2024. Journées Recherche Porcine, 56, 217-218. Publication sous Licence Creative Commons

Prédiction des besoins nutritionnels de truies gestantes à partir de données de capteurs et d'algorithmes d'apprentissage automatique

Maëva DURAND (1), Christine LARGOUET (2), Louis Bonneau de BEAUFORT (2), Jean-Yves DOURMAD (1), Charlotte GAILLARD (1)

(1) PEGASE, INRAE, Institut Agro, 35590 Saint-Gilles, France
(2) Institut Agro, Univ Rennes1, CNRS, INRIA, IRISA, 35000, Rennes, France

charlotte.gaillard@inrae.fr

Prediction of the nutritional requirements of gestating sows using sensor data and machine-learning algorithms

Precision feeding aims to provide a ration close to the nutritional requirements of each gestating sow, which are calculated using a model (e.g. InraPorc) that requires input data (e.g. sow characteristics) and an estimate of the herd's farrowing performance. This study evaluated machine-learning methods to predict the daily nutritional requirements of gestating sows based on sensor data as a function of different configurations of virtual farms. Data on 73 gestating sows were recorded by automatons or sensors such as electronic feeders, drinking stations, connected weight scales, and accelerometers. Nine machine-learning algorithms were then trained on various dataset scenarios as a function of different virtual farm configurations (using data from one or two sensors) to predict daily standardized ileal digestible lysine and metabolizable energy requirements for each sow. Adding the inputs usually provided to the InraPorc model (i.e. housing conditions and sow characteristics at artificial insemination) to the sensor data improved the mean average percentage error by 5.6 % for lysine and 2.2 % for energy. The highest coefficients of multiple determination for lysine (R^2 = 0.99) and for energy (R^2 = 0.95) were obtained for scenarios that involved an automatic feeder and included housing and sow characteristics. For these scenarios, the root mean square error was lower with Gradient Tree Boosting (0.91 MJ/d for energy and 0.08 g/d for lysine) than that with linear regression (2.75 MJ/d and 1.07 g/d, respectively). The results of this study show that the daily nutrient requirements of gestating sows can be predicted accurately with data provided by sensors and machine-learning methods, which paves the way to simpler solutions for precision feeding.

INTRODUCTION

L'alimentation sur mesure est une stratégie visant à fournir une quantité et une composition d'aliments aussi proches que possible des besoins en nutriments de chaque animal. Le but est de réduire le coût alimentaire, les ressources utilisées et les impacts environnementaux (Gaillard *et al.,* 2020). Habituellement, les besoins en nutriments des truies gestantes sont déterminés par un modèle nutritionnel mécaniste (ex. InraPorc) nécessitant des données d'entrée (ex. certaines caractéristiques de la truie et du troupeau). De nouveaux capteurs et automates ont été développés au cours des dernières décennies dans les élevages de porcs et produisent de grandes quantités de données souvent peu analysées (Neethirajan, 2020). Cette étude vise à explorer la prédiction journalière individuelle des besoins nutritionnels (i.e. l'énergie métabolisable, en MJ/j et la lysine digestible iléale standardisée, en g/j) des truies gestantes à partir de données mesurées par des capteurs (automate d'alimentation et d'abreuvement, balance connectée et accéléromètre). Cette étude propose ainsi de tester différentes configurations de fermes numériques (présence d'un ou deux de ces quatre capteurs, soit 20 scénarios en tout) et de neuf algorithmes d'apprentissage automatique : une régression linéaire simple (LR), une LR avec une régularisation LASSO (LASSO) ou RIDGE (RIDGE), une régression polynomiale (PR), une machine à vecteur de support pour régression (SVR), les k-voisins les plus proches (KNN), une forêt aléatoire (RF), un arbre à gradient boosté (GTB) et un perceptron multicouches (MLP).

1. MATERIEL ET METHODES

1.1. Données collectées et pré-traitement

Cette étude s'est déroulée de juillet 2020 à avril 2021, dans l'unité Expérimentale Physiologie et Phénotypage des Porcs (UE3P, INRAE, Rennes, France, doi : 10.15454/1.5573932732039927E12). Les données ont été collectées sur 73 truies (provenant de 4 bandes), dont huit primipares, durant toute la phase d'élevage en groupe de la gestation. Le comportement alimentaire était déterminé à l'aide d'automates d'alimentation (Gestal, JYGA Technologies inc., Canada) : le temps et le nombre de visites journalières (avec et sans ingestion), ainsi que l'ordre de passage. Des automates d'abreuvement (Asserva, France) permettaient de suivre le comportement d'abreuvement : le temps et le nombre de visites journalières (avec et sans buvée), ainsi que la quantité

journalière d'eau bue. Le poids vif était relevé chaque semaine à l'aide d'une balance manuelle (Schippers, Pays-Bas). Les truies étaient équipées d'accéléromètres triaxiaux (RF-Track, France) sur l'oreille afin de caractériser leur activité physique individuelle journalière : le temps passé en position couchée, debout immobile et debout en mouvement, ainsi que le nombre de changements de position.

1.2. Mise au point des hyperparamètres des algorithmes et évaluation des performances

Les algorithmes d'apprentissage automatique étaient développés en langage Python via le logiciel Pycharm (version 2022.3.2), à l'aide de la librairie scikit-learn (version 1.2.1.). Les 8 323 observations (i.e. une observation par truie par jour de gestation) ont été découpées à 100 reprises, de manière aléatoire, entre des données d'apprentissage (70 %) et de test (30 %). La mise au point des hyperparamètres des algorithmes a été réalisée par une validation croisée de type trois blocs pour chaque algorithme et scénario. Le modèle InraPorc, modifié par Gaillard *et al.* (2020), a permis de produire les valeurs de référence des besoins nutritionnels, à partir des caractéristiques individuelles des truies (âge, poids et épaisseur de lard à l'insémination et objectifs à la mise bas) et des données historiques de l'élevage (prédiction des performances de la portée). Ces valeurs ont été comparées avec les résultats de prédiction des algorithmes via le RMSE (racine de l'écart quadratique moyenne), le MAPE (pourcentage de la moyenne de l'erreur absolue) et le R^2 (coefficient de détermination) à l'aide de la librairie scikit-learn (version 1.2.1.).

2. RESULTATS ET DISCUSSION

2.1. Comparaison des performances de prédiction des scénarios

2.1.1. *Importance des caractéristiques de la truie et du logement*

Pour la lysine, les scénarios incluant les caractéristiques de la truie et du logement ont des MAPE et RMSE améliorés par rapport à ceux n'incluant pas ces données (respectivement 5,5 *vs* 11,1 % et 0,70 *vs* 1,28 g/j). Pour l'énergie, les scénarios avec un seul capteur ont aussi de meilleures performances de prédiction avec l'intégration de ces caractéristiques (R^2 = 0,73 *vs* 0,38 sans ces variables), mais des performances similaires à celles des scénarios avec deux capteurs (R^2 = 0,73 pour un capteur et 0,72 pour deux capteurs).

2.1.2. *Supériorité de l'automate alimentaire pour la prédiction*

Pour l'énergie, les prédictions les plus précises ont été obtenues pour les scénarios cumulant l'automate alimentaire seul (R^2 = 0,74) ou avec un autre capteur (R^2 = 0,75). L'activité physique journalière de la truie est reliée au comportement alimentaire (Chapinal *et al.,* 2010). Ainsi, le comportement alimentaire peut être utilisé comme un proxy du temps debout, un paramètre clé des calculs des besoins journaliers énergétiques (Gaillard *et al.,* 2019).

Pour la lysine, les scénarios incluant les caractéristiques avec uniquement l'automate d'alimentation ou la balance avaient les R^2 les plus élevés (0,92) et les plus faibles RMSE (0,64-0,65 g/j) et MAPE (5,1-5,2 %), suivis du scénario cumulant l'automate d'alimentation avec la balance (MAPE = 5,3 %). Les besoins en lysine calculés par InraPorc sont basés sur le poids vif et le rang de portée (Gaillard *et al.,* 2019). Ces deux grandeurs sont reliées à la hiérarchie, elle-même corrélée à l'ordre de passage à l'automate alimentaire (Lanthony *et al.,* 2022), expliquant les performances de prédictions élevées avec l'automate.

2.2. Comparaison des performances de prédiction des algorithmes

Les MAPE et RMSE les plus faibles (et meilleurs), ainsi que les R^2 les plus élevés, ont été obtenus avec le GTB (R^2 = 0,99 et 0,95, respectivement pour la lysine et l'énergie), suivis du RF (R^2 = 0,97 et 0,92) et enfin du MLP (R^2 = 0,97 et 0,89). Les plus faibles performances de prédiction ont été obtenues avec LR, LASSO et RIDGE. La supériorité de ces algorithmes d'apprentissage automatique comparés à des régressions linéaires a également été montrée dans d'autres études sur le comportement (Kleanthous *et al.,* 2018) et l'ingestion alimentaire (Misiura *et al.,* 2021).

CONCLUSION

Les méthodes d'apprentissage automatique, utilisant les données fournies par les automates et capteurs, peuvent prédire précisément les besoins nutritionnels quotidiens des truies gestantes avec seulement 5 et 7 % d'erreur, respectivement pour l'énergie et la lysine. Ils ouvrent la voie à des solutions plus simples pour appliquer une alimentation de précision dans les fermes commerciales. De plus, l'utilisation d'un ou deux capteurs, utiles pour d'autres tâches sur la ferme, avec des algorithmes à faible consommation de ressources, vont dans le sens de « l'intelligence artificielle verte ».

REMERCIEMENTS

Ce travail a bénéficié d'une aide financière de l'État gérée par l'ANR au titre du programme d'Investissements d'avenir portant la référence ANR-16-CONV-0004.

REFERENCES BIBLIOGRAPHIQUES

- Chapinal N., Ruiz de la Torre J.L., Cerisuelo A., Gasa J., Baucells M.D., Coma J., Vidal A., Manteca X., 2010. Evaluation of welfare and productivity in pregnant sows kept in stalls or in 2 different group housing systems. J. Vet. Behav., 5, 83-93.
- Gaillard C., Gauthier R., Cloutier L., Dourmad J.Y., 2019. Exploration of individual variability to better predict the nutrient requirements of gestating sows. J. Anim. Sci., 97, 4934-4935.
- Gaillard C., Quiniou N., Gauthier R., Cloutier L., Dourmad J.Y., 2020. Evaluation of a decision support system for precision feeding of gestating sows. J. Anim. Sci., 98, 1-12.
- Kleanthous N., Hussain A., Mason A., Sneddon J., Shaw A., Fergus P., Chalmers P., Al-Jumeily D., 2018. Machine learning techniques for classification of livestock behaviour. Proc. Conference "ICONIP 2018: Neural Information Processing", Siem Reap, Cambodge, pp. 304-315.
- Lanthony M., Danglot M., Spinka M., Tallet C., 2022. Dominance hierarchy in groups of pregnant sows: Characteristics and identification of related indicators. Appl. Anim. Behav. Sci., 254, 105683.
- Misiura M.M., Filipe J.A.N., Brossard L., Kyriazakis I., 2021. Bayesian comparison of models for precision feeding and management in growing-finishing pigs. Biosyst. Eng., 211, 205-218.
- Neethirajan S., 2020. The role of sensors, big data and machine learning in modern animal farming. Sens. Bio-Sens. Res., 29, 100367.