

Система автоматизированной оценки качества мяса на основе интеграции компьютерного зрения и трансферного обучения

Исса Али, В.А. Каргин, Е.А. Назойкин, Д.Ю. Сохинов

Российский биотехнологический университет

Аннотация: В настоящей статье рассматривается проблема повышения точности и объективности оценки качества мяса. Представлен подход к автоматизированной оценке качества продукта, основанный на интеграции системы компьютерного зрения (СКЗ) и методов глубокого обучения. Здесь использована сверточная нейронная сеть VGG-16, предварительно обученная на большом наборе данных ImageNet, что позволило эффективно применить трансферное обучение. Описан процесс предварительной обработки данных, архитектура используемой нейронной сети. Приведены результаты обучения и валидации модели, демонстрирующие высокую точность классификации образцов мяса по признаку «свежее/испорченное». Подчеркивается потенциал предложенного подхода для автоматизации контроля качества в мясной промышленности и снижения влияния субъективных факторов.

Ключевые слова: компьютерное зрение, глубокое обучение, сверточная нейронная сеть, трансферное обучение, оценка качества мяса, автоматизация процесса, классификация изображений, автоматизация контроля качества.

Введение

В условиях возрастающих требований потребителей к качеству и безопасности пищевой продукции, в частности мясной, задача оперативной и объективной оценки приобретает первостепенное значение [1]. Традиционные методы оценки качества продукта, например, органолептический или химический анализ и др., обладают рядом существенных недостатков, включая трудоемкость, длительность, деструктивный характер, потребность в квалифицированных специалистах и подверженность субъективным ошибкам [2, 3].

В этой связи, системы компьютерного зрения (СКЗ) рассматриваются как перспективная альтернатива традиционным методам, обеспечивающая возможность получения объективных и оперативных результатов без повреждения образцов и минимизирующая потребность в использовании вредных химических реагентов [4, 5]. СКЗ позволяют автоматизировать процесс контроля качества на различных этапах переработки мяса, используя

широкий спектр устройств захвата изображений, включая цифровые гиперспектральные камеры, ультразвуковые сканеры и компьютерные томографы [6, 7]. Эти устройства обеспечивают получение информации как о внешних, в частности цвет, текстура, мраморность, так и о внутренних, например, структура, химический состав, характеристиках мясной продукции.

Существующие исследования демонстрируют успешное применение СКЗ для решения различных задач в мясной промышленности, таких как определение сортности мяса, выявление дефектов, оценка степени зрелости и прогнозирование органолептических свойств [8, 9]. Однако, эффективность СКЗ во многом зависит от алгоритмов обработки и анализа изображений. Традиционные методы обработки изображений, основанные на ручном извлечении признаков, часто оказываются недостаточно эффективными для решения сложных задач классификации.

Таким образом, разработка подхода к автоматизированной оценке качества мяса, направленного на повышение точности и объективности контроля, а также на снижение влияния субъективных факторов и трудозатрат, является актуальной задачей.

Цель исследования

Разработать и экспериментально доказать эффективность системы автоматизированной оценки качества мяса на основе интеграции компьютерного зрения и методов глубокого обучения с использованием архитектуры VGG-16 и трансферного обучения.

Материалы и методы

Цвет мяса является одним из основных индикаторов качества и может быть количественно охарактеризован с помощью цифровых изображений и специализированного программного обеспечения, реализующего цветовые

модели. Анализ цифровых изображений является ключевым этапом функционирования систем компьютерного зрения. Он включает в себя широкий спектр операций, таких как предварительная обработка изображений, сегментация объектов, выделение признаков и классификация [10-12].

В работе для реализации модели использовалась платформа Kaggle, предоставляющая доступ к наборам данных и вычислительным ресурсам. В качестве базовой архитектуры применена сверточная нейронная сеть VGG-16, предварительно обученная на большом наборе изображений ImageNet, что позволило эффективно использовать трансферное обучение [13-15]. Использование предобученной модели позволило значительно сократить время обучения и повысить точность классификации.

Для предварительной обработки данных использован класс ImageDataGenerator из TensorFlow [16-18], который позволяет осуществить нормализацию изображений и применить технику аугментации, в том числе, вращение, масштабирование, отражение, что повысило обобщающую способность модели:

```
train_datagen = ImageDataGenerator(  
    rescale=1./255, # Normalize pixel values to [0,1]  
    rotation_range=20,  
    width_shift_range=0.2,  
    height_shift_range=0.2,  
    shear_range=0.2,  
    zoom_range=0.2,  
    horizontal_flip=True  
)  
  
test_datagen = ImageDataGenerator(rescale=1./255)
```

Предварительно обученная модель VGG-16 загружается без верхних классификационных слоев [19, 20]. Здесь добавляются новые слои: Flatten, два полносвязных слоя Dense с функцией активации ReLU, Dropout для

предотвращения переобучения и выходной слой с активацией sigmoid для бинарной классификации – «свежее/испорченное»:

```
# Create a new model with the VGG16 base
model = keras.Sequential([
    base_model,
    Flatten(),
    Dense(256, activation='relu'),
    Dropout(0.5),
    Dense(1, activation='sigmoid')
])
```

Модель компилируется с оптимизатором Adam, функцией потерь бинарной кросс-энтропии и метрикой точности. В процессе обучения применялись обратные вызовы для оптимизации процесса [20]:

```
# Compile the model
model.compile(optimizer=Adam(learning_rate=0.001),
              loss='binary_crossentropy',
              metrics=['accuracy'])

# Define callbacks
early_stopping = EarlyStopping(monitor='val_loss', patience=5, re-
store_best_weights=True)
checkpoint = ModelCheckpoint('best_model.h5', monitor='val_loss',
save_best_only=True)
reduce_lr = ReduceLRonPlateau(monitor='val_loss', factor=0.2, patience=3,
min_lr=0.0001)

# Train the model
epochs = 20
history = model.fit(
    train_generator,
    steps_per_epoch=train_generator.samples // batch_size,
    epochs=epochs,
    validation_data=test_generator,
    validation_steps=test_generator.samples // batch_size,
    callbacks=[early_stopping, checkpoint, reduce_lr]
)
```

После обучения модель оценивается на тестовом наборе данных, который предоставляет потери и точность [19, 20]. Кроме того, выбираются несколько тестовых изображений, и делаются предсказания с использованием обученной модели. Предсказанные метки сравниваются с пороговым значением 0,5, чтобы определить, является ли мясо «свежим» или

«испорченным». Выводятся истинные метки, предсказанные метки и соответствующие изображения:

```
# Evaluate the model on the test dataset
test_loss, test_accuracy = model.evaluate(test_generator, verbose=2)
print('Test loss:', test_loss)
print('Test accuracy:', test_accuracy)

# Make predictions on a few test images
num_test_images = 5

test_images, test_labels = next(test_generator)
predictions = model.predict(test_images)
predicted_labels = ['Fresh' if pred >= 0.5 else 'Spoiled' for pred in
predictions]

for i in range(num_test_images):
    true_label = 'Fresh' if test_labels[i] == 1 else 'Spoiled'
    predicted_label = predicted_labels[i]

    print('True label:', true_label)
    print('Predicted label:', predicted_label)

plt.imshow(test_images[i])
plt.axis('off')
plt.show()
```

Результаты и обсуждение.

В процессе обучения модели VGG-16 с использованием трансферного обучения наблюдалась устойчивая динамика улучшения точности (рис. 1) и снижения потерь (рис. 2) как на обучающей (Train), так и на валидационной (Validation) выборках. Высокая точность на обучающем наборе (более 95%) свидетельствует о способности модели эффективно изучать закономерности в данных, а сопоставимая точность на валидационном наборе (более 90%) указывает на отсутствие переобучения и хорошую обобщающую способность. Небольшая разница между точностью на обучающей и валидационной выборках подтверждает эффективность использования аугментации данных для предотвращения переобучения.

Минимальные значения функции потерь на этапах обучения и валидации, а также их сближение, свидетельствуют о стабильности и

надежности модели. Динамика изменения точности и потерь показывает, что модель успешно адаптируется к решаемой задаче классификации свежего и испорченного мяса.




Рис. 1. - Точность модели VGG-16





Рис. 2. - Потери модели VGG-16

На рисунке 3 представлены примеры результатов работы модели для изображений свежего и испорченного мяса. Визуальная оценка результатов классификации подтверждает высокую точность работы модели.

True label: Fresh
Predicted label: Fresh



а)

True label: Spoiled
Predicted label: Spoiled



б)

Рис. 3. - Результаты работы модели VGG-16:
свежее мясо (а), испорченное мясо (б)

Кроме того, были рассчитаны метрики точность (precision), полнота (recall) и F1-score для оценки качества классификации [20]. Значения этих метрик составили: precision = 0,92, recall = 0,90, F1-score = 0,91, что подтверждает эффективность предложенного подхода для решения задачи классификации качества мяса.

Заключение

Использование трансферного обучения на базе сверточной нейронной сети VGG-16 показало высокую эффективность в задаче классификации качества мяса по изображениям. Модель продемонстрировала низкие значения потерь и высокую точность как на обучающей, так и на тестовой выборках, что свидетельствует о ее способности к обобщению и применимости в реальных условиях. Автоматизация оценки качества мяса с помощью систем компьютерного зрения и нейросетевых технологий позволяет повысить оперативность, точность и объективность контроля, что ведет к снижению брака и экономическому эффекту для предприятий.

Литература

1. Благовещенская М.М., Фомушкин В.И., Благовещенский И.Г., Татаринов А.В. Автоматизированная система контроля безопасности пищевых продуктов на примере мясного сырья // Хранение и переработка сельхозсырья. 2017. № 4. С. 49-52. EDN: WDEIUQ.
2. Репкин В.С., Ли А.В., Семенов Г.Ю., Сермавкин Н.И., Коваленко А.С., Егошин Н.С. Сравнительный анализ моделей классификации для определения качества вина по его химическому составу // Известия Томского политехнического университета. Промышленная кибернетика. 2023. Т. 1. № 1. С. 50-58. EDN: VKIADI.
3. Приймак Е.В., Сопин В.Ф., Зиннуров И.И. Автоматизация процесса квалитетической оценки уровня качества продукции // Вестник

Технологического университета. 2023. Т. 26. № 2. С. 99-103. DOI: 10.55421/1998-7072_2023_26_2_99.

4. Каргин В.А., Сохинов Д.Ю., Усанов К.М., Мокрушин С.А., Кротов И.В. Интеллектуальная автоматизированная система управления сортировкой фруктов // Электротехнологии и электрооборудование в АПК. 2024. Т. 71. № 2(55). С. 100–106. DOI: 10.22314/2658-4859-2024-71-2-100-106. EDN: GQEBAB.

5. Казначеева И. А., Власенко А. В. Разработка алгоритма распознавания изображений для автоматизированной системы контроля дефектов стеклоткани на основе методов машинного обучения // Инженерный вестник Дона, 2025, №5. URL: ivdon.ru/ru/magazine/archive/n5y2025/10058.

6. Каргин В. А., Кравченко Р. А., Сохинов Д. Ю., Усанов К. М. Система интеллектуального контроля качества плодов в промышленном плодоовощеводстве // Электротехнологии и электрооборудование в АПК. 2025. Т. 72. № 1 (58). С. 90-96. DOI: 10.22314/2658-4859-2025-72-1-90-96

7. Сохинов Д.Ю., Каргин В.А., Назойкин Е.А., Кравченко Р.А. Интеллектуальная управляющая система для косвенной оценки объема повреждения плодоовощной продукции // Инженерный вестник Дона, 2025, №8. URL: ivdon.ru/ru/magazine/archive/n8y2025/10270.

8. Донник И.М., Балыхин М.Г., Благовещенский И.Г., Благовещенская М.М. Разработка баз данных интеллектуальных экспертных систем автоматического контроля показателей качества пищевой продукции // Хранение и переработка сельхозсырья. 2018. № 4. С. 126-138.

9. Ahmed, M.R.; Reed, D.D., Jr.; Young, J.M.; Eshkabilov, S.; Berg, E.P.; Sun, X. Beef Quality Grade Classification Based on Intramuscular Fat Content Using Hyperspectral Imaging // Technology. Appl. Sci. 2021, 11, 4588, doi.org/10.3390/app11104588.

10. Farzan M.R. Physical distancing detection system using OpenCV based on raspberry pi4 // Journal of Computer Engineering, Electronics and Information Technology. 2023. Т. 1. № 2. С. 117-128. DOI: 10.17509/coelite.v1i2.59702.

11. Амонуллозода О.А. Методы распознавания объектов по изображению при помощи библиотеки OpenCV // Вестник Технологического университета Таджикистана. 2019. № 1 (36). С. 73-80.

12. Boikov A.V., Payor V.A., Savelev R.V. Technical vision system for analysing the mechanical characteristics of bulk materials // Journal of Physics: Conference Series. 2018. Vol. 944. Ser. 944 012021. DOI: 10.1088/1742-6596/944/1/012021.

13. Скворцов А. А., Анурьева М. С., Солодовников А. Н. Применение алгоритмов машинного обучения для прогнозирования отказов и адаптивного управления производственными системами // Инженерный вестник Дона, 2025, №5. URL: ivdon.ru/ru/magazine/archive/n5y2025/10059.

14. Sánchez CN, Orvañanos-Guerrero MT, Domínguez-Soberanes J, Álvarez-Cisneros YM. Analysis of beef quality according to color changes using computer vision and white-box machine learning techniques // Heliyon. 2023 Jul;9(7):e17976. doi: 10.1016/j.heliyon.2023.e17976. PMID: 37519729; PMCID: PMC10375562.

15. Муаль М. Н. Б. Использование предобученной нейросети (VGG16) для решения задачи переноса стиля изображения // Современные информационные технологии и ИТ-образование. 2022. Т. 18, № 2. С. 241-248, doi.org/10.25559/SITITO.18.202202.241-248.

16. Vidnerova P., Neruda R. Evolving Keras Architectures for Sensor Data Analysis // Proceedings of the Federated Conference on Computer Science and Information Systems. pp. 109–112. ACSIS, Vol. 11. DOI: 10.15439/2017F241.

17. Багаев И.И. Анализ понятий нейронная сеть и сверточная нейронная сеть, обучение сверточной нейросети при помощи модуля TensorFlow /

Математическое и программное обеспечение систем в промышленной и социальной сферах. 2020. Т. 8. № 1. С. 15-22. EDN: IZBILN. DOI: 10.18503/2306-2053-2020-8-1-15-22.

18. Homma Yuya & Moro Seiichiro Recognition of Landing Target of UAV by Vision Using Machine Learning / Journal of Signal Processing. 2019. 23(4). 193-196. DOI: 10.2299/jsp.23.193.

19. Шолле Франсуа Глубокое обучение на Python. – СПб: Питер, 2018. – 400 с.: ил. – (Серия «Библиотека программиста»).

20. Ростовцев В. С. Искусственные нейронные сети / В. С. Ростовцев. – 3-е изд., стер. – Санкт-Петербург: Лань, 2023. – 216 с.

References

1. Blagoveshchenskaya M.M., Fomushkin V.I., Blagoveshchenskiy I.G., Tatarnov A.V. Khranenie i pererabotka selkhozsyrya, 2017, № 4, pp. 49-52.

2. Repkin V.S., Li A.V., Semenov G.Yu, Sermavkin N.I., Kovalenko A.S., Egoshin N.S. Izvestiya Tomskogo politechnicheskogo universiteta. Promyshlennaya kibernetika, 2023, Vol. 1, № 1, pp. 50-58.

3. Priymak E.V., Sopin V.F., Zinnurov I.I. Vestnik Tekhnologicheskogo universiteta, 2023, Vol. 26, № 2, pp. 99-103. DOI: 10.55421/1998-7072_2023_26_2_99

4. Kargin V.A., Sokhinov D.Yu., Usanov K.M., Mokrushin S.A., Krotov I.V. Elektrotekhnologii i elektrooborudovanie v APK, 2024, Vol. 71, № 2(55), pp. 100–106. DOI: 10.22314/2658-4859-2024-71-2-100-106

5. Kaznacheeva I.A., Vlasenko A.V. Inzhenernyj vestnik Dona, 2025, №5. URL: ivdon.ru/ru/magazine/archive/n5y2025/10058

6. Kargin V.A., Kravchenko R.A., Sokhinov D.Yu., Usanov K.M. Elektrotekhnologii i elektrooborudovanie v APK, 2025, Vol. 72, № 1(58), pp. 90-96. DOI: 10.22314/2658-4859-2025-72-1-90-96

7. Sokhinov D.Yu., Kargin V.A., Nazoykin E.A., Kravchenko R.A. Inzhenernyj vestnik Dona, 2025, №8. URL: ivdon.ru/ru/magazine/archive/n8y2025/10270
 8. Donnik I.M., Balykhin M.G., Blagoveshchenskiy I.G., Blagoveshchenskaya M.M. Khranenie i pererabotka selkhozsyrya, 2018, №4, pp. 126-138.
 9. Ahmed M.R., Reed D.D. Jr., Young J.M., Eshkabilov S., Berg E.P., Sun X. Beef Quality Grade Classification Based on Intramuscular Fat Content Using Hyperspectral Imaging. Technology. Appl. Sci., 2021, 11, 4588. DOI: 10.3390/app11104588
 10. Farzan M.R. Physical distancing detection system using OpenCV based on raspberry pi4. Journal of Computer Engineering, Electronics and Information Technology, 2023, Vol. 1, № 2, pp. 117-128. DOI: 10.17509/coelite.v1i2.59702
 11. Amonullozoda O.A. Vestnik Tekhnologicheskogo universiteta Tadzhiqistana, 2019, № 1(36), pp. 73-80.
 12. Boikov A.V., Payor V.A., Savelev R.V. Technical vision system for analysing the mechanical characteristics of bulk materials. Journal of Physics: Conference Series, 2018, Vol. 944, 012021. DOI: 10.1088/1742-6596/944/1/012021
 13. Skvortsov A.A., Anuryeva M.S., Solodovnikov A.N. Inzhenernyj vestnik Dona, 2025, №5 URL: ivdon.ru/ru/magazine/archive/n5y2025/10059
 14. Sánchez C.N., Orvañanos-Guerrero M.T., Domínguez-Soberanes J., Álvarez-Cisneros Y.M. Analysis of beef quality according to color changes using computer vision and white-box machine learning techniques. Heliyon, 2023, 9(7), e17976. DOI: 10.1016/j.heliyon.2023.e17976
 15. Mual M.N.B. Ispolzovanie predobuchennoy neyroseti (VGG16) dlya resheniya zadachi perenosa stilya izobrazheniya. Sovremennye informatsionnye tekhnologii i IT-obrazovanie, 2022, Vol. 18, № 2, pp. 241-248. URL: doi.org/10.25559/SITITO.18.202202.241-248
-

16. Vidnerova P., Neruda R. Evolving Keras Architectures for Sensor Data Analysis. Proceedings of the Federated Conference on Computer Science and Information Systems, pp. 109–112, ACSIS, Vol. 11. DOI: 10.15439/2017F241

17. Bagaev I.I. Analiz ponyatiy neyronnaya set i svertochnaya neyronnaya set, obuchenie svertochnoy neyroseti pri pomoshchi modula TensorFlow. Matematicheskoe i programmnoye obespechenie sistem v promyshlennoy i sotsialnoy sferakh, 2020, Vol. 8, № 1, pp. 15-22. DOI: 10.18503/2306-2053-2020-8-1-15-22

18. Homma Yuya, Moro Seiichiro. Recognition of Landing Target of UAV by Vision Using Machine Learning. Journal of Signal Processing, 2019, 23(4), pp. 193-196. DOI: 10.2299/jsp.23.193

19. Sholle F. Glubokoe obuchenie na Python [Deep Learning with Python]. SPb.: Piter, 2018. 400 p.

20. Rostovtsev V.S. Iskusstvennye neyronnye seti [Artificial Neural Networks]. 3rd ed., SPb.: Lan, 2023. 216 p.

Дата поступления: 1.09.2025

Дата публикации: 26.10.2025