

Научная статья

УДК 004.932

DOI: <https://doi.org/10.18127/j20700970-202503-12>

Распознавание орхоно-енисейских рунических надписей методами машинного обучения

А.Д. Бородина¹, Р.А. Кочкаров²

^{1,2} Финансовый университет при Правительстве Российской Федерации (Москва, Россия)

¹ aborodinasty@gmail.com 89771775538, ² rkochkarov@fa.ru

Аннотация

Постановка проблемы. Распознавание орхоно-енисейских рунических надписей представляет собой важную, но крайне сложную задачу, связанную с низким качеством источников, визуальной неоднородностью рун и ограниченностью размеченных данных. Процесс расшифровки рунических надписей археологами подвержен ошибкам и субъективности. Особенно труден этап выделения и интерпретации символов в условиях плохой сохранности артефактов и сложного визуального контекста.

Цель. Разработать и обучить модель компьютерного зрения для автоматического распознавания и классификации символов рунического алфавита Кюль-Тегин на изображениях памятников, включая как черно-белые копии, так и реальные цветные фотографии.

Результаты. Разработан прототип системы, основанный на двух моделях: *YOLOv11* – для детекции символов, а также сверточной нейросети – для классификации символов. Установлено, что модель детекции достигла точности $mAP@0,5 = 0,825$, $recall = 0,801$ и $precision = 0,75$. Классификатор показал $accuracy = 90,23\%$ и F1-меру = 0.884. Отмечено, что визуализация признаков методом t-SNE продемонстрировала четкую кластеризацию большинства классов. Выявлены ограничения, связанные с переобучением и дисбалансом классов, особенно при работе с редкими и неизвестными рунами. Модель может быть применена для других рунических систем.

Практическая значимость. Полученные результаты могут быть применены в цифровой эпиграфике и историко-лингвистических исследованиях для ускорения анализа древних текстов и повышения его точности. Работа закладывает основу для построения более масштабируемых и устойчивых моделей распознавания письменных памятников в условиях низкого качества данных.

Ключевые слова

Компьютерное зрение, руническая письменность, орхоно-енисейский, *YOLOv11*, сверточная нейронная сеть, классификация изображений, машинное обучение, древнетюркские руны, детекция объектов

Для цитирования

Кочкаров Р.А., Бородина А.Д. Распознавание орхоно-енисейских рунических надписей методами машинного обучения // Нелинейный мир. 2025. Т. 23. № 3. С. 96–106. DOI: <https://doi.org/10.18127/j20700970-202503-12>

A brief version in English is given at the end of the article

Введение

Орхоно-енисейские руны – древнейшая система письма тюркских народов, использовавшаяся с VI по X век на территории Центральной Азии (включая современную Монголию, Южную Сибирь и часть Казахстана) [1–3, 9, 15]. Это были надгробные и памятные тексты, выбитые на камне. Они отражают политические, военные и культурные события тюркских племен. Их расшифровка началась во второй половине XIX века и остаётся предметом научных исследований и дискуссий.

Расшифровка рунических надписей представляет собой комплексную задачу, которую принято разбивать на два основных этапа:

- 1) определение отдельных знаков;
- 2) лингвистическая интерпретация выделенных рун.

Первый этап осложнен морфологическими особенностями и плохой сохранностью памятников. Также важен и человеческий фактор: зафиксировано много неточностей в определении рун, которые впоследствии повлияли на расшифровку и понимание древних надписей.

Ц е л ь р а б о т ы – разработать и обучить модель компьютерного зрения для автоматического распознавания и классификации символов рунического алфавита Кюль-Тегин на изображениях памятников, включая как черно-белые копии, так и реальные цветные фотографии.

При проведении исследования планируется разработать модель компьютерного зрения для распознавания изображений рунических текстов, включая предобработку входного изображения, применение моделей детекции и классификации и последующая визуализация найденных и классифицированных рунических символов. При этом модель должна определять все рунические символы на изображении и классифицировать руны алфавита Кюль-Тегин.

Сбор и подготовка данных

Изображения с руническими надписями были собраны из общедоступных источников [1–21]. В набор данных были включены изображения, содержащие надписи не только из рун алфавита Кюль-Тегин, но и небольшое количество текстов других рунических алфавитов, в том числе Ирк Битиг [22]. Все рунические символы, не относящиеся к алфавиту Кюль-Тегин, были помечены классом 342. Во-первых, такой подход позволяет разметить все рунические символы на изображении. Во-вторых, модель будет учиться определять различные рунические знаки. В модель передаются:

бинарные изображения, содержащие перенесенные с древних памятников изображения рун; черно-белые и цветные фотографии памятников в реальной жизни.

Для маркировки изображений использовался инструмент с открытым исходным кодом – cvat.ai (рис. 1).

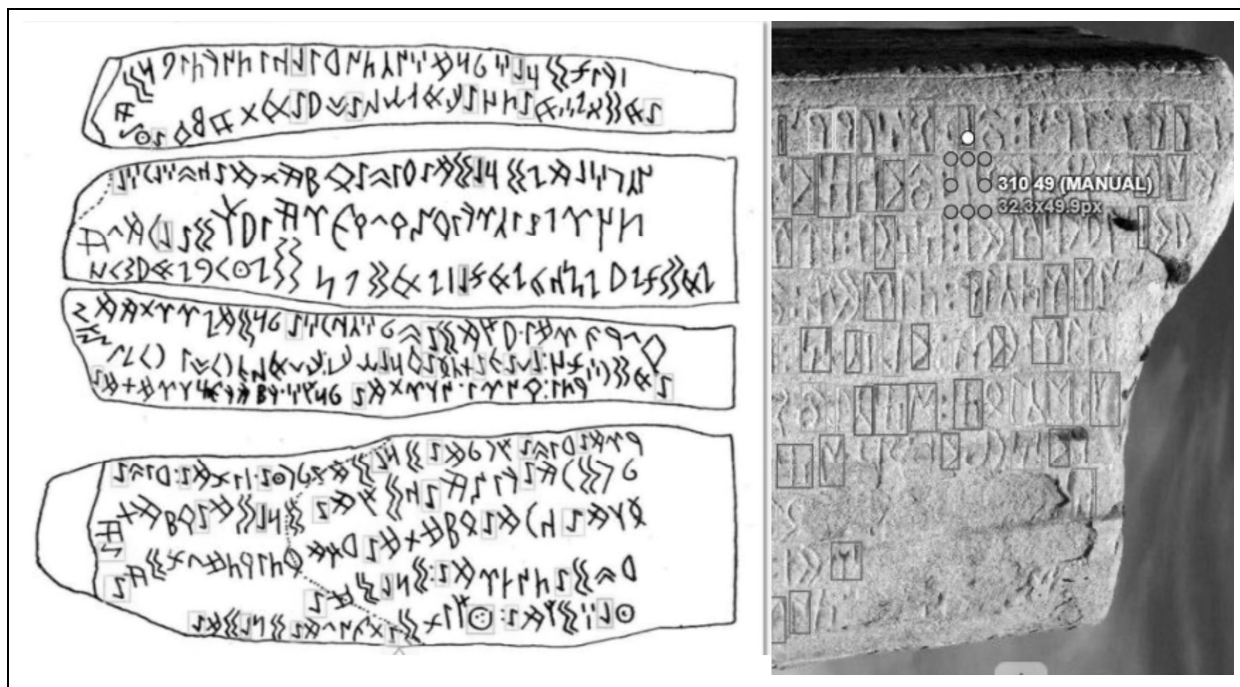


Рис. 1. Разметка изображений в сервисе CVAT

Fig. 1. Image markup in the CVAT service

Перед использованием в машинном обучении набор данных разделили на обучающую и тестовую выборки в соотношении 0,8 и 0,2. При разделении было важно, чтобы фотографии разных типов вошли в обе выборки. Таким образом, модель должна обучаться на всех вариантах изображений, и оценка ее результатов будет наиболее полной.

В процессе исследования лучший результат показало сочетание двух моделей машинного обучения: для детекции рунических символов и для их классификации. Точность совмещенной

модели детекции и классификации оказалась ниже ожидаемой, и не наблюдалось тенденции к ее росту при изменении различных управляющих параметров. Это можно объяснить малым размером обучающей выборки для данной задачи.

Обучение модели обнаружения рунических символов на изображениях

Для обнаружения рунических символов на изображениях различного типа (как реальных цветных фотографиях, так и бинаризованных изображениях) в настоящем исследовании была выбрана модель *YOLOv11* [23]. Модель *YOLOv11* изначально ориентирована на задачу *object detection*, обеспечивая одновременное определение местоположения и класса объектов на изображении. Это является основной причиной выбора модели для задачи локализации рун на разнородных визуальных данных. Более того, модель демонстрирует высокую устойчивость к шумам, вариациям освещения и масштабам объектов, что критично при работе с реальными археологическими фотографиями, содержащими артефакты, фрагменты и неоднородные фоны. Изображения передаются в модель без удаления фона или других ручных преобразований. Итоговый набор данных содержит рунические символы, размеченные в формате, совместимом с *YAML*-конфигурацией *Ultralytics*.

Функция потерь модели *YOLO* состоит из:

ошибки локализации (*bbox regression*);

классификационной ошибки;

ошибки распределения якорей (*Distribution Focal Loss*).

Изображения, подающиеся в модель, были приведены к размеру 928 пикселей. При этом применялись автоматические аугментации. Такой крупный масштаб был необходим для обнаружения мелких и тонких деталей, характерных для рунических знаков. Кроме того, в наборе данных присутствуют большие изображения, содержащие более 2000 символов, и при меньшем размере их было бы сложнее обнаружить.

Для модели было задано снижение скорости обучения с множителем 0,007. Такая настройка используется в сочетании с косинусным расписанием изменения скорости обучения, при котором она постепенно уменьшается по косинусному расписанию в течение всех эпох. Это позволяет избежать перенастройки модели на отдельные шумовые или редкие примеры из обучающего корпуса, что критично в условиях небольшой обучающей выборки.

Для количественной оценки производительности модели в задаче детекции рунических символов использовались следующие метрики: *mAP@0.5* (*mean average precision*), *mAP@0.5:0.95*, *precision* (точность), *recall* (полнота). При тестировании модели использовался *TTA* (*Test-Time Augmentation*). Этот метод приводит несколько вариаций одного и того же тестового изображения с преобразованиями и затем объединяет результаты этих предсказаний для получения более точного и стабильного результата.

Метрика *mAP@0.5* отражает среднюю точность предсказаний при пороге $\text{IoU} \geq 0,5$. В начальной фазе обучения наблюдаются резкие колебания обеих метрик, что может быть связано с чувствительностью модели к начальной скорости обучения или влиянием несбалансированности классов (рис. 2). Примерно после 120-й эпохи обе метрики входят в стабильную фазу, демонстрируя сходимость модели и отсутствие переобучения на тестовом наборе.

Не менее важным является график изменения метрик *precision* и *recall* во время обучения (рис. 3). В начальной фазе обучения наблюдается активный рост обеих метрик, что отражает быстрое освоение моделью базовых признаков рунических символов.

Начиная с 40-й эпохи, как точность, так и полнота стабилизируются на высоком уровне – в среднем от 0,7 до 0,8, что указывает на устойчиво хорошее качество предсказаний. В определенные моменты (например, около 100-й эпохи) наблюдаются локальные провалы метрик, особенно точности. Это может быть связано с влиянием отдельных трудных батчей, нестабильными предсказаниями по «неизвестным» классам или реакцией модели на изменения в обучении (например, переходы в расписании скорости обучения). В дальнейшем обе метрики демонстрируют умеренные колебания, но сохраняются в пределах высокого уровня, что свидетельствует о стабильности модели на фазе дообучения.

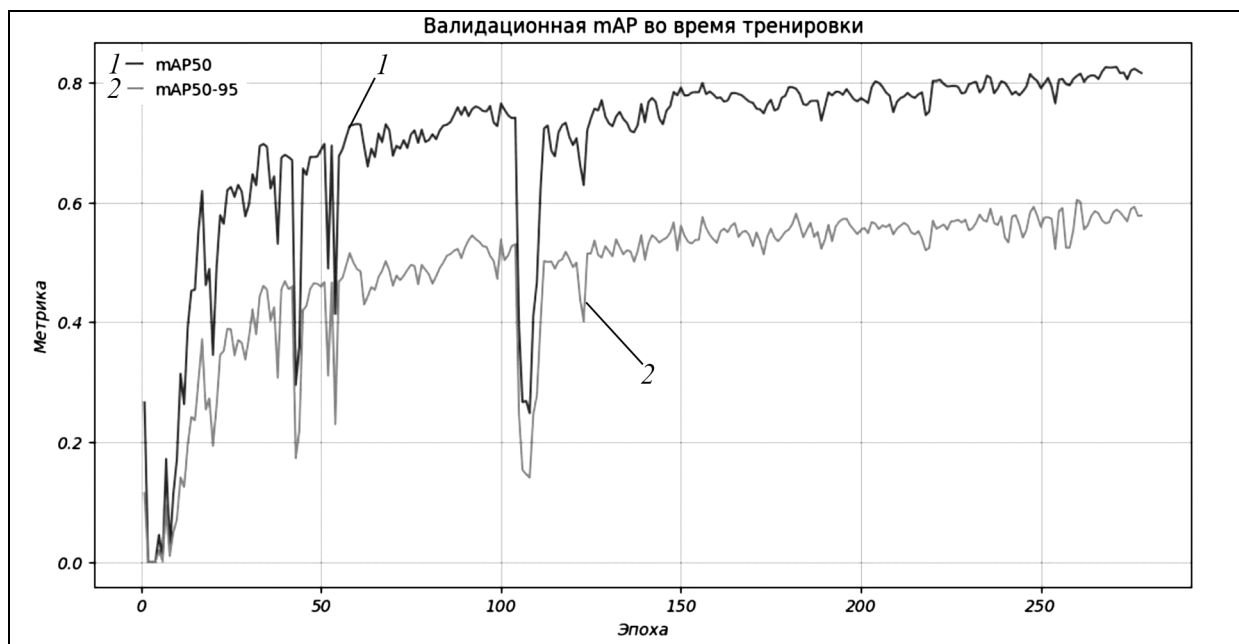


Рис. 2. Графическое представление средней точности на тестовом наборе в процессе обучения

Fig. 2. Average accuracy on the test set during training




Рис. 3. Графическое представление точности и полноты на валидации в процессе обучения

Fig. 3. Accuracy and recall on validation during training

На рис. 4 кривая Precision-Recall (PR-кривая) демонстрирует сбалансированную работу модели: при высоких значениях *recall* (до 0,9) сохраняется высокая точность (до 0,85–0,9). На представленной PR-кривой отображена зависимость точности от полноты при различных порогах классификации. В начале PR-кривой, при низком значении *recall*, точность равна 1, что свидетельствует о минимальном числе ложных срабатываний. На более высоких значениях *recall* точность падает, что подтверждает существование компромисса между этими двумя показателями. Увеличение полноты, как правило, приводит к ухудшению точности, так как модель классифицирует больше объектов как «положительные», что увеличивает число ложных положительных предсказаний.

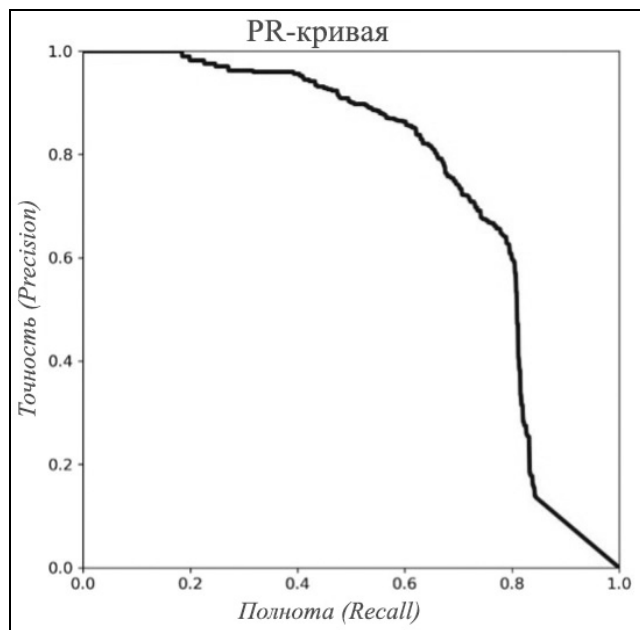


Рис. 4. Кривая Precision–Recall

Fig. 4. Precision–Recall curve

Анализ PR-кривой (рис.4) позволяет подобрать оптимальный порог уверенности в зависимости от цели применения модели:

для максимального охвата редких или важных объектов (например, уникальных символов) целесообразно использовать низкий порог (например, 0.2–0.3), обеспечивающий высокий *recall*;

для высокой точности и автоматической фильтрации ложных срабатываний предпочтительно устанавливать более высокий порог – около 0.9, при котором модель демонстрирует максимальную уверенность в корректности своих предсказаний.

После начальной фазы обучения модель демонстрирует устойчивое поведение всех метрик, без признаков переобучения или деградации качества. Также можно отметить хорошую управляемость качеством работы за счет варьирования уровня *confidence*, что позволяет адаптировать модель под различные исследовательские и прикладные задачи. Сле-

довательно, модель достигла высокой степени устойчивости и эффективно решает задачу детекции рунических символов в условиях ограниченного и визуально разнообразного датасета.

Обучение модели классификации рунических символов

Для классификации изображений была разработана сверточная нейронная сеть (рис. 5), состоящая из нескольких сверточных блоков и линейных слоев. Архитектура включает в себя два основных компонента: модуль извлечения признаков и классификационный модуль.

Для обучения классификатора был сформирован дополнительный массив данных. Из исходных изображений с руническими надписями пришлось вырезать размеченные символы, сформировав наборы символов для каждого класса рун. Для компенсации неравномерного распределения классов в обучающем наборе данных использовалось взвешивание функции потерь. Вес каждого класса вычислялся на основе обратной частоты его появления в обучающей выборке, что позволяет увеличивать вклад редких классов при оптимизации модели. Полученные веса нормализовались и использовались в качестве параметра *weight* в функции потерь, что способствует более сбалансированному обучению и снижению смещения в сторону доминирующих классов. Во избежание переобучения классификатор обучался на разнообразных аугментациях. Так как изображения символов достаточно однотипны (имеют похожие фоны, цвета и наклон), применение аугментаций делает классификатор мощнее и позволяет добиться большей точности.

Качество обученной модели классификации было оценено на тестовой выборке с использованием следующих метрик: точность (*accuracy*), F1-мера, точность (*precision*) и полнота (*recall*). В совокупности эти метрики позволяют не только оценить общее качество модели, но и проанализировать характер ее ошибок.

Анализ кривых обучения (рис. 6) показывает высокое качество классификации рунических символов. Модель достигает точности около 90% на тестовой выборке и сохраняет высокий уровень F1-меры. Классификатор успешно обучается на ограниченном наборе данных, демонстрируя высокие значения точности и F1-меры как на тренировочной, так и на тестовой выборках. Из этого следует, что модель способна извлекать релевантные визуальные признаки, несмотря на вариативность изображений. После примерно 10-й эпохи наблюдается расхождение между функцией по-

теперь на обучающей и тестовой выборках – тестовая ошибка начинает увеличиваться, несмотря на снижение обучающей. Это указывает на переобучение классификатора и ограниченность объема обучающего корпуса. На тестовой выборке полнота стабилизируется на более низком уровне, чем точность, что может свидетельствовать о склонности модели пропускать редкие или атипичные классы, включая класс неизвестных рун. После 30-й эпохи большинство метрик на тестовой выборке демонстрируют стабилизацию, что может указывать на достижение модели пределов обучаемости при текущем объеме и качестве данных.

```
CNNClassifier(
  (features): Sequential(
    (0): Conv2d(3, 64, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (1): BatchNorm2d(64, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
    (2): ReLU()
    (3): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
    (4): Conv2d(64, 128, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (5): BatchNorm2d(128, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
    (6): ReLU()
    (7): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
    (8): Conv2d(128, 256, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (9): BatchNorm2d(256, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
    (10): ReLU()
    (11): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
  )
  (classifier): Sequential(
    (0): Flatten(start_dim=1, end_dim=-1)
    (1): Linear(in_features=6400, out_features=512, bias=True)
    (2): ReLU()
    (3): Linear(in_features=512, out_features=128, bias=True)
    (4): ReLU()
    (5): Dropout(p=0.7, inplace=False)
    (6): Linear(in_features=128, out_features=39, bias=True)
  )
)
```

Рис. 5. Архитектура классификатора

Fig. 5. Classifier architecture

Результаты модели детекции

После завершения обучения модели обнаружения символов была проведена ее финальная оценка на тестовой выборке. Приведем полученные значения ключевых метрик:

precision: 0.75;

recall: 0.801;

mAP@0.5: 0.825;

mAP@0.5:0.95: 0.643.

Достигнутое значение точности свидетельствует о высокой достоверности предсказаний: модель корректно распознает подавляющее большинство рун. Модель обнаруживает более 80% всех истинных объектов на изображениях, что особенно важно в условиях визуальной неоднородности данных, включая как бинарные изображения, так и реальные цветные фотографии рунических надписей.

Метрика mAP@0.5, равная 0.825, подтверждает, что модель способна уверенно локализовать и классифицировать большую часть объектов при пороге 0,5. Более строгая усредненная метрика mAP@0.5:0.95 свидетельствует о том, что модель сохраняет устойчивое качество локализации и при более высоких требованиях к точности, что делает ее пригодной для использования в реальных

условиях археологического и эпиграфического анализа. Визуализация предсказания модели для разных вариантов изображений, чтобы убедиться в ее работоспособности, представлена на рис. 7.

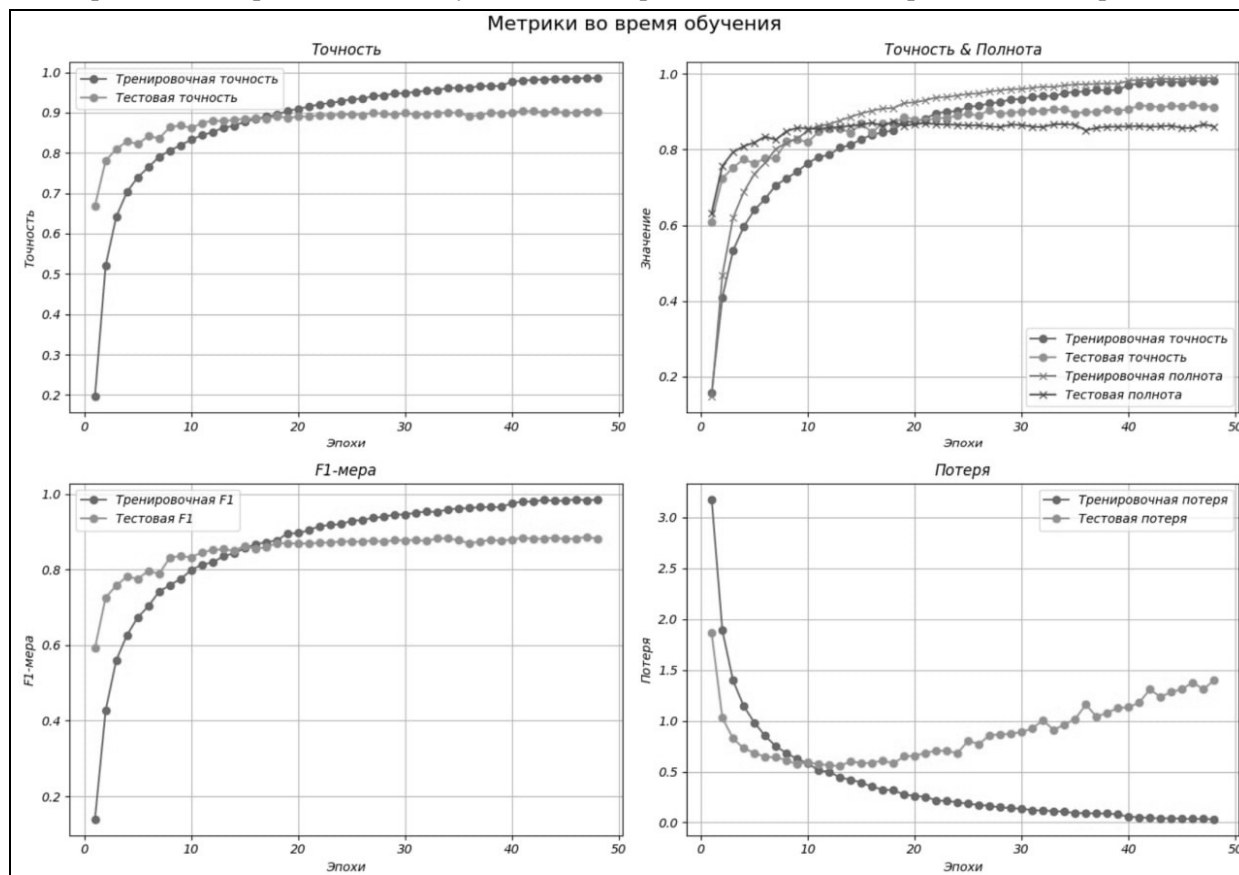


Рис. 6. Кривые обучения классификатора

Fig. 6. Classifier learning curves

Результаты модели классификации

Модель классификации достигла следующих результатов:

accuracy: 0.9023;

F1-мера: 0.8840;

precision: 0.8994;

recall: 0.8745.

Высокое значение общей точности (90.23%) указывает на способность успешно классифицировать подавляющее большинство изображений, несмотря на разнообразие визуальных характеристик входных данных (различия в освещении, фоновых шумах, стилистике начертания и др.). Тем не менее, учитывая возможный дисбаланс между различными классами рун в обучающем наборе, отметим, что ключевую роль в интерпретации результатов играет F1-мера – сбалансированный показатель, характеризующий точность предсказаний и их полноту. Полученное значение свидетельствует о том, что модель сохраняет высокую устойчивость к ошибкам обоих типов (ложноположительным и ложноотрицательным).

Метрика демонстрирует, что около 90% предсказанных моделью символов действительно соответствуют истинным меткам. Это особенно важно при обработке реальных изображений, где присутствуют фрагменты, визуально схожие с рунами, но не являющиеся таковыми (например, орнаменты). Однако значение метрики *recall* отражает способность модели обнаруживать максимальное количество подлинных рун, включая и те, что представлены в менее распространенных формах.

Исходя из отчета классификации, можно заметить, что практически все классы имеют высокие значения метрик. Низкие значения наблюдаются у класса 342 (38 на рис. 8) и у класса 331 (29 на рис. 8). Класс 331 имеет самые маленькие *recall* и F1-меру. У класса 342 самая низкая точность, а полнота и F1-мера хоть и выше, чем у класса 331, все равно хуже, чем у остальных классов. Такое низкое значение F1-метрики можно объяснить тем, что модель не может эффективно сформировать стабильное представление признаков для этих классов. Класс 331 самый малочисленный в наборе данных (рис. 9). Модели не хватает этих данных для обучения, поэтому точность этого класса, соответственно, ниже всех остальных. Класс 342 объединяет в себе множество визуально и семантически разнородных символов, не имеющих четких общих признаков. Кроме того, некоторые символы, отнесенные к этому классу, могут визуально напоминать элементы из основных классов, что приводит к повышенному количеству ложноположительных и ложноотрицательных предсказаний.

Заметим, что класс 342 неизвестных рун не является преобладающим в наборе данных: из 30662 обнаруженных объектов всего 1931 объект относится к этому классу. Следовательно, всего 6% надписей принадлежат другим алфавитам. В тестовой выборке неизвестные руны встречаются чаще всего (рис. 9). На цветной фотографии были размечены 223 руны, все из алфавита Кюль-Тегин. Подчеркнем, что разметка для этой картинки была неполная, остаются еще видимые символы, не отмеченные никаким классом. Модель смогла определить на ней 300 рунических символов (см. рис. 7). В точности детекции модели можно наглядно убедиться, поскольку границы новых символов определены правильно. Точность классификации для символов, которых нет в изначальной разметке, посчитать затруднительно. Из обнаруженных символов модель отнесла 10 к классу неизвестной руны. Можно определить, что 8 символов из них были отнесены к классу 342 ошибочно. На черно-белом изображении были обнаружены все руны, и лишь одну из них модель отнесла к классу 342 (см. рис. 7). Модель ошибочно выделила еще 7 неизвестных символов, определив их к алфавиту Кюль-Тегин.

В итоге получили, что модель демонстрирует высокую степень обобщающей способности для классификации рунических символов в условиях сильной визуальной вариативности. Модель применима для обработки как оцифрованных рунических надписей, так и их полевых фотографий. Тем не менее сниженное качество работы класса 342 отражает фундаментальные ограничения модели в ситуации обобщения на непредставленные или атипичные классы.

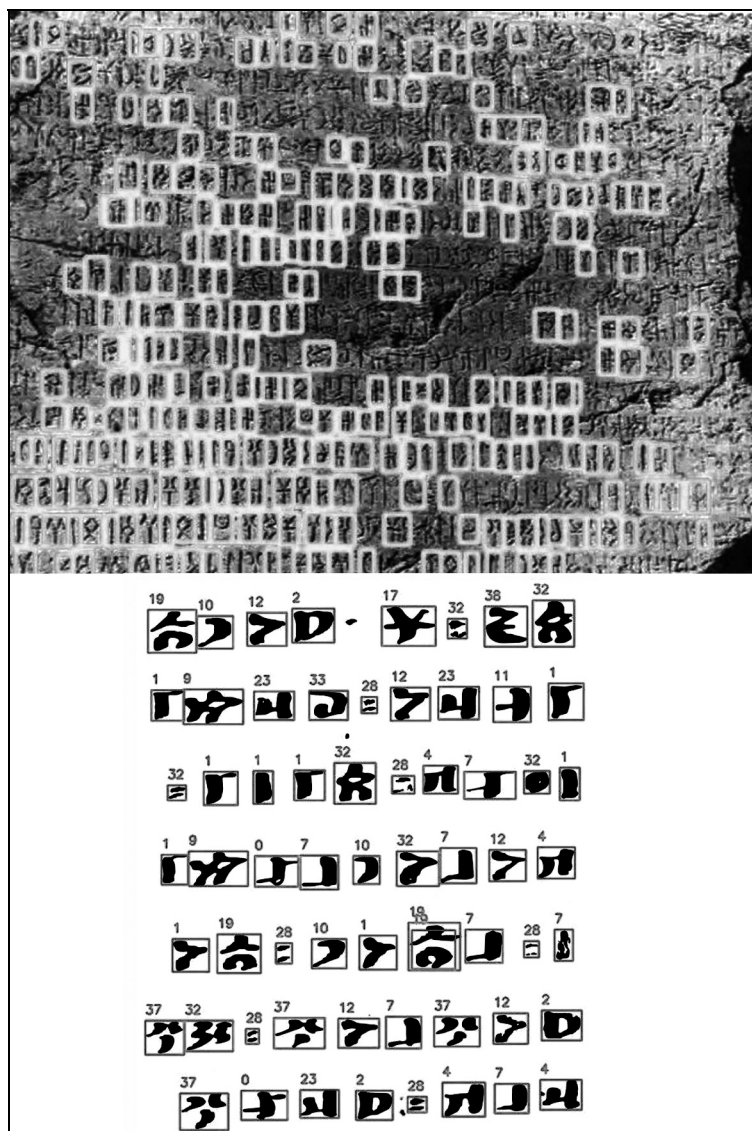


Рис. 7. Пример работы моделей на тестовых изображениях

Fig. 7. Examples of models' work

class_28	0.86	0.93	0.89
class_29	0.67	0.33	0.44
class_3	0.91	0.94	0.92
class_30	0.92	0.92	0.92
class_31	0.73	0.77	0.75
class_32	0.93	0.92	0.92
class_33	0.75	0.78	0.76
class_34	0.98	0.95	0.96
class_35	1.00	0.88	0.93
class_36	0.75	0.68	0.71
class_37	0.92	0.86	0.89
class_38	0.64	0.66	0.65
class_4	0.94	0.90	0.92
class_5	0.98	0.90	0.94
class_6	0.92	0.93	0.92
class_7	0.86	0.90	0.88
class_8	0.97	0.96	0.97
class_9	0.93	0.92	0.92
	precision	recall Metric	f1-score

Рис. 8. Фрагмент отчета о классификации

Fig. 8. Fragment of the classification report

С учетом сказанного можно сделать вывод, что для более корректной обработки новых или редко встречающихся символов необходимо расширить обучающую выборку. Это подводит к серьезной проблеме, с которой столкнулись в процессе исследования, – нехватке размеченных данных. Представленные в работе модели обучались на небольшом наборе, включающем в себя всего 81 изображение. Такое малое количество размеченных примеров существенно ограничивает способность модели к обобщению, особенно в условиях высокой внутриклассовой вариативности рунических символов и наличия фоновых шумов на фотографиях.




Рис. 9. Распределение классов рунических символов

Fig. 9. Distribution of classes of runic symbols

низкая устойчивость к вариациям: неохваченное стилевое, масштабное и цветовое разнообразие рун в реальных условиях приводит к снижению точности на тестовых данных, что видно на графиках обучения.

Ограниченность обучающего корпуса привела к следующим последствиям:

переобучение: модель начинает «запоминать» индивидуальные особенности тренировочных данных, теряя способность к обобщению новых, ранее не встречавшихся объектов;

переобучение: модель начинает «запоминать» индивидуальные особенности тренировочных данных, теряя способность к обобщению новых, ранее не встречавшихся объектов;

Заключение

В результате проведенного исследования подготовлен прототип системы автоматического распознавания рунических символов. Несмотря на то, что классификация охватывает лишь руны алфавита Кюль-Тегин, внедрение отдельной модели детекции позволило успешно обнаруживать символы и из других рунических систем, что открывает возможности для масштабируемости решения. Выбранные архитектуры сверточного классификатора и модели семейства *YOLO* продемонстрировали свою эффективность и применимость в задаче обработки рунических данных.

В ходе работы также были выявлены проблемы, связанные прежде всего с недостатком размеченных данных, высокой визуальной вариативностью символов и сложностями открытой классификации. Эти аспекты определяют направление дальнейших исследований. Необходимо отметить, что нехватка данных выступает фундаментальным ограничением текущего этапа исследования. Это подчеркивает необходимость расширения обучающей выборки за счет привлечения дополнительных источников, создания полусинтетических данных, либо использования подходов с малым числом примеров или крупных языково-визуальных трансформеров.

Таким образом, представленная работа демонстрирует возможность применения современных методов компьютерного зрения для решения задач цифровой эпиграфики и закладывает основу для дальнейшей автоматизации анализа исторических письменных памятников.

Список источников

1. *Кормушин И.В.* Древние тюркские языки. М.: Восточная литература. 2006. 30 с.
2. *Кормушин И.В.* Тюркские енисейские эпиграфии. М.: Восточная литература. 2008. 5 с.
3. *Кызласов И.Л.* Рунические письменности евразийских степей. М.: Наука. 1994. 318 с.
4. Дешифровка орхонских и енисейских надписей // Записки Восточного отделения ИВ РАН. М. 1995. Вып. 25. С. 289–318.
5. *Круглов Е.В.* Формирование источниковой базы памятников Соколовской Балки // Нижневолжский археологический вестник. 2002. № 2. С. 69–72.
6. *Kyzlasov I.L.* Runic Scripts of the Eurasian Steppes. М.: Russian Academy of Sciences. 1994. 180 p.
7. Proposal for encoding the Khazarian Rovas script in the SMP of the UCS. ISO/IEC JTC1/SC2/WG2 N3999. 2011-01-21.
8. *Васильев Д.Д.* Графический фонд памятников тюркской рунической письменности азиатского ареала. М.: Наука. 1983. 192 с.
9. *Байчоров С.Я.* Древнетюркские рунические памятники Европы. Ставрополь: Ставропольское книжное изд-во. 1989. 150 с.
10. *Тишин В.В.* Новые соображения о возможности расшифровки надписей на рунических дирхемах на основе материала тюркских языков // Вестник БНЦ СО РАН. 2018. № 30. С. 46–56.
11. *Кононов А.Н.* Грамматика языка тюркских рунических памятников VII–IX вв. Л.: Наука. 1980. 260 с.
12. *Лебедев Ю.С., Попов П.В.* Погребение VIII–IX вв. из Астраханской области и горшок с рунической надписью // Российская археология. 2023. № 1. С. 178–186.
13. Проблемы археологии Кавказа. Вып. 1. М.: ТАУС. 2012. 248 с.
14. Вопросы тюркологии. М.: Институт тюркологии. 2010. № 1. 188 с.
15. *Кызласов И.Л.* К познанию нерасшифрованного письма // Хазарский альманах. М. 2020. № 28–29.
16. Хазарский альманах. Т. 15. М.: Институт славяноведения РАН. 2017. 228 с.
17. Поволжская археология. 2014. № 3 (9).
18. Тюркологические исследования. 2018. Т. 1. № 2.
19. Археологическое наследие / Под ред. *А.Н. Головтина*. Липецк: Аргамач. 2018. ПИ № ТУ48-00362.
20. Народы и религии Евразии. Барнаул: Изд-во Алтайского гос. ун-та, 2019. № 4 (21).
21. Нижневолжский археологический вестник. Волгоград: Волгоградский гос. ун-т. 2018. Т. 17. № 1.
22. *Кочкаров У.Ю., Беляева В.Н., Кочкаров Р.А., Кочкаров А.А.* Подготовка набора визуальных данных для машинного распознавания рунической письменности // Проблематика и методология современных тюркологических исследований: Коллективная монография / отв. ред. *Е.А. Оганова*. М.: ООО «Издательство МБА». 2025. С.162–173.
23. Ultralytics. YOLOv11 Documentation [Electronic resource]. URL: <https://docs.ultralytics.com/ru/models/yolo11/>. Date of access: 10.04.2025.

Информация об авторах

Анастасия Дмитриевна Бородина – студент

SPIN-код: не представлен

Расул Ахматович Кочкаров – к.э.н, доцент кафедры искусственного интеллекта

SPIN-код: не представлен

Статья поступила в редакцию 10.06.2025

Одобрена после рецензирования 24.06.2025

Принята к публикации 30.06.2025

Original article

Detection of Orkhon-Yenisei runic inscriptions

R.A. Kochkarov¹, A.D. Borodina²^{1,2} Financial University under the Government of the Russian Federation (Moscow, Russia)¹ kochkarov@fa.ru, ² aborodinasty@gmail.com**Abstract**

The recognition of Orkhon-Yenisei runic inscriptions is an important yet highly challenging task due to the poor quality of source materials, the visual heterogeneity of runes, and the limited availability of annotated data. The deciphering process performed by archaeologists is prone to errors and subjectivity. The most difficult stage involves the segmentation and interpretation of symbols under conditions of artifact degradation and complex visual contexts.

Objective. To develop and train a computer vision model for the automatic detection and classification of characters from the Kül Tegin runic alphabet on monument images, including both black-and-white copies and real color photographs.

A prototype system was developed, combining two models: YOLOv11 for symbol detection and a convolutional neural network for classification. The detection model achieved $\text{mAP}@0.5 = 0.825$, recall = 0.801, and precision = 0.75. The classifier achieved 90.23% accuracy and an F1-score of 0.884. Feature visualization using t-SNE demonstrated clear clustering for most classes. Limitations were identified, including overfitting and class imbalance-especially when working with rare or unknown runes. The model can be adapted to other runic systems.

The results can be applied in digital epigraphy and historical-linguistic research to enhance the speed and accuracy of ancient text analysis. The work lays the foundation for the development of more scalable and robust recognition systems for inscriptions under low-quality data conditions.

Keywords

Computer vision, runic script, Orkhon-Yenisei, YOLOv11, convolutional neural network, image classification, machine learning, Old Turkic runes, object detection

For citation

Kochkarov R.A., Borodina A. D. Detection of Orkhon-Yenisei runic inscriptions. *Nonlinear World*. 2025. V. 23. № 3. P. 96–106. DOI: <https://doi.org/10.18127/j20700970-202503-12> (In Russian)

REFERENCES

1. Kormushin I.V. Drevnie tyurkskie yazyki. M.: Vostochnaya literatura. 2006. 30 s. (In Russian)
2. Kormushin I.V. Tyurkskie enisejskie epitafii. M.: Vostochnaya literatura. 2008. 5 s. (In Russian)
3. Kyzlasov I.L. Runicheskie pis'mennosti evrazijskih stepej. M.: Nauka. 1994. 318 s. (In Russian)
4. Deshifrovka orhonskih i enisejskih nadpisej. Zapiski Vostochnogo otdeleniya IV RAN. M. 1995. Vyp. 25. S. 289–318 (In Russian).
5. Kruglov E.V. Formirovanie istochnikov bazy pamyatnikov Sokolovskoj Balki. Nizhnevolzhskij arheologicheskij vestnik. 2002. № 2. S. 69–72 (In Russian).
6. Kyzlasov I.L. Runic Scripts of the Eurasian Steppes. M.: Russian Academy of Sciences. 1994. 180 p.
7. Proposal for encoding the Khazarian Rovas script in the SMP of the UCS. ISO/IEC JTC1/SC2/WG2 N3999. 2011-01-21.
8. Vasil'ev D.D. Graficheskij fond pamyatnikov tyurkskoj runicheskoj pis'mennosti aziatskogo areala. M.: Nauka. 1983. 192 s. (In Russian).
9. Bajchorov S.Ya. Drevnetyurkskie runicheskie pamyatniki Evropy. Stavropol': Stavropol'skoe knizhnoe izd-vo. 1989. 150 s. (In Russian).
10. Tishin V.V. Novye soobrazheniya o vozmozhnosti rasshifrovki nadpisej na runicheskikh dirhemah na osnove materiala tyurkskih yazykov. Vestnik BNC SO RAN. 2018. № 30. S. 46–56 (In Russian).
11. Kononov A.N. Grammatika yazyka tyurkskih runicheskikh pamyatnikov VII–IX vv. L.: Nauka. 1980. 260 s. (In Russian).
12. Lebedev Yu.S., Popov P.V. Pogrebenie VIII–IX vv. iz Astrahanskoj oblasti i gorshok s runicheskoy nadpis'yu. Rossijskaya arheologiya. 2023. № 1. S. 178–186 (In Russian).
13. Problemy arheologii Kavkaza. Vyp. 1. M.: TAUS. 2012. 248 s. (In Russian).
14. Voprosy tyurkologii. M.: Institut tyurkologii. 2010. № 1. 188 s. (In Russian).
15. Kyzlasov I.L. K poznaniyu nerasshifrovannogo pis'ma. Hazarskij al'manah. M. 2020. № 28–29 (In Russian).
16. Hazarskij al'manah. T. 15. M.: Institut slavyanovedeniya RAN. 2017. 228 s. (In Russian).
17. Povolzhskaya arheologiya. 2014. № 3 (9) (In Russian).
18. Tyurkologicheskie issledovaniya. 2018. T. 1. № 2 (In Russian).
19. Arheologicheskoe nasledie. Pod red. A.N. Golovtina. Lipect: Argamach. 2018. PI № TU48-00362 (In Russian).
20. Narody i religii Evrazii. Barnaul: Izd-vo Altajskogo gos. un-ta, 2019. № 4 (21) (In Russian).
21. Nizhnevolzhskij arheologicheskij vestnik. Volgograd: Volgogradskij gos. un-t. 2018. T. 17. № 1 (In Russian).
22. Kochkarov U.Yu., Belyaeva V.N., Kochkarov R.A., Kochkarov A.A. Podgotovka nabora vizual'nyh dannyh dlya mashinnogo raspoznavaniya runicheskoy pis'mennosti. Problematika i metodologiya sovremennyh tyurkologicheskikh issledovanij: Kollektivnaya monografiya. otv. red. E.A. Oganova. M.: OOO «Izdatel'stvo MBA». 2025. S. 162–73 (In Russian).
23. Ultralytics. YOLOv11 Documentation [Electronic resource]. URL: <https://docs.ultralytics.com/ru/models/yolo11/>. Date of access: 10.04.2025.

Information about the authors

Rasul A. Kochkarov – Ph. D. (Eng.), Associate Professor

Anastasia D. Borodina – Undergraduate

The article was submitted 10.06.2025

Approved after reviewing 24.06.2025

Accepted for publication 30.06.2025