
ЗООТЕХНИЯ, БИОЛОГИЯ И ВЕТЕРИНАРНАЯ МЕДИЦИНА

**Алгоритм адаптивной дискретизации видеопотока
для повышения точности детекции реперных анатомических
ориентиров КРС в задачах оценки их упитанности**

**Анастасия Владимировна Греченева[✉], Евгения Сергеевна Латынина,
Магдалина Алексеевна Акимовкина, Максим Дмитриевич Бакнин**

Российский государственный аграрный университет –
МСХА имени К.А. Тимирязева, Москва, Россия

[✉] **Автор, ответственный за переписку:** a.grecheneva@rgau-msha.ru

Аннотация

Оценка упитанности молочного крупного рогатого скота по шкале Body Condition Score (BCS) используется для контроля энергетического статуса животных и выявления рисков метаболических и репродуктивных нарушений. При производственной видеосъемке точность автоматизированного определения BCS ограничивается смещением реперных анатомических ориентиров, возникающим вследствие изменения позы животного, скорости прохода, неравномерного освещения, бликов и теней. Целью исследований являлась разработка алгоритма адаптивного выбора кадров видеопотока для повышения точности детекции реперных точек и контурных ориентиров в задачах автоматизированной оценки упитанности крупного рогатого скота молочного направления продуктивности. Материал исследований составили видеопоследовательности 983 коров молочного направления продуктивности. Для анализа использовали систему реперных точек и контурных ориентиров тазовой области, а обработку изображений выполняли многозадачной нейросетевой моделью локализации ключевых точек и контуров с последующим прогнозом BCS по шкале 1–5. Разработанный алгоритм включал в себя адаптивную дискретизацию кадров по скорости движения животного, оценку наблюдаемости анатомических зон и покомпонентный отбор наиболее информативных кадров для формирования согласованного набора признаков. Применение алгоритма обеспечило снижение средней абсолютной ошибки оценки BCS с 0,34 до 0,22 балла, увеличение доли оценок в пределах $\pm 0,5$ балла с 86,2 до 93,7% и рост взвешенного коэффициента Cohen's κ с 0,74 до 0,86. Нормированная ошибка локализации реперных точек уменьшилась с 0,071 до 0,048. Полученные результаты подтверждают, что адаптивная кадровая предобработка повышает точность и устойчивость автоматизированной оценки упитанности в условиях производственной видеосъемки.

Ключевые слова

крупный рогатый скот, молочное скотоводство, упитанность, body condition score, компьютерное зрение, видеопоток, адаптивная дискретизация, ключевые точки, контурные ориентиры, нейросетевая модель

Благодарности

Работа выполнена при поддержке гранта РНФ № 25–76–00067.

Для цитирования

Греченева А.В., Латынина Е.С., Акимушкина М.А., Бакнин М.Д. Алгоритм адаптивной дискретизации видеопотока для повышения точности детекции реперных анатомических ориентиров КРС в задачах оценки упитанности // *Известия Тимирязевской сельскохозяйственной академии*. 2026. № 2. С. 105–122.

LIVESTOCK BREEDING, BIOLOGY AND VETERINARY MEDICINE

An adaptive video stream sampling algorithm for improving the detection accuracy of reference anatomical landmarks in cattle for their body condition assessment

**Anastasia V. Grecheneva[✉], Evgeniya S. Latynina,
Magdalena A. Akimushkina, Maxim D. Baknin**

Russian State Agrarian University – Moscow Timiryazev Agricultural Academy,
Moscow, Russia

[✉]**Corresponding author:** a.grecheneva@rgau-msha.ru

Abstract

Body Condition Score (BCS) in dairy cattle is used to monitor animal energy status and to identify the risks of metabolic and reproductive disorders. In industrial video recording, the accuracy of automated BCS estimation is limited by the displacement of reference anatomical landmarks. This displacement arises due to changes in animal posture, walking speed, uneven lighting, glare, and shadows. The study aimed to develop an adaptive video-frame selection algorithm to improve the detection accuracy of reference keypoints and contour landmarks in automated body condition assessment of dairy cattle. The research material consisted of video sequences of 983 dairy cows. For analysis, a system of reference points and contour landmarks of the pelvic region was used. Image processing was performed using a multitask neural network model for localizing key points and contours, followed by BCS prediction on a 1–5 scale. The developed algorithm included adaptive frame sampling based on animal walking speed, visibility assessment of anatomical zones, and component-wise selection of the most informative frames to form a consistent set of features. Application of the algorithm resulted in a reduction of the mean absolute error in BCS estimation from 0.34 to 0.22 score points, an increase in the proportion of predictions within ± 0.5 points from 86.2% to 93.7%, and an improvement in the weighted Cohen's κ coefficient from 0.74 to 0.86. The normalized localization error of reference keypoints decreased from 0.071 to 0.048. The findings confirm that adaptive frame preprocessing enhances the accuracy and robustness of automated body condition assessment under industrial video recording conditions.

Keywords

cattle, dairy farming, body condition, Body Condition Score, computer vision, video stream, adaptive sampling, keypoints, contour landmarks, neural network model

Acknowledgments

The research was funded by the Russian Science Foundation, grant No. 25–76–00067.

For citation

Grecheneva A.V., Latynina E.S., Akimushkina M.A., Baknin M.D. An adaptive video stream sampling algorithm for improving the detection accuracy of reference anatomical landmarks in cattle for their body condition assessment. *Izvestiya of Timiryazev Agricultural Academy*. 2026;(2):105–122.

Введение Introduction

Показатель упитанности молочных коров – Body Condition Score (BCS) [1-4] – является интегральным показателем энергетического баланса и здоровья, связанным с продуктивностью, фертильностью и риском метаболических заболеваний в раннюю лактацию. Исследования подтверждают наличие устойчивых взаимосвязей балла упитанности и клинических проявлений заболеваний. Так, низкий уровень BCS ассоциирован с повышенным риском возникновения кетоза [5-7], а высокий, особенно в сухостойный период, рассматривается как фактор риска дистоции [8]. Дополнительно доказана связь BCS с продуктивностью и продолжительностью хозяйственного использования животных [9].

Следует отметить, что в племенных заводах, племрепродукторах и в товарных хозяйствах с организованным племенным учетом контроль BCS, как правило, осуществляется ежемесячно [9], что характеризует данный процесс повышенной трудоемкостью. Несмотря на клиническую значимость показателя традиционная экспертная оценка обладает выраженной субъективностью. В настоящее время на большинстве предприятий АПК оценка BCS осуществляется посредством пальпаторной и визуальной оценки жировых отложений в области поясничного отдела, маклаков, крестца и основания хвоста коровы по шкале от 1 (сильно истощенное животное) до 5 (ожирение) с шагом 0,25 или 0,5 [1, 3-5]. Межнаблюдательная вариабельность, влияние условий освещения и человеческого фактора ограничивают воспроизводимость результатов. Исследования, опубликованные в *Journal of Dairy Science*, демонстрируют: коэффициент согласия Cohen's kappa между экспертами варьируется в пределах 0,6-0,8, что соответствует умеренной или высокой, но не идеальной согласованности [10]. Данная вариабельность означает наличие стохастического шума в целевой переменной, что с точки зрения машинного обучения приводит к ограничению верхней границы достижимой точности модели.

Указанные ограничения обусловили рост интереса к автоматизированным методам оценки упитанности на основе технологий компьютерного зрения и машинного обучения. Развитие цифровых камер, глубинных сенсоров и алгоритмов обработки изображений позволило перейти от субъективной экспертной оценки к количественному анализу морфометрических признаков.

Цель исследований: разработка алгоритма адаптивного выбора кадров видеопотока для повышения точности детекции ключевых экстерьерных точек крупного рогатого скота молочного направления продуктивности в задачах оценки упитанности.

Методика исследований Research method

В задачах видеомониторинга молочного КРС целесообразно подразделять признаки на динамические и статические, поскольку эти классы по-разному проявляются в видеопотоке и предъявляют различные требования к методике измерения. Динамическая биометрия опирается на временную структуру движения и используется для контроля хромоты, так как патологические изменения чаще выражаются через скорость, амплитуду и симметрию локомоции [11]. Упитанность относится к статической биометрии и отражает распределение мягких тканей. При этом визуальные проявления упитанности связаны с тем, насколько выражены костные ориентиры и мягкотканые впадины в области таза и поясницы [12]. Следовательно, в видеопотоке ключевым становится не число кадров, а наличие наблюдений, в которых рельеф этих зон фиксируется устойчиво и сопоставимо.

Степень визуализации костных структур обратно пропорциональна количеству подкожного жира. Таким образом, задача автоматизации BCS по изображениям фактически сводится к количественной оценке геометрических характеристик формы тела, что делает данную задачу пригодной для использования методов компьютерного зрения и технологий искусственного интеллекта [13-15].

В представленных исследованиях для анализа изображений коров в дорсальной проекции (вид сверху) и боковой проекции были выделены реперные анатомические ориентиры и контурные точки, традиционно используемые при визуальной оценке упитанности. На изображениях в дорсальной проекции к ним были отнесены маклоки (1, 2), краниолатеральные контурные точки тазовой области (3, 4), парасакральные реперные точки (5, 6), межмаклочная точка (7), межседалищная точка (8), латеральные точки перехода от маклаков к седалищным буграм (9, 10), а также седалищные бугры (11, 12). На изображениях в боковой проекции выделяли маклок (2), краниальную контурную точку пояснично-тазовой области (4), область крестцовой связки (6), область коротких ребер (7), седалищный бугор (8), область тазобедренного сустава (10) и хвостовую связку (12).

Выбор указанных анатомических ориентиров (ключевых точек) обусловлен тем, что именно в этих участках наиболее отчетливо проявляются морфологические изменения, связанные с накоплением или дефицитом подкожного жира. С позиции компьютерного зрения данные ориентиры представляют собой информативные элементы изображения, характеризующиеся изменением кривизны внешнего контура, выраженностью костных выступов, глубиной анатомических углублений, а также взаимным расположением ключевых структур. При снижении упитанности в указанных зонах возрастает визуальная выраженность костных ориентиров, увеличивается контрастность контуров и углублений, тогда как при повышении упитанности наблюдаются сглаживание соответствующих анатомических переходов и уменьшение их геометрической выраженности. Использование данных реперных ориентиров позволяет формализовать визуальную оценку упитанности в виде набора морфометрических признаков, пригодных для последующего извлечения и анализа средствами искусственного интеллекта.

Практическая трудность точной детекции анатомических ориентиров обусловлена фотометрическими помехами [16]. В селекционном коридоре на животноводческих комплексах светотеневая картина меняется по мере прохода животного, возникают блики на шерсти, тени от ограждений, а также колебания яркости ввиду работы автоэкспозиции. В области таза рельеф часто читается по микроконтрасту, поэтому постановка ключевых точек в проекции маклока (*tuber coxae*), седалищного бугра (*tuber ischii*), крестца и области основания хвоста (*tailhead*) может смещаться к ложным градиентам, сформированным бликом или тенью. Даже небольшое смещение центров ключевых точек приводит к заметной ошибке в индексах упитанности, которые строятся на нормированных расстояниях, углах и локальной форме контура. В связи с этим предлагается специализированный алгоритм анализа изображений, блок-схема которого приведена на рисунке 2.

Алгоритм рассматривает оценку упитанности как восстановление статической морфологии по серии неоднородных наблюдений. На первом этапе выполняются детекция животного и трекинг, чтобы кадры одного прохода были связаны единым идентификатором. Затем вводится адаптивная дискретизация видеопотока, поскольку скорость прохода сильно варьирует; при фиксированной частоте кадрирования быстрые животные дают разреженную выборку и повышенный смаз, а медленные формируют избыточные, почти одинаковые кадры, среди которых возрастает риск «закрепить» неблагоприятную светотень (рис. 3).




Рис. 1. Реперные точки и контурные ориентиры, используемые при разметке изображений коров для оценки упитанности:

- а – вид сверху; б – вид сбоку. Для вида сверху: 1, 2 – маклоки; 11, 12 – седалищные бугры; 7 – межмаклочная точка; 8 – межседалищная точка; 5, 6 – парасакральные реперные точки; 9, 10 – латеральные точки перехода от маклоков к седалищным буграм; 3, 4 – краниолатеральные контурные точки тазовой области. Для вида сбоку: 2 – маклак; 4 – краниальная контурная точка пояснично-тазовой области; 6 – крестцовая связка; 7 – область коротких ребер; 8 – седалищный бугор; 10 – тазобедренный сустав; 12 – хвостовая связка

Figure 1. Reference points and contour landmarks used for annotating cow images for body condition assessment: (a) top view; (b) side view. For the top view: 1, 2 – hook bones; 11, 12 – pin bones; 7 – inter-hook point; 8 – inter-pin point; 5, 6 – parasacral reference points; 9, 10 – lateral transition points from hook to pin bones; 3, 4 – craniolateral contour points of the pelvic region. For the side view: 2 – hook bone; 4 – cranial contour point of the lumbar-pelvic region; 6 – sacral ligament; 7 – short rib area; 8 – pin bone; 10 – hip joint; 12 – tailhead ligament

Особое значение в контексте автоматизации BCS имеет выбор ракурса съемки. Традиционно экспертная оценка выполняется при наблюдении животного сзади или под углом, что отражает исторически сложившуюся практику визуального осмотра. Однако при использовании стационарных камер в условиях промышленной фермы более технологически оправданной является дорсальная (top-view) съемка, когда камера размещается над проходом или доильной установкой. Такой ракурс минимизирует перекрытия между животными, снижает влияние фона и обеспечивает стабильную геометрию проекции тазовой области. В дорсальной проекции маклаки и крестцовая область располагаются в почти плоской конфигурации относительно плоскости изображения, что упрощает количественный анализ угловых и линейных параметров. Таким образом, съемка top-view представляет собой не только инженерно-удобное, но и морфологически обоснованное решение для автоматической оценки упитанности.




Рис. 2. Блок-схема подпрограммы алгоритма адаптивной дискретизации видеопотока

Figure 2. Flowchart of the adaptive video stream sampling algorithm subroutine



Рис. 3. Принцип работы алгоритма адаптивной дискретизации видеопотока

Figure 3. Operating principle of the adaptive video stream sampling algorithm

Рассмотрим блок-схему подпрограммы процесса «Трекинг и оценка скорости» (рис. 3):

- D_t – детекции на текущем кадре (координаты, уверенность нейросети);
- T_t – множество активных треков, представляющее собой объекты, идентифицированные и отслеживаемые на кадре t ;
- $TrackTable(t-1)$ – таблица треков, хранящая историю состояний (координаты, скорость, идентификаторы) всех треков на предыдущем кадре;
- ROI – зона интереса, прямоугольная подобласть кадра, определяющая пространство, в котором производится целевой анализ;
- Параметры – настройки (пороги, max_lost и т.д.).

Выбор кадров привязывается к перемещению объекта в кадре, что обеспечивает почти постоянный пространственный шаг наблюдения.

Пусть c_t обозначает характерную точку объекта (например, центр рамки или центр масс маски), а S_{acc} – накопленное смещение. Тогда кадр выбирается для анализа при достижении порога Δs , после чего накопление перезапускается.

$$S_{acc} \leftarrow S_{acc} + \|c_t - c_{\{t-\Delta t\}}\|; \quad (1)$$

выбрать кадр, если $S_{acc} \geq \Delta s$; затем $S_{acc} = 0$.

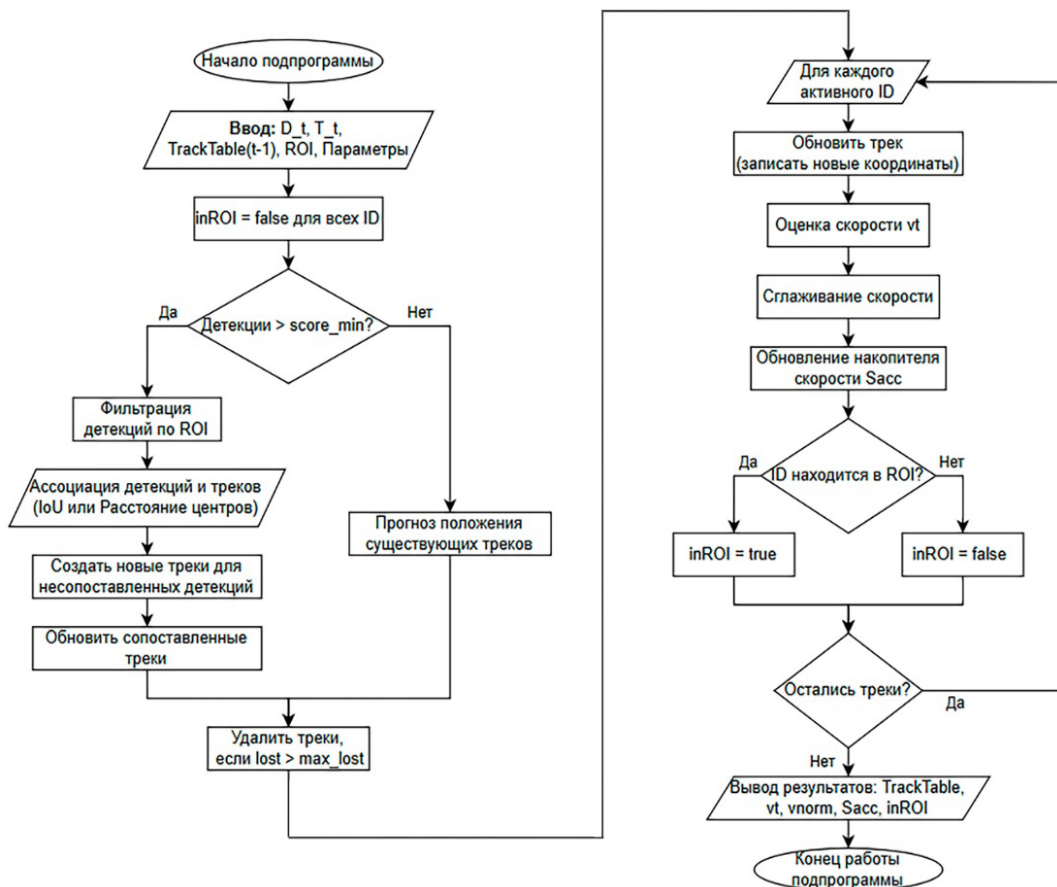


Рис. 4. Блок-схема алгоритма подпрограммы трекинга и оценки скорости особей КРС

Figure 4. Flowchart of the cattle tracking and speed estimation subroutine

Для каждого выбранного кадра оцениваются первичные ключевые точки таза и формируются зоны интереса (ROI) [17], которые задаются как функция этих точек. Этот шаг является принципиальным, поскольку критерии качества рассчитываются не по всему кадру, а внутри анатомически обоснованной области. В ROI вычисляются показатели, отражающие пригодность кадра для постановки ключевых точек и оценки рельефа. В качестве полезных факторов выступают выраженность рельефа в зоне впадин и резкость, а в качестве штрафов используются доли переосвещения, провала экспозиции и спекулярных бликов. Итоговая оценка пригодности кадра Q_t задается так, чтобы рельеф и резкость повышали оценку, а фотометрические артефакты – понижали.

$$Q_i = \sigma(a_r \cdot S_{\{relief,t\}} + a_s \cdot S_{\{sharp,t\}} + a_c \cdot conf_{\{avg,t\}}) \times \exp(-\lambda_1 \cdot r_{\{sat,t\}} - \lambda_2 \cdot r_{\{dark,t\}} - \lambda_3 \cdot r_{\{spec,t\}}). \quad (2)$$

Полученная величина Q_t формализует понятие «выигрышного кадра» по наблюдаемости рельефа и устойчивости фотометрии. После ранжирования кадров по Q_t отбирается верхняя часть выборки. При этом разные ключевые точки могут лучше наблюдаться в разные моменты прохода, поэтому применяется покомпонентный выбор кадров для постановки точек: для каждой точки i выбирается тот кадр, который одновременно обеспечивает высокую уверенность детектора и высокую пригодность наблюдения:

$$t_{i \wedge \{best\}} = \arg \max_t (conf_{\{i,t\}} \cdot Q_t), \quad p_{i \wedge \{sel\}} = p_{\{i,t_{i \wedge \{best\}}\}}. \quad (3)$$

Если требуется дополнительная устойчивость к единичным выбросам, применяется многокадровая компоновка. Из top-K-кадров выполняется выравнивание по устойчивым якорям таза, после чего координаты каждой точки оцениваются как робастная агрегация наблюдений с весами, пропорциональными $conf_{\{i,t\}} \cdot Q_t$. Таким образом, каждая точка фактически «берется» из тех наблюдений, в которых соответствующая зона была видна наиболее отчетливо, а влияние кадров с бликом или глубокими тенями подавляется через штраф в Q_t .

В итоге блок-схема алгоритма подпрограммы «Детекция и ключевые точки» выглядит, как показано на рисунке 5.

Подпрограмма предназначена для локализации анатомических ориентиров крупного рогатого скота на последовательности кадров видеопотока. Входными данными служат текущий кадр t , множество активных идентификаторов ID_k , параметры конфигурации Θ и обученные нейросетевые модели. Для каждого активного ID_k выполняется итеративная процедура: на основе предшествующей информации формируется локальная область интереса, в пределах которой производится детекция животного. При успешной верификации обнаружения выполняется наложение скелетной модели с последующим выделением четырех ключевых точек: маклоков (Tuber soxae), седалищных бугров (Tuber ischii), тазобедренных суставов (Thurl) и основания хвоста (Tailhead). Точки, удовлетворяющие пороговое значение уверенности $conf \geq conf_{min}$, подвергаются геометрической валидации для подтверждения анатомической правдоподобности их взаимного расположения. Для валидных конфигураций вычисляются бинарные показатели видимости $visi \in \{0,1\}$ каждой точки и формируются локальные области интереса ROI $_i$ вокруг них. По завершении обработки всех активных идентификаторов подпрограмма возвращает структурированный результат, содержащий координаты точек, флаги их видимости и соответствующие области интереса для каждого ID_k .

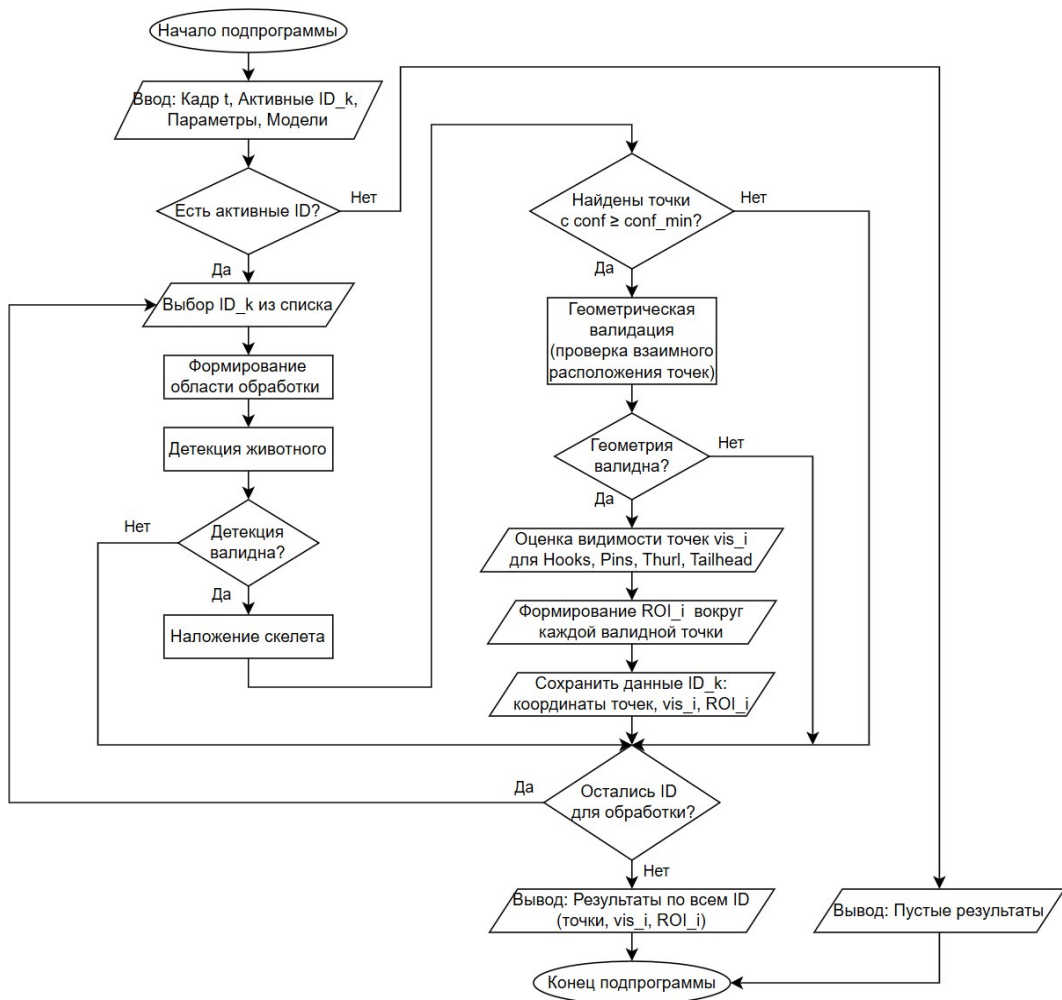


Рис. 5. Блок-схема алгоритма подпрограммы «Сегментация и ключевые точки»

Figure 5. Flowchart of the “segmentation and keypoints” subroutine

После получения согласованного набора ключевых точек и при наличии контурных признаков из ROI вычисляются показатели, коррелирующие с упитанностью. В геометрической части используются нормированные расстояния и углы между тазовыми ориентирами, а в морфологической части – характеристики угловатости и выраженности впадин в привязанных ROI. Полученные признаки подаются в модель, переводящую их в оценку BCS. Результат сопровождается диагностикой достоверности, которая учитывает число валидных кадров, согласованность компоновки и уверенность модели; дополнительно сохраняется набор доказательных кадров из топ-выборки, что упрощает экспертную верификацию и настройку порогов качества для конкретного коридора.

В исследования включены видеопоследовательности 983 коров молочного направления продуктивности. Оценка упитанности выполнялась по шкале BCS1-5. Разметка изображений осуществлялась по системе реперных точек и контурных ориентиров тазовой области. Для вида сверху использовали маклоки, седалищные бугры, межмаклочную и межседалищную точки, парасакральные реперные точки,

латеральные точки перехода от маклоков к седалищным буграм и краниолатеральные контурные точки тазовой области. Для вида сбоку использовали маклок, краниальную контурную точку пояснично-тазовой области, крестцовую связку, область коротких ребер, седалищный бугор, тазобедренный сустав и хвостовую связку. Указанные ориентиры использовали для расчета нормированных расстояний, угловых характеристик и параметров локальной формы контура, определяющих индекс упитанности.

Обработка изображений выполнялась с использованием многозадачной высоко-разрешающей нейросетевой модели локализации ключевых точек и контурных ориентиров с последующим регрессионным прогнозом значения BCS. На вход модели подавали кадрированное изображение коровы размером 512×512 пикселей. Выход сети включал в себя тепловые карты реперных точек, контурную маску тазовой области и итоговую оценку BCS. Обучение проводили с использованием оптимизатора AdamW [18] при начальной скорости обучения $1 \cdot 10^{-3}$, размере мини-батча 16, весовом затухании $1 \cdot 10^{-4}$ и длительности обучения 120 эпох. Для локализации точек применяли метрики *NME* и *PCK@0.05*, для контурной области – Dice coefficient, для итоговой оценки упитанности – MAE, RMSE и взвешенный коэффициент Cohen's κ .

Формирование входных кадров осуществлялось в двух режимах. В первом режиме применялась равномерная временная дискретизация видеопотока без учета скорости перемещения животного и без оценки пригодности отдельных кадров для локализации экстерьерных ориентиров. Во втором режиме использовали алгоритм кадровой предобработки, включающий в себя адаптивную дискретизацию по скорости движения животного и покадровую оценку наблюдаемости анатомических зон. Частота выборки кадров изменялась в зависимости от перемещения объекта в кадре, что позволяло уменьшать избыточность при медленной проходке и сохранять информативные фазы движения при высокой скорости. Для каждой реперной точки и контурного ориентира вычисляли показатель наблюдаемости, учитывающий выраженность локального рельефа, резкость изображения, отсутствие пересветов, глубоких теней, бликов и окклюзий. По результатам ранжирования для каждой анатомической зоны отбирали кадры с наибольшей информативностью, после чего формировали согласованный набор ключевых точек и контурных ориентиров, использованный для расчета BCS.

Результаты и их обсуждение

Results and discussion

Применение алгоритма кадровой предобработки сопровождалось повышением точности оценки упитанности по всем анализируемым показателям. Средняя абсолютная ошибка определения BCS снизилась с 0,34 до 0,22 балла, среднеквадратичная ошибка – с 0,46 до 0,31 балла. Доля оценок, попавших в интервал $\pm 0,5$ балла BCS относительно экспертного значения, увеличилась с 86,2 до 93,7%. Точность точной классификации по шкале BCS1-5 возросла с 71,8 до 81,6%, значение взвешенного коэффициента Cohen's κ – с 0,74 до 0,86 (табл. 1).

На уровне локализации анатомических ориентиров также отмечено снижение ошибки. Нормированная ошибка по реперным точкам уменьшилась с 0,071 до 0,048, доля невалидных проходов, при которых надежная оценка упитанности не могла быть получена вследствие смаза, неблагоприятной позы или фотометрических искажений, сократилась с 11,8 до 3,1%. Наиболее выраженное улучшение зарегистрировано для крестцовой связки, области коротких ребер, седалищных бугров и тазобедренного сустава, то есть для тех анатомических зон, где ошибка локализации в наибольшей степени зависит от фазовой изменчивости движения, светотеневого рисунка и характера контура (рис. 6).

Таблица 1

**Сравнение итоговых метрик оценки упитанности в режимах
без алгоритма предобработки и с алгоритмом адаптивной дискретизации
и компоновки ключевых точек**

Table 1

**Comparison of final body condition assessment metrics in the modes
without the preprocessing algorithm and with the adaptive frame sampling
and keypoint fusion algorithm**

Статистический показатель	Значение показателя	
	Без применения алгоритма	С применением алгоритма
Средняя абсолютная ошибка, MAE (балл BCS)	0,34	0,22
Среднеквадратичная ошибка, RMSE (балл BCS)	0,46	0,31
Доля оценок в пределах $\pm 0,5$ балла BCS, %	86,2	93,7
Точная классификация по шкале BCS1-5, %	71,8	81,6
Взвешенный коэффициент согласия Cohen's k	0,74	0,86
Нормированная ошибка локализации реперных точек, NME	0,071	0,048
Доля невалидных проходов, %	11,8	3,1




Рис. 6. Тепловая карта нормированной ошибки локализации реперных точек и контурных ориентиров в двух режимах обработки

Figure 6. Heat map of the normalized localization error for reference points and contour landmarks in two processing modes

На уровне реперных точек наибольший эффект был получен для зон, наиболее чувствительных к светотеневым и позовым искажениям. По тепловой карте ошибок видим, что после применения алгоритма уменьшалась нормированная ошибка

локализации не только для маклока и седалищного бугра, но и для крестцовой связки, тазобедренного сустава и области коротких ребер. Последняя зона ожидаемо оставалась наиболее трудной для детекции, однако и здесь снижение ошибки было выраженным (рис. 7). Это подтверждает, что ключевой вклад предложенной схемы связан не столько с глобальным улучшением качества изображения, сколько с более корректным выбором кадров и более устойчивым восстановлением локального рельефа в анатомически значимых участках.

Дополнительный анализ по условиям съемки показал, что выигрыш от алгоритма возрастает по мере усложнения визуальной сцены. Наибольшее относительное снижение MAE наблюдалось при контрастном освещении, наличии бликов и у животных с быстрой проходкой, где при фиксированной дискретизации базовый режим чаще пропускал информативные фазы движения. В модельном примере относительное снижение MAE составляло от 18-24% при равномерном освещении до 35-42% в условиях выраженных теней и бликов при средней и высокой скорости прохода. Тем самым подтверждается, что адаптивная дискретизация и отбор best-кадров особенно важны в тех режимах, где ошибки локализации формируются вследствие непостоянства внешних условий, а не только вследствие ограничений самой нейросетевой архитектуры.

Распределение животных по классам BCS1-5 при использовании алгоритма кадровой оптимизации в большей степени соответствовало экспертной структуре выборки (рис. 8). В режиме равномерной дискретизации наблюдалось сглаживание распределения с перераспределением части животных в соседние классы, преимущественно в центральную область шкалы. После применения адаптивной выборки и покомпонентного отбора наиболее информативных кадров распределение автоматических оценок приближалось к экспертному, что указывает на уменьшение систематического смещения при интерпретации экстерьерных признаков.



Рис. 7. Тепловая карта относительного снижения MAE при использовании алгоритма в зависимости от условий освещения и скорости прохода животного

Figure 7. Heat map of the relative reduction in MAE when using the algorithm depending on lighting conditions and animal walking speed




Рис. 8. Распределение голов по классам BCS1-5
Figure 8. Distribution of cows across BCS classes 1-5

Практическая значимость предложенного алгоритма определяется тем, что повышение точности автоматической оценки упитанности непосредственно влияет на корректность выделения группы животных с метаболическим и репродуктивным риском. Упитанность у молочного скота рассматривается как индикатор обеспеченности их организма энергией, а отклонение BCS от физиологически оптимального диапазона ассоциировано с нарушениями обмена и снижением продуктивности. По данным литературы, повышенная упитанность связана с риском кетоза, жировой дистрофии печени и задержания последа, тогда как недостаточная упитанность ассоциирована с хромотой и снижением молочной продуктивности; снижение BCS также коррелирует с метритом, неактивностью яичников, смещением сычуга и увеличением продолжительности сервис-периода. Следовательно, точность определения BCS имеет не только зоотехническое, но и клиническое значение.

В рассматриваемой выборке применение алгоритма кадровой оптимизации сопровождалось уменьшением средней абсолютной ошибки с 0,34 до 0,22 балла BCS и увеличением доли оценок, попавших в интервал $\pm 0,5$ балла, с 86,2 до 93,7%. Для шкалы BCS1-5 такая разница является принципиальной, поскольку при отсутствии кадровой селекции и покомпонентного отбора информативных фаз проходки возрастает вероятность смещения животного в соседний оценочный диапазон. В практическом отношении это означает риск ошибочного отнесения коровы либо к группе животных с удовлетворительной упитанностью, либо к группе, требующей коррекции кормления, дополнительного осмотра и более частого мониторинга. При массовом скрининге стада даже систематическое смещение на 0,3-0,5 балла приводит к перераспределению животных между управленчески значимыми категориями и, следовательно, к снижению чувствительности системы к ранним изменениям их энергетического статуса.

Клиническая ценность алгоритма особенно возрастает в отношении животных с пограничными значениями BCS. Именно в этой зоне решение о корректировке рациона, контроле транзитного периода или повторной ветеринарной оценке принимается на основе небольших различий в выраженности маклаков, седалищных бугров, крестцовой связки, хвостовой связки и области коротких ребер. При равномерной временной дискретизации без анализа наблюдаемости этих зон ошибка локализации реперных точек возрастает вследствие светотеневых и позовых искажений, что непосредственно отражается на итоговом балле. Применение алгоритма, напротив, обеспечивает выбор тех кадров, в которых экстерьерные признаки упитанности представлены наиболее отчетливо, и тем самым уменьшает вероятность клинически значимой ошибки классификации.

С производственной точки зрения это создает предпосылки для более надежного автоматизированного мониторинга животных в критические физиологические периоды, прежде всего – в сухостойный, транзитный и ранний лактационный периоды, когда изменения упитанности наиболее тесно связаны с последующим риском развития метаболических и репродуктивных нарушений. В этом смысле алгоритм кадровой предобработки повышает не только формальную точность модели компьютерного зрения, но и диагностическую ценность результата как инструмента раннего выявления животных группы риска. С учетом того, что ручная оценка BCS является трудоемкой и характеризуется ограниченной воспроизводимостью между экспертами, автоматизированная система с уменьшенной ошибкой измерения может рассматриваться как практически значимый компонент цифрового ветеринарного мониторинга стада.

Выводы

Conclusions

По результатам исследований разработан алгоритм адаптивной дискретизации видеопотока для повышения точности детекции реперных анатомических ориентиров КРС в задачах автоматизированной оценки упитанности. Он основан на изменении частоты выборки кадров в зависимости от скорости движения животного и на покомпонентном отборе наиболее информативных кадров по наблюдаемости анатомических зон, что позволяет уменьшить влияние светотеневых и позовых искажений на локализацию ключевых точек и контурных ориентиров.

Применение предложенного подхода на выборке из 983 коров обеспечило снижение средней абсолютной ошибки оценки BCS с 0,34 до 0,22 балла, увеличение доли оценок в пределах $\pm 0,5$ балла с 86,2 до 93,7% и повышение значения взвешенного коэффициента Cohen's k с 0,74 до 0,86. Нормированная ошибка локализации реперных точек уменьшилась с 0,071 до 0,048, а доля невалидных проходов сократилась с 11,8 до 3,1%.

Наибольший эффект алгоритма установлен для анатомических зон, чувствительных к изменениям освещения и фазы движения, прежде всего – для крестцовой связки, области коротких ребер, седалищных бугров и тазобедренного сустава. Это подтверждает, что повышение точности оценки упитанности достигается за счет более устойчивого восстановления геометрии экстерьерных признаков, а не изменения базовой модели извлечения признаков.

Полученные результаты показывают, что адаптивная кадровая предобработка повышает точность, устойчивость и практическую применимость систем компьютерного зрения для автоматизированного мониторинга упитанности крупного рогатого скота молочного направления продуктивности в условиях производственной видеосъемки.

Список источников

1. Садиков Р.З., Морозова Н.И., Садиков Р.Р., Морозов И.А. и др. Система автоматического определения упитанности коров как инструмент поддержания оптимального физиологического состояния здоровья и продуктивности // *Вестник Рязанского государственного агротехнологического университета имени П.А. Костычева*. 2024. Т. 16, № 1. С. 54–61. <https://doi.org/10.36508/RSATU.2024.83.84.008>
2. Турлюн В.И. Оценка упитанности голштинского скота // *Сборник научных трудов Северо-Кавказского научно-исследовательского института животноводства*. 2014. Т. 1, № 3. С. 167–170.
3. Loker S., Bastin C., Miglior F., Sewalem A. et al. Genetic and environmental relationships between body condition score and milk production traits in Canadian Holsteins. *Journal of Dairy Science*. 2012;95(1):410-419. <https://doi.org/10.3168/jds.2011-4497>
4. Gentil N.R., Santos A.D.F., Pereira M.A., Lima M.S. et al. Validation of body condition score system in Holstein × Zebu cows via ultrasound method during the transition period and early lactation. *Semina: Ciências Agrárias*. 2017;38(6):3797-3806. <https://doi.org/10.5433/1679-0359.2017v38n6p3797>
5. Nagy S.Á., Kilim O., Csabai I., Gábor G. et al. Impact Evaluation of Score Classes and Annotation Regions in Deep Learning-Based Dairy Cow Body Condition Prediction. *Animals*. 2023;13(2):194. <https://doi.org/10.3390/ani13020194>
6. Bewley J.M., Schutz M.M. An interdisciplinary review of body condition scoring for dairy cattle. *The Professional Animal Scientist*. 2008;24(6):507-529. [https://doi.org/10.15232/S1080-7446\(15\)30901-3](https://doi.org/10.15232/S1080-7446(15)30901-3)
7. Morrow D.A. Fat cow syndrome. *Journal of Dairy Science*. 1976;59(9):1625-1629. [https://doi.org/10.3168/jds.S0022-0302\(76\)84415-3](https://doi.org/10.3168/jds.S0022-0302(76)84415-3)
8. Roche J.R., Kay J.K., Friggens N.C., Looor J.J. et al. Assessing and managing body condition score for the prevention of metabolic disease in dairy cows. *Veterinary Clinics of North America: Food Animal Practice*. 2013;29(2):323-336. <https://doi.org/10.1016/j.cvfa.2013.03.003>
9. Безбородов П.Н. Показатель кондиции Body Condition Score (BCS) у молочных коров со смещениями сычуга // *Вестник НГАУ (Новосибирский государственный аграрный университет)*. 2017. № 4. С. 124–141. EDN: YLQGX5
10. Roche J.R., Friggens N.C., Kay J.K., Fisher M.W. et al. Invited review: Body condition score and its association with dairy cow productivity, health, and welfare. *Journal of Dairy Science*. 2009;92(12):5769-5801. <https://doi.org/10.3168/jds.2009-2431>
11. Ненашев И.В., Марьин Е.М. Распространенность ортопедических болезней дистального отдела конечностей у крупного рогатого скота в зависимости от условий содержания // *Известия Самарской государственной сельскохозяйственной академии*. 2024. Т. 9, № 4. С. 103–108. <https://doi.org/10.55170/1997-3225-2024-9-4-103-108>
12. Sun Y., Huo P., Wang Y., Cui Z. et al. Automatic monitoring system for individual dairy cows based on a deep learning framework that provides identification via body parts and estimation of body condition score. *Journal of Dairy Science*. 2019;102(11):10140-10151. <https://doi.org/10.3168/jds.2018-16164>
13. Summerfield G.I., De Freitas A., van Marle-Koster E., Myburgh H.C. Automated Cow Body Condition Scoring Using Multiple 3D Cameras and Convolutional Neural Networks. *Sensors*. 2023;23(22):9051. <https://doi.org/10.3390/s23229051>
14. Çevik K.K., Boğa M. Body Condition Score (BCS) Segmentation and Classification in Dairy Cows Using R-CNN Deep Learning Architecture. *European Journal of Science and Technology*. 2019;17:1248-1255. <https://doi.org/10.31590/ejosat.658365>

15. Zin T.T., Seint P.T., Tin P., Horii Y. et al. Body Condition Score Estimation Based on Regression Analysis Using a 3D Camera. *Sensors*. 2020;20(13):3705. <https://doi.org/10.3390/s20133705>

16. Мищенко И.И., Мисник А.Е., Александров А.В. Применение технологий компьютерного зрения и предварительной обработки изображений в системах поддержки принятия решений // *Вестник Самарского государственного технического университета. Серия «Технические науки»*. 2024. Т. 32, № 4. С. 6–26. <https://doi.org/10.14498/tech.2024.4.1>

17. Olt L.S., Rice M.S., St. Clair M., Million C. et al. III. Automating Region of Interest (ROI) Selection for Spectral Analyses of Mastcam-Z Observations. *56th Lunar and Planetary Science Conference*. 2025:2154. URL: <https://www.hou.usra.edu/meetings/lpsc2025/pdf/2154.pdf> (дата обращения: 13.03.2026).

18. PyTorch Contributors. AdamW – PyTorch Documentation. URL: <https://docs.pytorch.org/docs/stable/generated/torch.optim.AdamW.html> (дата обращения: 13.03.2026).

References

1. Sadikov R.Z., Morozova N.I., Sadikov R.R., Morozov I.A. et al. The system of automatic determination of fatness of cows as a tool for maintaining optimal physiological health and productivity. *Bulletin of the Ryazan State Agrotechnological University named after P.A. Kostychev*. 2024;16(1):54-61. (In Russ.) <https://doi.org/10.36508/RSATU.2024.83.84.008>

2. Turlyun V.I. Body condition score of the Holstein dairy cattle. *Sbornik nauchnykh trudov Severo-Kavkazskogo nauchno-issledovatel'skogo instituta zhivotnovodstva*. 2014;1(3):167-170. (In Russ.)

3. Loker S., Bastin C., Miglior F., Sewalem A. et al. Genetic and environmental relationships between body condition score and milk production traits in Canadian Holsteins. *Journal of Dairy Science*. 2012;95(1):410-419. <https://doi.org/10.3168/jds.2011-4497>

4. Gentil N.R., Santos A.D.F., Pereira M.A., Lima M.S. et al. Validation of body condition score system in Holstein × Zebu cows via ultrasound method during the transition period and early lactation. *Semina: Ciências Agrárias*. 2017;38(6):3797-3806. <https://doi.org/10.5433/1679-0359.2017v38n6p3797>

5. Nagy S.Á., Kilim O., Csabai I., Gábor G. et al. Impact Evaluation of Score Classes and Annotation Regions in Deep Learning-Based Dairy Cow Body Condition Prediction. *Animals*. 2023;13(2):194. <https://doi.org/10.3390/ani13020194>

6. Bewley J.M., Schutz M.M. An interdisciplinary review of body condition scoring for dairy cattle. *The Professional Animal Scientist*. 2008;24(6):507-529. [https://doi.org/10.15232/S1080-7446\(15\)30901-3](https://doi.org/10.15232/S1080-7446(15)30901-3)

7. Morrow D.A. Fat cow syndrome. *Journal of Dairy Science*. 1976;59(9):1625-1629. [https://doi.org/10.3168/jds.S0022-0302\(76\)84415-3](https://doi.org/10.3168/jds.S0022-0302(76)84415-3)

8. Roche J.R., Kay J.K., Friggens N.C., Looor J.J. et al. Assessing and managing body condition score for the prevention of metabolic disease in dairy cows. *Veterinary Clinics of North America: Food Animal Practice*. 2013;29(2):323-336. <https://doi.org/10.1016/j.cvfa.2013.03.003>

9. Bezborodov P.N. Condition parameter “Body Condition Score (BCS)” of the dairy cows with displaced abomasum. *Vestnik NSAU (Novosibirsk State Agrarian University)*. 2017;(4):124-141. (In Russ.)

10. Roche J.R., Friggens N.C., Kay J.K., Fisher M.W. et al. Invited review: Body condition score and its association with dairy cow productivity, health, and welfare. *Journal of Dairy Science*. 2009;92(12):5769-5801. <https://doi.org/10.3168/jds.2009-2431>
11. Nenashev I.V., Marin E.M. The prevalence of orthopedic diseases of the distal extremities in cattle depending on housing conditions. *Bulletin Samara State Agricultural Academy*. 2004;9(4):103-108. (In Russ.) <https://doi.org/10.55170/1997-3225-2024-9-4-103-108>
12. Sun Y., Huo P., Wang Y., Cui Z. et al. Automatic monitoring system for individual dairy cows based on a deep learning framework that provides identification via body parts and estimation of body condition score. *Journal of Dairy Science*. 2019;102(11):10140-10151. <https://doi.org/10.3168/jds.2018-16164>
13. Summerfield G.I., De Freitas A., van Marle-Koster E., Myburgh H.C. Automated Cow Body Condition Scoring Using Multiple 3D Cameras and Convolutional Neural Networks. *Sensors*. 2023;23(22):9051. <https://doi.org/10.3390/s23229051>
14. Çevik K.K., Boğa M. Body Condition Score (BCS) Segmentation and Classification in Dairy Cows Using R-CNN Deep Learning Architecture. *European Journal of Science and Technology*. 2019;17:1248-1255. <https://doi.org/10.31590/ejosat.658365>
15. Zin T.T., Seint P.T., Tin P., Horii Y. et al. Body Condition Score Estimation Based on Regression Analysis Using a 3D Camera. *Sensors*. 2020;20(13):3705. <https://doi.org/10.3390/s20133705>
16. Mishchenko I.I., Misnik A.E., Alexandrov A.V. Application of computer vision and image preprocessing technologies in decision support systems. *Vestnik Samarskogo gosudarstvennogo tekhnicheskogo universiteta. Seriya "Tekhnicheskie nauki"*. 2024;32(4):6-26. (In Russ.) <https://doi.org/10.14498/tech.2024.4.1>
17. Olt L.S., Rice M.S., St. Clair M., Million C. et al. III. Automating Region of Interest (ROI) Selection for Spectral Analyses of Mastcam-Z Observations. *56th Lunar and Planetary Science Conference*. 2025:2154. URL: <https://www.hou.usra.edu/meetings/lpsc2025/pdf/2154.pdf> (accessed: March 13, 2026).
18. PyTorch Contributors. AdamW – PyTorch Documentation. URL: <https://docs.pytorch.org/docs/stable/generated/torch.optim.AdamW.html> (accessed: March 13, 2026).

Сведения об авторах

Анастасия Владимировна Греченева, канд. техн. наук, директор Проектного института цифровой трансформации АПК, доцент кафедры прикладной информатики, Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет – МСХА имени К.А. Тимирязева»; 127434, Российская Федерация, г. Москва, ул. Тимирязевская, 49; e-mail: a.grecheneva@rgau-msha.ru; <https://orcid.org/0000-0002-7341-5237>

Евгения Сергеевна Латынина, канд. ветеринар. наук, доцент, доцент кафедры морфологии и ветеринарно-санитарной экспертизы, Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет – МСХА имени К.А. Тимирязева»; 127434, Российская Федерация, г. Москва, ул. Тимирязевская, 49; e-mail: evgenialatynina@rgau-msha.ru; <https://orcid.org/0000-0001-5145-1184>

Магдалина Алексеевна Акимовкина, обучающийся магистратуры кафедры статистики и кибернетики, Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный

университет – МСХА имени К.А. Тимирязева»; 127434, Российская Федерация, г. Москва, ул. Тимирязевская, 49

Максим Дмитриевич Бакнин, канд. техн. наук, доцент кафедры прикладной информатики, Федеральное государственное бюджетное образовательное учреждение высшего образования «Российский государственный аграрный университет – МСХА имени К.А. Тимирязева»; 127434, Российская Федерация, г. Москва, ул. Тимирязевская, 49; e-mail: baknin@rgau-msha.ru; <https://orcid.org/0000-0002-3124-6252>

Information about the authors

Anastasia V. Grecheneva, CSc (Eng), Director of the Project Institute for Digital Transformation of the Agro-Industrial Sector, Associate Professor at the Department of Applied Informatics, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; 49 Timiryazevskaya St., Moscow, 127434, Russian Federation; e-mail: a.grecheneva@rgau-msha.ru; <https://orcid.org/0000-0002-7341-5237>

Evgeniya S. Latynina, CSc (Vet), Associate Professor, Associate Professor at the Department of Morphology and Veterinary and Sanitary Examination, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; 49 Timiryazevskaya St., Moscow, 127434, Russian Federation; e-mail: evgenialatynina@rgau-msha.ru; <https://orcid.org/0000-0001-5145-1184>

Magdalena A. Akimushkina, Master's degree student of the Department of Statistics and Cybernetics, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; 49 Timiryazevskaya St., Moscow, 127434, Russian Federation

Maxim D. Baknin, CSc (Eng), Associate Professor at the Department of Applied Informatics, Russian State Agrarian University – Moscow Timiryazev Agricultural Academy; 49 Timiryazevskaya St., Moscow, 127434, Russian Federation; e-mail: baknin@rgau-msha.ru; <https://orcid.org/0000-0002-3124-6252>