.013153	0.00055848	0.87649	0.89352	0.94343	0.69131	0.008944	0.0061641	0.00054597	0.0031246	0.0031246	0.0031246
21	0.01371	0.013121	0.00054135	0.88488	0.89439	0.94675	0.69099	0.0085249	0.0061231	0.00053223	0.0031132	0.0031132	0.0031132
22	0.013227	0.012777	0.00052303	0.87603	0.90011	0.9446	0.68966	0.0087776	0.0061052	0.0005174	0.0031019	0.0031019	0.0031019
23	0.013401	0.012696	0.00051851	0.88687	0.89497	0.9451	0.69339	0.0085529	0.006078	0.00050475	0.0030906	0.0030906	0.0030906
24	0.013127	0.012693	0.0005028	0.89365	0.89462	0.94803	0.70122	0.008655	0.0060651	0.00049639	0.0030792	0.0030792	0.0030792
25	0.012853	0.012436	0.00049483	0.89777	0.88686	0.95003	0.70399	0.0084745	0.0059993	0.00049313	0.0030679	0.0030679	0.0030679
26	0.012784	0.012317	0.00048846	0.89197	0.9034	0.9485	0.70423	0.0085528	0.0059672	0.00047871	0.0030566	0.0030566	0.0030566
27	0.012731	0.0122	0.00048098	0.89368	0.89572	0.9531	0.71373	0.0083541	0.0059346	0.00048287	0.0030452	0.0030452	0.0030452
28	0.012688	0.012396	0.00047468	0.89108	0.89806	0.94643	0.71828	0.0082356	0.0059445	0.00047091	0.0030339	0.0030339	0.0030339
29	0.012406	0.012118	0.00046652	0.89926	0.90889	0.95095	0.72938	0.0078801	0.0059078	0.00046473	0.0030225	0.0030225	0.0030225
30	0.01244	0.012456	0.00045988	0.90289	0.89809	0.95	0.72227	0.0080023	0.0058868	0.00045666	0.0030112	0.0030112	0.0030112
31	0.012208	0.012002	0.00044623	0.90201	0.9056	0.95356	0.72667	0.008039	0.0058575	0.00044702	0.0029999	0.0029999	0.0029999
32	0.012094	0.012013	0.00044145	0.89583	0.9062	0.95105	0.71953	0.0080124	0.0058334	0.00043411	0.0029885	0.0029885	0.0029885
33	0.011957	0.011665	0.00043772	0.9004	0.90889	0.9528	0.73024	0.0077306	0.0058229	0.00042873	0.0029772	0.0029772	0.0029772
34	0.011918	0.011742	0.000423	0.89307	0.9067	0.95285	0.72863	0.0079416	0.0058128	0.00042891	0.0029658	0.0029658	0.0029658
35	0.011941	0.012178	0.00042114	0.90574	0.90713	0.95386	0.73025	0.0077591	0.0057587	0.00041979	0.0029545	0.0029545	0.0029545
36	0.011725	0.011854	0.00041174	0.89965	0.90534	0.95446	0.72868	0.0079448	0.0057672	0.00041544	0.0029432	0.0029432	0.0029432
37	0.01135	0.011435	0.00039308	0.90418	0.91155	0.95711	0.74262	0.007566	0.0057099	0.00040017	0.0029318	0.0029318	0.0029318
38	0.011364	0.011293	0.00039308	0.90969	0.90665	0.9571	0.73997	0.0075759	0.0057012	0.00040199	0.0029205	0.0029205	0.0029205
39	0.011284	0.011563	0.00038193	0.90986	0.9045	0.95765	0.73985	0.0076063	0.0057098	0.00038256	0.0029092	0.0029092	0.0029092
40	0.0112	0.011431	0.00036936	0.90875	0.9034	0.9568	0.73396	0.0077046	0.0057013	0.00038134	0.0028978	0.0028978	0.0028978
41	0.011295	0.011372	0.00037166	0.91166	0.90621	0.95711	0.74702	0.0074222	0.005654	0.00037795	0.0028865	0.0028865	0.0028865
42	0.011128	0.01118	0.00037067	0.9078	0.897	0.95775	0.73839	0.0075978	0.0057045	0.00037604	0.0028751	0.0028751	0.0028751
43	0.011141	0.01146	0.00036346	0.91327	0.9016	0.95782	0.7458	0.0074818	0.0056436	0.00036219	0.0028638	0.0028638	0.0028638
44	0.011012	0.011423	0.00035697	0.91091	0.9091	0.95776	0.74257	0.0076136	0.005685	0.00036096	0.0028525	0.0028525	0.0028525
45	0.01086	0.011484	0.00035266	0.91955	0.89086	0.95866	0.74583	0.0074057	0.0056692	0.00034554	0.0028411	0.0028411	0.0028411
46	0.011036	0.011079	0.00034694	0.917	0.89352	0.96236	0.74659	0.0074	0.0056459	0.00036034	0.0028298	0.0028298	0.0028298
47	0.010883	0.011491	0.00034429	0.91161	0.89791	0.95887	0.7555	0.0072826	0.0056233	0.00035299	0.0028185	0.0028185	0.0028185
48	0.010784	0.011621	0.00033157	0.9141	0.89947	0.95903	0.74965	0.0073831	0.0056446	0.00033993	0.0028071	0.0028071	0.0028071
49	0.010671	0.011379	0.00032687	0.91917	0.89869	0.95889	0.75749	0.0071841	0.0056065	0.00034029	0.0027958	0.0027958	0.0027958
50	0.010617	0.01132	0.00032492	0.90622	0.90164	0.95772	0.74891	0.0074231	0.0056072	0.00033528	0.0027844	0.0027844	0.0027844
51	0.010493	0.011119	0.00032186	0.90661	0.90889	0.95868	0.74726	0.0074326	0.0056158	0.00032607	0.0027731	0.0027731	0.0027731
52	0.010405	0.010954	0.00031118	0.90886	0.9056	0.95798	0.75192	0.0073798	0.0056088	0.00032447	0.0027618	0.0027618	0.0027618
53	0.010311	0.010825	0.00030909	0.89887	0.91548	0.95721	0.75746	0.0072544	0.0056198	0.00032092	0.0027504	0.0027504	0.0027504
54	0.01036	0.011228	0.00030829	0.92613	0.89682	0.96113	0.75959	0.0071387	0.0055863	0.00031627	0.0027391	0.0027391	0.0027391
55	0.010354	0.011141	0.00030316	0.9306	0.88319	0.959	0.75544	0.0072238	0.0056032	0.00031506	0.0027277	0.0027277	0.0027277
56	0.010204	0.010981	0.00029465	0.93279	0.89572	0.96323	0.76133	0.0071755	0.005537	0.00029705	0.0027164	0.0027164	0.0027164
57	0.01029	0.011094	0.00028837	0.92789	0.89352	0.96174	0.76212	0.0071159	0.0055531	0.00029812	0.0027051	0.0027051	0.0027051
58	0.009865	0.010381	0.00028368	0.9178	0.90999	0.96124	0.75925	0.0071805	0.005547	0.00029518	0.0026937	0.0026937	0.0026937
59	0.010155	0.010835	0.00028885	0.92033	0.90036	0.96235	0.76285	0.007146	0.0055611	0.00029837	0.0026824	0.0026824	0.0026824
60	0.010221	0.010965	0.00028035	0.9116	0.90553	0.95985	0.76308	0.007072	0.0055463	0.00029737	0.0026711	0.0026711	0.0026711
61	0.010136	0.010937	0.00028378	0.91207	0.90011	0.9583	0.76388	0.0070553	0.0055563	0.00029229	0.0026597	0.0026597	0.0026597
62	0.010013	0.01099	0.00027207	0.92477	0.90999	0.96485	0.76167	0.0070956	0.0055106	0.0002763	0.0026484	0.0026484	0.0026484
63	0.0097605	0.010602	0.00026625	0.92784	0.90011	0.96307	0.76605	0.0070596	0.0055168	0.00027316	0.002637	0.002637	0.002637
64	0.0097078	0.010563	0.00025513	0.91973	0.90779	0.96211	0.76551	0.0070473	0.0055173	0.00026883	0.0026257	0.0026257	0.0026257
65	0.0096127	0.010945	0.00025859	0.9205	0.9024	0.96152	0.76842	0.0070428	0.0054977	0.00027125	0.0026144	0.0026144	0.0026144
66	0.009686	0.010686	0.000										

80	0.0091843	0.010252	0.00021763	0.90712	0.91218	0.96342	0.77526	0.0068894	0.0054417	0.00022948	0.0024443	0.0024443	0.0024443
81	0.0094227	0.010381	0.00021672	0.91818	0.89926	0.96351	0.77653	0.006806	0.0054164	0.00023052	0.002433	0.002433	0.002433
82	0.0089831	0.01014	0.00021189	0.92452	0.90121	0.96414	0.77983	0.0067542	0.0054334	0.00021842	0.0024216	0.0024216	0.0024216
83	0.0092608	0.010335	0.00020777	0.90894	0.92036	0.96379	0.77748	0.0067872	0.0054198	0.00021831	0.0024103	0.0024103	0.0024103
84	0.0093046	0.010604	0.00020419	0.91214	0.91109	0.96384	0.77849	0.0067431	0.0053989	0.00021385	0.0023989	0.0023989	0.0023989
85	0.0090332	0.010197	0.00019662	0.91277	0.9056	0.96391	0.78167	0.0067463	0.0053972	0.00020953	0.0023876	0.0023876	0.0023876
86	0.0089192	0.010333	0.00019339	0.89817	0.92206	0.96477	0.77676	0.0067599	0.0054295	0.00020412	0.0023763	0.0023763	0.0023763
87	0.0089771	0.010124	0.00019441	0.90947	0.91527	0.96342	0.7786	0.0067127	0.0053887	0.00021026	0.0023649	0.0023649	0.0023649
88	0.0088177	0.010197	0.00019317	0.90974	0.91987	0.96528	0.77865	0.0067773	0.0054501	0.0002057	0.0023536	0.0023536	0.0023536
89	0.0089566	0.010352	0.00019202	0.90857	0.92723	0.96206	0.77896	0.006698	0.0054112	0.00020484	0.0023423	0.0023423	0.0023423
90	0.0089053	0.010176	0.00019049	0.91019	0.91227	0.96241	0.77806	0.0067509	0.0054103	0.00020297	0.0023309	0.0023309	0.0023309
91	0.0090156	0.010153	0.00019438	0.91441	0.90301	0.96201	0.77837	0.0067493	0.0054458	0.00020634	0.0023196	0.0023196	0.0023196
92	0.0090625	0.010313	0.00019628	0.91118	0.91658	0.96119	0.77475	0.0067427	0.0054593	0.0002108	0.0023082	0.0023082	0.0023082
93	0.0089473	0.010238	0.00018906	0.90931	0.91352	0.96231	0.77851	0.0066932	0.0054726	0.0001977	0.0022969	0.0022969	0.0022969
94	0.0087508	0.0099462	0.0001806	0.89444	0.93015	0.96216	0.78323	0.0066876	0.0054025	0.00019115	0.0022856	0.0022856	0.0022856
95	0.0088463	0.010359	0.00018109	0.9241	0.89546	0.96299	0.78202	0.0067071	0.0054565	0.00019184	0.0022742	0.0022742	0.0022742
96	0.009162	0.010678	0.0001834	0.91239	0.90889	0.96344	0.78005	0.0067107	0.0054423	0.0001989	0.0022629	0.0022629	0.0022629
97	0.008791	0.010008	0.00018386	0.91215	0.91328	0.96259	0.78044	0.0067244	0.0054574	0.00019656	0.0022516	0.0022516	0.0022516
98	0.0087036	0.010071	0.00017873	0.90525	0.91987	0.96408	0.78316	0.0067136	0.0054065	0.00019011	0.0022402	0.0022402	0.0022402
99	0.0087739	0.0099694	0.00018057	0.91404	0.91044	0.96403	0.782	0.0066911	0.0054284	0.00019124	0.0022289	0.0022289	0.0022289
100	0.0087447	0.010358	0.00017502	0.90377	0.9067	0.96088	0.77827	0.006712	0.0054918	0.00018941	0.0022175	0.0022175	0.0022175
101	0.0086217	0.010442	0.00017135	0.90827	0.91987	0.96009	0.77958	0.0066456	0.0054585	0.00018166	0.0022062	0.0022062	0.0022062
102	0.0087568	0.010011	0.00016946	0.90817	0.91987	0.96391	0.78316	0.0066481	0.0054433	0.00018279	0.0021949	0.0021949	0.0021949
103	0.0086633	0.010041	0.00017158	0.90934	0.9138	0.96163	0.78313	0.0066489	0.0054429	0.00018582	0.0021835	0.0021835	0.0021835
104	0.0085519	0.010022	0.00017072	0.90606	0.91548	0.96167	0.78165	0.0066502	0.0054636	0.00018029	0.0021722	0.0021722	0.0021722
105	0.0086761	0.0099003	0.00016615	0.90648	0.915	0.96108	0.7811	0.0066567	0.0054949	0.00017597	0.0021609	0.0021609	0.0021609
106	0.0084057	0.009684	0.00016157	0.91174	0.90889	0.96091	0.77956	0.0066616	0.0055089	0.00017342	0.0021495	0.0021495	0.0021495
107	0.008589	0.0097871	0.00015991	0.90637	0.91379	0.96144	0.78176	0.0066375	0.0054851	0.00016973	0.0021382	0.0021382	0.0021382
108	0.0085143	0.0099416	0.00015894	0.91084	0.91987	0.96178	0.78296	0.0066363	0.0054204	0.00016836	0.0021268	0.0021268	0.0021268
109	0.0085328	0.010107	0.00015859	0.91785	0.91548	0.96101	0.78224	0.0066222	0.0054294	0.0001683	0.0021155	0.0021155	0.0021155
110	0.0083635	0.009611	0.00015435	0.91602	0.90992	0.96262	0.78413	0.0065897	0.0054436	0.00016516	0.0021042	0.0021042	0.0021042
111	0.0085796	0.010075	0.00015206	0.90783	0.91987	0.96246	0.78656	0.0066338	0.0054936	0.00016437	0.0020928	0.0020928	0.0020928
112	0.0085076	0.010063	0.00015053	0.90474	0.92206	0.96443	0.78504	0.0065681	0.0054553	0.00016105	0.0020815	0.0020815	0.0020815
113	0.0084786	0.0099633	0.00014796	0.91008	0.92211	0.96463	0.78379	0.0065916	0.0054462	0.00015696	0.0020701	0.0020701	0.0020701
114	0.0083304	0.009749	0.00014989	0.9095	0.92661	0.96442	0.78481	0.0065889	0.0054139	0.00015922	0.0020588	0.0020588	0.0020588
115	0.0083428	0.0094099	0.00014969	0.9055	0.92563	0.96347	0.7846	0.0065607	0.0054259	0.00016116	0.0020475	0.0020475	0.0020475
116	0.0082743	0.0099116	0.00014593	0.91781	0.9045	0.96053	0.78318	0.006592	0.0054896	0.00015601	0.0020361	0.0020361	0.0020361
117	0.0084071	0.00983	0.00014413	0.91272	0.92097	0.96268	0.7857	0.0066064	0.0054714	0.000156	0.0020248	0.0020248	0.0020248
118	0.0083786	0.0098513	0.00014501	0.91122	0.90999	0.96135	0.7877	0.0065854	0.0054978	0.00015335	0.0020135	0.0020135	0.0020135
119	0.0083762	0.0099043	0.00014459	0.91086	0.91977	0.96128	0.78425	0.0065833	0.0054608	0.00015507	0.0020021	0.0020021	0.0020021
120	0.0083869	0.0097734	0.00014061	0.91001	0.92097	0.96111	0.78598	0.0065864	0.0054489	0.00015251	0.0019908	0.0019908	0.0019908
121	0.0083782	0.0098377	0.0001395	0.9123	0.91349	0.96177	0.78698	0.0065689	0.0055006	0.00015109	0.0019794	0.0019794	0.0019794
122	0.0082628	0.0098394	0.00013481	0.92575	0.90231	0.96294	0.78916	0.0065006	0.005436	0.00014298	0.0019681	0.0019681	0.0019681
123	0.008118	0.0093382	0.00013264	0.9166	0.91684	0.96325	0.78813	0.0065436	0.0054279	0.00014269	0.0019568	0.0019568	0.0019568
124	0.0081978	0.0095222	0.00013471	0.91844	0.91467	0.96299	0.78919	0.0065321	0.0054308	0.00014602	0.0019454	0.0019454	0.0019454
125	0.0079994	0.009453	0.00013388	0.91389	0.91548	0.96252	0.78835	0.0065117	0.0054431	0.00014353	0.0019341	0.0019341	0.0019341
126	0.0080686	0.0096236	0.00012952	0.90859	0.91645	0.96235	0.7886	0.0065021	0.0054442	0.00013881	0.0019228	0.0019228	0.0019228
127	0.0081437	0.009606	0.00012795	0.92421	0.90121	0.96389	0.79003	0.006512	0.0054244	0.00013787	0.0019114	0.0019114	0.0019114
128	0.0082418	0.0098972	0.00012702	0.92126	0.90779	0.96284	0.78911	0.0065271	0.0054275	0.00013932	0.0019001	0.0019001	0.0019001
129	0.0078961	0.0094334	0.00012537	0.92407	0.9034	0.96313	0.78802	0.0065151	0.0054162	0.00013511	0.0018887	0.0018887	0.0018887
130	0.0080477	0.0097606	0.00012572	0.9225	0.90151	0.96362	0.78887	0.0065129	0.0054188	0.00013486	0.0018774	0.0018774	0.0018774
131	0.0080392	0.0095499	0.00012395	0.9305	0.89655	0.96253	0.7875	0.0065179	0.0054469	0.00013507	0.0018661	0.0018661	0.0018661
132	0.0081005	0.0095506	0.00012592	0.92806	0.9063	0.96419	0.78875	0.006489	0.0054205	0.00013702	0.0018547	0.0018547	0.0018547
133	0.0081852	0.0097423	0.00012658	0.9287	0.90077	0.96306	0.78969	0.0064852	0.0054403	0.00013768	0.0018434	0.0018434	0.0018434
134	0.0079321	0.0095262	0.00012163	0.92286	0.9045	0.96248	0.79107	0.0065004	0.0054308	0.00013134	0.0018321	0.0018321	0.0018321
135	0.0080643	0.0094357	0.00012351	0.93033	0.90011	0.96256	0.78948	0.00652	0.0054345	0.00013403	0.0018207	0.0018207	0.0018207
136	0.007949	0.009613	0.00011926	0.92156	0.9056	0.96261	0.79031	0.0065233	0.0054607	0.0001286	0.0018094	0.0018094	0.0018094
137	0.0078386	0.0092459	0.00011859	0.92865	0.9067	0.96389	0.7896	0.0065072	0.005479	0.00012782	0.001798	0.001798	0.001798
138	0.0078118	0.0094443	0.00011758	0.91988	0.9034	0.96344	0.78861	0.0065187	0.0054938	0.00012777	0.0017867	0.0017867	0.0017867
139	0.007912	0.0097191	0.00011488	0.91291	0.92426	0.96338	0.78871	0.0064839	0.0055162	0.00012441	0.0017754	0.0017754	0.0017754
140	0.0079859	0.0095133	0.00011274	0.9184	0.91428	0.96356	0.78782	0.0064722	0.0054689	0.00012325	0.001764	0.001764	0.001764
141	0.0079591	0.0095117	0.00011506	0.91374	0.91854	0.96345	0.79009	0.0064805	0.0054528	0.00012417	0.0017527	0.0017527	0.0017527
142	0.0080077	0.0096495	0.00011329	0.90879	0.92097	0.96302	0.79081	0.0064754	0.0054695	0.00012256	0.0017413	0.0017413	0.0017413
143	0.007892	0.0094241	0.00011098	0.91473	0.91846	0.96409	0.79059	0.0064582	0.0054722	0.00011941	0.00173	0.00173	0.00173
144	0.0077712	0.009438	0.00010904	0.93127	0.9056	0.96339	0.78731	0.0064878	0.0054746	0.00011835	0.0017187	0.0017187	0.0017187
145	0.0077571	0.0093592	0.0001064	0.92133	0.91548	0.96404	0.78693	0.0065038	0.005461	0.0001161	0.0017073	0.0017073	0.0017073
146	0.0												

162	0.0076387	0.0092511	8.8776e-05	0.92633	0.9056	0.96503	0.79415	0.0064193	0.0054446	9.9042e-05	0.0015146	0.0015146	0.0015146
163	0.0075437	0.0092218	8.9041e-05	0.93675	0.8941	0.96381	0.79441	0.006413	0.0054542	9.8654e-05	0.0015032	0.0015032	0.0015032
164	0.0077185	0.0093956	8.7235e-05	0.93208	0.89901	0.96446	0.79348	0.0064267	0.0054739	9.7815e-05	0.0014919	0.0014919	0.0014919
165	0.0074964	0.0092897	8.8081e-05	0.92802	0.90011	0.96569	0.795	0.0064137	0.0054939	9.7593e-05	0.0014806	0.0014806	0.0014806
166	0.007711	0.0092797	8.6759e-05	0.92558	0.90231	0.96481	0.79696	0.0064118	0.0054806	9.6518e-05	0.0014692	0.0014692	0.0014692
167	0.0075152	0.0091595	8.4022e-05	0.91783	0.90734	0.96367	0.79382	0.0064155	0.0054927	9.4901e-05	0.0014579	0.0014579	0.0014579
168	0.0076489	0.0091951	8.5052e-05	0.91198	0.92123	0.96519	0.79178	0.0064394	0.0054821	9.3436e-05	0.0014466	0.0014466	0.0014466
169	0.0076458	0.0093279	8.1606e-05	0.92406	0.90831	0.96473	0.79197	0.0064225	0.0054685	9.1081e-05	0.0014352	0.0014352	0.0014352
170	0.0075509	0.0093547	8.0116e-05	0.92034	0.9131	0.96385	0.7914	0.0064246	0.0054919	9.0367e-05	0.0014239	0.0014239	0.0014239
171	0.0074564	0.0090499	8.0122e-05	0.93082	0.90092	0.96497	0.79098	0.0064351	0.0054883	8.997e-05	0.0014125	0.0014125	0.0014125
172	0.00758	0.0093645	7.9778e-05	0.93214	0.90121	0.96615	0.79309	0.0064294	0.0054784	8.9355e-05	0.0014012	0.0014012	0.0014012
173	0.0074806	0.0093029	7.6895e-05	0.93261	0.90011	0.96529	0.79358	0.0064099	0.0054581	8.7841e-05	0.0013899	0.0013899	0.0013899
174	0.0075784	0.0093737	7.5887e-05	0.92604	0.90706	0.96593	0.7928	0.0063979	0.0054774	8.7134e-05	0.0013785	0.0013785	0.0013785
175	0.007425	0.0090126	7.5578e-05	0.92304	0.9056	0.96553	0.79248	0.0063787	0.0054853	8.6284e-05	0.0013672	0.0013672	0.0013672
176	0.0074588	0.0091667	7.5058e-05	0.92778	0.89791	0.96504	0.7933	0.006375	0.0054848	8.5462e-05	0.0013559	0.0013559	0.0013559
177	0.0073496	0.0088681	7.4132e-05	0.92779	0.9034	0.96522	0.79279	0.0063743	0.005504	8.4738e-05	0.0013445	0.0013445	0.0013445
178	0.0074448	0.0090269	7.3684e-05	0.91888	0.90768	0.9644	0.79362	0.0063556	0.0054968	8.3719e-05	0.0013332	0.0013332	0.0013332
179	0.0073677	0.0091446	7.1924e-05	0.91428	0.91319	0.96408	0.79226	0.0063513	0.0055042	8.272e-05	0.0013218	0.0013218	0.0013218
180	0.0073332	0.0092597	7.1665e-05	0.91868	0.90522	0.96414	0.79299	0.0063422	0.0055095	8.1706e-05	0.0013105	0.0013105	0.0013105
181	0.0072116	0.0091355	6.9644e-05	0.91425	0.91109	0.96489	0.79409	0.006352	0.0054904	7.9903e-05	0.0012992	0.0012992	0.0012992
182	0.0071727	0.0088778	6.894e-05	0.91826	0.91218	0.96467	0.79527	0.0063497	0.0054963	7.9167e-05	0.0012878	0.0012878	0.0012878
183	0.0073316	0.0091882	6.797e-05	0.91709	0.91109	0.96433	0.79418	0.0063446	0.0055212	7.8463e-05	0.0012765	0.0012765	0.0012765
184	0.0075144	0.0094942	6.6598e-05	0.92091	0.90999	0.96467	0.79554	0.0063476	0.0055074	7.7178e-05	0.0012652	0.0012652	0.0012652
185	0.0072757	0.0088985	6.6359e-05	0.92453	0.90091	0.96473	0.79371	0.0063559	0.005493	7.6661e-05	0.0012538	0.0012538	0.0012538
186	0.007342	0.0089573	6.6122e-05	0.92441	0.90889	0.96569	0.79515	0.0063716	0.0054896	7.635e-05	0.0012425	0.0012425	0.0012425
187	0.0074393	0.0090703	6.4982e-05	0.92483	0.90999	0.96507	0.79491	0.0063812	0.0054847	7.5487e-05	0.0012311	0.0012311	0.0012311
188	0.0071894	0.0090127	6.4457e-05	0.92622	0.90945	0.96461	0.79485	0.006373	0.005492	7.4529e-05	0.0012198	0.0012198	0.0012198
189	0.0072321	0.0090614	6.3013e-05	0.90462	0.92755	0.96485	0.79482	0.0063877	0.0054958	7.3281e-05	0.0012085	0.0012085	0.0012085
190	0.0073781	0.0093853	6.7561e-05	0.90552	0.92579	0.96304	0.7929	0.0063802	0.0055168	7.303e-05	0.0011971	0.0011971	0.0011971
191	0.0074116	0.0092861	6.2595e-05	0.92578	0.9045	0.9627	0.79398	0.0063782	0.005542	7.2841e-05	0.0011858	0.0011858	0.0011858
192	0.007266	0.0090035	6.13e-05	0.92141	0.90999	0.96367	0.79611	0.0063695	0.0055403	7.1695e-05	0.0011744	0.0011744	0.0011744
193	0.0071633	0.0088973	6.1131e-05	0.92173	0.90489	0.96312	0.79283	0.0063798	0.0055484	7.0566e-05	0.0011631	0.0011631	0.0011631
194	0.0071902	0.0090945	6.0195e-05	0.92575	0.9034	0.96274	0.79287	0.0063714	0.0055499	7.0058e-05	0.0011518	0.0011518	0.0011518
195	0.0072813	0.0091301	5.9125e-05	0.92663	0.90109	0.9628	0.79478	0.0063664	0.0055296	6.9483e-05	0.0011404	0.0011404	0.0011404
196	0.0072792	0.0091204	5.9302e-05	0.92258	0.9034	0.9632	0.79579	0.0063561	0.0054957	6.8454e-05	0.0011291	0.0011291	0.0011291
197	0.0072531	0.0091795	5.7979e-05	0.92177	0.90539	0.96389	0.79581	0.0063486	0.0054908	6.7212e-05	0.0011178	0.0011178	0.0011178
198	0.0073343	0.0093076	5.7387e-05	0.92176	0.9034	0.96368	0.79616	0.006337	0.0055048	6.6388e-05	0.0011064	0.0011064	0.0011064
199	0.0071503	0.0089736	5.6726e-05	0.9329	0.89572	0.96392	0.79501	0.006344	0.0055287	6.4909e-05	0.0010951	0.0010951	0.0010951
200	0.0072301	0.0090398	5.728e-05	0.92111	0.90889	0.9639	0.7967	0.0063546	0.0055385	6.4535e-05	0.0010837	0.0010837	0.0010837
201	0.0072039	0.0092408	5.5254e-05	0.92591	0.90011	0.96332	0.79649	0.0063674	0.0055535	6.3698e-05	0.0010724	0.0010724	0.0010724
202	0.0071888	0.0090101	5.5442e-05	0.9233	0.90889	0.9636	0.79634	0.0063775	0.0055402	6.2947e-05	0.0010611	0.0010611	0.0010611
203	0.0071291	0.0088604	5.446e-05	0.9237	0.90999	0.96521	0.79735	0.0063769	0.0055201	6.2289e-05	0.0010497	0.0010497	0.0010497
204	0.0072199	0.0088852	5.4453e-05	0.93249	0.90977	0.96619	0.79533	0.006372	0.0055064	6.1133e-05	0.0010384	0.0010384	0.0010384
205	0.0071702	0.0090991	5.2905e-05	0.92504	0.90999	0.96526	0.7976	0.006374	0.005508	6.0005e-05	0.0010271	0.0010271	0.0010271
206	0.0070163	0.0087949	5.1625e-05	0.92086	0.91218	0.9647	0.79761	0.0063678	0.0055103	5.8625e-05	0.0010157	0.0010157	0.0010157
207	0.0071584	0.0091063	5.101e-05	0.92128	0.9067	0.96476	0.79886	0.0063591	0.0055222	5.785e-05	0.0010044	0.0010044	0.0010044
208	0.0070855	0.0089766	5.1039e-05	0.92164	0.90779	0.96449	0.79679	0.0063609	0.0055249	5.6984e-05	0.00099304	0.00099304	0.00099304
209	0.0071072	0.0090263	5.1243e-05	0.92959	0.90231	0.96429	0.79719	0.0063588	0.0055259	5.6292e-05	0.0009817	0.0009817	0.0009817
210	0.0071516	0.0089616	4.9609e-05	0.92375	0.9067	0.96403	0.7961	0.006353	0.005551	5.556e-05	0.00097037	0.00097037	0.00097037
211	0.0070841	0.0087981	4.9451e-05	0.92673	0.90246	0.96389	0.79527	0.0063607	0.005577	5.4805e-05	0.00095903	0.00095903	0.00095903
212	0.0072756	0.0092064	5.0791e-05	0.92545	0.9067	0.96364	0.79707	0.0063598	0.0055854	5.431e-05	0.00094769	0.00094769	0.00094769
213	0.0070672	0.0089638	4.9217e-05	0.92473	0.90779	0.96502	0.79777	0.0063676	0.0055721	5.3606e-05	0.00093635	0.00093635	0.00093635
214	0.0070239	0.0088737	4.7462e-05	0.92414	0.90938	0.96513	0.79669	0.0063696	0.0055733	5.2562e-05	0.00092501	0.00092501	0.00092501
215	0.0071327	0.0092546	4.8072e-05	0.92699	0.90593	0.96361	0.79675	0.0063659	0.0055738	5.199e-05	0.00091368	0.00091368	0.00091368
216	0.0069473	0.0087621	4.6749e-05	0.92546	0.9056	0.96321	0.7969	0.0063515	0.0055717	5.0902e-05	0.00090234	0.00090234	0.00090234
217	0.0072478	0.0092817	4.6659e-05	0.92476	0.90395	0.96312	0.79853	0.006338	0.0055587	4.9999e-05	0.000891	0.000891	0.000891
218	0.0071361	0.0091911	4.5986e-05	0.92604	0.90714	0.96436	0.79765	0.006332	0.0055516	4.9276e-05	0.00087966	0.00087966	0.00087966
219	0.0069281	0.0086456	4.5226e-05	0.92593	0.90571	0.96437	0.79676	0.0063317	0.0055443	4.8291e-05	0.00086832	0.00086832	0.00086832
220	0.0070581	0.0090343	4.5611e-05	0.92612	0.90816	0.96464	0.79782	0.0063322	0.0055411	4.7451e-05	0.00085699	0.00085699	0.00085699
221	0.0071118	0.0088492	4.4194e-05	0.92434	0.91195	0.9646	0.79735	0.0063298	0.0055421	4.653e-05	0.00084565	0.00084565	0.00084565
222	0.006961	0.0089381	4.4546e-05	0.92256	0.9056	0.96474	0.79852	0.0063295	0.0055555	4.5504e-05	0.00083431	0.00083431	0.00083431
223	0.0070867	0.0089351	4.3579e-05	0.91886	0.90999	0.96518	0.79806	0.0063326	0.0055575	4.4336e-05	0.00082297	0.00082297	0.00082297
224	0.00707	0.0090882	4.3727e-05	0.92211	0.90963	0.96503	0.79771	0.0063295	0.0055564	4.3566e-05	0.00081163	0.00081163	0.00081163
225	0.006975	0.0089177	4.2153e-05	0.92211	0.90972	0.96605	0.79747	0.0063239	0.0055618	4.2475e-05	0.0008003	0.0008003	0.0008003
226	0.0070046	0.0089246	4.2311e-05	0.92161	0.91109	0.96585	0.79781	0.0063237	0.0055651	4.1555e-05	0.00078896	0.00078896	0.00078896
227	0.0070677	0.0091427	4.1545e-05	0.92259	0.90999	0.96496	0.79784	0					

244	0.0069137	0.0088272	3.5142e-05	0.927	0.9034	0.96377	0.79678	0.0063035	0.0056218	3.0507e-05	0.00058487	0.00058487	0.00058487
245	0.0070316	0.0088845	3.5081e-05	0.92698	0.90579	0.96416	0.79564	0.0063031	0.0056239	3.0042e-05	0.00057354	0.00057354	0.00057354
246	0.0069226	0.008875	3.5359e-05	0.92295	0.90724	0.96424	0.79745	0.0063011	0.0056216	2.9669e-05	0.0005622	0.0005622	0.0005622
247	0.0070108	0.008814	3.4846e-05	0.92297	0.90749	0.9644	0.79713	0.0063059	0.0056223	2.9219e-05	0.00055086	0.00055086	0.00055086
248	0.0070382	0.0089721	3.4303e-05	0.92003	0.90923	0.96409	0.79593	0.0063107	0.0056137	2.871e-05	0.00053952	0.00053952	0.00053952
249	0.006919	0.0089528	3.4632e-05	0.91807	0.91024	0.96323	0.79711	0.0063139	0.0056168	2.8196e-05	0.00052818	0.00052818	0.00052818

ANNEXE B

RÉSULTATS EXPÉRIMENTAUX DE LA DÉTECTION ET DU TRACKING

bounding_boxes

frame number	cow ID	x1	y1	x2	y2	confidence	track coordinates	pixels per inch width	pixels per inch height
34	1	2637.0	311.0	2939.0	531.0	0.5824455618858337	(2788.0; 421.0)	12.08	3.3846153846153846
35	1	2619.0	308.0	2924.0	525.0	0.5497276186943054	(2771.5; 416.5)	12.2	3.3384615384615386
36	1	2603.0	306.0	2929.0	528.0	0.8000552654266357	(2766.0; 417.0)	13.04	3.4153846153846152
37	1	2594.0	302.0	2918.0	527.0	0.7948962450027466	(2756.0; 414.5)	12.96	3.4615384615384617
38	1	2597.0	306.0	2859.0	525.0	0.7544577717781067	(2728.0; 415.5)	10.48	3.3692307692307693
39	1	2592.0	305.0	2879.0	524.0	0.8151072263717651	(2735.5; 414.5)	11.48	3.3692307692307693
40	1	2581.0	305.0	2863.0	522.0	0.8375394940376282	(2722.0; 413.5)	11.28	3.3384615384615386
41	1	2574.0	299.0	2859.0	529.0	0.8425750732421875	(2716.5; 414.0)	11.4	3.5384615384615383
42	1	2561.0	296.0	2853.0	530.0	0.8549144864082336	(2707.0; 413.0)	11.68	3.6
43	1	2553.0	294.0	2856.0	531.0	0.8493637442588806	(2704.5; 412.5)	12.12	3.646153846153846
44	1	2555.0	299.0	2856.0	526.0	0.8299857378005981	(2705.5; 412.5)	12.04	3.4923076923076923
45	1	2549.0	298.0	2854.0	525.0	0.8190126419067383	(2701.5; 411.5)	12.2	3.4923076923076923
46	1	2545.0	296.0	2848.0	520.0	0.805674135684967	(2696.5; 408.0)	12.12	3.4461538461538463
47	1	2531.0	297.0	2840.0	521.0	0.6715324521064758	(2685.5; 409.0)	12.36	3.4461538461538463
48	1	2520.0	297.0	2833.0	515.0	0.7825420498847961	(2676.5; 406.0)	12.52	3.353846153846154
49	1	2522.0	297.0	2836.0	524.0	0.8189658522605896	(2679.0; 410.5)	12.56	3.4923076923076923
50	1	2509.0	294.0	2838.0	521.0	0.8540831804275513	(2673.5; 407.5)	13.16	3.4923076923076923
51	1	2504.0	294.0	2843.0	525.0	0.8521842956542969	(2673.5; 409.5)	13.56	3.5538461538461537
52	1	2501.0	293.0	2844.0	522.0	0.8836190104484558	(2672.5; 407.5)	13.72	3.523076923076923
53	1	2499.0	293.0	2840.0	521.0	0.8800397515296936	(2669.5; 407.0)	13.64	3.5076923076923077
54	1	2502.0	290.0	2835.0	518.0	0.892309844493866	(2668.5; 404.0)	13.32	3.5076923076923077
55	1	2499.0	288.0	2829.0	517.0	0.8919473886489868	(2664.0; 402.5)	13.2	3.523076923076923
56	1	2499.0	285.0	2827.0	515.0	0.8902068138122559	(2663.0; 400.0)	13.12	3.5384615384615383
57	1	2497.0	289.0	2829.0	520.0	0.8854312896728516	(2663.0; 404.5)	13.28	3.5538461538461537
58	1	2496.0	290.0	2822.0	521.0	0.8994666934013367	(2659.0; 405.5)	13.04	3.5538461538461537
59	1	2497.0	289.0	2811.0	521.0	0.8915044665336609	(2654.0; 405.0)	12.56	3.5692307692307694
60	1	2494.0	291.0	2807.0	520.0	0.8874498009681702	(2650.5; 405.5)	12.52	3.523076923076923
61	1	2494.0	291.0	2800.0	519.0	0.8790745139122009	(2647.0; 405.0)	12.24	3.5076923076923077
62	1	2489.0	290.0	2798.0	520.0	0.8721068501472473	(2643.5; 405.0)	12.36	3.5384615384615383
63	1	2489.0	292.0	2797.0	522.0	0.8901376128196716	(2643.0; 407.0)	12.32	3.5384615384615383
64	1	2488.0	289.0	2792.0	522.0	0.8837772011756897	(2640.0; 405.5)	12.16	3.5846153846153848
65	1	2490.0	290.0	2786.0	522.0	0.8840528726577759	(2638.0; 406.0)	11.84	3.5692307692307694
66	1	2489.0	290.0	2782.0	523.0	0.8821958899497986	(2635.5; 406.5)	11.72	3.5846153846153848
67	1	2483.0	291.0	2780.0	525.0	0.8699418902397156	(2631.5; 408.0)	11.88	3.6
68	1	2483.0	292.0	2775.0	525.0	0.8637036085128784	(2629.0; 408.5)	11.68	3.5846153846153848
69	1	2478.0	292.0	2766.0	524.0	0.8310407996177673	(2622.0; 408.0)	11.52	3.5692307692307694
70	1	2482.0	291.0	2764.0	524.0	0.790809690952301	(2623.0; 407.5)	11.28	3.5846153846153848
71	1	2494.0	286.0	2763.0	519.0	0.7140213251113892	(2628.5; 402.5)	10.76	3.5846153846153848
72	1	2472.0	288.0	2752.0	522.0	0.8005737066268921	(2612.0; 405.0)	11.2	3.6
73	1	2470.0	285.0	2731.0	515.0	0.7003137469291687	(2600.5; 400.0)	10.44	3.5384615384615383
74	1	2469.0	285.0	2727.0	514.0	0.6823370456695557	(2598.0; 399.5)	10.32	3.523076923076923
75	1	2472.0	283.0	2719.0	513.0	0.617258608341217	(2595.5; 398.0)	9.88	3.5384615384615383
76	1	2470.0	282.0	2721.0	513.0	0.6955341100692749	(2595.5; 397.5)	10.04	3.5538461538461537
77	1	2470.0	283.0	2716.0	513.0	0.7483557462692261	(2593.0; 398.0)	9.84	3.5384615384615383
78	1	2469.0	283.0	2703.0	512.0	0.7246719598770142	(2586.0; 397.5)	9.36	3.523076923076923

79	1	2512.0	279.0	2698.0	521.0	0.5347320437431335	(2605.0; 400.0)	7.44	3.723076923076923
80	1	2465.0	280.0	2692.0	511.0	0.6927498579025269	(2578.5; 395.5)	9.08	3.5538461538461537
81	1	2547.0	277.0	2696.0	513.0	0.5262492299079895	(2621.5; 395.0)	5.96	3.6307692307692307
86	1	2456.0	284.0	2686.0	517.0	0.6853037476539612	(2571.0; 400.5)	9.2	3.5846153846153848
88	1	2463.0	286.0	2680.0	520.0	0.7132449150085449	(2571.5; 403.0)	8.68	3.6
89	1	2461.0	284.0	2682.0	522.0	0.7757995128631592	(2571.5; 403.0)	8.84	3.6615384615384614
90	1	2460.0	283.0	2679.0	524.0	0.7649314999580383	(2569.5; 403.5)	8.76	3.707692307692308
91	1	2461.0	282.0	2675.0	528.0	0.8073890805244446	(2568.0; 405.0)	8.56	3.7846153846153845
92	1	2469.0	283.0	2671.0	517.0	0.7798364758491516	(2570.0; 400.0)	8.08	3.6
93	1	2465.0	286.0	2662.0	534.0	0.7493730783462524	(2563.5; 410.0)	7.88	3.8153846153846156
94	1	2454.0	283.0	2669.0	538.0	0.8107456564903259	(2561.5; 410.5)	8.6	3.923076923076923
95	1	2458.0	283.0	2659.0	541.0	0.7411011457443237	(2558.5; 412.0)	8.04	3.9692307692307693
96	1	2462.0	289.0	2649.0	529.0	0.6319360733032227	(2555.5; 409.0)	7.48	3.6923076923076925
97	1	2460.0	287.0	2646.0	535.0	0.6651941537857056	(2553.0; 411.0)	7.44	3.8153846153846156
98	1	2464.0	286.0	2643.0	529.0	0.6153692603111267	(2553.5; 407.5)	7.16	3.7384615384615385
99	1	2471.0	287.0	2643.0	527.0	0.6468645930290222	(2557.0; 407.0)	6.88	3.6923076923076925
100	1	2465.0	288.0	2634.0	534.0	0.6067129373550415	(2549.5; 411.0)	6.76	3.7846153846153845
101	1	2469.0	289.0	2628.0	532.0	0.6066532135009766	(2548.5; 410.5)	6.36	3.7384615384615385
102	1	2467.0	292.0	2625.0	539.0	0.6688880920410156	(2546.0; 415.5)	6.32	3.8
103	1	2469.0	296.0	2620.0	531.0	0.5729382038116455	(2544.5; 413.5)	6.04	3.6153846153846154
104	1	2471.0	297.0	2613.0	538.0	0.5179815292358398	(2542.0; 417.5)	5.68	3.707692307692308
105	1	2472.0	297.0	2617.0	536.0	0.5370510816574097	(2544.5; 416.5)	5.8	3.6769230769230767
106	1	2469.0	303.0	2613.0	539.0	0.554000973701477	(2541.0; 421.0)	5.76	3.6307692307692307
107	1	2466.0	323.0	2602.0	543.0	0.5610132217407227	(2534.0; 433.0)	5.44	3.3846153846153846
108	1	2466.0	318.0	2607.0	548.0	0.6513014435768127	(2536.5; 433.0)	5.64	3.5384615384615383
109	1	2467.0	319.0	2607.0	548.0	0.6104265451431274	(2537.0; 433.5)	5.6	3.523076923076923
110	1	2468.0	318.0	2594.0	542.0	0.6626967191696167	(2531.0; 430.0)	5.04	3.4461538461538463
111	1	2470.0	322.0	2590.0	545.0	0.6989986896514893	(2530.0; 433.5)	4.8	3.4307692307692306
112	1	2470.0	323.0	2591.0	545.0	0.7073798775672913	(2530.5; 434.0)	4.84	3.4153846153846152
113	1	2470.0	319.0	2588.0	558.0	0.6887959241867065	(2529.0; 438.5)	4.72	3.6769230769230767
114	1	2471.0	316.0	2591.0	559.0	0.6340466141700745	(2531.0; 437.5)	4.8	3.7384615384615385
115	1	2466.0	316.0	2589.0	566.0	0.6711715459823608	(2527.5; 441.0)	4.92	3.8461538461538463
116	1	2469.0	319.0	2591.0	566.0	0.6849319934844971	(2530.0; 442.5)	4.88	3.8
117	1	2471.0	324.0	2595.0	563.0	0.6590957045555115	(2533.0; 443.5)	4.96	3.6769230769230767
118	1	2472.0	313.0	2592.0	567.0	0.6542323231697083	(2532.0; 440.0)	4.8	3.9076923076923076
119	1	2471.0	314.0	2592.0	570.0	0.6585662364959717	(2531.5; 442.0)	4.84	3.9384615384615387
120	1	2472.0	323.0	2593.0	571.0	0.6484410166740417	(2532.5; 447.0)	4.84	3.8153846153846156
121	1	2472.0	318.0	2595.0	574.0	0.6785617470741272	(2533.5; 446.0)	4.92	3.9384615384615387
122	1	2472.0	316.0	2597.0	578.0	0.7154222726821899	(2534.5; 447.0)	5.0	4.030769230769231
123	1	2469.0	317.0	2598.0	580.0	0.7292739748954773	(2533.5; 448.5)	5.16	4.046153846153846
124	1	2469.0	314.0	2600.0	580.0	0.6761454343795776	(2534.5; 447.0)	5.24	4.092307692307692
125	1	2470.0	307.0	2600.0	572.0	0.670466423034668	(2535.0; 439.5)	5.2	4.076923076923077
126	1	2471.0	312.0	2609.0	572.0	0.6351261138916016	(2540.0; 442.0)	5.52	4.0
127	1	2475.0	323.0	2611.0	564.0	0.6453339457511902	(2543.0; 443.5)	5.44	3.707692307692308
128	1	2479.0	315.0	2615.0	569.0	0.6821182370185852	(2547.0; 442.0)	5.44	3.9076923076923076
129	1	2475.0	318.0	2619.0	565.0	0.6852273941040039	(2547.0; 441.5)	5.76	3.8
130	1	2472.0	326.0	2620.0	570.0	0.7352883219718933	(2546.0; 448.0)	5.92	3.753846153846154

131	1	2477.0	320.0	2640.0	574.0	0.8006556034088135	(2558.5; 447.0)	6.52	3.9076923076923076
131	3	2712.0	333.0	2836.0	523.0	0.5340995192527771	(2774.0; 428.0)	4.96	2.923076923076923
132	1	2478.0	317.0	2646.0	576.0	0.7119672298431396	(2562.0; 446.5)	6.72	3.9846153846153847
132	3	2710.0	331.0	2842.0	525.0	0.5637737512588501	(2776.0; 428.0)	5.28	2.9846153846153847
133	1	2470.0	313.0	2652.0	584.0	0.8371302485466003	(2561.0; 448.5)	7.28	4.1692307692307695
133	3	2706.0	335.0	2846.0	525.0	0.5360294580459595	(2776.0; 430.0)	5.6	2.923076923076923
134	1	2475.0	312.0	2658.0	589.0	0.8487340807914734	(2566.5; 450.5)	7.32	4.2615384615384615
134	3	2700.0	329.0	2864.0	525.0	0.5937749743461609	(2782.0; 427.0)	6.56	3.0153846153846153
135	1	2480.0	318.0	2667.0	589.0	0.8313549757003784	(2573.5; 453.5)	7.48	4.1692307692307695
135	3	2690.0	324.0	2873.0	524.0	0.6099890470504761	(2781.5; 424.0)	7.32	3.076923076923077
136	1	2482.0	316.0	2674.0	588.0	0.8001614212989807	(2578.0; 452.0)	7.68	4.184615384615385
137	1	2482.0	314.0	2679.0	591.0	0.8073869347572327	(2580.5; 452.5)	7.88	4.2615384615384615
138	1	2481.0	319.0	2686.0	594.0	0.8089120388031006	(2583.5; 456.5)	8.2	4.230769230769231
139	1	2484.0	315.0	2687.0	591.0	0.7302960157394409	(2585.5; 453.0)	8.12	4.246153846153846
140	1	2482.0	322.0	2695.0	591.0	0.7906273603439331	(2588.5; 456.5)	8.52	4.138461538461539
140	3	2693.0	321.0	2939.0	531.0	0.5182674527168274	(2816.0; 426.0)	9.84	3.230769230769231
141	1	2480.0	326.0	2701.0	597.0	0.8117008209228516	(2590.5; 461.5)	8.84	4.1692307692307695
142	1	2481.0	307.0	2705.0	598.0	0.841418445110321	(2593.0; 452.5)	8.96	4.476923076923077
143	1	2477.0	304.0	2719.0	596.0	0.8026859760284424	(2598.0; 450.0)	9.68	4.492307692307692
144	1	2478.0	300.0	2729.0	595.0	0.8292548656463623	(2603.5; 447.5)	10.04	4.538461538461538
146	1	2477.0	286.0	2649.0	585.0	0.5598263740539551	(2563.0; 435.5)	6.88	4.6
147	1	2477.0	305.0	2700.0	593.0	0.5108327269554138	(2588.5; 449.0)	8.92	4.430769230769231
147	3	2800.0	324.0	2956.0	533.0	0.510608971118927	(2878.0; 428.5)	6.24	3.2153846153846155
148	1	2473.0	291.0	2649.0	590.0	0.6086329817771912	(2561.0; 440.5)	7.04	4.6
148	3	2834.0	325.0	2951.0	534.0	0.5146425366401672	(2892.5; 429.5)	4.68	3.2153846153846155
149	1	2473.0	291.0	2659.0	585.0	0.5501748919487	(2566.0; 438.0)	7.44	4.523076923076923
150	1	2470.0	289.0	2648.0	586.0	0.5226550102233887	(2559.0; 437.5)	7.12	4.569230769230769
151	1	2464.0	288.0	2621.0	579.0	0.5311532020568848	(2542.5; 433.5)	6.28	4.476923076923077
152	1	2470.0	292.0	2644.0	579.0	0.6303433179855347	(2557.0; 435.5)	6.96	4.415384615384616
152	3	2633.0	324.0	2834.0	542.0	0.5243926644325256	(2733.5; 433.0)	8.04	3.353846153846154
153	1	2467.0	292.0	2625.0	571.0	0.6351529359817505	(2546.0; 431.5)	6.32	4.292307692307692
153	3	2672.0	317.0	2836.0	532.0	0.5956828594207764	(2754.0; 424.5)	6.56	3.3076923076923075
154	1	2472.0	294.0	2651.0	583.0	0.7101883888244629	(2561.5; 438.5)	7.16	4.446153846153846
155	1	2471.0	294.0	2654.0	587.0	0.7068049907684326	(2562.5; 440.5)	7.32	4.507692307692308
156	1	2472.0	293.0	2666.0	593.0	0.6753859519958496	(2569.0; 443.0)	7.76	4.615384615384615
157	1	2470.0	293.0	2634.0	579.0	0.7074088454246521	(2552.0; 436.0)	6.56	4.4
157	3	2552.0	317.0	2867.0	579.0	0.5507038831710815	(2709.5; 448.0)	12.6	4.030769230769231
158	1	2468.0	292.0	2633.0	579.0	0.7349969744682312	(2550.5; 435.5)	6.6	4.415384615384616
159	3	2545.0	314.0	2871.0	582.0	0.5338634848594666	(2708.0; 448.0)	13.04	4.123076923076923
160	1	2468.0	300.0	2702.0	603.0	0.5599960684776306	(2585.0; 451.5)	9.36	4.661538461538462
161	1	2465.0	298.0	2701.0	606.0	0.6362121105194092	(2583.0; 452.0)	9.44	4.7384615384615385
161	3	2620.0	309.0	2880.0	559.0	0.5605711340904236	(2750.0; 434.0)	10.4	3.8461538461538463
162	1	2463.0	296.0	2707.0	614.0	0.6361831426620483	(2585.0; 455.0)	9.76	4.892307692307693
162	3	2599.0	309.0	2869.0	563.0	0.6041364073753357	(2734.0; 436.0)	10.8	3.9076923076923076
163	1	2514.0	306.0	2852.0	603.0	0.6561341285705566	(2683.0; 454.5)	13.52	4.569230769230769
164	1	2496.0	303.0	2836.0	612.0	0.647179365158081	(2666.0; 457.5)	13.6	4.753846153846154
165	1	2481.0	302.0	2798.0	611.0	0.5815132260322571	(2639.5; 456.5)	12.68	4.753846153846154

166	1	2504.0	304.0	2830.0	620.0	0.5944629311561584	(2667.0; 462.0)	13.04	4.861538461538461
167	1	2535.0	313.0	2830.0	614.0	0.6847939491271973	(2682.5; 463.5)	11.8	4.630769230769231
168	1	2540.0	314.0	2844.0	616.0	0.5684598088264465	(2692.0; 465.0)	12.16	4.6461538461538465
169	3	2523.0	305.0	2833.0	608.0	0.6284843683242798	(2678.0; 456.5)	12.4	4.661538461538462
170	1	2487.0	303.0	2805.0	619.0	0.5665715336799622	(2646.0; 461.0)	12.72	4.861538461538461
171	1	2485.0	303.0	2813.0	621.0	0.6830160021781921	(2649.0; 462.0)	13.12	4.892307692307693
172	3	2520.0	302.0	2842.0	618.0	0.7661447525024414	(2681.0; 460.0)	12.88	4.861538461538461
173	3	2517.0	302.0	2838.0	618.0	0.7519664764404297	(2677.5; 460.0)	12.84	4.861538461538461
174	3	2500.0	302.0	2836.0	619.0	0.7285733819007874	(2668.0; 460.5)	13.44	4.876923076923077
175	3	2501.0	301.0	2838.0	616.0	0.7030370831489563	(2669.5; 458.5)	13.48	4.846153846153846
176	3	2474.0	299.0	2808.0	620.0	0.6284704804420471	(2641.0; 459.5)	13.36	4.938461538461539
177	3	2485.0	298.0	2834.0	620.0	0.6479578614234924	(2659.5; 459.0)	13.96	4.953846153846154
178	3	2469.0	295.0	2824.0	621.0	0.6935847401618958	(2646.5; 458.0)	14.2	5.015384615384615
179	3	2474.0	294.0	2830.0	620.0	0.7480589747428894	(2652.0; 457.0)	14.24	5.015384615384615
180	3	2470.0	294.0	2831.0	622.0	0.8154299259185791	(2650.5; 458.0)	14.44	5.046153846153846
181	3	2470.0	294.0	2829.0	621.0	0.8374931216239929	(2649.5; 457.5)	14.36	5.030769230769231
182	3	2468.0	294.0	2821.0	623.0	0.8632487058639526	(2644.5; 458.5)	14.12	5.061538461538461
183	3	2467.0	293.0	2819.0	626.0	0.869108259677887	(2643.0; 459.5)	14.08	5.123076923076923
184	3	2467.0	293.0	2815.0	627.0	0.8684332966804504	(2641.0; 460.0)	13.92	5.138461538461539
185	3	2466.0	293.0	2813.0	628.0	0.8738856315612793	(2639.5; 460.5)	13.88	5.153846153846154
186	3	2471.0	295.0	2812.0	627.0	0.8576186895370483	(2641.5; 461.0)	13.64	5.107692307692307
187	3	2475.0	293.0	2804.0	626.0	0.8397909998893738	(2639.5; 459.5)	13.16	5.123076923076923
188	3	2471.0	293.0	2807.0	627.0	0.8500420451164246	(2639.0; 460.0)	13.44	5.138461538461539
189	3	2473.0	294.0	2807.0	626.0	0.8432556986808777	(2640.0; 460.0)	13.36	5.107692307692307
190	3	2471.0	295.0	2808.0	626.0	0.8522794842720032	(2639.5; 460.5)	13.48	5.092307692307692
191	3	2476.0	296.0	2806.0	625.0	0.8344446420669556	(2641.0; 460.5)	13.2	5.061538461538461
192	3	2482.0	298.0	2805.0	623.0	0.7849193811416626	(2643.5; 460.5)	12.92	5.0
193	3	2490.0	300.0	2802.0	622.0	0.7482295632362366	(2646.0; 461.0)	12.48	4.953846153846154
194	3	2481.0	298.0	2797.0	621.0	0.7140882611274719	(2639.0; 459.5)	12.64	4.969230769230769
195	3	2475.0	297.0	2794.0	621.0	0.7269479036331177	(2634.5; 459.0)	12.76	4.984615384615385
196	3	2472.0	296.0	2794.0	624.0	0.7943413853645325	(2633.0; 460.0)	12.88	5.046153846153846
197	3	2470.0	296.0	2793.0	624.0	0.7821377515792847	(2631.5; 460.0)	12.92	5.046153846153846
198	3	2471.0	296.0	2791.0	624.0	0.7971057295799255	(2631.0; 460.0)	12.8	5.046153846153846
199	3	2469.0	295.0	2786.0	625.0	0.8089714050292969	(2627.5; 460.0)	12.68	5.076923076923077
200	3	2466.0	294.0	2783.0	626.0	0.8107264041900635	(2624.5; 460.0)	12.68	5.107692307692307
201	3	2466.0	294.0	2777.0	626.0	0.8093075752258301	(2621.5; 460.0)	12.44	5.107692307692307
202	3	2466.0	293.0	2778.0	618.0	0.8188021779060364	(2622.0; 455.5)	12.48	5.0
203	3	2472.0	294.0	2775.0	624.0	0.8067160248756409	(2623.5; 459.0)	12.12	5.076923076923077
204	3	2471.0	293.0	2773.0	625.0	0.8007729053497314	(2622.0; 459.0)	12.08	5.107692307692307
205	3	2470.0	294.0	2771.0	618.0	0.8098477125167847	(2620.5; 456.0)	12.04	4.984615384615385
206	3	2471.0	295.0	2771.0	618.0	0.8153480887413025	(2621.0; 456.5)	12.0	4.969230769230769
207	3	2472.0	295.0	2765.0	618.0	0.7831220030784607	(2618.5; 456.5)	11.72	4.969230769230769
208	3	2470.0	294.0	2766.0	620.0	0.7941417098045349	(2618.0; 457.0)	11.84	5.015384615384615
209	3	2470.0	293.0	2768.0	620.0	0.7889956831932068	(2619.0; 456.5)	11.92	5.030769230769231
210	1	2846.0	330.0	2961.0	522.0	0.7279812097549438	(2903.5; 426.0)	4.6	2.953846153846154
210	3	2474.0	295.0	2764.0	624.0	0.5498513579368591	(2619.0; 459.5)	11.6	5.061538461538461
211	1	2857.0	331.0	2965.0	518.0	0.7304113507270813	(2911.0; 424.5)	4.32	2.876923076923077

212	3	2472.0	293.0	2767.0	627.0	0.7520071268081665	(2619.5; 460.0)	11.8	5.138461538461539
213	3	2470.0	292.0	2762.0	627.0	0.7640395164489746	(2616.0; 459.5)	11.68	5.153846153846154
214	1	2844.0	325.0	2971.0	530.0	0.7741735577583313	(2907.5; 427.5)	5.08	3.1538461538461537
214	3	2468.0	292.0	2763.0	627.0	0.5141637325286865	(2615.5; 459.5)	11.8	5.153846153846154
215	1	2844.0	328.0	2971.0	530.0	0.7868415713310242	(2907.5; 429.0)	5.08	3.1076923076923078
215	3	2465.0	291.0	2768.0	626.0	0.6004710793495178	(2616.5; 458.5)	12.12	5.153846153846154
216	1	2845.0	328.0	2967.0	529.0	0.7711599469184875	(2906.0; 428.5)	4.88	3.0923076923076924
216	3	2466.0	291.0	2769.0	625.0	0.5873834490776062	(2617.5; 458.0)	12.12	5.138461538461539
217	1	2848.0	328.0	2970.0	529.0	0.7433733940124512	(2909.0; 428.5)	4.88	3.0923076923076924
218	1	2844.0	324.0	2973.0	518.0	0.7663192749023438	(2908.5; 421.0)	5.16	2.9846153846153847
218	3	2471.0	293.0	2768.0	623.0	0.6181873679161072	(2619.5; 458.0)	11.88	5.076923076923077
219	1	2814.0	323.0	2968.0	538.0	0.7498229146003723	(2891.0; 430.5)	6.16	3.3076923076923075
219	3	2474.0	294.0	2764.0	623.0	0.6928339004516602	(2619.0; 458.5)	11.6	5.061538461538461
220	1	2823.0	325.0	2966.0	543.0	0.7311067581176758	(2894.5; 434.0)	5.72	3.353846153846154
220	3	2479.0	295.0	2768.0	622.0	0.541153073310852	(2623.5; 458.5)	11.56	5.030769230769231
221	1	2822.0	323.0	2969.0	541.0	0.706731915473938	(2895.5; 432.0)	5.88	3.353846153846154
221	3	2482.0	295.0	2771.0	621.0	0.6835464835166931	(2626.5; 458.0)	11.56	5.015384615384615
222	1	2824.0	323.0	2970.0	542.0	0.7018170952796936	(2897.0; 432.5)	5.84	3.3692307692307693
222	3	2478.0	294.0	2773.0	621.0	0.6396591663360596	(2625.5; 457.5)	11.8	5.030769230769231
223	1	2832.0	324.0	2971.0	537.0	0.7285308837890625	(2901.5; 430.5)	5.56	3.276923076923077
223	3	2486.0	298.0	2781.0	621.0	0.6703660488128662	(2633.5; 459.5)	11.8	4.969230769230769
224	1	2837.0	323.0	2971.0	536.0	0.735188901424408	(2904.0; 429.5)	5.36	3.276923076923077
224	3	2481.0	298.0	2803.0	619.0	0.6557307839393616	(2642.0; 458.5)	12.88	4.938461538461539
225	1	2842.0	323.0	2971.0	536.0	0.7264816164970398	(2906.5; 429.5)	5.16	3.276923076923077
225	3	2474.0	299.0	2817.0	618.0	0.6574134826660156	(2645.5; 458.5)	13.72	4.907692307692308
226	1	2834.0	321.0	2968.0	540.0	0.7531377077102661	(2901.0; 430.5)	5.36	3.3692307692307693
226	3	2485.0	302.0	2817.0	618.0	0.6815604567527771	(2651.0; 460.0)	13.28	4.861538461538461
227	1	2835.0	319.0	2967.0	540.0	0.7379542589187622	(2901.0; 429.5)	5.28	3.4
227	3	2477.0	300.0	2813.0	618.0	0.7114712595939636	(2645.0; 459.0)	13.44	4.892307692307693
228	1	2827.0	319.0	2969.0	540.0	0.729030191898346	(2898.0; 429.5)	5.68	3.4
228	3	2492.0	306.0	2819.0	620.0	0.6456448435783386	(2655.5; 463.0)	13.08	4.8307692307692305
229	1	2813.0	319.0	2965.0	537.0	0.7324870228767395	(2889.0; 428.0)	6.08	3.353846153846154
229	3	2486.0	305.0	2814.0	620.0	0.6197957396507263	(2650.0; 462.5)	13.12	4.846153846153846
230	1	2815.0	319.0	2967.0	537.0	0.7701261043548584	(2891.0; 428.0)	6.08	3.353846153846154
230	3	2480.0	300.0	2814.0	620.0	0.6331316232681274	(2647.0; 460.0)	13.36	4.923076923076923
231	1	2835.0	320.0	2969.0	534.0	0.7791207432746887	(2902.0; 427.0)	5.36	3.292307692307692
231	3	2473.0	299.0	2821.0	620.0	0.5576209425926208	(2647.0; 459.5)	13.92	4.938461538461539
232	1	2836.0	320.0	2970.0	534.0	0.756020724773407	(2903.0; 427.0)	5.36	3.292307692307692
233	3	2468.0	300.0	2843.0	620.0	0.7472833395004272	(2655.5; 460.0)	15.0	4.923076923076923
234	3	2478.0	301.0	2819.0	620.0	0.7327142357826233	(2648.5; 460.5)	13.64	4.907692307692308
235	1	2819.0	312.0	2969.0	540.0	0.7244177460670471	(2894.0; 426.0)	6.0	3.5076923076923077
235	3	2483.0	302.0	2813.0	621.0	0.5305399894714355	(2648.0; 461.5)	13.2	4.907692307692308
236	1	2817.0	311.0	2970.0	541.0	0.709290623664856	(2893.5; 426.0)	6.12	3.5384615384615383
237	3	2483.0	302.0	2826.0	620.0	0.692066490650177	(2654.5; 461.0)	13.72	4.892307692307693
238	1	2829.0	313.0	2968.0	534.0	0.6499181985855103	(2898.5; 423.5)	5.56	3.4
238	3	2487.0	302.0	2821.0	619.0	0.6079146265983582	(2654.0; 460.5)	13.36	4.876923076923077
239	1	2815.0	312.0	2965.0	532.0	0.7210344076156616	(2890.0; 422.0)	6.0	3.3846153846153846

BIBLIOGRAPHIE

- AAC (2024). Aperçu du secteur agricole et agroalimentaire canadien. Récupéré le 2025-09-02 de <https://agriculture.canada.ca/fr/secteur/apercu#>
- Al Jaber, S. M., Patel, A. et AL-Masri, A. N. (2023). Object tracking and detection techniques under GANN threats : A systemic review. *Applied Soft Computing*, 139, 110224. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.asoc.2023.110224>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S1568494623002429>
- Ali, M. L. et Zhang, Z. (2024). The YOLO Framework : A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection. *Computers*, 13(12), 336. <http://dx.doi.org/10.3390/computers13120336>. Récupéré le 2026-01-20 de <https://www.mdpi.com/2073-431X/13/12/336>
- Andrew, W., Gao, J., Mullan, S., Campbell, N., Dowsey, A. W. et Burghardt, T. (2021). Visual Identification of Individual Holstein-Friesian Cattle via Deep Metric Learning. *Computers and Electronics in Agriculture*, 185, 106133. arXiv :2006.09205 [cs], <http://dx.doi.org/10.1016/j.compag.2021.106133>. Récupéré le 2025-04-22 de <http://arxiv.org/abs/2006.09205>
- Andrew, W., Greatwood, C. et Burghardt, T. (2017). Visual Localisation and Individual Identification of Holstein Friesian Cattle via Deep Learning. Dans *2017 IEEE International Conference on Computer Vision Workshops (ICCVW)*, 2850–2859., Venice. IEEE. <http://dx.doi.org/10.1109/ICCVW.2017.336>. Récupéré le 2025-04-22 de <http://ieeexplore.ieee.org/document/8265547/>
- Aye, C. C., Zin, T. T. et Kobayashi, I. (2022). Black Cow Tracking by Using Deep Learning-Based Algorithms. <http://dx.doi.org/10.24507/icicelb.13.12.1313>. Récupéré le 2025-07-16 de <https://doi.org/10.24507/icicelb.13.12.1313>
- Bansal, V., Foresti, G. L. et Martinel, N. (2021). Where Did I See It ? Object Instance Re-Identification with Attention. Dans *2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW)*, 298–306., Montreal, BC, Canada. IEEE. <http://dx.doi.org/10.1109/ICCVW54120.2021.00038>. Récupéré le 2025-04-22 de <https://ieeexplore.ieee.org/document/9607447/>
- Bello, R. W., Mohamed, A. S. A., Talib, A. Z., Olubummo, D. A. et Enuma, O. C. (2021). Computer vision-based techniques for cow object recognition. *IOP Conference Series : Earth and Environmental Science*, 858(1), 012008. <http://dx.doi.org/10.1088/1755-1315/858/1/012008>. Récupéré le 2025-04-22 de <https://iopscience.iop.org/article/10.1088/1755-1315/858/1/012008>
- Benaissa, S., Tuytens, F., Plets, D., Martens, L., Vandaele, L., Joseph, W. et Sonck, B. (2023). Improved cattle behaviour monitoring by combining Ultra-Wideband location and accelerometer data. *animal*, 17(4), 100730. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.animal.2023.100730>. Récupéré le 2025-07-23 de <https://linkinghub.elsevier.com/retrieve/pii/S1751731123000265>

- Bergamini, L., Porrello, A., Dondona, A. C., Negro, E. D., Mattioli, M., D'Alterio, N. et Calderara, S. (2019). Multi-views Embedding for Cattle Re-identification. *arXiv :1902.04886* [cs], <http://dx.doi.org/10.48550/arXiv.1902.04886>. Récupéré le 2025-04-22 de <http://arxiv.org/abs/1902.04886>
- Bewley, A., Ge, Z., Ott, L., Ramos, F. et Upcroft, B. (2016). Simple Online and Realtime Tracking. Dans *2016 IEEE International Conference on Image Processing (ICIP)*, 3464–3468. *arXiv :1602.00763* [cs], <http://dx.doi.org/10.1109/ICIP.2016.7533003>. Récupéré le 2025-04-22 de <http://arxiv.org/abs/1602.00763>
- Bonneau, M., Vayssade, J.-A., Troupe, W. et Arquet, R. (2020). Outdoor animal tracking combining neural network and time-lapse cameras. *Computers and Electronics in Agriculture*, 168, 105150. <http://dx.doi.org/10.1016/j.compag.2019.105150>. Récupéré le 2025-04-22 de <https://linkinghub.elsevier.com/retrieve/pii/S0168169919322562>
- Cernadas, E. (2024). Applications of Computer Vision, 2nd Edition. *Electronics*, 13(18), 3779. Publisher : MDPI AG, <http://dx.doi.org/10.3390/electronics13183779>. Récupéré le 2025-07-16 de <https://www.mdpi.com/2079-9292/13/18/3779>
- Chai, J., Zeng, H., Li, A. et Ngai, E. W. (2021). Deep learning in computer vision : A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, 6, 100134. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.mlwa.2021.100134>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S2666827021000670>
- Chen, X., Yang, T., Mai, K., Liu, C., Xiong, J., Kuang, Y. et Gao, Y. (2022). Holstein Cattle Face Re-Identification Unifying Global and Part Feature Deep Network with Attention Mechanism. *Animals*, 12(8), 1047. <http://dx.doi.org/10.3390/ani12081047>. Récupéré le 2025-04-22 de <https://www.mdpi.com/2076-2615/12/8/1047>
- Da Silva Santos, A., De Medeiros, V. W. C. et Gonçalves, G. E. (2023). Monitoring and classification of cattle behavior : a survey. *Smart Agricultural Technology*, 3, 100091. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.atech.2022.100091>. Récupéré le 2025-07-23 de <https://linkinghub.elsevier.com/retrieve/pii/S2772375522000569>
- Dallago, G., Elsohaby, I., McClure, J., Lacroix, R. et Vasseur, E. (2024). The associations of early-life health and performance with subsequent dairy cow longevity, productivity, and profitability. *animal*, 18(9), 101281. <http://dx.doi.org/10.1016/j.animal.2024.101281>. Récupéré le 2025-04-22 de <https://linkinghub.elsevier.com/retrieve/pii/S175173112400212X>
- Dallago, G. M., Wade, K. M., Cue, R. I., McClure, J. T., Lacroix, R., Pellerin, D. et Vasseur, E. (2021). Keeping Dairy Cows for Longer : A Critical Literature Review on Dairy Cow Longevity in High Milk-Producing Countries. *Animals*, 11(3), 808. <http://dx.doi.org/10.3390/ani11030808>. Récupéré le 2025-04-22 de <https://www.mdpi.com/2076-2615/11/3/808>
- De Castro, A. L., Wang, J., Bonney-King, J. G., Morota, G., Miller-Cushon, E. K. et Yu, H. (2025). AnimalMotionViz : An interactive software tool for tracking and visualizing animal motion patterns using computer vision. *JDS Communications*, p. S2666910225000183. <http://dx.doi.org/10.3168/jdsc.2024-0706>. Récupéré le 2025-04-25 de <https://linkinghub.elsevier.com/retrieve/pii/S2666910225000183>

- Du, Y., Zhao, Z., Song, Y., Zhao, Y., Su, F., Gong, T. et Meng, H. (2023). StrongSORT : Make DeepSORT Great Again. arXiv :2202.13514 [cs], <http://dx.doi.org/10.48550/arXiv.2202.13514>. Récupéré le 2025-04-22 de <http://arxiv.org/abs/2202.13514>
- Dubourvieux, F., Lapouge, G., Loesch, A., Luvison, B. et Audigier, R. (2023). Cumulative unsupervised multi-domain adaptation for Holstein cattle re-identification. *Artificial Intelligence in Agriculture*, 10, 46–60. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.aiaa.2023.10.002>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S2589721723000429>
- Ducrot, C., Barrio, M., Boissy, A., Charrier, F., Even, S., Mormède, P., Petit, S., Pinard-van Der Laan, M.-H., Schelcher, F., Casabianca, F., Ducos, A., Foucras, G., Guatteo, R., Peyraud, J.-L., Vayssier-Taussat, M., Veysset, P., Friggens, N. et Fernandez, X. (2024). Animal board invited review : Improving animal health and welfare in the transition of livestock farming systems : Towards social acceptability and sustainability. *animal*, 18(3), 101100. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.animal.2024.101100>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S1751731124000314>
- Frasco, C., Radmacher, M., Lacroix, R., Cue, R., Valtchev, P., Robert, C., Boukadoum, M., Sirard, M.-A. et Diallo, A. (2020). Towards an Effective Decision-making System based on Cow Profitability using Deep Learning :. Dans *Proceedings of the 12th International Conference on Agents and Artificial Intelligence*, 949–958., Valletta, Malta. SCITEPRESS - Science and Technology Publications. <http://dx.doi.org/10.5220/0009174809490958>. Récupéré le 2025-04-22 de <http://www.scitepress.org/DigitalLibrary/Link.aspx?doi=10.5220/0009174809490958>
- Fraser, M. D., Friesen, M. E. et Trépanier, H. Membres du Groupe de travail sur le bien-être animal.
- Fuentes, A., Han, S., Nasir, M. F., Park, J., Yoon, S. et Park, D. S. (2023). Multiview Monitoring of Individual Cattle Behavior Based on Action Recognition in Closed Barns Using Deep Learning. *Animals*, 13(12), 2020. <http://dx.doi.org/10.3390/ani13122020>. Récupéré le 2025-04-22 de <https://www.mdpi.com/2076-2615/13/12/2020>
- Gauly, M. et Ammer, S. (2020). Review : Challenges for dairy cow production systems arising from climate changes. *Animal*, 14, s196–s203. Publisher : Elsevier BV, <http://dx.doi.org/10.1017/s1751731119003239>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S1751731119003239>
- Ghazal, S., Munir, A. et Qureshi, W. S. (2024). Computer vision in smart agriculture and precision farming : Techniques and applications. *Artificial Intelligence in Agriculture*, 13, 64–83. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.aiaa.2024.06.004>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S2589721724000266>
- Graving, J. M., Chae, D., Naik, H., Li, L., Koger, B., Costelloe, B. R. et Couzin, I. D. (2019). DeepPoseKit, a software toolkit for fast and robust animal pose estimation using deep learning. *eLife*, 8, e47994. <http://dx.doi.org/10.7554/eLife.47994>. Récupéré le 2025-04-22 de <https://elifesciences.org/articles/47994>
- Guo, Y., Hong, W., Wu, J., Huang, X., Qiao, Y. et Kong, H. (2023). Vision-Based Cow Tracking and Feeding Monitoring for Autonomous Livestock Farming : The YOLOv5s-CA+DeepSORT-Vision Transformer.

- IEEE Robotics & Automation Magazine*, 30(4), 68–76. Publisher : Institute of Electrical and Electronics Engineers (IEEE), <http://dx.doi.org/10.1109/mra.2023.3310857>. Récupéré le 2025-07-23 de <https://ieeexplore.ieee.org/document/10303740/>
- Han, S., Fuentes, A., Yoon, S., Jeong, Y., Kim, H. et Sun Park, D. (2023). Deep learning-based multi-cattle tracking in crowded livestock farming using video. *Computers and Electronics in Agriculture*, 212, 108044. <http://dx.doi.org/10.1016/j.compag.2023.108044>. Récupéré le 2025-04-22 de <https://linkinghub.elsevier.com/retrieve/pii/S0168169923004325>
- Hao, W., Ren, C., Fan, Y., Han, M. et Li, F. (2025). YSD-BPTrack : A multi-object tracking framework for calves in occluded environments. *Smart Agricultural Technology*, 11, 100876. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.atech.2025.100876>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S2772375525001091>
- Hao, W., Ren, C., Han, M., Zhang, L., Li, F. et Liu, Z. (2023). Cattle Body Detection Based on YOLOv5-EMA for Precision Livestock Farming. *Animals*, 13(22), 3535. <http://dx.doi.org/10.3390/ani13223535>. Récupéré le 2025-04-22 de <https://www.mdpi.com/2076-2615/13/22/3535>
- He, L., Liao, X., Liu, W., Liu, X., Cheng, P. et Mei, T. (2020). FastReID : A Pytorch Toolbox for General Instance Re-identification. *arXiv :2006.02631 [cs]*, <http://dx.doi.org/10.48550/arXiv.2006.02631>. Récupéré le 2025-07-16 de <http://arxiv.org/abs/2006.02631>
- Higaki, S., Matsui, Y., Miwa, M., Yamamura, T., Hojo, T., Yoshioka, K., Vang, A., Negreiro, A. et Dórea, J. R. (2024). Leveraging computer vision-based pose estimation technique in dairy cows for objective mobility analysis and scoring system. *Computers and Electronics in Agriculture*, 217, 108573. <http://dx.doi.org/10.1016/j.compag.2023.108573>. Récupéré le 2025-04-22 de <https://linkinghub.elsevier.com/retrieve/pii/S0168169923009614>
- Huang, J., Wu, X. H. Y. et Zhao, S. (2025). The detection and rectification for identity-switch based on unfalsified control. *arXiv :2307.14591 [cs]*, <http://dx.doi.org/10.48550/arXiv.2307.14591>. Récupéré le 2025-07-23 de <http://arxiv.org/abs/2307.14591>
- Huang, X., Hu, Z., Qiao, Y. et Sukkarieh, S. (2023). Deep Learning-Based Cow Tail Detection and Tracking for Precision Livestock Farming. *IEEE/ASME Transactions on Mechatronics*, 28(3), 1213–1221. <http://dx.doi.org/10.1109/TMECH.2022.3175377>. Récupéré le 2025-04-22 de <https://ieeexplore.ieee.org/document/9787071/>
- Jacques, A. A. B., Diallo, A. B. et Lord, E. (2023). The Canadian Cropland Dataset : A New Land Cover Dataset for Multitemporal Deep Learning Classification in Agriculture. *arXiv :2306.00114 [cs]*, <http://dx.doi.org/10.48550/arXiv.2306.00114>. Récupéré le 2025-07-16 de <http://arxiv.org/abs/2306.00114>
- Javaid, M., Haleem, A., Singh, R. P. et Ahmed, M. (2024). Computer vision to enhance healthcare domain : An overview of features, implementation, and opportunities. *Intelligent Pharmacy*, 2(6), 792–803. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.ipha.2024.05.007>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S2949866X24000662>
- Kanchana, B., Peiris, R., Perera, D., Jayasinghe, D. et Kasthurirathna, D. (2021). Computer Vision for

- Autonomous Driving. Dans *2021 3rd International Conference on Advancements in Computing (ICAC)*, Colombo, Sri Lanka. IEEE. <http://dx.doi.org/10.1109/icac54203.2021.9671099>. Récupéré le 2025-07-16 de <https://ieeexplore.ieee.org/document/9671099/>
- Kang, X., Zhang, X. D. et Liu, G. (2021). A Review : Development of Computer Vision-Based Lameness Detection for Dairy Cows and Discussion of the Practical Applications. *Sensors*, 21(3), 753. Publisher : MDPI AG, <http://dx.doi.org/10.3390/s21030753>. Récupéré le 2025-07-16 de <https://www.mdpi.com/1424-8220/21/3/753>
- Karoui, Y., Boatswain Jacques, A. A., Diallo, A. B., Shepley, E. et Vasseur, E. (2021). A Deep Learning Framework for Improving Lameness Identification in Dairy Cattle. *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(18), 15811-15812. <http://dx.doi.org/10.1609/aaai.v35i18.17902>. Récupéré le 2025-04-22 de <https://ojs.aaai.org/index.php/AAAI/article/view/17902>
- Khan, A. I. et Al-Habsi, S. (2020). Machine Learning in Computer Vision. *Procedia Computer Science*, 167, 1444-1451. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.procs.2020.03.355>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S1877050920308218>
- Koutouzidou, G., Ragkos, A. et Melfou, K. (2022). Evolution of the Structure and Economic Management of the Dairy Cow Sector. *Sustainability*, 14(18), 11602. Publisher : MDPI AG, <http://dx.doi.org/10.3390/su141811602>. Récupéré le 2025-07-16 de <https://www.mdpi.com/2071-1050/14/18/11602>
- Lauer, J., Zhou, M., Ye, S., Menegas, W., Schneider, S., Nath, T., Rahman, M. M., Di Santo, V., Soberanes, D., Feng, G., Murthy, V. N., Lauder, G., Dulac, C., Mathis, M. W. et Mathis, A. (2022). Multi-animal pose estimation, identification and tracking with DeepLabCut. *Nature Methods*, 19(4), 496-504. <http://dx.doi.org/10.1038/s41592-022-01443-0>. Récupéré le 2025-04-22 de <https://www.nature.com/articles/s41592-022-01443-0>
- Lee, S., Lee, W. et Park, J. (2023). A Study on Tracking Moving Objects : Pig counting with YOLOv5 and StrongSORT.
- Lennox, M., Ltd, C. et McLaughlin, N. (2022). Visual Re-identification within Large Herds of Holstein Friesian Cattle.
- Li, G., Sun, J., Guan, M., Sun, S., Shi, G. et Zhu, C. (2024). A New Method for Non-Destructive Identification and Tracking of Multi-Object Behaviors in Beef Cattle Based on Deep Learning. *Animals*, 14(17), 2464. <http://dx.doi.org/10.3390/ani14172464>. Récupéré le 2025-04-22 de <https://www.mdpi.com/2076-2615/14/17/2464>
- Linstädt, J., Thöne-Reineke, C. et Merle, R. (2024). Animal-based welfare indicators for dairy cows and their validity and practicality : a systematic review of the existing literature. *Frontiers in Veterinary Science*, 11. Publisher : Frontiers Media SA, <http://dx.doi.org/10.3389/fvets.2024.1429097>. Récupéré le 2025-07-16 de <https://www.frontiersin.org/articles/10.3389/fvets.2024.1429097/full>
- Liu, R., Wu, S. et Lu, X. (2021). Real-time fire detection network for intelligent surveillance systems. Dans F.

- Cen et B. H. Bin Ahmad (dir.). *2nd International Conference on Computer Vision, Image, and Deep Learning*, p. 30., Liuzhou, China. SPIE. <http://dx.doi.org/10.1117/12.2604559>. Récupéré le 2025-04-22 de <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/11911/2604559/Real-time-fire-detection-network-for-intelligent-surveillance-systems/10.1117/12.2604559.full>
- Luiten, J., Osep, A., Dendorfer, P., Torr, P., Geiger, A., Leal-Taixe, L. et Leibe, B. (2021). HOTA : A Higher Order Metric for Evaluating Multi-Object Tracking. *International Journal of Computer Vision*, 129(2), 548–578. arXiv :2009.07736 [cs], <http://dx.doi.org/10.1007/s11263-020-01375-2>. Récupéré le 2025-04-22 de <http://arxiv.org/abs/2009.07736>
- Luo, W., Zhang, G., Yuan, Q., Zhao, Y., Chen, H., Zhou, J., Meng, Z., Wang, F., Li, L., Liu, J., Wang, G., Wang, P. et Yu, Z. (2024). High-precision tracking and positioning for monitoring Holstein cattle. *PLOS ONE*, 19(5), e0302277. <http://dx.doi.org/10.1371/journal.pone.0302277>. Récupéré le 2025-04-22 de <https://dx.plos.org/10.1371/journal.pone.0302277>
- Mar, C. C., Zin, T. T., Tin, P., Honkawa, K., Kobayashi, I. et Horii, Y. (2023). Cow detection and tracking system utilizing multi-feature tracking algorithm. *Scientific Reports*, 13(1). Publisher : Springer Science and Business Media LLC, <http://dx.doi.org/10.1038/s41598-023-44669-4>. Récupéré le 2025-07-16 de <https://www.nature.com/articles/s41598-023-44669-4>
- Marina, H., Fikse, W. et Rønnegård, L. (2024). Social network analysis to predict social behavior in dairy cattle. *JDS Communications*, 5(6), 608–612. Publisher : American Dairy Science Association, <http://dx.doi.org/10.3168/jdsc.2023-0507>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S266691022400067X>
- Marques, T. C., Marques, L. R., Fernandes, P. B., De Lima, F. S., Do Prado Paim, T. et Leão, K. M. (2024). Machine Learning to Predict Pregnancy in Dairy Cows : An Approach Integrating Automated Activity Monitoring and On-Farm Data. *Animals*, 14(11), 1567. Publisher : MDPI AG, <http://dx.doi.org/10.3390/ani14111567>. Récupéré le 2025-07-16 de <https://www.mdpi.com/2076-2615/14/11/1567>
- McDonagh, J., Tzimiropoulos, G., Slinger, K. R., Huggett, Z. J., Down, P. M. et Bell, M. J. (2021). Detecting Dairy Cow Behavior Using Vision Technology. *Agriculture*, 11(7), 675. Publisher : MDPI AG, <http://dx.doi.org/10.3390/agriculture11070675>. Récupéré le 2025-07-16 de <https://www.mdpi.com/2077-0472/11/7/675>
- Medeiros, I., Fernandez-Novoa, A., Astiz, S. et Simões, J. (2022). Historical Evolution of Cattle Management and Herd Health of Dairy Farms in OECD Countries. *Veterinary Sciences*, 9(3), 125. Publisher : MDPI AG, <http://dx.doi.org/10.3390/vetsci9030125>. Récupéré le 2025-07-16 de <https://www.mdpi.com/2306-7381/9/3/125>
- Myat Noe, S., Zin, T. T., Tin, P. et Kobayashi, I. (2023). Comparing State-of-the-Art Deep Learning Algorithms for the Automated Detection and Tracking of Black Cattle. *Sensors*, 23(1), 532. <http://dx.doi.org/10.3390/s23010532>. Récupéré le 2025-04-22 de <https://www.mdpi.com/1424-8220/23/1/532>
- Naghashi, V., Dallago, G. M., Diallo, A. B. et Boukadoum, M. (2022). Univariate and multivariate

time-series methods to forecast dairy income.

- Naghashi, V. et Diallo, A. B. (2022). A Model for the Prediction of Lifetime Profit Estimate of Dairy Cattle (Student Abstract). *Proceedings of the AAAI Conference on Artificial Intelligence*, 36(11), 13021-13022. <http://dx.doi.org/10.1609/aaai.v36i11.21647>. Récupéré le 2025-04-22 de <https://ojs.aaai.org/index.php/AAAI/article/view/21647>
- Naik, H., Chan, A. H. H., Yang, J., Delacoux, M., Couzin, I. D., Kano, F. et Nagy, M. (2023). 3D-POP – An automated annotation approach to facilitate markerless 2D-3D tracking of freely moving birds with marker-based motion capture. *arXiv :2303.13174 [cs]*, <http://dx.doi.org/10.48550/arXiv.2303.13174>. Récupéré le 2025-04-22 de <http://arxiv.org/abs/2303.13174>
- N.B., H. (2019). Confusion matrix, accuracy, precision, recall, f1 score. Récupéré le 2026-01-21 de <https://medium.com/analytics-vidhya/confusion-matrix-accuracy-precision-recall-f1-score-ade299cf63cd>
- Orihuela, A. (2021). Review : Management of livestock behavior to improve welfare and production. *Animal*, 15, 100290. <http://dx.doi.org/10.1016/j.animal.2021.100290>. Récupéré le 2025-09-04 de <https://linkinghub.elsevier.com/retrieve/pii/S1751731121001336>
- Ozella, L., Magliola, A., Vernengo, S., Ghigo, M., Bartoli, F., Grangetto, M., Forte, C., Montrucchio, G. et Giacobini, M. (2024). A computer vision approach for the automatic detection of social interactions of dairy cows in automatic milking systems. *Acta IMEKO*, 13(3), 1–6. Publisher : IMEKO International Measurement Confederation, <http://dx.doi.org/10.21014/actaimeko.v13i3.1628>. Récupéré le 2025-07-16 de <https://acta.imeko.org/index.php/acta-imeko/article/view/1628>
- Parmiggiani, A., Liu, D., Psota, E., Fitzgerald, R. et Norton, T. (2023). Don't get lost in the crowd : Graph convolutional network for online animal tracking in dense groups. *Computers and Electronics in Agriculture*, 212, 108038. <http://dx.doi.org/10.1016/j.compag.2023.108038>. Récupéré le 2025-04-22 de <https://linkinghub.elsevier.com/retrieve/pii/S016816992300426X>
- Petrovic, B., Tunguz, V. et Bartos, P. (2023). Application of computer vision in livestock and crop production—A review. *Computing and Artificial Intelligence*, 1(1), 360. Publisher : Academic Publishing Pte. Ltd., <http://dx.doi.org/10.59400/cai.v1i1.360>. Récupéré le 2025-07-16 de <https://ojs.acad-pub.com/index.php/CAI/article/view/360>
- Price, R. (2019). Step-by-step guide to identifying and treating lame cows. Récupéré le 2025-09-02 de <https://www.fwi.co.uk/livestock/health-welfare/identifying-and-treating-lame-cows-for-the-best-results>
- Rasche, C. (2019). *Computer Vision*.
- Ravoor, P. C. et T.S.B., S. (2020). Deep Learning Methods for Multi-Species Animal Re-identification and Tracking – a Survey. *Computer Science Review*, 38, 100289. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.cosrev.2020.100289>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S1574013720303890>

- Ray, S. et Stopfer, M. A. (2022). Argos : A toolkit for tracking multiple animals in complex visual environments. *Methods in Ecology and Evolution*, 13(3), 585–595.
<http://dx.doi.org/10.1111/2041-210X.13776>. Récupéré le 2025-04-22 de
<https://besjournals.onlinelibrary.wiley.com/doi/10.1111/2041-210X.13776>
- Redmon, J., Divvala, S., Girshick, R. et Farhadi, A. (2016). You Only Look Once : Unified, Real-Time Object Detection. arXiv :1506.02640 [cs], <http://dx.doi.org/10.48550/arXiv.1506.02640>.
Récupéré le 2025-04-22 de <http://arxiv.org/abs/1506.02640>
- Ren, K., Bernes, G., Hetta, M. et Karlsson, J. (2021). Tracking and analysing social interactions in dairy cattle with real-time locating system and machine learning. *Journal of Systems Architecture*, 116, 102139. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.sysarc.2021.102139>. Récupéré le 2025-07-23 de <https://linkinghub.elsevier.com/retrieve/pii/S138376212100103X>
- Roboflow. *Roboflow Inference Server*. Récupéré de <https://roboflow.com>
- Russello, H., Van Der Tol, R., Holzhauer, M., Van Henten, E. J. et Kootstra, G. (2024). Video-based automatic lameness detection of dairy cows using pose estimation and multiple locomotion traits. *Computers and Electronics in Agriculture*, 223, 109040. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.compag.2024.109040>. Récupéré le 2025-07-16 de
<https://linkinghub.elsevier.com/retrieve/pii/S0168169924004319>
- Saeed, H., Haider, M., Ansari, T., Fatima, A., Khalid, A., Gilani, M., Saleem, M., Shoaib, M., Sarmad, M., Ahmar, M. et Sakhawat, A. (2023). ROLE OF ANIMAL BEHAVIOUR AND WELFARE IN LIVESTOCK PRODUCTION AND MANAGEMENT. *Biological and Clinical Sciences Research Journal*, 2023(1), 442. Publisher : Medeye Publishers, <http://dx.doi.org/10.54112/bcsrj.v2023i1.442>.
Récupéré le 2025-07-16 de <http://bcsrj.com/ojs/index.php/bcsrj/article/view/442>
- Schneider, S., Taylor, G. W., Linqvist, S. et Kremer, S. C. (2020). Similarity Learning Networks for Animal Individual Re-Identification – Beyond the Capabilities of a Human Observer. arXiv :1902.09324 [cs], <http://dx.doi.org/10.48550/arXiv.1902.09324>. Récupéré le 2025-04-22 de
<http://arxiv.org/abs/1902.09324>
- Shi, X., Qiao, Y., Liu, L. et Dayoub, F. (2025). Embodied Domain Adaptation for Object Detection. arXiv :2506.21860 [cs], <http://dx.doi.org/10.48550/arXiv.2506.21860>. Récupéré le 2025-07-16 de <http://arxiv.org/abs/2506.21860>
- Shreya M. Shelke, Indrayani S. Pathak, Aniket P. Sangai, Dipali V. Lunge, Kalyani A. Shahale et Harsha R. Vyawahare (2023). A Review Paper on Computer Vision. *International Journal of Advanced Research in Science, Communication and Technology*, 673–677. Publisher : Naksh Solutions, <http://dx.doi.org/10.48175/ijarsct-8901>. Récupéré le 2025-07-16 de
<http://ijarsct.co.in/Paper8901.pdf>
- Sim, H.-S. et Cho, H.-C. (2025). Enhanced DeepSORT and StrongSORT for Multicattle Tracking With Optimized Detection and Re-Identification. *IEEE Access*, 13, 19353–19364. Publisher : Institute of Electrical and Electronics Engineers (IEEE),
<http://dx.doi.org/10.1109/access.2025.3535092>. Récupéré le 2025-07-16 de
<https://ieeexplore.ieee.org/document/10855392/>

- Siriani, A. L. R., Kodaira, V., Mehdizadeh, S. A., De Alencar Nääs, I., De Moura, D. J. et Pereira, D. F. (2022). Detection and tracking of chickens in low-light images using YOLO network and Kalman filter. *Neural Computing and Applications*, 34(24), 21987–21997. <http://dx.doi.org/10.1007/s00521-022-07664-w>. Récupéré le 2025-04-22 de <https://link.springer.com/10.1007/s00521-022-07664-w>
- Stankovski, S., Ostojic, G., Senk, I., Rakic-Skokovic, M., Trivunovic, S. et Kucevic, D. (2012). Dairy cow monitoring by RFID. *Scientia Agricola*, 69(1), 75–80. <http://dx.doi.org/10.1590/S0103-90162012000100011>. Récupéré le 2025-04-22 de http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-90162012000100011&lng=en&tlng=en
- Sueur, C. et Pelé, M. (2023). Editorial : Recent Advances in Animal Cognition and Ethology. *Animals*, 13(18), 2890. <http://dx.doi.org/10.3390/ani13182890>. Récupéré le 2025-09-04 de <https://www.mdpi.com/2076-2615/13/18/2890>
- Tan, M., Chao, W., Cheng, J.-K., Zhou, M., Ma, Y., Jiang, X., Ge, J., Yu, L. et Feng, L. (2022). Animal Detection and Classification from Camera Trap Images Using Different Mainstream Object Detection Architectures. *Animals*, 12(15), 1976. <http://dx.doi.org/10.3390/ani12151976>. Récupéré le 2025-04-22 de <https://www.mdpi.com/2076-2615/12/15/1976>
- Tanyildiz, E. et Yildirim, G. (2019). Performance Comparison of Classification Algorithms for The Diagnosis of Mastitis Disease in Dairy Animals. Dans *2019 7th International Symposium on Digital Forensics and Security (ISDFS)*, 1–4., Barcelos, Portugal. IEEE. <http://dx.doi.org/10.1109/isdfs.2019.8757469>. Récupéré le 2025-07-16 de <https://ieeexplore.ieee.org/document/8757469/>
- Tiwari, A., Sachdeva, K. et Jain, N. (2021). Computer Vision and Deep Learningbased Framework for Cattle Monitoring. Dans *2021 IEEE 8th Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering (UPCON)*, 1–6., Dehradun, India. IEEE. <http://dx.doi.org/10.1109/UPCON52273.2021.9667617>. Récupéré le 2025-04-22 de <https://ieeexplore.ieee.org/document/9667617/>
- Uddin, J., McNeill, D. M. et Phillips, C. J. (2023). Measuring emotions in dairy cows : Relationships between infrared temperature of key body parts, lateralised behaviour and milk production. *Applied Animal Behaviour Science*, 269, 106115. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.applanim.2023.106115>. Récupéré le 2025-07-23 de <https://linkinghub.elsevier.com/retrieve/pii/S0168159123002873>
- Ultralytics (2025). Comprehensive comparison : Yolov5 vs. yolov8. Récupéré le 2026-01-21 de <https://docs.ultralytics.com/compare/yolov5-vs-yolov8/>
- Waldmann, U., Chan, A. H. H., Naik, H., Nagy, M., Couzin, I. D., Deussen, O., Goldluecke, B. et Kano, F. (2023). 3D-MuPPET : 3D Multi-Pigeon Pose Estimation and Tracking. arXiv :2308.15316 [cs], <http://dx.doi.org/10.48550/arXiv.2308.15316>. Récupéré le 2025-04-22 de <http://arxiv.org/abs/2308.15316>
- Wang, M., Larsen, M. L., Liu, D., Winters, J. F., Rault, J.-L. et Norton, T. (2022). Towards re-identification for long-term tracking of group housed pigs. *Biosystems Engineering*, 222, 71–81.

<http://dx.doi.org/10.1016/j.biosystemseng.2022.07.017>. Récupéré le 2025-04-22 de <https://linkinghub.elsevier.com/retrieve/pii/S1537511022001799>

Wojke, N., Bewley, A. et Paulus, D. (2017). Simple Online and Realtime Tracking with a Deep Association Metric. arXiv :1703.07402 [cs], <http://dx.doi.org/10.48550/arXiv.1703.07402>. Récupéré le 2025-04-22 de <http://arxiv.org/abs/1703.07402>

Yazdi, M. et Bouwmans, T. (2018). New trends on moving object detection in video images captured by a moving camera : A survey. *Computer Science Review*, 28, 157–177. Publisher : Elsevier BV, <http://dx.doi.org/10.1016/j.cosrev.2018.03.001>. Récupéré le 2025-07-16 de <https://linkinghub.elsevier.com/retrieve/pii/S1574013716301794>

Yu, P., Burghardt, T., Dowsey, A. W. et Campbell, N. W. (2025). Holstein-Friesian Re-Identification using Multiple Cameras and Self-Supervision on a Working Farm. arXiv :2410.12695 [cs], <http://dx.doi.org/10.48550/arXiv.2410.12695>. Récupéré le 2025-04-22 de <http://arxiv.org/abs/2410.12695>

Zheng, Z., Li, J. et Qin, L. (2023). YOLO-BYTE : An efficient multi-object tracking algorithm for automatic monitoring of dairy cows. *Computers and Electronics in Agriculture*, 209, 107857. <http://dx.doi.org/10.1016/j.compag.2023.107857>. Récupéré le 2025-04-22 de <https://linkinghub.elsevier.com/retrieve/pii/S0168169923002454>

Zheng, Z. et Qin, L. (2023). PrunedYOLO-Tracker : An efficient multi-cows basic behavior recognition and tracking technique. *Computers and Electronics in Agriculture*, 213, 108172. <http://dx.doi.org/10.1016/j.compag.2023.108172>. Récupéré le 2025-04-22 de <https://linkinghub.elsevier.com/retrieve/pii/S0168169923005604>

Zhou, K., Yang, Y., Cavallaro, A. et Xiang, T. (2021). Learning Generalisable Omni-Scale Representations for Person Re-Identification. arXiv :1910.06827 [cs], <http://dx.doi.org/10.48550/arXiv.1910.06827>. Récupéré le 2025-04-22 de <http://arxiv.org/abs/1910.06827>

Zimmerman, P., Bolhuis, L., Willemsen, A., Meyer, E. et Noldus, L. (2008). The observer xt : A tool for the integration and synchronization of multimodal signals.