

Методы преобразования табличных данных в изображения в задаче выявления аномалий в киберфизических системах

Евгения Новикова¹, Марат Бухтияров²

¹ Санкт-Петербургский Федеральный Исследовательский центр РАН

² Санкт-Петербургский государственный электротехнический университет «ЛЭТИ»



РусКрипто

Солнечногорск, Россия – Март 21, 2024

Структура доклада

- 1 Постановка проблемы
- 2 Методы преобразования данных
- 3 Экспериментальная оценка
- 4 Заключение

Актуальность исследования

- В настоящее время предложено большое число подходов к выявлению аномалий в потоках данных от киберфизических системах на основе методов глубокого обучения [Sun et al., 2024; Wang et al., 2020; Xia et al., 2023; Tushkanova et al., 2023]
 - они выявлять нелинейные пространственные и временные зависимости между анализируемыми признаками
 - применение методов глубокого обучения требовательно к наличию вычислительных ресурсов
- Граничные вычисления: концепция переноса вычислений, связанных с обработкой данных, ближе к устройствам, которые генерируют эти данные
 - предложено федеративное обучение как парадигма МО с сохранением конфиденциальности, которая может быть развернута в IoT
 - устройства Интернета Вещей имеют ограниченные ресурсы вычислительной техники и памяти

Эффективность модели МО

Ментальная модель
эффективности модели МО
[Menghani, 2023]

- **Эффективность модели МО во время применения:**
Каков размер модели?
Сколько параметров имеет модель? Каково потребление оперативной памяти при прогнозе? Какова задержка при прогнозе?
- **Эффективность модели МО во время применения:**
Время обучения модели? сколько устройств? каковы их вычислительные возможности? и т.д.

Подходы к построению эффективных модели МО



Цель и задачи исследования

Цель


Поиск "легковесных" решений для обнаружения аномалий в многомерных временных рядах путем анализа различных методов предварительной обработки данных и применения сверточных нейронных сетей

Задачи:


- анализ существующих подходов к построению изображений по табличным данным
- экспериментальная оценка влияния различных подходов к преобразованию на эффективность обнаружения аномалий в киберфизических системах.

Преобразование табличных данных в изображения

Схема потока данных в процессе выявления аномалий



Timestamp	HT101	LIT101	MV101	P101	P102
28/12/2015 10:00:00 AM	2,427057	522,8467	2	2	1
28/12/2015 10:00:01 AM	2,446274	522,886	2	2	1
28/12/2015 10:00:02 AM	2,489191	522,8467	2	2	1
28/12/2015 10:00:03 AM	2,53435	522,9645	2	2	1
28/12/2015 10:00:04 AM	2,56926	523,4748	2	2	1
28/12/2015 10:00:05 AM	2,609294	523,8673	2	2	1
28/12/2015 10:00:06 AM	2,637158	524,1028	2	2	1
28/12/2015 10:00:07 AM	2,652211	524,2206	2	2	1
28/12/2015 10:00:08 AM	2,655735	524,4954	2	2	1



Требования к входным данным:

- входной вектор - числовой вектор;
- обучающая выборка представлена таблицей с объектами и метками;

Методы преобразования:

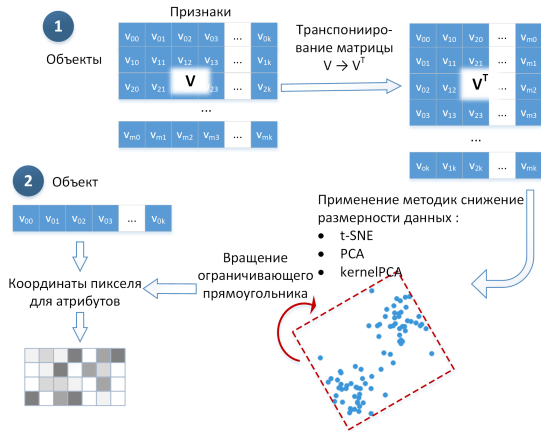
- прямое построение изображения
- нелинейное преобразование DeepInsight
- преобразование на основе оценки подобия IGDT

Прямое преобразование данных



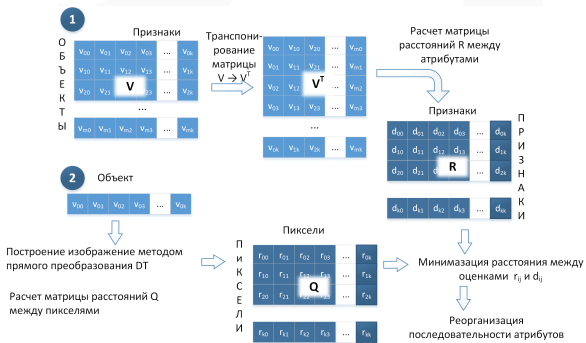
- Положение параметра (пикселя) определяется его положением в векторе и размером изображения;
- размер изображения определяется как $W_{image} = \text{ceil}((N + M)/2)$ для квадратных изображений;
- отсутствует корреляция между ближайшими пикселями

Нелинейное преобразование



- DeepInsight [Sharma et al., 2019], REFINED [Bazgir et al., 2020];
- на основе проекции многомерных данных на двумерную плоскость;
- генерируемые изображения слишком разрежены \rightarrow их необходимо переобработать размер;
- в измененных изображениях один пиксель может отражать усредненное значения перекрывающихся признаков.


Преобразование на основе оценки подобия признаков




- IGDT (Image Generator for Tabular Data) [Zhu et al 2021];
- оценивает расстояние между признаками и перестраивает пиксели на изображении

Методы преобразования данных: пример


Изображения построенные для одного объекта



прямое
преобразование



преобразование
на основе
оценки подобия
IGDT



нелинейное
преобразование
DeepInsight
(t-SNE)

Сценарий эксперимента

- Бинарный классификатор: CNN с 2 сверточными слоями
- Цель: оценить влияние методов преобразования данных на эффективности выявления аномалий .
- Метрики оценки эффективности:
 - полнота (recall) , точность(precision),и F1-мера,
 - число параметров и время прогноза

Информация о тестовом наборе данных


Набор данных SWAT:

- доступен в двух форматах: PCAP (сетевой трафика) и CSV (данные от физических датчиков) ;
- описывает 5 дней функционирования системы водоочистных сооружений (физическая уменьшенная копия);
- используется во многих исследованиях [Sun et al., 2024; Wang et al., 2020; Xia et al, 2023; Tushkanova et al., 2023]



Распределение атак по процессам в SWAT

Тип записи	Число атакуемых процессов	Атакуемые процессы	Число записей
Норма	0	0	399157
Ненорма	1	P1	4053
	1	P2	1809
	1	P3	37860
	1	P4	1700
	1	P5	1044
	2	P3, P4	1691
	2	P1, P3	1445
	2	P3, P6	697
2	P4, P5	463	



Результаты эксперимента

Эффективность обнаружения аномалий

Подход	Точность	Полнота	f1-мера	Число параметров	Время прогноза
CNN+DT	0.98	0.96	0.97	10 561	2.07 * 10 ⁻⁵ сек
CNN+DeepInsight with t-SNE	0.98	0.92	0.95	10 561	2.07 * 10 ⁻⁵ сек
DeepSVDD**	0.95	0.68	0.82	11 648	2.21 * 10 ⁻⁵ сек
LSTM**	0.98	0.71	0.82	66 035	5.32 * 10 ⁻⁵ сек
MTS-DVGAN** [Sun et al., 2024]	0.99	0.67	0.78	-	-
CAN** [Xie et al., 2023]	0.91	0.94	0.92	-	-

** - trained on GPU-equipped computational cluster

Изображения для нормы и не нормы



Прямое преобразование (норма)



DeepInsight (t-SNE) (норма)



Прямое преобразование (ненорма)



DeepInsight (t-SNE) (ненорма)

Результаты и направление будущих исследований

Результаты

- Использование специальных методов предварительной обработки (формирования анализируемых признаков) позволяет использовать эффективные архитектуры нейронных сетей для обнаружения аномалий
- Точность алгоритма классификации, используемого для обнаружения аномалий, зависит от того, насколько точно метод проекции данных отражает сходство между признаками..
- Более точная проекция точек данных, более устойчивый к новым и невидимым аномалиям обученный классификатор.

Направление будущих исследований

- Разработка подходов, основанных на сходстве признаков, для построения изображений для подмножества объектов (для формирования временного контекста).
- Применение методов объяснения МО, разработанных для сверточных сетей, для обнаружения аномальных датчиков

Литература

- Zhu et al., 2021 Zhu, Y., Brettin, T., Xia, F., Partin, A., Shukla, M., Yoo, H., Evrard, Y.A., Doroshov, J.H., Stevens, R.L.: Converting tabular data into images for deep learning with convolutional neural networks. Scientific Reports (2021). <https://doi.org/10.1038/s41598-021-90923-y>
- Sharma et al., 2019 Sharma, A., Vans, E., Shigemizu, D., Boroevich, K.A., Tsunoda, T.: Deepinsight: A methodology to transform a non-image data to an image for convolution neural network architecture. Scientific Reports (2019). <https://doi.org/10.1038/s41598-019-47765-6>
- Bazgir et al., 2020 Bazgir, O., Zhang, R., Dhruba, S.R., Rahman, R., Ghosh, S., Pal, R.: Rep resenatation of features as images with neighborhood dependencies for compatibility with convolutional neural networks. Nature communications (2020). <https://doi.org/10.1038/s41467-020-18197-y>
- Menghani, 2023 Menghani G.: Efficient Deep Learning: A Survey on Making Deep Learning Models Smaller, Faster, and Better. ACM Comput. Surv. 55, 12, Article 259 (December 2023), 37 pages. <https://doi.org/10.1145/3578938>
- Sun et al., 2024 Sun H, Huang Y., Han L., Fu C., Liu H., Long X.: MTS-DVGAN: Anomaly detection in cyber-physical systems using a dual variational generative adversarial network. Computers & Security, Vol. 139, 2024, 103570, <https://doi.org/10.1016/j.cose.2023.103570>.
- Wang et al., 2020 Wang, C., Wang, B., Liu, H., Qu, H.: Anomaly detection for industrial control system based on autoencoder neural network. Wirel. Commun. Mob. Comput. 2020, 8897926–1889792610 (2020)
- Xia et al, 2023 Xia F., Chen X., Yu S, Hou M., Liu M. and You L.: Coupled Attention Networks for Multivariate Time Series Anomaly Detection. IEEE Transactions on Emerging Topics in Computing, doi: 10.1109/TETC.2023.3280577.
- Tushkanova et al., 2023 Tushkanova, O.; Levshun, D.; Branitskiy, A.; Fedorchenko, E.; Novikova, E.; Kotenko, I. Detection of Cyberattacks and Anomalies in Cyber-Physical Systems: Approaches, Data Sources, Evaluation. Algorithms 2023, 16, 85. <https://doi.org/10.3390/a16020085>

*Спасибо за внимание!
Вопросы?*

Контакты:

Евгения Новикова

novikova@comsec.spb.ru

