

УДК 004.896

DOI: 10.25206/2310-4597-2023-1-96-100

РАЗРАБОТКА СВЁРТОЧНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ КЛАССИФИКАЦИИ ПИЩЕВОГО ПОВЕДЕНИЯ КРУПНОГО РОГАТОГО СКОТА

DEVELOPMENT OF A CONVOLUTIONAL NEURAL NETWORK FOR THE CLASSIFICATION OF THE FEEDING BEHAVIOR OF CATTLE

Д. Н. Шлома

Омский государственный технический университет, г. Омск, Россия

D. N. Shloma

Omsk State Technical University, Omsk, Russia

Аннотация. В исследовании, приведен обзор сведений об использовании характеристик пищевого поведения крупного рогатого скота (КРС), для выявления у них проблем со здоровьем и благополучием. Представлен обзор алгоритмов машинного обучения, пригодных для классификации пищевого поведения КРС и обосновано использование свёрточной нейронной сети (CNN). Показано использование внутрижелудочного болюса и недоузка, в качестве источников входных данных для CNN. Для решения проблем практической реализации разработанной CNN, обозначен компромисс между производительностью CNN, сложностью вычислений и требуемым аппаратным ресурсам, выполнен поиск гиперпараметров и произведена оптимизация CNN.

Ключевые слова: свёрточная нейронная сеть, пищевое поведение, классификация, внутрижелудочный болюс, датчик ускорения, недоузок, крупный рогатый скот

Abstract. The study provides an overview of the evidence for using the eating behavior characteristics of bovine animals to identify health and well-being problems. A review of machine learning algorithms suitable for classifying the feeding behavior of cattle is presented and the use of a convolutional neural network (CNN) is substantiated. Shows the use of intragastric bolus and halter as input sources for CNN. To solve the problems of practical implementation of the developed CNN, a trade-off between CNN performance, computational complexity and required hardware resources was identified, a search for hyperparameters was performed, and CNN optimization was performed.

Keyword: convolutional neural network, feeding behavior, classification, intragastric bolus, acceleration sensor, halter, pressure sensor, cattle.

I. ВВЕДЕНИЕ

Классификация пищевого поведения крупного рогатого скота (КРС), позволяет выявить такую важную поведенческую характеристику как руминацию, которая является одним из ключевых показателей, предоставляющих важную информацию для эффективной оценки здоровья и благополучия животных. Изменение периодов руминации, свидетельствует о том, что КРС имеет заболевания, травмы, употребляет неподходящий корм или испытывает дискомфорт, например из-за стресса. Получение истинных данных о периодах руминации КРС, способом непосредственного наблюдения за процессом жизнедеятельности КРС, требует значительных усилий от наблюдателя, и зачастую приводит к накоплению погрешности измерений [1,2]. Использование недоузка современной конструкции, является общепринятым подходом получения истинных данных о пищевом поведении КРС, за счет автоматического измерения движения челюстей КРС и определения периодов руминации [3]. Различные исследования [1, 4] сообщают о высокой корреляции Спирмена (0,96;0,75) для руминации и (0,96;0,81) для приема пищи, соответственно. Однако недоузок является дорогостоящим устройством, подверженным механическим повреждениям, вследствие взаимодействия КРС между собой, характеризуется

непродолжительным временем автономной работы, и при долгом использовании может создавать дискомфорт для КРС.

В работах [3, 4] описывается применение внутрижелудочного болюса (ВЖБ) для классификации пищевого поведения КРС, с использованием метода опорных векторов, где в качестве входных данных, выступают временные ряды ускорений от сокращения мышц желудка КРС, полученные с ВЖБ. Однако, применение метода опорных векторов, требует не только, значительной вычислительной мощности для извлечения признаков, позволяющих точно различать пищевое поведение, но и привлечения экспертов в данной предметной области. Кроме того, несмотря на эффективность, таких признаков для классификации пищевого поведения, их нельзя расширить на дополнительные классы поведения, поскольку, в этом случае потребуется поиск и извлечение новых признаков, что вносит дополнительную трудоемкость.

В такой ситуации, целесообразным является исследовать возможность использования свёрточной нейронной сети (CNN) глубокого обучения (DL) для классификации пищевого поведения КРС, с выделением типов пищевого поведения и времени, затрачиваемого животным на руминацию.

II. ПОСТАНОВКА ЗАДАЧИ

В исследовании [3] продемонстрировано использование CNN для идентификации периодов выпаса КРС, однако цель исследования являлась бинарной, что существенно снижало трудоемкость классификации, чем в задаче с несколькими состояниями. В работе [5] продемонстрировано, что рекуррентная нейронная сеть с долговременной кратковременной памятью (RNN-LSTM) классифицирует восемь типов поведения КРС, используя входные данные с аналогичных источников. Но, при этом RNN-LSTM, в связи со значительной сложностью алгоритма, для своего функционирования требует существенных вычислительных и энергетических мощностей, что на современном уровне развития техники, не осуществимо в мобильном исполнении.

Анализ показывает, что CNN подобно RNN-LSTM, представляют собой сложные математические модели, которые при развертывании могут быть требовательными к мощности аппаратного обеспечения. Однако, CNN позволяют использовать компромисс между требуемой производительностью и объемом модели, что может способствовать снижению их требований к мощности аппаратного обеспечения и энергопотреблению, и, ожидаемо, обеспечит их функционирование на мобильных средствах измерения [3, 5].

Следовательно, целью настоящего исследования является разработка CNN глубокого обучения (DL) для классификации пищевого поведения КРС. Использование CNN, разработанной в данном исследовании, позволит устранить трудоемкость процесса создания функций, который сопровождает подходы машинного обучения (ML) и затрудняет ввод новых состояний поведения в прогнозную модель. В качестве источников входных данных, для разработанной CNN, используются ВЖБ и недоузок. При этом входными данными являются: с ВЖБ временные ряды ускорений от мышц желудка, а с недоузка – временные ряды с достоверной информацией о типе пищевого поведения.

III. ТЕОРИЯ

Архитектура классификатора была основана на многоклассовой CNN, которая принимает на вход три сегмента временного ряда, соответственно, по одному для каждой оси X, Y и Z и выводит прогнозируемый класс. Базовая архитектура состоит из двух логических блоков. Экстрактор признаков состоит из 4 блоков сверточных уровней: «Dropout», «BatchNorm» и «ReLU». Архитектура классификатора отображает размер ядра и последовательности для всех слоев. На последнем уровне размер ядра равен 1, что позволяет расширять карту признаков от 64 до 512. Схема, детализирующая процесс разработки CNN, который включает сбор данных, предварительную обработку данных, поиск гиперпараметров, оптимизацию сети и оценку производительности, показана на рис. 1.

Экстрактор содержит слой «Adaptive Average Pooling», который используется для агрегирования функции в пространственном измерении и создает согласованный выходной размер для случаев, когда длина ввода варьируется. Такой прием необходим для изучения влияния размера окна на производительность. Главная часть состоит из одного полносвязного слоя с 512 входами и 3 выходами, за которыми следует слой «Softmax» для создания классифицированного вывода.




Рис. 1. Схема, показывающая все этапы разработки предлагаемой CNN:

I – производительность исходной модели; II – производительность оптимизированной модели

IV. РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ

Все исследования проводились в период с 5 по 19 июля 2022 г. на коровах голштинской породы, содержащихся на молочной ферме ЗАО «Конёвское» (Россия, Новосибирская обл.). В качестве объектов для исследования, были отобраны пять коров, при этом критерием отбора являлось наличие болуса, уже установленного в желудке коровы. Для идентификации коровам были присвоены номера. На время исследований, для коров сохранялся привычный распорядок дня, тип и количество потребляемой ими пищи и жидкости.

В процессе исследования, корову №1 помещали в отдельный загон и закрепляли на ней недоуздок, который фиксировал: порядковый номер измерения, время измерения, тип пищевого поведения. Внутрижелудочный болус коровы №1 фиксировал: порядковый номер измерения, время измерения, значения ускорений мышц желудка. Частота дискретизации болуса и недоуздки составляла 10 Гц. Фиксация данных происходила в файлы, находящиеся во внутренней памяти соответствующего устройства, при этом, формат имени каждого файла, соответствовал дате каждого суток эксперимента. По истечении 72 ч. исследование завершалось, с коровы №1 снимали недоуздок и возвращали ее обратно в стадо. Затем исследование повторялось для следующей отобранной коровы.

Данные, собранные во время исследований с недоуздки и болуса, синхронизировались по дате и времени измерений и объединялись в общий массив данных для каждой коровы, приблизительным объемом 3,75 млн. строк измерений. Для классификации пищевого поведения, случайным образом была выбрана корова №4, и из соответствующего ей общего массива данных, была сделана выборка, объемом в 26,1 тыс. измерений, что соответствует 30 мин исследования. Выборка измерений для коровы №4 (дата исследования 14 июля 2022 г.) приведена в таблице 1.

ТАБЛИЦА 1
ВЫБОРКА ИЗМЕРЕНИЙ ДЛЯ КОРОВЫ №4

№	Дата и время измерения	Значения ускорений мышц желудка коровы, g			Тип пищевого поведения
		ось X	ось Y	ось Z	
469796	2022-07-14 09:00:36.011718	872.0	-16732.0	-1248.0	2
469797	2022-07-14 09:00:36.080684	860.0	-16856.0	-1176.0	2
469798	2022-07-14 09:00:36.149650	808.0	-16824.0	-1256.0	2
469799	2022-07-14 09:00:36.218616	776.0	-16748.0	-1256.0	0
469800	2022-07-14 09:00:36.287582	876.0	-16788.0	-1172.0	0
...	...	...	...	...	...
495894	2022-07-14 09:29:59.908487	-1836.0	6220.0	-17016.0	1
495895	2022-07-14 09:29:59.977414	-1912.0	6196.0	-17040.0	1
495896	2022-07-14 09:30:00.046341	-1856.0	6120.0	-17220.0	1

Тип пищевого поведения: 1 – руминация, 2 – прием пищи; 0 – животное занято деятельностью, не связанной пищевым поведением №1 и №2, например прием жидкости.

Разработанная CNN обучалась с помощью оптимизатора AdamW [4] со скоростью обучения 1×10^{-4} . Размер пакета был установлен на 256. Сеть была обучена не более чем на 50 примерах с ранним завершением, когда потери при проверке достигли плато [6] при выдержке 15 циклов и изменении $\Delta 0,01$. Кроме того, для всех результатов снижения весов, при λ использовалось значение 0,01. Оптимальная модель была выбрана из тренировочного цикла после завершения процесса.

Балл $F1$ использовался для оценки производительности CNN, и определялся как среднее гармоническое параметров $precision$ и $recall$, по выражению:

$$F1 = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (1)$$

Параметры $precision$ и $recall$ из выражения (1) определялись следующим образом:

$$precision = \frac{TP}{TP + FP},$$

$$recall = \frac{TP}{TP + FN} \quad (2)$$

Поиск по гиперпараметрам был выполнен для оптимизации количества сверточных признаков в экстракторе, размера ядра сверточных фильтров и слоев [7]. Количество фильтров для экстрактора признаков остается постоянным на протяжении всего поиска гиперпараметров. Принимая во внимание стохастический характер обучения модели, процесс повторялся 5 раз и модель с наибольшим средним значением $F1$, среди всех, была выбрана. CNN с четырьмя сверточными блоками, размером ядра 16, слоем «Dropout» и вероятностью 0,25 дала наилучшие результаты. Средняя производительность проверки для этих параметров ($F1$, $precision$ и $recall$) была соответственно 0,82, 0,83 и 0,82. Матрица ошибок при проверке показана на рис. 2(а).




Рис. 2. Матрица ошибок полной сети после настройки гиперпараметров:

а) набор проверки; б) тестовый набор; I – деятельность, не связанная пищевым поведением II и III; II – руминация; III – прием пищи

Матрица ошибок полной сети после настройки гиперпараметров, также содержит стандартные отклонения для всех ячеек. Например, нормализованная производительность TP «прием пищи» составляет $0,81 \pm 0,04$, тогда как «руминация» ошибочно классифицируется как «прием пищи» при $0,16 \pm 0,03$. Во всех случаях стандартное отклонение ниже 0,04. Если предположить, что среднее время руминации КРС составляет около 400 мин. в день, то увеличение чувствительности на 1% приведет к увеличению времени, затрачиваемого на руминацию, примерно на 4 мин. в день.

В следующем случае, для оценки на тестовом наборе была выбрана модель с наилучшей производительностью на проверочном наборе. Производительность проверочного набора была ($F1$, $precision$ и $recall$) соответственно (0,86; 0,87; 0,86), а тестовая выборка ($F1$, $precision$ и $recall$) соответственно (0,82; 0,84; 0,82).

Матрица ошибок при проверке в тестовом наборе показана на рис. 2(б). Поскольку пищевые поведения «прием пищи» и «руминация» характеризуются у КРС сходными движениями челюстей, то модель испытывает наибольшую ошибку между этими двумя состояниями; тогда как ошибка между другими состояниями значи-

тельно ниже. Для полного набора тестовых данных без стратификации или балансировки, взвешенные показатели производительности ($F1$, *precision* и *recall*) соответственно составили (0,82;0,87;0,81).

V. ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

В исследовании показано, что разработанная CNN, обеспечивает точную классификацию пищевого поведения КРС. Для оптимизации архитектуры модели была выполнена настройка гиперпараметров, при этом, производительность модели оценивалась как функция длины временного окна [7]. Поскольку реализация моделей классификации пищевого поведения КРС регулируется ограничениями, устанавливаемыми вычислительными ресурсами, была произведена оценка влияния на производительность CNN функций оптимизации и обучения смешанной точности. Результаты подтверждают, что высокая производительность может быть достигнута при значительном сокращении модели, что в свою очередь, значительно снижает сложность вычислений и требований к объему памяти. Модель CNN с оптимизированными фильтрами в количестве 48 штук, способна классифицировать три типа пищевого поведения КРС – руминация (а), прием пищи (б) и деятельность, не связанная пищевым поведением (а) и (б), при этом $F1 = 0,82$.

Полученная производительность разработанной CNN сопоставима с классическими подходами к ML и DL, о которых сообщается в различных исследованиях [8].

VI. ВЫВОДЫ И ЗАКЛЮЧЕНИЕ

В исследовании, представлена реализация разработанной CNN, пригодной для классификации пищевого поведения КРС. Показано использование внутрижелудочного болюса и недоузка, в качестве источников входных данных для CNN. Обозначен компромисс между производительностью разработанной CNN, сложностью вычислений и требуемым аппаратным ресурсам, затем выполнен поиск гиперпараметров и произведена оптимизация CNN. Полученная производительность разработанной CNN сравнена с классическими подходами к ML и DL. Полученная CNN может быть использована в системах мониторинга КРС, для выявления у них проблем со здоровьем и благополучием. В последующем, представленная CNN, может быть использована для выявления таких поведенческих состояний КРС, как «стояние», «лежание» и «ходьба», в случае беспривязного содержания – выявления хромоты.

СПИСОК ЛИТЕРАТУРЫ

1. Антонов Л. В. Разработка и апробация алгоритмов выделения комплексных показателей состояния здоровья вымени животных на основе анализа данных с сенсоров предприятия молочного животноводства // Вестник ЧГУ. 2017. № 1. С. 19–21.
2. Шлома Д. Н. Разработка системы сбора данных для экспериментальных исследований цифровизации молочно-мясного скотоводства // Информационные технологии и автоматизация управления: материалы XIII Всерос. науч.-практ. конф. студентов, аспирантов, работников образования и промышленности. Омск: Изд-во ОмГТУ, 2022. С. 295–305.
3. Rahman A., Smith D. V., Little B., Ingham A. B., Greenwood P. L., Bishop-Hurley G.J. Cattle behaviour classification from collar halter, and ear tag sensors // Inf. Process. Agric. 2018. Pp. 31–40.
4. Robert B., White B. J., Renter D. G., Larson R. L. Evaluation of three-dimensional accelerometers to monitor and classify behavior patterns in cattle // Comput. Electron. Agric. 2009. Pp. 80–84.
5. Smith D., Rahman A., Bishop-Hurley G. J., Hills J., Shahriar S., Henry D., Rawnsley R. Behavior classification of cows fitted with motion collars: Decomposing multi-class classification into a set of binary problems // Comput. Electron. Agric. 2016. Pp. 40–50.
6. Han S., Pool J., Tran J., Dally W. J. Learning both weights and connections for efficient neural networks // Adv. Neural Inf. Process. Syst. 2015. Pp. 1135–1143.
7. Han S., Mao H., Dally W. J. Deep compression: Compressing deep neural networks with pruning, trained quantization and huffman coding. arXiv. 2015.
8. Rastegari M., Ordonez V., Redmon J., Farhadi A. Xnor-net: Imagenet classification using binary convolutional neural networks // In Proceedings of the European Conference on Computer Vision, Amsterdam, The Netherlands, 11–14 October 2016. Springer: Berlin/Heidelberg, Germany, 2016. Pp. 525–542.