

УДК 338.364-048.57:681.11.031.12

АВТОМАТИЗИРОВАННАЯ СОРТИРОВКА АККУМУЛЯТОРОВ NiCd/NiMH НА ОСНОВЕ РЕНТГЕНОВСКИХ ПРИЗНАКОВ И МАШИННОГО ОБУЧЕНИЯ

М.О. БЫКОВЦЕВ, И.И. ФРОЛОВ

*Белорусский государственный университет информатики и радиоэлектроники
(г. Минск, Беларусь)*

E-mail: mikhail3789@gmail.com, frolov@bsuir.by

Аннотация. Предложен метод автоматизированной классификации аккумуляторов типов NiCd и NiMH на основе анализа двухэнергетических рентгеновских изображений. Метод включает сегментацию батарейки, выделение областей интереса, формирование признаков, а также классификацию с применением SVM, дерева решений и Random Forest. Показано, что использование комбинаций признаков обеспечивает высокое качество распознавания для типоразмеров AAA, AA, C и D, при этом наилучшие результаты получены с классификатором Random Forest.

Abstract. This paper proposes a method for automated classification of NiCd and NiMH rechargeable batteries based on dual-energy X-ray image analysis. The method includes battery segmentation, region-of-interest extraction, feature generation, and classification using SVM, Decision Tree, and Random Forest algorithms. The results show that feature combinations provide high recognition quality for AAA, AA, C, and D battery sizes, with the best results achieved using the Random Forest classifier.

Введение

В современных условиях особую актуальность приобретает задача автоматизированной сортировки элементов питания, обусловленная требованиями экологической безопасности и необходимостью рационального использования вторичных ресурсов. Используемые батарейки содержат токсичные компоненты, такие как кадмий и другие тяжелые металлы, которые при некорректной утилизации способны загрязнять окружающую среду. В связи с этим разработка эффективных методов их классификации является важной научно-практической задачей. Существующие методы сортировки элементов питания включают измерение массогабаритных параметров, анализ электрофизических характеристик, оптическое распознавание, а также ультразвуковые и рентгеновские технологии. Несмотря на высокую точность (до 95–99 %), данные подходы обладают рядом ограничений. Методы, основанные на геометрических параметрах и ультразвуке, чувствительны к условиям хранения и физическим повреждениям объектов. Электрофизические методы характеризуются низкой производительностью, тогда как оптические системы не обеспечивают надежного распознавания контрафактных изделий с ложной маркировкой. Наиболее перспективным направлением является применение рентгеновских технологий, обеспечивающих высокое быстродействие при сохранении точности классификации. Однако существующие решения не позволяют в полной мере различать элементы питания внутри одной химической группы, в частности аккумуляторы типов NiCd и NiMH, что обусловлено сходством их конструктивных и интегральных характеристик. В связи с этим актуальной является разработка методов классификации, основанных на анализе внутренних характеристик элементов питания. В данной работе рассматривается подход, основанный на обработке двухэнергетических рентгеновских изображений с использованием методов машинного обучения [1]. Предлагаемый метод позволяет учитывать физические параметры объектов, такие как эффективный атомный номер и плотность [2], что обеспечивает повышение точности классификации и расширяет возможности автоматизации процесса сортировки элементов питания.

Входные данные

Входными данными для разработанного пайплайна являются четыре 16-битных TIFF-изображения, полученных с рентгеновской установки BSS160X для одного элемента питания. Каждое изображение представляет собой двумерный массив пиксельных значений в диапазоне [0, 65535]. Дальнейшая обработка осуществляется над указанными массивами с применением попиксельных операций, а также операций, выполняемых вдоль строк изображения.

В табл. 1 приведено описание входных изображений.

Таблица 1. Описание входных изображений

Обозначение изображения	Описание	Тип данных
$I(E_{high})$	Изображение высокой энергии	uint16
$I(E_{low})$	Изображение низкой энергии	uint16
$I(D_{16})$	Проекционная толщина, эквивалентная слою чистого алюминия	float32
$I(Z_{eff})$	Изображение, представляющее собой эффективный атомный номер	float32

В табл. 2 приведены параметры рентгеновской установки.

Таблица 2. Параметры рентгеновской установки

Параметры установки	Значение	Описание
FS	100 мм	расстояние фокус–конвейер
FD	360 мм	расстояние фокус–детектор
I_0	60 000	Отклик детектора без объекта
Диапазон	[0, 65535]	16-битная шкала

Первичная сегментация изображения.

На первом этапе сегментации выполняется выделение батарейки как единого объекта на фоне. Пиксели с интенсивностью $I(E_{high})$, значения которых ниже заданного порога τ_1 , соответствуют области материала объекта, поскольку элемент питания поглощает рентгеновское излучение. Пиксели с более высокими значениями интенсивности относятся к фоновым областям, включая воздух и элементы конструкции сканирующей системы.

Бинаризация изображения осуществляется по следующему правилу (рис. 1):

$$B(x, y) = \begin{cases} 1, & \text{если } I(E_{high}) < \tau_1 \\ 0, & \text{иначе} \end{cases} \quad (1)$$

В качестве порогового значения используется $\tau_1 = 55000$, выбранное эмпирически на основе анализа интенсивностей изображений. В результате данной операции формируется бинарная маска $I_{mask}(0,1)$, в которой единичные значения соответствуют области батарейки, а нулевые — фону.




Рис. 1. Схема формирования бинарной маски по пороговому значению τ_1

Поиск внешнего контура батарейки

После формирования бинарной маски выполняется поиск контуров исследуемого объекта. Для этого используется метод выделения контуров, реализованный в библиотеке OpenCV [3]. Поиск осуществляется без построения иерархии контуров, при этом сохраняются все точки границы объекта без аппроксимации. Из множества найденных контуров исключаются области, площадь которых превышает заданное пороговое значение $S_{max} = 70000$ пикселей. Такое ограничение позволяет исключить крупные фоновые области и элементы конструкции сканирующей системы, которые не относятся к анализируемому объекту. Далее в качестве контура батарейки выбирается контур с максимальной площадью среди оставшихся допустимых контуров.

Алгоритм выбора контура можно представить следующим образом:

$$C = \{c_i : S(c_i) < S_{max}\} \quad (2)$$

$$cnt = \operatorname{argmax} S(c_i), \quad c_i \in C \quad (3)$$

где $S(c_i)$ — площадь i -го контура, S_{max} — эмпирически заданное ограничение площади, cnt — выбранный внешний контур батарейки.

Пороговое значение $S_{max} = 70000$ пикселей выбрано эмпирически с учетом размеров анализируемых элементов питания. При изменении типоразмера объектов данное значение требует дополнительной корректировки.




Рис. 2. Поиск внешнего контура объекта на бинарной маске.

Формирование маски объекта и выделение области интереса (ROI)

После определения внешнего контура объекта выполняется его заливка с целью формирования бинарной маски $I_{mask_battery}(x, y)$, описывающей область батарейки. Для этого все пиксели, принадлежащие контуру и его внутренней области, принимают значение единицы, тогда как остальные пиксели обнуляются.

Далее на основе найденного контура определяется ограничивающий прямоугольник (Region of Interest, ROI), который используется для обрезки исходных изображений [3]. Применение ROI позволяет существенно сократить объём обрабатываемых данных, а также исключить влияние фоновых областей, не относящихся к объекту исследования.

Координаты ROI задаются параметрами (x, y, w, h) , соответствующими положению и размерам ограничивающего прямоугольника. Обрезка изображений выполняется в пределах данной области с дополнительным отступом в один пиксель по горизонтали, что позволяет исключить крайние столбцы, потенциально содержащие артефакты, обусловленные неточностями выделения контура.

В результате выполняется обрезка всех исходных изображений по единой области ROI, включая изображения высокой и низкой энергий, а также производные изображения эффективного атомного номера и эквивалентной толщины. Это обеспечивает сохранение пространственного соответствия пикселей между различными каналами данных и корректность последующего анализа.




Рис. 3. Формирование маски объекта и выделение области интереса (ROI).

Вторичная бинаризация (выделение внутренних структур)

На втором этапе сегментации выполняется уточняющее разделение области батарейки на внутренние функциональные элементы (активное вещество электродов, разделитель) и корпус. Для этого используется бинаризация изображения $cropHigh$, полученного после обрезки по области интереса (ROI).

Пороговая обработка осуществляется с использованием пониженного порогового значения τ_2 , позволяющего выделить более плотные внутренние структуры объекта. Бинарная маска формируется по следующему правилу:

$$B_2(x, y) = \begin{cases} 1, & \text{если } cropHigh(x, y) < \tau_2 \\ 0, & \text{иначе} \end{cases} \quad (4)$$

Порог τ_2 подобран эмпирически. Требуется настройка при изменении условий съёмки или появлении новых партий аккумуляторов.

Физическое обоснование выбора τ_2 основано на различии коэффициентов ослабления рентгеновского излучения [2]. Области, соответствующие активному веществу (например, никель и кадмий), характеризуются более высоким поглощением излучения, что приводит к снижению интенсивности сигнала на детекторе ($cropHigh < \tau_2$). Напротив, корпус, разделитель и воздушные промежутки обладают меньшим коэффициентом ослабления и, соответственно, более высоким уровнем сигнала ($cropHigh \geq \tau_2$).

Следует отметить, что $\tau_2 \ll \tau_1$, поскольку внутренние структуры батарейки характеризуются более низкими значениями интенсивности по сравнению с объектом в целом. В результате формируется внутренняя бинарная маска $I'_{mask}(0,1)$, отражающая распределение плотных компонентов внутри батарейки.

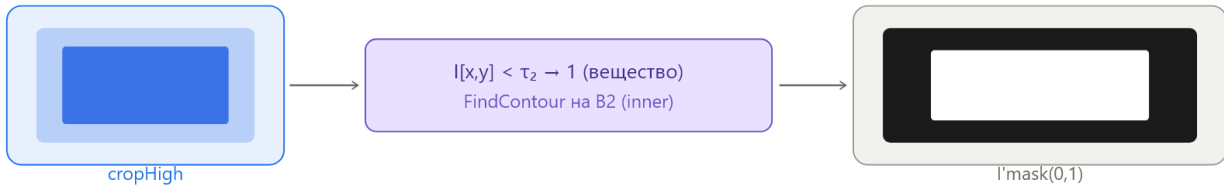


Рис. 4. Схема вторичной бинаризации и выделения внутренней области батарейки по порогу τ_2 .

Формирование масок I_{in_mask} и I_{out_mask}

На основе выделенного внутреннего контура формируются две взаимодополняющие бинарные маски, соответствующие различным областям аккумулятора: области активного вещества и области корпуса. Маска I_{in_mask} описывает внутреннюю область батарейки, включающую электроды и разделитель, тогда как маска I_{out_mask} соответствует области корпуса. Формирование маски внутренней области осуществляется следующим образом:

$$I_{in_mask}(x, y) = \begin{cases} 1, & \text{если пиксель принадлежит внутреннему контуру,} \\ 0, & \text{иначе} \end{cases} \quad (5)$$

Маска корпуса определяется как разность между внешней и внутренней областями:

$$I_{out_mask}(x, y) = \begin{cases} 1, & \text{если пиксель принадлежит внешнему контуру,} \\ 0, & \text{иначе.} \end{cases} \quad (6)$$

Таким образом, маски $I_{in_mask}(x, y)$ и $I_{out_mask}(x, y)$ являются взаимодополняющими и в совокупности полностью покрывают область интереса (ROI) батарейки без перекрытия:

$$I_{mask_battery}(x, y) = I_{in_mask}(x, y) + I_{out_mask}(x, y), \quad (7)$$

$$I_{mask_total}(x, y) \in \{0,1\}, \quad I_{out_mask}(x, y) \cap I_{in_mask}(x, y) = \emptyset$$

Следует отметить, что область $I_{in_mask}(x, y)$ соответствует активному веществу (электроды и разделитель), тогда как область $I_{out_mask}(x, y)$ характеризует материал корпуса, который может варьироваться между различными производителями. В связи с этим признаки, извлекаемые из области корпуса, обладают меньшей устойчивостью и информативностью по сравнению с признаками, относящимися к внутренней области аккумулятора.

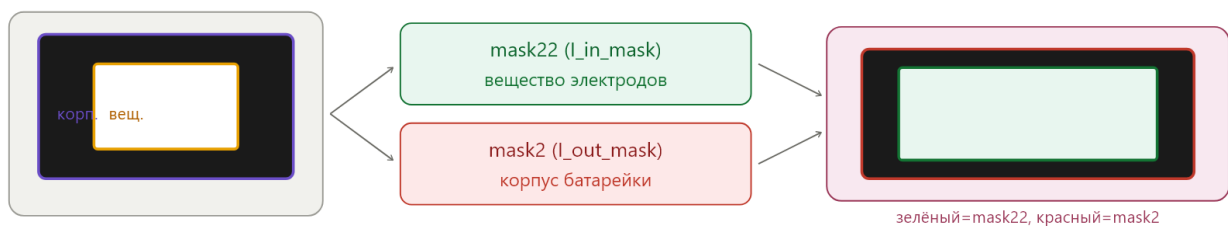


Рис. 5. Формирование взаимодополняющих масок внутренней области и корпуса батарейки.

Применение масок к изображению $I(Z_{eff})$

На данном этапе выполняется попиксельное применение ранее сформированных бинарных масок к изображению эффективного атомного номера $I(Z_{eff})$. В результате формируются три производных изображения, соответствующие различным структурным областям батарейки: всей области объекта, области корпуса и области активного вещества.

Таким образом, каждое из полученных изображений содержит значения Z_{eff} , ограниченные соответствующей анатомической зоной объекта.

Во всех случаях диапазон значений эффективного атомного номера лежит в пределах $Z_{eff} \in [0, 50]$. На основе полученных изображений вычисляются скалярные признаки, представляющие собой усреднённые значения Z_{eff} по ненулевым пикселям каждой области:

$$f_1 = \text{mean}(I_{\text{акк}}(Z_{\text{eff}}) \mid Z_{\text{eff}} > 0), \quad (8)$$

$$f_2 = \text{mean}(I_{\text{вещ}}(Z_{\text{eff}}) \mid Z_{\text{eff}} > 0), \quad (9)$$

$$f_3 = \text{mean}(I_{\text{корп}}(Z_{\text{eff}}) \mid Z_{\text{eff}} > 0) \quad (10)$$

Полученные признаки характеризуют средний эффективный атомный номер для различных структурных зон батарейки и используются на последующих этапах классификации.




Рис. 6. Применение масок к изображению $I(Z_{\text{eff}})$ и выделение зон батарейки.

Геометрическая нормировка $\rightarrow I'(\rho > 0)$

Для корректного определения эффективной плотности материала аккумулятора необходимо учитывать проекционную толщину объекта в каждом пикселе. В силу конической геометрии рентгеновского пучка угол прохождения луча через объект изменяется вдоль строки изображения, что приводит к вариации эффективной длины пути излучения в материале. В связи с этим выполняется геометрическая нормировка сигнала с использованием аналитически вычисляемой проекционной толщины.

На основе вычисленной проекционной толщины выполняется нормировка сигнала изображения эквивалентной толщины:

$$\rho(x, y) = \frac{D_{16}(x, y)}{N_1 N_2(x, y)} \quad (11)$$

где $\rho(x, y)$ — эффективная плотность материала, выраженная в эквиваленте алюминия $[\frac{\Gamma}{\text{см}^3}]$.

Пиксели, для которых $N_1 N_2(x, y) = 0$ (как правило, соответствующие крайним областям изображения), исключаются из анализа путем обнуления. В результате формируется изображение $I'(\rho > 0)$, в котором каждое значение пикселя имеет физическую интерпретацию как эффективная плотность материала.

Следует отметить, что описанный подход корректен при условии, что объект имеет близкое к круговому поперечному сечению, что соответствует геометрии большинства цилиндрических элементов питания.




Рис. 7. Определение проекционной толщины объекта.

Формирование признакового пространства и структуры датасета

На заключительном этапе обработки из каждого производного изображения извлекается одно скалярное значение, представляющее собой среднее арифметическое по ненулевым пикселям соответствующей области. Полученные значения формируют вектор признаков, характеризующий одну батарейку, который далее используется для построения обучающей выборки.

Общая формула для всех 5 признаков:

$$f_k = \frac{1}{n_k} \sum_i X_i, \text{ при } X_i > 0 \quad (12)$$

где n_k – число ненулевых пикселей в области k ; X_i – значение пикселя.

Для каждого объекта формируется вектор признаков $f = (f_1, f_2, f_3, f_4, f_5)$, где f_1 – среднее значение эффективного атомного номера по всей области батарейки; f_2 – среднее значение по области активного вещества (электроды и разделитель); f_3 – среднее значение по области корпуса; f_4 – средняя эквивалентная толщина, характеризующая проекционную массу; f_5 – средняя эффективная плотность.

На основе сформированных векторов признаков формируется размеченный датасет (табл. 3), в котором каждая строка соответствует отдельному объекту (батарейке). Признаки $f_1 \dots f_5$ выступают в качестве независимых переменных, тогда как поле `type` задаёт целевую метку класса (*NiCd* или *NiMH*), а поле `Size` – типоразмер элемента питания (AAA, AA, C, D). Дополнительное поле `number` содержит идентификатор исходного файла и не используется при обучении модели.

Таблица 3. Структура датасета (1 строка = 1 батарейка):

$f_1 \dots f_5$	Независимые переменные (признаки)
<code>type</code>	'nicd' / 'nimh' – целевая метка
<code>Size</code>	'aaa' / 'aa' / 'c' / 'd' – типоразмер
<code>number</code>	ID файла (не используется при обучении)

Для оценки эффективности классификации рассматриваются все возможные непустые подмножества признаков. В общей сложности анализируется 31 комбинация признаков, каждая из которых тестируется с использованием трёх различных классификаторов для четырёх типоразмеров элементов питания, что в совокупности составляет 372 вычислительных эксперимента.




Рис. 8. Формирование вектора признаков и подача на классификатор.

Описание признаков

Для каждого аккумулятора формируется вектор из пяти скалярных признаков (табл. 4), вычисляемых как среднее арифметическое по ненулевым пикселям соответствующей сегментированной области:

Таблица 4. Описание признаков

№	Источник	Физический смысл и особенности
f_1	$I_{акк}(Z_{eff})$	Среднее значение эффективного атомного номера, вычисленное по всей области объекта, отражает интегральный вклад как материала корпуса, так и внутреннего вещества батарейки. Данный признак характеризует обобщённый химический состав объекта, однако при совместном анализе различных типоразмеров обладает ограниченной дискриминирующей способностью.
f_2	$I_{корп}(Z_{eff})$	Среднее значение эффективного атомного номера в области корпуса отражает материал оболочки (например, металлические или неметаллические полимерные покрытия). Данный признак демонстрирует наибольшую информативность при классификации элементов питания типоразмера C. Однако данный признак является нестабильным, так как материалы корпуса могут различаться у разных производителей, что снижает его способность эффективно различать классы при анализе разных партий аккумуляторов.
f_3	$I_{вещ}(Z_{eff})$	Среднее значение эффективного атомного номера в области активного вещества электродов. Данный признак демонстрирует наибольшую информативность при классификации элементов питания типоразмеров AAA и AA. В то же время для типоразмера C его дискриминирующая способность снижается вследствие перекрытия значений между классами.
f_4	$I(D_{1\epsilon})$	Средняя эквивалентная толщина, выраженная в пересчёте на алюминий $[\frac{\Gamma}{\text{см}^2}]$, характеризует проекционную массу единицы площади сечения объекта. Данный признак

№	Источник	Физический смысл и особенности
		коррелирует с плотностью материала: аккумуляторы типа NiCd, как правило, обладают более высокими значениями по сравнению с NiMH. Признак вносит вклад в задачу классификации для всех типоразмеров, однако его использование в качестве единственного параметра является недостаточным для надёжного разделения классов.
f_5	$\Gamma(\rho)$	Средняя эффективная плотность, выраженная в эквиваленте алюминия $[\frac{\rho}{\text{см}^3}]$, определяется после геометрической нормировки с учётом конической геометрии рентгеновского пучка. В отличие от признака f_4 , значения пикселей нормируются на их фактическую проекционную толщину, что обеспечивает более корректную физическую интерпретацию. Следует отметить, что данный подход применим при условии близкого к круговому поперечному сечению объекта.

Разделимость признаков по типоразмерам

Качественная оценка информативности каждого признака в задаче бинарного разделения NiCd/NiMH представлена в табл. 5.

Таблица 5. Качественная оценка информативности признаков при классификации NiCd/NiMH аккумуляторов

Признак	AAA	AA	C	D	Физический смысл
f_1	Умеренная	Умеренная	Слабая	Слабая	Глобальный состав объекта
f_2	Слабая	Умеренная	Хорошая	Слабая	Состав корпуса (ненадёжен)
f_3	Отличная	Отличная	Слабая	Умеренная	Активное вещество электродов
f_4	Хорошая	Хорошая	Хорошая	Умеренная	Средняя проекционная масса
f_5	Хорошая	Хорошая	Умеренная	Умеренная	Эффективная плотность (норм.)

В рамках качественной оценки используются следующие уровни информативности: «отличная» — практически полное отсутствие перекрытия между классами; «хорошая» — умеренное перекрытие при сохранении разделимости; «умеренная» — значительное перекрытие; «слабая» — отсутствие выраженной разделяющей способности признака.

Формирование датасета

Для каждого аккумулятора формируется одна строка в структурированном датасете. Датасет компонуется отдельно по типоразмерам (AAA, AA, C, D), поскольку абсолютные значения признаков существенно различаются между типоразмерами. Классы не сбалансированы: количество NiMH-аккумуляторов в выборках заметно превышает количество NiCd. Метка класса ('nacd/'nimh') является зависимой переменной, остальные 5 столбцов – независимые переменные.

Применяемые классификаторы

Для задачи бинарной классификации NiCd/NiMH тестируются три нелинейных классификатора [4]:

SVM с RBF-ядром ($C=1$, $\text{gamma}=\text{'scale'}$). Метод опорных векторов с радиальной базисной функцией. Трансформирует пространство признаков в высокоразмерное пространство посредством kernel-функции, что обеспечивает нелинейное разделение без явного вычисления отображения. Выделен как наиболее перспективный с точки зрения дальнейшей работы с пространствами признаков.

DecisionTreeClassifier (random_state=42). Интерпретируемое дерево решений на основе взаимной информации. Позволяет явно выявить пороговые значения признаков, обеспечивающих разделение, что важно для физической интерпретации.

RandomForestClassifier (random_state=42). Ансамблевый метод (bagging) деревьев решений.

Устойчив к переобучению и к шуму в признаках. Обеспечивает оценку важности признаков через среднее снижение примесей.

Метрики оценки

Метрика Accuracy (точность) не используется ввиду несбалансированности классов.

Применяются:

Recall (полнота) – доля правильно обнаруженных объектов данного класса. Критична в задачах, где пропуск NiCd-аккумулятора (высокотоксичного) недопустим.

Precision (точность) – доля верных предсказаний среди всех предсказанных как данный класс.

ROC-AUC – площадь под ROC-кривой. Является интегральной характеристикой классификатора, инвариантной к порогу принятия решения. Позволяет корректно сравнивать классификаторы на несбалансированных выборках.

Recall и Precision вычисляются отдельно для каждого класса (NiCd и NiMH), что позволяет независимо оценить качество обнаружения каждого типа.

После сортировки элементы питания направляются на специализированную переработку, в том числе с применением технологических процессов, зависящих от химического состава батареек. Поэтому попадание элементов питания другого типа в отсортированную фракцию может ухудшать качество переработки, снижать эффективность извлечения полезных компонентов и создавать дополнительные технологические риски.

Метрика **Precision** напрямую отражает чистоту фракции. Таким образом, чем выше значение **Precision**, тем меньше посторонних элементов содержится в соответствующей фракции.

Recall используется как дополнительная метрика, поскольку позволяет контролировать полноту извлечения каждого класса. При использовании только Precision возможна ситуация, когда фракция имеет высокую чистоту, но значительная часть элементов данного класса не попадает в соответствующую бочку и направляется в нераспознанные или ошибочные фракции. Таким образом, Recall позволяет убедиться, что высокая чистота фракции не достигается за счёт чрезмерного количества пропущенных или нераспознанных элементов питания.

Также дополнительно используется метрика **ROC-AUC**. Она применяется как интегральная проверка качества классификатора и его способности корректно различать типы элементов питания.

Протокол экспериментов

Тестируются все 31 непустое подмножество из 5 признаков ($C(5,1) + C(5,2) + C(5,3) + C(5,4) + C(5,5) = 5 + 10 + 10 + 5 + 1 = 31$).

Для каждой комбинации признаков каждый из 3 классификаторов обучается и оценивается на данных соответствующего типоразмера. Итого: $31 \times 3 = 93$ эксперимента на типоразмер, 372 эксперимента суммарно.

Оценка производится в режиме кросс-валидации без жёсткого разделения на обучающую и тестовую выборку (согласно структуре отчёта). Параметры классификаторов фиксированы (не оптимизируются по сетке). Данные по каждому типоразмеру обрабатываются независимо.

Таблица 6. Сравнение классификаторов по метрике ROC-AUC

Классификатор	AAA	AA	C	D
SVM (RBF)	1.00	0.99	0.97	0.96
DecisionTree	1.00	0.99	0.94	0.92
RandomForest	1.00	0.99	0.99	0.97

Аналитические выводы

AAA (наилучший типоразмер для классификации). Для этого типоразмера задача решается идеально: все три классификатора при достаточном наборе признаков достигают ROC-AUC = 1.0, Recall = 1.0, Precision = 1.0. Уже одиночный признак f_3 с SVM или RF даёт ROC-AUC = 1.0. Это объясняется наибольшей однородностью партии и наибольшим относительным вкладом активного вещества в суммарный сигнал для малого типоразмера AAA.

AA. Задача решается с высоким качеством: максимальный ROC-AUC = 0.99 (SVM и RF на нескольких комбинациях). Признак f_3 снова ключевой – комбинация $f_3 + f_4$ с RF даёт ROC-AUC = 0.99 при Recall NiCd = 1.0. Расширение набора признаков от одиночного к паре или тройке устойчиво улучшает результат.

С (сложный типоразмер). Одиночный признак f_3 практически бесполезен (ROC-AUC \leq 0.65), тогда как f_2 даёт 0.93. Лучшие результаты достигаются только при комбинировании f_2 с другими признаками: $f_2 + f_3$ с RF = 0.99, $f_2 + f_3 + f_5$ с RF = 0.99. Это свидетельствует о том, что для С-аккумуляторов различие в составе вещества слабее выражено, и дополнительную разделяющую информацию несёт корпус.

D (наиболее сложный типоразмер). Максимальный ROC-AUC = 0.97 (RF, комбинация $f_1 + f_2 + f_5$). Ни один одиночный признак не даёт более 0.91. Для этого типоразмера необходимы минимум 2–3 признака, а RF стабильно превосходит SVM и DT. Сложность объясняется более толстым корпусом и большим абсолютным размером, что снижает чувствительность относительного сигнала к составу вещества.

Роль RandomForest. RF является наиболее устойчивым классификатором: для типоразмеров С и D он превосходит SVM и DT на большинстве комбинаций. SVM с RBF конкурентоспособен на AAA/AA и имеет потенциал улучшения через kernel engineering.

Одиночные vs. составные признаки. Устойчивый вывод для всех типоразмеров: добавление второго и третьего признака к лучшему одиночному улучшает или не ухудшает результат. Оптимальный размер набора признаков составляет 2–4: полный набор из 5 признаков не всегда обеспечивает лучший результат (например, для AA сочетания из 2–3 признаков с RF иногда превосходят полный набор).

Заключение

В работе разработан и реализован воспроизводимый пайплайн автоматизированной классификации аккумуляторов типов NiCd и NiMH. Предложенный подход включает двухуровневую сегментацию с применением методов компьютерного зрения, обеспечивающую выделение батарейки из фона и последующее разделение на области активного вещества и корпуса, а также формирование геометрически нормированного признака эффективной плотности f_5 , учитывающего коническую геометрию рентгеновского пучка. Проведено систематическое исследование всех 31 комбинации признаков с использованием трёх классификаторов для четырёх типоразмеров аккумуляторов, что в совокупности составляет 372 вычислительных эксперимента.

Экспериментально установлено, что признак f_3 , характеризующий область активного вещества, обладает наибольшей дискриминирующей способностью для типоразмеров AAA и AA. Показано, что использование комбинаций признаков обеспечивает более устойчивые результаты по сравнению с применением одиночных признаков, при этом наилучшие показатели достигаются при использовании 2–4 признаков. Среди рассмотренных методов классификации наибольшую эффективность продемонстрировал алгоритм Random Forest, обеспечивающий стабильные результаты для всех типоразмеров.

Достигнуты высокие значения метрики ROC-AUC: 1.0 для типоразмера AAA, 0.99 для AA и С, и 0.97 для D, что свидетельствует о высокой точности и надёжности предложенного метода. На основе полученных результатов сформулированы рекомендации для практического применения: для типоразмеров AAA и AA целесообразно использование комбинации признаков $f_3 + f_4$, тогда как для типоразмеров С и D — комбинации $f_2 + f_3 + f_5$ в сочетании с классификатором Random Forest.

Список использованных источников

1. Lehmann, L. A. Generalized image combinations in dual KVP digital radiography / L. A. Lehmann, R. E. Alvarez, A. Macovski [et al.] // Medical Physics. — 1981. — Vol. 8, № 5. — P. 659—667.
2. Hubbell, J. H. Tables of X-Ray Mass Attenuation Coefficients and Mass Energy-Absorption Coefficients 1 keV to 20 MeV for Elements Z = 1 to 92 and 48 Additional Substances of Dosimetric Interest / J. H. Hubbell, S. M. Seltzer. — Gaithersburg : National Institute of Standards and Technology, 1995. — 120 p. — NISTIR 5632.
3. Szeliski, R. Computer Vision: Algorithms and Applications / R. Szeliski. — 2nd ed. — Cham : Springer, 2022. — 925 p.
4. James, G. An Introduction to Statistical Learning: with Applications in Python / G. James, D. Witten, T. Hastie, R. Tibshirani, J. Taylor. — Cham : Springer, 2023. — 607 p.