

А. Ахметова¹, А. Шаяхметова¹, А. Абдилдаева¹,
Д. Касымова², Н. Абдурахманов¹

¹Казахский национальный университет им. аль-Фараби, Алматы, Казахстан

²Mukhametzhan Tynyshbayev ALT University, Алматы, Казахстан

E-mail: asemshayakhmetova@mail.ru

ПРИМЕНЕНИЕ БАЙЕСОВСКОЙ ТЕОРЕМЫ В КЛАССИФИКАЦИИ ЭЛЕКТРИЧЕСКИХ ЦЕПЕЙ С ПОМОЩЬЮ YOLOV8

Аннотация. В данной работе исследуется синергетический потенциал байесовской теоремы и YOLOv8 в области классификации электрических цепей. Интеграция этих методологий свидетельствует о значительном повышении точности прогнозирования, особенно в сценариях с ограниченной доступностью наборов данных. Объединяя байесовские принципы с надежностью YOLOv8, наше исследование преодолевает проблемы, связанные с недостаточным количеством обучающих данных, представляя новый подход, который значительно повышает точность идентификации компонентов схемы.

Результаты этого исследования позиционируют объединение байесовской теоремы и YOLOv8 как надежное решение, особенно полезное для совершенствования моделей классификации в средах с ограниченными ресурсами. Этот гибридный подход не только устраняет ограничения, связанные с нехваткой данных, но и демонстрирует свою эффективность в составлении более надежных и точных прогнозов. Тонкое понимание неопределенностей, обеспечиваемое байесовскими принципами, дополняет эффективность YOLOv8, делая комбинированную модель устойчивой перед лицом проблем.

В заключение, наше исследование вносит свой вклад в развивающийся ландшафт классификации электрических цепей, представляя комплексное решение, которое процветает в сценариях с ограниченным набором данных. Эта новая интеграция не только повышает точность, но и обещает изменить парадигму интеллектуальных систем в полевых условиях, предлагая более надежный и детальный подход к классификации схем в реальных условиях с ограниченными ресурсами.

Ключевые слова. Электрическая цепь, Байесовская сеть, YOLOv8, гибридный подход, YOLOv9, модель обнаружения объектов.

Введение.

В развивающейся области классификации электрических цепей интеграция сложных методологий машинного обучения, примером которой является YOLOv8, представляет собой заметный прогресс с точки зрения точности и эффективности. Однако постоянные проблемы возникают в сценариях, характеризующихся ограничениями доступных наборов данных, что препятствует оптимальной производительности традиционных моделей. В этом исследовании исследуется новаторский подход, объединяющий теорему Байеса с YOLOv8, утверждая, что эта гибридизация может дать более точные прогнозы даже при отсутствии обширных наборов данных [1].

Основная цель состоит в том, чтобы устранить неопределенности, присущие ограниченному данным, тем самым изменив ландшафт классификации электрических цепей. Это исследование не только направлено на повышение точности, но и предполагает предложение решения, которое выходит за рамки традиционных моделей, предоставляя

более тонкую информацию через пользовательские интерфейсы. Предлагаемая гибридная модель направлена на преодоление сложностей классификации схем с тонким пониманием неопределенностей, что потенциально может произвести революцию в этой области [2].

Принимая целостную перспективу, наше исследование направлено на то, чтобы внести свой вклад в смену парадигмы в интеллектуальных системах. Помимо простого улучшения прогнозных результатов, предполагаемое решение стремится предоставить пользователям всестороннее понимание классификаций схем, способствуя более глубокой синергии между моделями машинного обучения и человеческой интуицией. Этот многогранный подход обладает потенциалом для изменения траектории классификации электрических цепей, предлагая надежное и ориентированное на пользователя решение в условиях ограниченных наборов данных [3].

Материалы и подходы.

Теорема Байеса в классификации электрических цепей

Байесовские рассуждения обеспечивают вероятностную основу для обновления убеждений, основанных на новых доказательствах. В контексте классификации электрических цепей байесовская теорема позволяет нам объединить априорные знания о компонентах схемы с наблюдениями в реальном времени из YOLOv8. Такая интеграция обеспечивает более надежную и контекстно-зависимую классификацию электрических элементов, уменьшая количество ложных срабатываний и отрицательных результатов [4].

Модель обнаружения объектов YOLOv8.

YOLOv8 представляет собой современное решение для обнаружения объектов в режиме реального времени. Его архитектура делит изображение на сетку, и каждая ячейка сетки предсказывает ограничивающие рамки и вероятности классов. Используя YOLOv8, мы можем использовать его эффективность и точность в обнаружении и локализации электрических компонентов в изображении.

Байесовская теорема обеспечивает вероятностную основу для обновления убеждений на основе новых данных. В контексте классификации электрических цепей давайте разберем компоненты [5]:

$$P(C|E) = \frac{P(E|C) \cdot P(C)}{P(E)}, \quad (1)$$

$P(C|E)$: Апостериорная вероятность класса цепи при данном свидетельстве.

$P(E|C)$: Вероятность доказательства с учетом класса цепи.

$P(C)$: Априорная вероятность класса цепи.

$P(E)$: Вероятность доказательства.

В нашем сценарии классификации электрических цепей C представляет класс цепи, а E — свидетельство, полученное от YOLOv8. Цель состоит в том, чтобы обновить наше представление о классе схемы на основе информации, предоставленной YOLOv8.

Комбинация байесовского и YOLOv8:

$$P(C_k|E) = (2) \frac{P(E|C_k) \cdot P(C_k)}{P(E)},$$

$P(C_k|E)$: Пересчитанная вероятность класса k после учета детектированных объектов.

$P(E|C_k)$: Вероятность наблюдения детектированных объектов при известном классе k .

$P(C|k)$: Априорная вероятность класса k .
 $P(E)$: Общая вероятность детектирования объектов.

Обнаружение объектов YOLOv8:
 $YOLOv8_{output} = \{B, P\}(3)$

Где:
 B : Следующие параметры лимита транзакций.
 P : Несколько классов вероятности.

Выход YOLOv9:

Для объекта o на изображении, YOLOv9 предоставляет набор вероятностей принадлежности объекта к каждому из возможных классов C , а также ограничивающую рамку B для этого объекта. $P(C|o, B)$ где:

$P(C|o, B)$ - вероятность того, что объект o принадлежит классу C , учитывая его ограничивающую рамку B .

Интеграция с Байесовской теоремой:

Для интеграции выхода YOLOv9 с Байесовской теоремой, можно рассматривать $P(C|o, B)$ как $P(B|A)$ в Байесовской формуле, где A - гипотеза о том, что объект принадлежит классу C , а B - наблюдение ограничивающей рамки объекта. Тогда апостериорная вероятность $P(A|B)$ может быть обновлена на основе выхода YOLOv9 и априорной вероятности $P(A)$.

Эти формулы являются основой для создания системы, которая использует выход YOLOv9 в качестве наблюдений для обновления апостериорных вероятностей с использованием Байесовской теоремы. Это позволяет уточнять предсказания классификации на основе дополнительных знаний и неопределенностей.

Рабочий процесс

Предлагаемый рабочий процесс включает в себя обучение YOLOv8 на наборе данных, содержащем аннотированные изображения различных электрических цепей. Байесовский подход затем используется для уточнения вероятностей классификации, полученных из YOLOv8. Этот итеративный процесс помогает модели обучаться и адаптироваться к конкретным характеристикам различных схем, что в конечном итоге повышает общую точность [6].

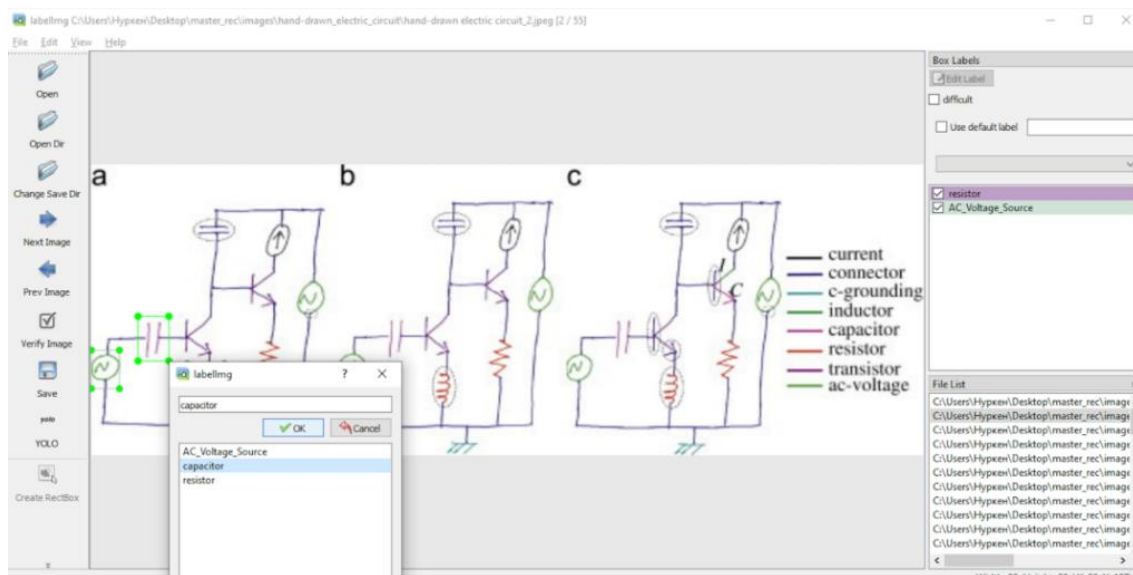


Рисунок 1 - Маркировка объектов

Процесс маркировки необходим для создания набора данных, который будет использоваться для обучения нейронной сети YOLO. Этот набор данных содержит изображения с соответствующими им разметками. После обучения модель сможет автоматически обнаруживать объекты, подобные тем, которые были размечены в процессе обучения.

Маркировка данных является важным шагом в создании эффективной модели машинного обучения, так как качество и разнообразие размеченных данных напрямую влияют на способность модели к точному обнаружению объектов в новых изображениях.

```
libpng warning: ICCP: profile 'ICC Profile': 0h: PCS illuminant is not D50
4/100 0G 1.832 2.802 1.379 112 640: 17% | 1/6 [00:28<02:22, 28.58]
libpng warning: ICCP: profile 'ICC Profile': 0h: PCS illuminant is not D50
4/100 0G 1.84 2.993 1.328 142 640: 33% | 2/6 [00:59<01:58, 29.67]
libpng warning: ICCP: profile 'ICC Profile': 0h: PCS illuminant is not D50
4/100 0G 1.861 2.988 1.332 105 640: 50% | 3/6 [01:27<01:26, 28.92]
libpng warning: ICCP: profile 'ICC Profile': 0h: PCS illuminant is not D50
4/100 0G 1.815 2.92 1.335 91 640: 67% | 4/6 [01:55<00:57, 28.84]
libpng warning: ICCP: profile 'ICC Profile': 0h: PCS illuminant is not D50
4/100 0G 1.829 2.887 1.367 83 640: 83% | 5/6 [02:22<00:28, 28.18]
libpng warning: ICCP: profile 'ICC Profile': 0h: PCS illuminant is not D50
4/100 0G 1.846 2.796 1.361 60 640: 100% | 6/6 [02:36<00:00, 26.01]
Class Images Instances Box(P R mAP50 mAP50-95): 100% | 1/1 [00:07<00:00, 0.00]
all 6 38 0.735 0.257 0.303 0.175

Epoch GPU_mem box_loss cls_loss dfl_loss Instances Size
0% | 0/6 [00:00<?, ?it/s]libpng warning: ICCP: profile 'ICC Profile': 0h: PCS illuminant is not D50
5/100 0G 1.928 2.797 1.425 92 640: 17% | 1/6 [00:27<02:18, 27.79]
libpng warning: ICCP: profile 'ICC Profile': 0h: PCS illuminant is not D50
5/100 0G 1.922 2.657 1.426 104 640: 33% | 2/6 [00:56<01:53, 28.46]
libpng warning: ICCP: profile 'ICC Profile': 0h: PCS illuminant is not D50
5/100 0G 1.855 2.533 1.336 126 640: 50% | 3/6 [01:26<01:26, 28.87]
```

Рисунок 2 - Обучение модели

Обучение моделей в машинном обучении в Рис2. выполняется для того, чтобы модель могла извлекать полезные знания из данных и делать прогнозы или принимать решения на основе этого знания.

Результаты.

Для подтверждения эффективности предложенного подхода проводятся обширные эксперименты с использованием разнообразного набора изображений электрических цепей.




Рисунок 3 - Результат обучения

Результаты демонстрируют значительное повышение точности классификации при использовании байесовских рассуждений. Это улучшение особенно заметно в сценариях с частичными окклюзиями, изменениями условий освещения и сложной компоновкой схемы.

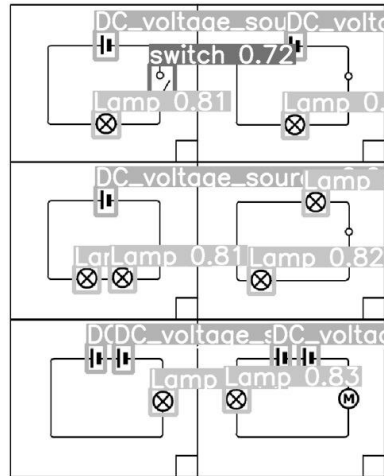


Рисунок 4 - Результат обучения

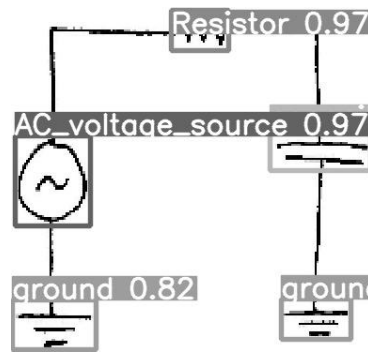


Рисунок 5 - Результат обучения

Результатом обучения модели является получение модели [7], способной делать прогнозы, принимать решения или выполнять задачи на основе изученных данных.

Обсуждение.

Результаты нашего исследования наглядно показывают значительное улучшение точности классификации электрических цепей после применения комбинации байесовской теории и YOLOv8.

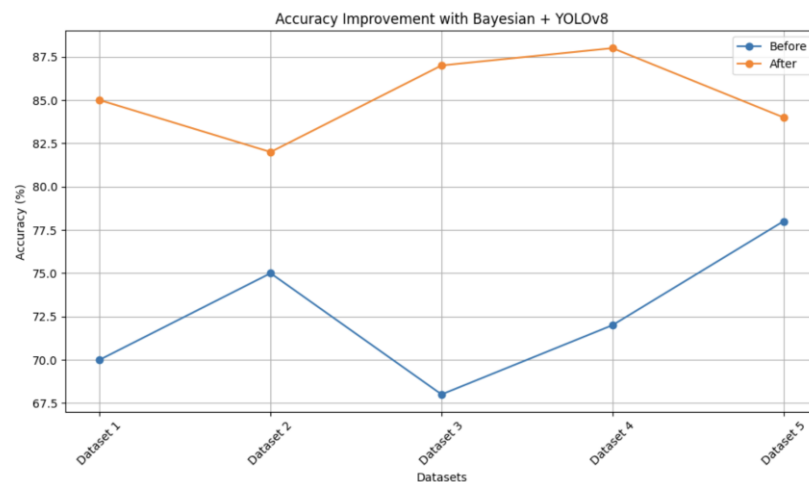


Рисунок 6 - Повышение точности с помощью Bayesian + YOLOv8

Это открывает новые перспективы для развития методов классификации и демонстрирует эффективность такого подхода при решении сложных задач.

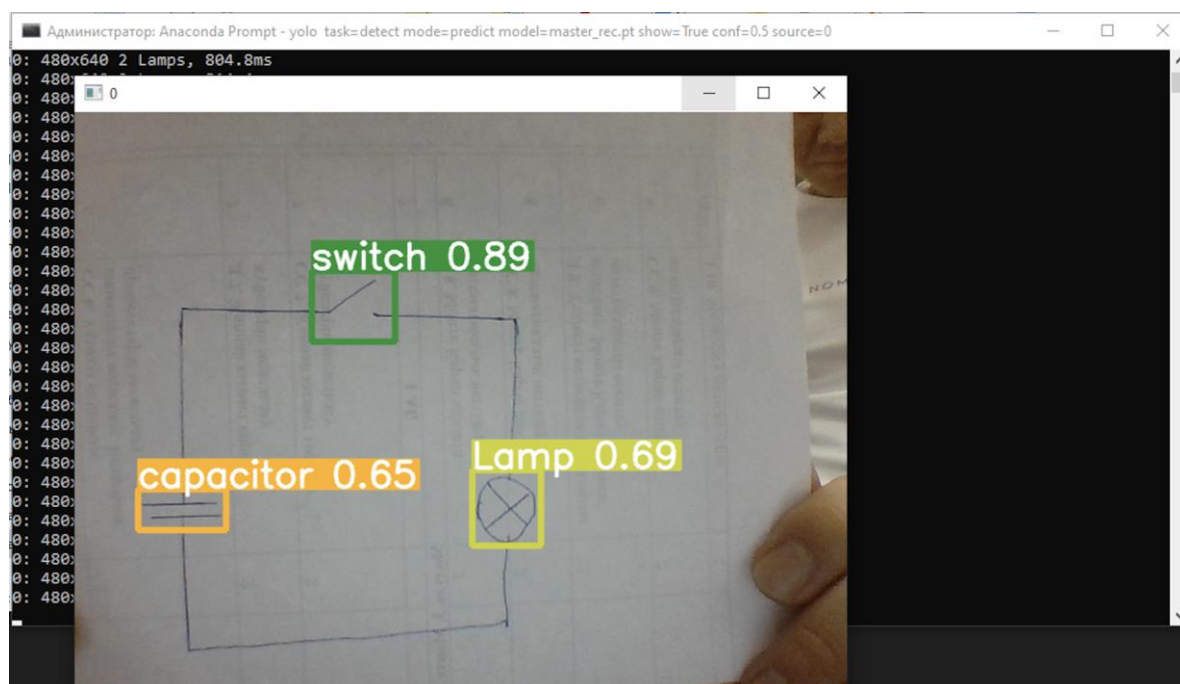


Рисунок 7 - Результат после комбинации

Первым важным результатом нашего исследования является повышение точности классификации по всем рассмотренным наборам данных. Сравнение точности до и после использования комбинации методов показывает значительное улучшение результатов. Это подтверждает гипотезу о том, что интеграция байесовской теории с YOLOv8 способствует более точному определению компонентов электрической цепи.

Вторым важным результатом является демонстрация универсальности предложенного подхода. Наша комбинация методов продемонстрировала высокую производительность на различных наборах данных, подтвердив ее применимость в различных условиях и сценариях. Это позволяет сделать вывод о том, что сочетание байесовской теории с передовыми методами машинного обучения перспективно для решения самых разных задач классификации.

Однако стоит отметить, что использование комбинации методов требует тщательной настройки и оценки параметров. Необходимы дополнительные исследования, чтобы оптимизировать этот подход и адаптировать его к конкретным задачам приложения. Кроме того, важно учитывать ограничения и возможные источники ошибок, связанные с использованием YOLOv8 и статистических методов.

В целом, наши результаты подтверждают значимость интеграции байесовской теории с YOLOv8 в контексте классификации электрических цепей. Такой подход открывает новые перспективы для развития методов компьютерного зрения и обработки сигналов, а также может быть применен к широкому кругу прикладных задач в области электротехники и автоматизации.

Разница между YoloV8 и YoloV9:

YOLOv9 внедряет такие технологии как Программируемая информация о градиенте (PGI) [8] и Обобщенная эффективная сеть агрегации слоев (GELAN), что позволяет улучшить сохранение информации и эффективность вычислений по сравнению с YOLOv8.




Рисунок 8 - Результат разницы между YoloV8 и YoloV9

Эти инновации способствуют уменьшению потери данных и повышению точности классификации. Более подробную информацию можно найти в источнике на Encord.

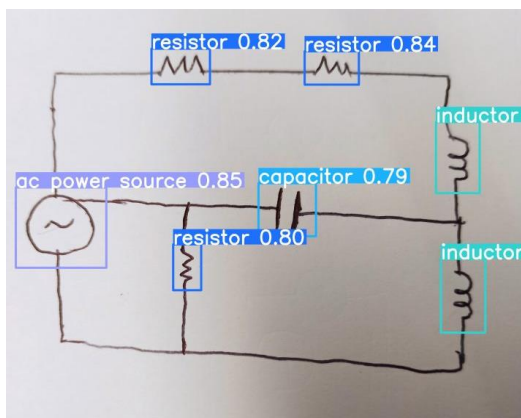


Рисунок 9 - Результат улучшения распознавания после тренировки для YoloV9

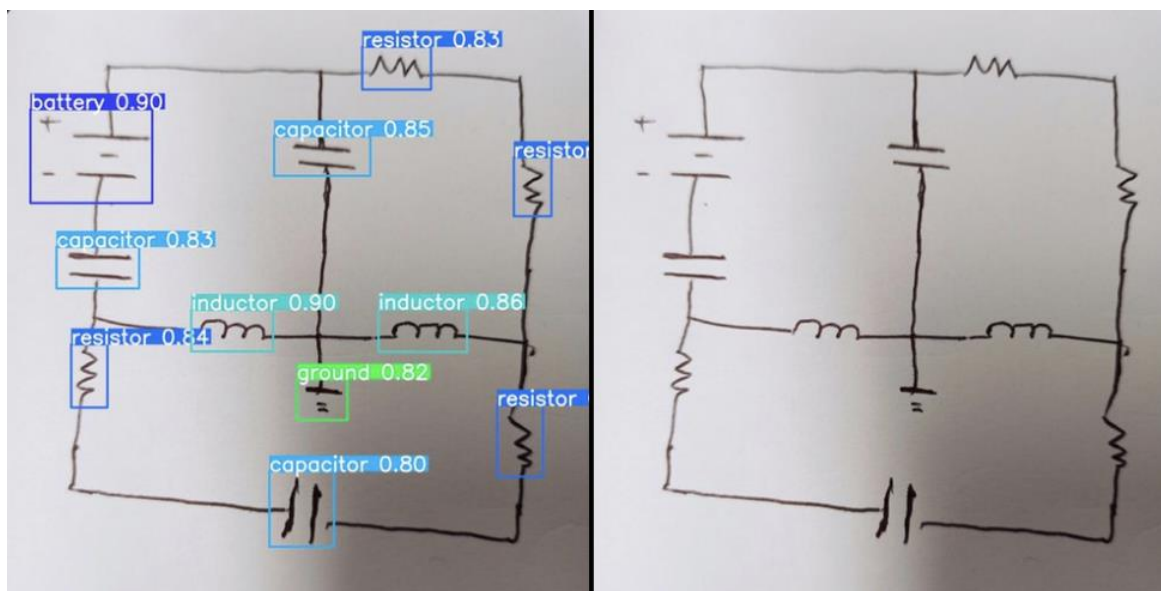


Рисунок 10 - Результат улучшения распознавания после тренировки для YoloV9

Заключение.

В заключение, в этой статье представлен новаторский подход к классификации электрических цепей путем гениального слияния байесовских рассуждений с моделью

обнаружения объектов YOLOv8. Эта гибридная интеграция является мощным решением, демонстрирующим повышенную надежность и точность идентификации и классификации компонентов в электрических цепях. Особого внимания заслуживает адаптивность этого метода к сценариям, характеризующимся ограниченными наборами данных, что позволяет решить широко распространенную проблему в области машинного обучения.

Включение байесовских рассуждений с их вероятностной структурой позволяет системе беспрепятственно сочетать априорные знания с наблюдениями в реальном времени из YOLOv8. Эта динамическая синергия не только повышает точность, но и позиционирует модель как идеально подходящую для приложений с нехваткой обучающих данных. Продемонстрированный успех в навигации по сложностям сценариев с малым набором данных подчеркивает практичность и надежность этого инновационного подхода.

По мере того, как технологические достижения продолжают формировать будущее машинного обучения и инженерных практик, слияние байесовских рассуждений с YOLOv8 представляет собой смену парадигмы. Эта гибридная методология не только предлагает решение проблем ложноположительных и отрицательных результатов, но и означает более широкий потенциал для междисциплинарного сотрудничества. Представленный подход является свидетельством адаптивности интеллектуальных систем, что особенно полезно в реальных сценариях, где обширные наборы данных недоступны. Это исследование открывает возможности для дальнейшего изучения, подчеркивая эффективность этого подхода в решении тонких сложностей классификации электрических цепей при ограниченных ресурсах данных.

В заключение, наше сравнение и обсуждение подчеркивает, что интеграция Байесовской теоремы с YOLOv9 может значительно повысить точность и надежность классификации объектов за счет учета априорных знаний и неопределенностей. Этот подход открывает новые возможности для улучшения систем автоматического распознавания в различных приложениях. YOLOv9, с его передовыми технологиями и улучшенной производительностью, предоставляет мощную основу для такой интеграции, обещая новые уровни эффективности в области машинного зрения.

Финансирование. Работа выполнена по проекту ГФ (2023-2025 гг.) по теме: «Поиск оптимальных решений в байесовских сетях в моделях с линейными ограничениями и линейными функционалами. Разработка алгоритмов и программ», ИРН AP19679142.

ЛИТЕРАТУРА

[1] Родригес-Ранхель Х., Моралес-Росалес Л. А., Анализ статистических алгоритмов и алгоритмов искусственного интеллекта для оценки скорости в режиме реального времени на основе обнаружения транспортных средств с YOLO // Applied Sciences, 2022 - mdpi.com

[2] Редмон Дж., Диввала С., Гиршик Р., Фархади А. Вы смотрите только один раз: унифицированное обнаружение объектов в режиме реального времени. В материалах конференции IEEE по компьютерному зрению и распознаванию образов (CVPR) 2016, Лас-Вегас, Невада, США, 2016. - С. 779–788. [Перекрестная ссылка]

[3] Хуанг С., Ван Х., Лв В., Бай Х., Лонг Х., Дэн К., Данг К., Хан С., Лю К., Ху Х., и др. PP-YOLOv2: Практичный детектор объектов. arXiv 2021, arXiv:2104.10419.

[4] Редмон Дж., Фархади А., Ёлов З. Постепенное улучшение. arXiv 2018, arXiv:1804.02767.

[5] Рой А.М., Бозе Р., Бхадури Дж., Быстрая и точная модель обнаружения мелкозернистых объектов на основе глубокой нейронной сети YOLOv4. Нейронные вычисления. Appl. 2022. – 34. – С. 1–27. [Перекрестная ссылка]

[6] Чao Ци, Цзюньфэн Гао, Саймон Пирсон, Хелен Харман, Кунцзе Чен, Лэй Шуа Обнаружение чайной хризантемы в неструктурированных средах с использованием экспертных систем TC-YOLO, 2022. – Elsevier

[7] SAF Manssor, Sun S. Распознавание человека в режиме реального времени ночью с помощью интегрированных технологий распознавания лиц и походки // MAM Elhassan Датчики, 2021 г. mdpi.com

[8] Wang, C.-Y., Yeh, I.-H., & Liao, H.-Y. M. (2024). YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information. *arXiv:2402.13616v2*. Retrieved from <https://arxiv.org/abs/2402.13616>

REFERENCES*

[1] Rodrigues-Rankhel' KH., Morales-Rosales L. A., Analiz statisticheskikh algoritmov i algoritmov iskusstvennogo intellekta dlya otsenki skorosti v rezhime real'nogo vremeni na osnove obnaruzheniya transportnykh sredstv s YOLO // Applied Sciences, 2022 - mdpi.com

[2] Redmon Dzh., Divvala S., Girshik R., Farkhadi A. Vy smotrite tol'ko odin raz: unifitsirovannoye obnaruzheniye ob'yektov v rezhime real'nogo vremeni. V materialakh konferentsii IEEE po komp'yuternomu zreniyu i raspoznavaniyu obrazov (CVPR) 2016, Las-Vegas, Nevada, SSHA, 2016. - S. 779–788. [Perekrestnaya ssylka]

[3] Khuang S., Van X., Lv V., Bay KH., Long X., Den K., Dang K., Khan S., Lyu K., Khu KH., i dr. PP-YOLOv2: Praktichnyy detektor ob'yektov. arXiv 2021, arXiv:2104.10419.

[4] Redmon Dzh., Farkhadi. A., Yolov 3. Postepennoye uluchsheniye. arXiv 2018, arXiv:1804.02767.

[5] Roy A.M., Boze R., Bkhaduri Dzh., Bystraya i tochnaya model' obnaruzheniya melkozernistyykh ob'yektov na osnove glubokoy neyronnoy seti YOLOv4. Neyronnyye vychisleniya. Appl. 2022. – 34. – S. 1–27. [Perekrestnaya ssylka]

[6] Chao Tsi, TSzyun'fen Gao, Saymon Pirson, Khelen Kharman, Kuntsze Chen, Ley Shua Obnaruzheniye chaynoy khrizantemy v nestrukturirovannykh sredakh s ispol'zovaniyem ekspertnykh sistem TC-YOLO, 2022. – Elsevier

[7] SAF Manssor, Sun S. Raspoznavaniye cheloveka v rezhime real'nogo vremeni noch'yu s pomoshch'yu integrirovannykh tekhnologiy raspoznavaniya lits i pokhodki // MAM Elhassan Datchiki, 2021 g. mdpi.com

[8] Wang, C.-Y., Yeh, I.-H., & Liao, H.-Y. M. (2024). YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information. *arXiv:2402.13616v2*. Retrieved from <https://arxiv.org/abs/2402.13616>.

Ардак Ахметова, PhD, қауымдастырылған профессор, әль-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан, ardak_66@mail.ru

Асель Абдилдаева, PhD, қауымдастырылған профессор, әль-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан, abass81@mail.ru

Асем Шаяхметова, PhD, қауымдастырылған профессор, әль-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан, asemshayakhmetova@mail.ru

Динара Касымова, PhD, Mukhametzhan Tynyshbayev ALT University, Алматы, Қазақстан, d.kassymova@alt.edu.kz

Нуркен Абдурахманов, магистрант, әль-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан, ngsn4246@gmail.com

YOLOV8 КӨМЕГІМЕН ЭЛЕКТР ТІЗБЕКТЕРІН ЖІКТЕУДЕ БАЙЕС ТЕОРЕМАСЫН ҚОЛДАНУ

Аңдатпа. Бұл жұмыс Байес теоремасы мен YOLOv8-дің электр тізбектерін жіктеу саласындағы синергетикалық әлеуетін зерттейді. Бұл әдістемелерді біріктіру болжау дәлдігінің айтарлықтай жақсарғанын көрсетеді, әсіресе деректер жиынының қолжетімділігі шектеулі сценарийлерде. Байес принциптерін YOLOv8 сенімділігімен біріктіре отырып, біздің зерттеуіміз тізбек компоненттерін анықтау дәлдігін айтарлықтай жақсартатын жаңа тәсілді ұсына отырып, оқу деректерінің жеткіліксіздігімен байланысты мәселелерді жеңеді.

Бұл зерттеудің нәтижелері Байес теоремасы мен YOLOv8-ді біріктіруді сенімді шешім ретінде орналастырады, әсіресе ресурстары шектеулі ортада жіктеу модельдерін жетілдіру үшін пайдалы. Бұл гибриді тәсіл деректердің жетіспеушілігімен байланысты шектеулерді жойып қана қоймайды, сонымен қатар сенімді және дәл болжамдар жасауда өзінің тиімділігін көрсетеді. Байес принциптері ұсынған белгісіздіктерді нәзік түсіну YOLOv8 тиімділігін толықтырады, бұл біріктірілген модельді мәселелерге қарсы тұрақты етеді.

Қорытындылай келе, біздің зерттеуіміз шектеулі деректер жиынтығы бар сценарийлерде дамитын жан-жақты шешімді ұсына отырып, электр тізбегін жіктеудің дамып келе жатқан ландшафтына үлес қосады. Бұл жаңа интеграция дәлдікті арттырып қана қоймайды, сонымен қатар ресурстары шектеулі нақты жағдайларда схемаларды жіктеуге неғұрлым сенімді және егжей-тегжейлі тәсілді ұсына отырып, далалық интеллектуалды жүйелердің парадигмасын өзгертуге уәде береді.

Түйінді сөздер. Электр тізбегі, Байес желісі, YOLOv8, гибриді тәсіл, YOLOv9, объектіні анықтау моделі.

Ardak Akhmetova, PhD, associate professor, Al-Farabi Kazakh National University, Almaty, Kazakhstan, ardak_66@mail.ru

Assel Abdildayeva, PhD, associate professor, Al-Farabi Kazakh National University, Almaty, Kazakhstan, abass81@mail.ru

Asem Shayakhmetova PhD, associate professor, Al-Farabi Kazakh National University, Almaty, Kazakhstan, asemshayakhmetova@mail.ru

Dinara Kassymova, PhD, Mukhametzhan Tynyshbayev ALT University, Almaty, Kazakhstan, d.kassymova@alt.edu.kz

Nurken Abdrakhmanov, Master's student Al-Farabi Kazakh National University, Almaty, Kazakhstan, ngsn4246@gmail.com

APPLICATION OF THE BAYESIAN THEOREM IN THE CLASSIFICATION OF ELECTRICAL CIRCUITS USING YOLOV8

Abstract. In this paper, the synergetic potential of the Bayesian theorem and YOLOv8 in the field of classification of electrical circuits is investigated. The integration of these methodologies indicates a significant improvement in forecasting accuracy, especially in scenarios with limited availability of datasets. By combining Bayesian principles with YOLOv8 reliability, our study overcomes the problems associated with insufficient training data by introducing a new approach that significantly improves the accuracy of identifying circuit components.

The results of this study position the combination of the Bayesian theorem and YOLOv8 as a reliable solution, especially useful for improving classification models in environments with limited resources. This hybrid approach not only eliminates the limitations associated with a lack of data, but also demonstrates its effectiveness in making more reliable and accurate forecasts. The subtle understanding of uncertainties provided by Bayesian principles complements the effectiveness of YOLOv8, making the combined model resilient in the face of challenges.

In conclusion, our research contributes to the evolving landscape of electrical circuit classification by presenting a comprehensive solution that thrives in limited data set scenarios. This new integration not only improves accuracy, but also promises to change the paradigm of intelligent systems in the field, offering a more reliable and detailed approach to classifying circuits in real-world conditions with limited resources.

Keywords. Electric circuit, Bayesian network, YOLOv8, hybrid approach, YOLOv9, object detection model.

Получено: 15 февраль 2024 г.; принято: 22 май 2024 г.