

Исследование эффективности машинного обучения в мониторинге сигнальной точки

Research on the efficiency of machine learning in signal point monitoring

Канарский В.А.¹
Kanarsky V.A.¹

¹Дальневосточный государственный университет путей сообщения, Хабаровск, Российская Федерация
¹Far Eastern State University of Railway Transport, Khabarovsk, Russian Federation

jizzierose@yahoo.com



Канарский В.А.

Резюме. Устройства железнодорожной автоматики и телемеханики существуют уже достаточно давно, многие системы, будучи в эксплуатации, считаются устаревшими. При этом модернизация не успевает охватить все протяженные участки российских железных дорог. Внедрение систем мониторинга с начала 2000-х годов привело к более комфортному техническому обслуживанию громоздких систем сигнализации, централизации и блокировки СЦБ, сокращению времени поиска отказа в них. Во втором десятилетии XXI в. началось активное внедрение информационных технологий в разные сферы жизни, включая промышленность, однако в более медленном темпе, особенно на железнодорожном транспорте. Одной из инноваций стало появление ИИ – искусственного интеллекта, что на производстве привело к более прогрессивному поддержанию работоспособности устройств за счет прогнозирования предотказных состояний. В этом случае появляется возможность оповещения технического персонала интеллектуальной системой, обрабатывающей значимые параметры наблюдаемого объекта или процесса, тем самым заменяя ручной мониторинг, требующий времени и профессионального опыта. **Цель.** Предложить использование методов искусственного интеллекта в устройствах железнодорожной автоматики на базе действующих систем технической диагностики и мониторинга. **Методы.** Для создания, обработки и визуализации данных применяются методы машинного обучения без учителя на базе языка программирования Python. **Результаты.** Получен отклик моделей ИИ на аномальные изменения во временных характеристиках формирователей кода. **Заключение.** Программа с поддержкой ИИ может являться ядром обработки данных мониторинга устройств СЦБ и требует тщательного исследования в прогнозировании их известных сбоев на сигнальной точке.

Abstract. Railway signalling automation devices have been around for quite some time. Many systems in operation are considered obsolete. At the same time, modernization does not cover the whole Russian railway system. The deployment of monitoring systems since the beginning of the 2000s made the maintenance of bulky signalling systems more comfortable, reduced the time of fault detection. The second decade of the 21-st century saw a widespread deployment of information technologies in various spheres of life, including industry, yet at a slower pace, especially in railway transportation. One of the innovations was the emergence of the artificial intelligence, which enabled more progressive maintenance of devices through prediction of pre-failure states. The latter allows notification of technical personnel by an intelligent system that processes significant parameters of the observed facility or process, thereby replacing manual monitoring that requires time and professional experience. **Aim.** To suggest the use of artificial intelligence-based methods in railway signalling devices based on the existing technical diagnostics and monitoring systems. **Methods.** Python-based unsupervised machine learning methods are used to create, process and visualise data. **Results.** The AI models showed a reaction to anomalous changes in the temporal characteristics of code generators. **Conclusion.** An AI-enabled program can serve as the core for processing data related to the monitoring of railway signalling devices and requires careful research in predicting their known failures at the signal point.

Ключевые слова: железнодорожная автоматика и телемеханика, автоблокировка, системы мониторинга, отказ, искусственный интеллект, машинное обучение без учителя, предиктивное обслуживание.

Keywords: railway signalling, automatic block, monitoring systems, failure, artificial intelligence, unsupervised machine learning, predictive maintenance

Для цитирования: Канарский В.А. Исследование эффективности машинного обучения в мониторинге сигнальной точки// *Надежность*. 2023. №1. С. 38-44. <https://doi.org/10.21683/1729-2646-2023-23-1-38-44>

For citation: Kanarsky V.A. Research on the efficiency of machine learning in signal point monitoring. *Dependability* 2023; 1:38-44. <https://doi.org/10.21683/1729-2646-2023-23-1-38-44>

Поступила 20.11.2022/ **После доработки** 05.12.2022/ **К печати** 14.03.2023

Received on: 20.11.2022/ **Revised on:** 05.12.2022/ **For printing:** 14.03.2023

Системы железнодорожной автоматики и телемеханики (ЖАТ) предназначены для автоматизации перевозочного процесса, обеспечения безопасности движения поездов, увеличению пропускной способности участка, повышению производительности труда сотрудников. Исторически их внедрение и развитие началось в конце XIX века. Использование электрического тока привело к появлению различных типов систем, обеспечивающих как станции (электрическая централизация), так и перегоны (системы интервального регулирования движения поездов, СИРДП). Фундаментальным элементом первых электрических систем ЖАТ, обеспечивающим логические взаимозависимости, стало реле. И станционные, и перегонные релейные системы получили повсеместное распространение на территории России. После третьей промышленной революции с приходом программируемых контроллеров и микропроцессоров, а также анализа очевидных недостатков релейных систем с точки зрения трудовых и эксплуатационных расходов, отказоустойчивости и надежности, стали проектировать микропроцессорные системы, обладающие рядом весомых преимуществ. Однако модернизация объектов железнодорожной инфраструктуры требует значительных денежных затрат, особенно если учитывать протяженность российских железных дорог. Поэтому даже спустя более полувека остается еще много участков, где действуют устаревшие системы.

Решению проблемы технического обслуживания этих комплексов во многом способствовало внедрение *систем технической диагностики и мониторинга* (СТДМ). С помощью датчиков, контроллеров и измерительных модулей, устанавливаемых поверх действующих систем ЖАТ, удалось перейти от традиционного планово-предупредительного ремонта к техническому обслуживанию (ТО) по состоянию. Снимаемая информация с релейных контактов, источников электропитания и др. передается на автоматизированное рабочее место электромеханика – компьютер с предустановленным специализированным программным обеспечением, в основу которого положена *экспертная система*, содержащая справочную информацию о номинальных параметрах, их допустимых пределах, функционал информирования об отказах, архивы данных и т.п. По получаемой в режиме on-line информации персоналом принимается решение о проведении технического обслуживания. В настоящее время такой вид ТО является наиболее предпочтительным.

Переход к индустрии 4.0 повлек за собой массовое внедрение информационных технологий в производство и распространение *искусственного интеллекта* (ИИ), что

привело к возможности *предиктивного обслуживания*. В отличие от планово-предупредительного ремонта и ремонта по техническому состоянию предиктивное (прогнозное) обслуживание позволяет выполнять техническое обслуживание и ремонт не по заранее запланированной программе, а когда в нем возникает необходимость [1, с. 50]. Это реализуется посредством определения аномального поведения устройств, которое может свидетельствовать об их предотказном состоянии. Одним из важнейших условий применения данной концепции является сбор и передача огромного потока данных в интеллектуальную систему для их последующей обработки и интерпретации. Практически данное утверждение решается включением технологий промышленного Интернета вещей (Industrial Internet of Things, IIoT) в системы управления и созданием программного обеспечения с поддержкой ИИ.

Для систем железнодорожной автоматики сбор и обработка диагностических параметров уже были реализованы в системах ТДМ и не являются чем-то новым. К тому же специфика российской железнодорожной инфраструктуры требует применения особых датчиков, способных работать в достаточно агрессивной динамической среде (движение поезда) и жестких климатических условиях (районы Крайнего Севера). Данные особенности были учтены российскими компаниями при создании таких диагностических систем, как:

- аппаратно-программный комплекс диспетчерского контроля АПК-ДК (ООО «КИТ»),
- система диагностики технических средств СДТС («Инфотекс АТ»),
- автоматизированная система диспетчерского контроля АСДК (ООО «Сектор») и др.

Однако до сих пор ядром обработки и визуализации данных является экспертная система. Следуя современным тенденциям развития и внедрения искусственного интеллекта, можно найти ему применение и на железной дороге, поскольку выполняется, как минимум, одно из вышеупомянутых условий – получение большого объема диагностической информации об объекте в режиме реального времени. Таким образом, технически модернизация систем диагностики на железной дороге может быть сведена к совершенствованию применяемого программного обеспечения.

Объектом исследования, теоретически, может выступать любое устройство, их комплекс или полноценная система, над которыми осуществляется мониторинг. Возвращаясь к рассмотрению систем автоматики на перегонах и исходя из требований к пропускной способности участка, его протяженности, экономической

Табл. 1. Характеристики КППТ различных типов

Код	Тип КППТ											
	КППТШ – 515						КППТШ – 715					
	Длительность, с											
	1 – й имп.	1 – й инт.	2 – й имп.	2 – й инт.	3 – й имп.	3 – й инт.	1 – й имп.	1 – й инт.	2 – й имп.	2 – й инт.	3 – й имп.	3 – й инт.
З	0,35	0,12	0,22	0,12	0,22	0,57	0,35	0,12	0,24	0,12	0,24	0,79
Ж	0,38	0,12	0,38	0,72	-	-	0,35	0,12	0,66	0,79	-	-
КЖ	0,23	0,57	0,23	0,57	-	-	0,30	0,63	0,30	0,63	-	-

целесообразности, применяются различные виды систем ИРДП: электрожезловая, полуавтоблокировка и автоблокировка. Последняя является наиболее распространенным средством регулирования, так как на перегоне может находиться несколько поездов, а не один, и показания светофоров при движении по участку сменяются автоматически. Наиболее перспективной оказалась именно числовая кодовая автоблокировка (ЧКАБ), со второй половины XX века ее стали применять в качестве основной [2, с. 14].

Характерным для ЧКАБ является разделение перегона посредством изолирующих стыков на блок-участки (БУ), установка светофоров и релейных шкафов на их границах, оборудование каждого БУ рельсовыми цепями. При проектировании системы мониторинга для снятия диагностической информации контроллеры устанавливаются прямо в релейные шкафы и оттуда по выделенной физической паре в кабеле СЦБ передают диагностическую информацию на пост ЭЦ.

В данной работе объектом исследования стала информация, получаемая от контроллеров СДТС-АПС с одной сигнальной точки (СТ). Выбор данной системы мониторинга обоснован многообразием диагностируемых параметров: дискретные (состояние контактов реле), аналоговые (ток, напряжение, температура), временные характеристики формирователя кодов КППТШ и определение его типа¹.

В качестве инструмента для анализа данных выбраны алгоритмы машинного обучения на основе библиотеки Scikit-learn языка программирования Python. При помощи библиотек NumPy и Pandas искусственно сгенерирован пакет данных (датасет), содержащий необходимый перечень признаков, который использован для обучения моделей и решения задачи предиктивного обслуживания в устройствах железнодорожной автоматики

Моделирование кодовых посылок

СТ (рис. 1) характеризуется множеством дискретных и аналоговых сигналов, коррелированных между собой. К примеру, нарушение основного ПХ-ОХ и резервного РПХ-РОХ электропитания приведет к неправильной работе схем автоблокировки, либо к полному их отклю-

чению. От сигнального трансформатора СОБС в схемы дешифраторной ячейки (ДЯ) подается полюс питания СХ16. Через выпрямительный мост оно преобразуется в постоянное напряжение П-М, которое заряжает конденсаторы в блоке БК-ДЯ, питает реле в блоках БИ-ДЯ и БС-ДЯ, сигнальные реле З и Ж. Следуя только по одной этой цепочке можно столкнуться с множеством элементов, отказ которых приведет к неправильной работе СТ. К примеру, частыми поломками являются потеря емкости конденсаторов в БК-ДЯ, обрыв выпрямителя в БС-ДЯ, неисправность кодового путевого трансмиттера КППТШ².

Для исследования эффективности алгоритмов машинного обучения будет использован набор данных временных характеристик генерируемого кода от КППТШ-715 и принимаемого кода импульсным реле ИВГ от КППТШ-515 из соседней рельсовой цепи. КППТШ разных типов имеют различную длительность импульсов и пауз каждого кода и устанавливаются поочередно для исключения срабатывания сигнальных реле от кодов смежной рельсовой цепи при сгоне стыков.

Коды бывают трех типов: З, Ж и КЖ. Они отличаются количеством импульсов (имп.) и интервалов (инт.), их длительностью в одном цикле. В таблице 1 приведены временные параметры для КППТШ-515 и КППТШ-715 [3, с. 774]:

Импульсное реле работает при поступлении кода из своей рельсовой цепи и передает его в ДЯ, которая, в свою очередь, при условии «нормальности» этого кода, включает одно или оба сигнальных реле З и Ж. Контакты последних формируют цепи для передачи другого кода в соседнюю рельсовую цепь и так далее.

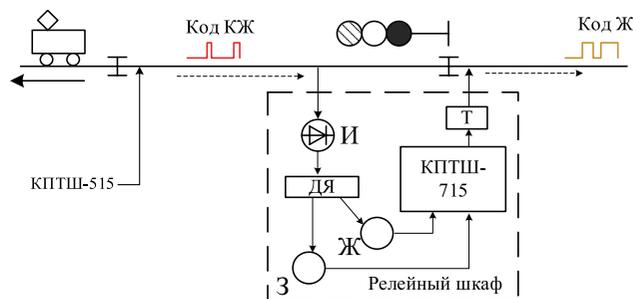


Рис. 1. Функциональная схема приема и передачи кода

¹ Из типовых материалов для проектирования системы диагностики технических средств железнодорожной автоматики и телемеханики на перегонах и станциях (СДТС-АПС, СДТС-ЭЦ). 411303-ТМП. Альбом 1. Пояснительная записка.

² Согласно сборнику методик и алгоритмов поиска и устранения неисправностей в устройствах СЦБ (2 редакция), утвержденным Центральной дирекцией инфраструктуры в 2015 году. URL: <http://scbiinfrastruktura.ru/wp-content/uploads/Sbornik-metodik-i-algoritmov-poiska-i-ustraneniya-neispravnostey-v-ustroystvah-STSB.pdf>

	1 имп. И	1 интерв. И	2 имп. И	2 интерв. И	3 имп. И	3 интерв. И	Реле Ж	Реле З	1 имп. Т	1 интерв. Т	2 имп. Т	2 интерв. Т	3 имп. Т	3 интерв. Т
1	0.352	0.116	0.207	0.116	0.214	0.573	1	1	0.346	0.110	0.254	0.125	0.256	0.787
50	0.348	0.113	0.217	0.114	0.219	0.568	1	1	0.342	0.131	0.263	0.133	0.244	0.787
100	0.000	0.000	0.000	0.000	0.000	0.000	0	0	0.307	0.630	0.313	0.631	0.000	0.000
150	0.000	0.000	0.000	0.000	0.000	0.000	0	0	0.279	0.620	0.298	0.642	0.000	0.000
200	0.230	0.574	0.238	0.583	0.000	0.000	1	0	0.341	0.108	0.675	0.801	0.000	0.000
250	0.223	0.558	0.233	0.573	0.000	0.000	1	0	0.348	0.120	0.659	0.791	0.000	0.000
300	0.381	0.112	0.382	0.720	0.000	0.000	1	1	0.344	0.109	0.246	0.124	0.252	0.798
350	0.383	0.121	0.386	0.719	0.000	0.000	1	1	0.351	0.113	0.242	0.118	0.250	0.803

Рис. 2. Сгенерированные данные сигнальной точки (показано 8 строк из 400), И – импульсное реле, Т – трансмиттер

Данный процесс зафиксирован в датасете на рис. 2 условно в четырех этапах.

1. Участок свободен – получаемый код З (Ж и З под током или «1»), генерируемый код З (от 0 до 99).

2. Участок занят подвижной единицей (ПЕ) – нет кода (Ж и З обесточены – «0»), генерируемый код КЖ (от 100 до 199).

3. Участок свободен, ПЕ заняла соседнюю РЦ – получаемый код КЖ, генерируемый код Ж (рисунок 1) (от 200 до 299).

4. Участок свободен, ПЕ заняла последующую РЦ, освободила соседнюю – получаемый код Ж, генерируемый З (от 300 до 399).

К сгенерированным значениям характеристик (табл. 1) в данных (рис. 2) добавлен белый шум для приближения к реальным показаниям, снимаемым системой мониторинга. Аномальное поведение устройств начинается тогда, когда изменчивость этих характеристик становится слишком большой, хотя в целом схема АБ может работать корректно еще какое-то время до возможного отказа. Именно это поведение должны зафиксировать алгоритмы машинного обучения и вовремя дать оповещение.

Обучение без учителя

Класс методов искусственного интеллекта, позволяющих обучать компьютер без явного программирования и прямых инструкций, называют машинным обучением¹. Традиционно его разделяют на обучение с учителем, без учителя, с частичным привлечением учителя и с подкреплением [4, с. 8].

Алгоритмы с учителем обучаются на размеченных выборках, т.е. должен быть в наличии массив признаков X и целевая переменная y , значение которой будут предсказаны \hat{y} . В основе предиктивного обслуживания лежит задача детектирования аномалий, и данные алгоритмы будут неэффективны, так как размеченных данных слишком мало, поскольку заранее предполагается, что аномалии редки. При этом они имеют слабое сходство с нормальными данными [4, с. 239], поэтому данная задача решается с помощью алгоритмов обучения без учителя и тогда потребуется лишь массив признаков X .

Помимо определения аномалий алгоритмы машинного обучения без учителя также решают задачи кла-

стеризации, поиска новизны, понижения размерности. Последний класс методов необходим для переноса сгенерированных данных (рис. 2) размерностью 400x14 в пространство более низкой размерности, например в 2D для визуализации и последующего анализа. Существуют алгоритмы линейного (*метод главных компонент*, от англ. *Principal Components Analysis, PCA*) и нелинейного выделения признаков (*t-Distributed Stochastic Neighbor Embedding, t-SNE*)². Первый при переносе в пространство низкой размерности старается сохранить глобальную структуру данных, теряя при этом лишь небольшое количество информации; второй, являясь подтипом обучения многообразию, способен разворачивать сложные «скрученные» наборы данных, сохраняя лишь локальную структуру [5]. Однако это приводит к тому, что t-SNE может отобразить несуществующие кластеры, поэтому он не рекомендован для последующей кластеризации, и в основном применяется для визуализации [6].

Перед определением подходящего алгоритма также нужно сделать важное замечание – структура данных мониторинга изначально уже имеет глобальные различия именно за счет состояний сигнальной точки при движении поезда. Обратив внимание на сгенерированные данные, можно заметить, что эти состояния размечены комбинациями из признаков «Реле Ж», «Реле З», импульсов и интервалов реле И (рис. 2). Равномерная аппроксимация и проекция многообразий (от англ. *Uniform Manifold Approximation and Projection, UMAP*) позволяет найти компромисс между глобальной и локальной структурой путем настройки гиперпараметров (параметров, позволяющие управлять процессом обучения): n -neighbours (количество соседей) и \min_dict (минимальное расстояние)³. На рисунке 3 представлены результаты понижения размерности с помощью PCA и UMAP:

Представление данных на обоих графиках рис. 3 отчетливо позволяет выделить 4 кластера точек, которые соответствуют состояниям рельсовой цепи (прием З, Ж, КЖ, отсутствие кода), описанным ранее в четырех этапах. Однако PCA возвращает плотно упакованные наборы данных. Возможность отследить внутрикластерные различия можно только по компонентам UMAP, что делает его более наглядным для будущих анализов.

² https://neerc.ifmo.ru/wiki/index.php?title=Уменьшение_размерности

³ Практический опыт использования представлен на сайте <https://habr.com/ru/post/651403/>

¹ <https://cloud.yandex.ru/blog/posts/2022/10/machine-learning>

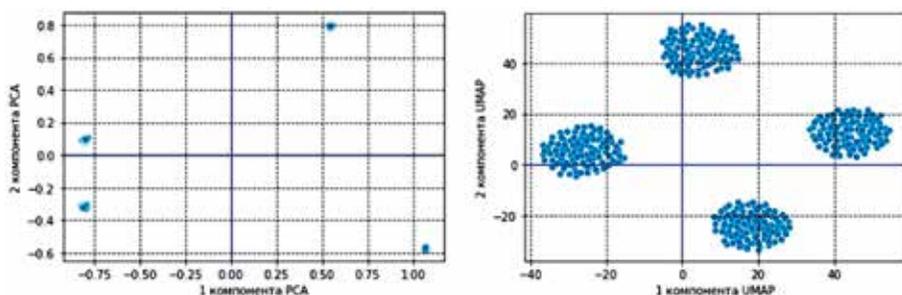


Рис. 3. Отображение на плоскости набора данных 400x14

Для последующей обработки этих данных лучше всего подойдут алгоритмы кластеризации, которые, помимо всего прочего, должны обнаружить выбросы. В реальности также учитывается объем исследуемой выборки, который наряду с вычислительной сложностью алгоритма, влияет на время его исполнения. Учитывая эти особенности и объем набора данных отличным решением станет основанная на плотности пространственная кластеризация для приложений с шумами (от англ. *Density-based spatial clustering of applications with noise, DBSCAN*) [7].

Распознавание аномальных данных

Для того чтобы оценить эффективность моделей машинного обучения, в данных (рис. 2) следует внести аномальные экземпляры. Временные характеристики КППШ (табл. 1) подобраны таким образом, чтобы во время импульсов и пауз включались реле-счетчики (1 и 1А). Они, согласно схеме ДЯ [3, с. 885], переключают сигнальные реле на питание от конденсаторов, которые заряжаются в начальный момент времени (С1, С2 для питания реле Ж в начале первого импульса, С3 для питания реле З в начале второго импульса, если принимаемый код Ж или З). Эти конденсаторы во время длинного интервала каждого из кодов удерживают сигнальные реле под током до появления следующего импульса. Однако если изначально время интервалов будет увеличено, то реле счетчики дольше будут включены, и конденсаторам может не хватить энергии удерживать сигнальные реле не ниже напряжения отпадания якоря из-за того, что общее время кодовой посылки увеличилось. Чаще всего это происходит из-за пониженного напряжения на трансмиттерном реле ТШ (дольше притягивается его якорь). В этом случае электромеханики СЦБ переключками на ТШ регулируют напряжение, которое влияет на время короткого интервала передаваемого кода, и на практике удерживают его от 0,12 до 0,18 с, для предотвращения сбоя. В действительности граница этой проблемной ситуации гораздо сложнее, так как в расчет нужно брать еще очень огромное количество других параметров (напряжение на ТШ, питание КППШ, основное питание ПХ-ОХ и многое другое). Однако реализовать постепенное увеличение интервала в наборе данных достаточно просто. Помехи искусственно внесены в экземпляры с 295 по 304, в результате чего наблюдалась следующая картина (рис. 4).

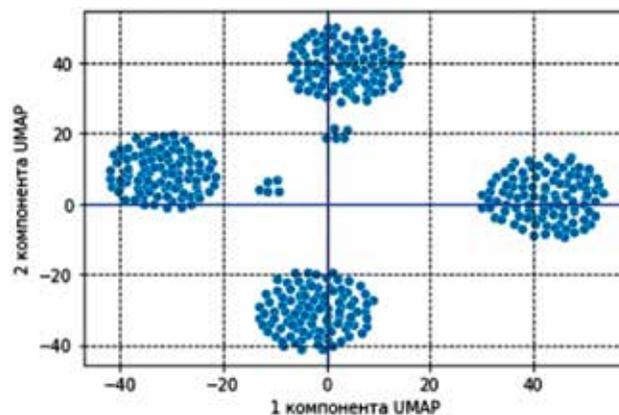


Рис. 4. Отображение на плоскости набора данных, содержащих аномальные экземпляры

Перед началом моделирования алгоритмом DBSCAN требуется настроить его гиперпараметры [7]. Они должны быть подобраны таким образом, чтобы лучшим результатом являлось детектирование только истинных аномалий, т.е. сгенерированных и заранее внесенных в датасет. Плохим в этом случае будет обнаружение либо не всех аномалий, либо дача ложно положительного результата. Данные утверждения оцениваются метриками *precision* (точность) и *recall* (полнота) в задачах классификации. Точность показывает долю истинных аномалий из всех выявленных, полнота демонстрирует способность обнаруживать их в принципе. На рис. 5 представлена зависимость этих метрик от значения гиперпараметра «eps» (радиуса круга для проверки плотности точек) алгоритма DBSCAN:

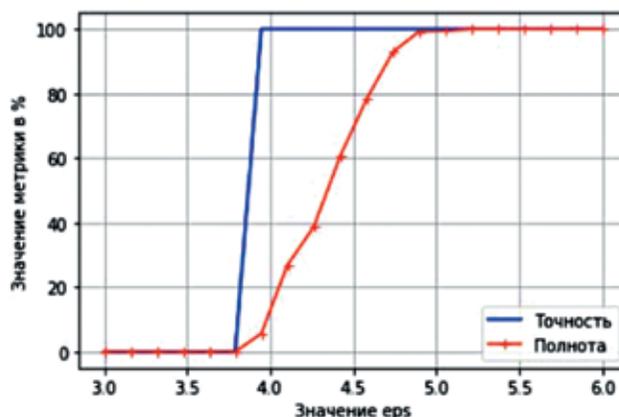
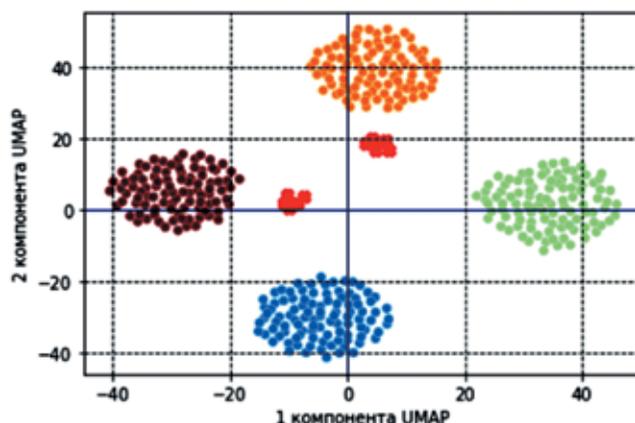


Рис. 5. Графики зависимостей $precision = f(eps)$ и $recall = f(eps)$



Зафиксированы аномалии в кодовых посылках № [295, 296, 297, 298, 299, 300, 301, 302, 303, 304]

Рис. 6. Результат кластеризации и детектирования аномалий алгоритмом DBSCAN

Анализируя рис. 5, можно сделать вывод о том, что уже при значении $\text{eps} = 4$ точность достигает 100%, но, судя по полноте (10%), лишь в рамках меньшего выявленного множества из всех аномальных точек. Наиболее удачно значение $\text{eps} = 6$, точность и полнота при нем максимальны. Дальнейшее увеличение значение eps приведет к крайне плохой кластеризации, метрики будут численно максимальны и неинформативны, так как абсолютно все точки будут принадлежать одному большому кластеру.

Результат кластеризации алгоритмом DBSCAN¹ после настройки его гиперпараметров показан на рис. 6.

DBSCAN идентифицировал 4 кластера, обнаружил 10 аномалий (отмечены красным), из 10 изначально сгенерированных аномалий.

Заключение

В результате вычислительного эксперимента обосновано использование алгоритмов ИИ к детектированию аномалий в основных устройствах приема и передачи кода на сигнальной точке на базе данных системы технической диагностики и мониторинга. Необходимость в использовании программы с поддержкой ИИ также обусловлена сложностью ручного мониторинга из-за большого количества диагностируемых параметров [8] только одной сигнальной точки. Помимо временных характеристик, контролируется также напряжение на трансмиттерном реле ТШ, на сигнальных Ж и З, основного и резервного фидеров питания и многое другое. В связи с этим дальнейшее направление исследования эффективности алгоритмом ИИ заключается в обработке всех диагностируемых параметров, и соответственно анализе предотказных состояний перед уже известными сбоями на основе реальных данных мониторинга, и выдачей оповещения за время, наиболее оптимального для проведения технического обслуживания.

¹ Официальная документация <https://scikit-learn.org/stable/modules/generated/sklearn.cluster.DBSCAN.html>

Библиографический список

1. Мынцов А.А., Мынцова О.В. Организация предиктивного обслуживания динамического оборудования // Информатизация и системы управления в промышленности 2020. № 1 (85). С. 50-53. URL: https://isup.ru/upload/pdf-zhurnala/2020/1-85-2020/050_053_Promservis.pdf (дата обращения 29.11.2022)
2. Федоров Н.Е. Современные системы автоблокировки с тональными рельсовыми цепями: Учебное пособие. Самара: СамГАПС, 2004. 132 с.
3. Сороко В.И., Фоткина Ж.В. Аппаратура железнодорожной автоматики и телемеханики: Справочник: в 4 кн. Кн. 2.: 4-е изд. М.: ООО «НПФ «ПЛАНЕТА», 2013. 1048 с.
4. Géron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. Sebastopol, CA: O'Reilly Media, 2019. 600 pp.
5. Брайт Д. Доходчиво об обучении на основе многообразий с алгоритмами IsoMap, t-SNE и LLE / Medium. URL: <https://medium.com/nuances-of-programming/доходчиво-об-обучении-на-основе-многообразий-с-алгоритмами-isomap-t-sne-и-lle-8fbb30851953> (дата обращения 29.11.2022)
6. Осколков Н. Как именно работает UMAP и почему именно он лучше tSNE / IT CHEF. URL: <https://itchef.ru/articles/309619/> (дата обращения 30.11.2022)
7. Bhattacharyya S. DBSCAN Algorithm: Complete Guide and Application with Python Scikit-Learn / Towards Data Science – официальный сайт. URL: <https://towardsdatascience.com/dbscan-algorithm-complete-guide-and-application-with-python-scikit-learn-d690cbae4c5d> (дата обращения 11.11.2022)
8. Sugizaki T. How automated anomaly detection can maximize production? // Control Engineering – официальный сайт. URL: <https://www.controleng.com/articles/how-automated-anomaly-detection-can-maximize-production/> (дата обращения 16.11.2022)

References

1. Myntsov A.A., Myntsova O.V. Organising predictive maintenance of rotating equipment. *Informatizatsiya i sistemy upravleniya v promyshlennosti* 2020;1(85):50-53. (accessed 29.11.2022). Available at: https://isup.ru/upload/pdf-zhurnala/2020/1-85-2020/050_053_Promservis.pdf. (in Russ.)
2. Fedorov N.E. [Modern automatic block systems with audio frequency track circuits: A study guide]. Samara: SamGUPS; 2004. (in Russ.)
3. Soroko V.I., Fotkina Zh.V. [Railway signalling equipment: a reference book in 4 volumes. Vol. 2. 4-th edition]. Moscow: OOO NPF PLANETA; 2013. (in Russ.)
4. Aurélien G. Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow: a monograph. O'Reilly; 2019. LSI 978-1-492-03264-9.
5. Bright D. [Explaining manifold learning using the IsoMap, t-SNE and LLE algorithms]. (accessed 29.11.2022). Available at: <https://medium.com/nuances-of-programming/доходчиво-об-обучении-на-основе-многообразий-с-алгоритмами-isomap-t-sne-и-lle-8fbb30851953>. (in Russ.)
6. Oskolkov N. How exactly UMAP works and why it is superior to tSNE / IT CHEF. (accessed 30.11.2022). Available at: <https://itchef.ru/articles/309619>.
7. Bhattacharyya S. DBSCAN Algorithm: Complete Guide and Application with Python Scikit-Learn. (accessed 11.11.2022). Available at: <https://towardsdatascience.com/dbscan-algorithm-complete-guide-and-application-with-python-scikit-learn-d690cbae4c5d>.
8. Sugizaki T. How automated anomaly detection can maximize production? (accessed 16.11.2022). Available

at: <https://www.controleng.com/articles/how-automated-anomaly-detection-can-maximize-production>.

Сведения об авторе

Канарский Вадим Андреевич – аспирант кафедры «Вычислительная техника и компьютерная графика», преподаватель кафедры «Автоматика, телемеханика и связь» в Дальневосточном государственном университете путей сообщения, Far Eastern State Transport University; Хабаровск, Российская Федерация, e-mail: jizzierose@yahoo.com; SPIN-код 3411-0352

About the author

Vadim A. Kanarsky, post-graduate student, Department of Computer Engineering and Computer Graphics, lecturer, Department of Automation, Remote Control and Communications, Far Eastern State Transport University; Khabarovsk, Russian Federation, e-mail: jizzierose@yahoo.com; SPIN code 3411-0352.

Вклад автора в статью

Канарским В.А. была исследована работа схем формирования кода в автоблокировке с учетом замечаний действующих электромехаников СЦБ, проанализированы актуальные зарубежные источники информации по машинному обучению, обоснованы результаты применения этих методик в отечественных системах мониторинга.

Конфликт интересов

Автор заявляет об отсутствии конфликта интересов.