

Доменная адаптация нейросетевых моделей на основе крупношагового метаобучения в задаче обнаружения аномалий¹

Н.С. Давыдов^{*,**}, Е. И. Ершов^{***}, А. В. Никоноров^{*,**}

^{*} Самарский национальный исследовательский университет им. академика С. П. Королева, Самара, Россия.

^{**} Институт систем обработки изображений РАН - филиал ФНИЦ «Кристаллография и фотоника» РАН, Самара, Россия.

^{***} Институт проблем передачи информации имени А.А. Харкевича РАН, 127051, Россия, г. Москва, Большой Каретный переулок, д. 19, стр. 1.

Поступила в редколлегию 14.11.2023

Аннотация—В настоящее время проблема адаптации нейросетевых моделей обучаемых и используемых на данных разных доменов особенно остро стоит в сферах, где объём доступных для обучения реальных данных мал. Данные для обучения обычно синтезируются с переносом параметров из реальных данных, чтобы согласовать распределения двух разных доменов, однако реальные данные могут также сильно различаться между собой, в связи с чем возникает необходимость адаптировать нейросетевую модель к каждому новому набору данных. В настоящей статье предложен метод доменной адаптации нейросетевых моделей для обнаружения ступенчатых аномалий в сигнале на основе нескольких шагов крупношагового метаобучения с использованием смешивания параметров моделей первого и второго шагов.

КЛЮЧЕВЫЕ СЛОВА: доменная адаптация, обнаружение аномалий, крупношаговое метаобучение, обучение по нулевой выборке.

DOI: 10.53921/18195822_2023_23_4_507

1. ВВЕДЕНИЕ

Использование глубоких нейросетевых моделей для анализа временных рядов крайне перспективное направление, однако, в этой сфере часто недостает размеченных наборов данных [1],[2], создание которых требует значительных трудозатрат экспертов [3],[4],[5],[6],[7]. Решением в таком случае является использование синтетических данных, а также адаптация моделей, обученных на данных одного домена для использования в другом домене — доменная адаптация [4]. Различные подходы к доменной адаптации распространены как для обработки изображений, так и, хотя в несколько меньшей степени, для обработки временных рядов.

Однако сгенерированные синтетические данные могут значительно отличаться по своим статистическим характеристикам и распределению от реальных данных, что ведёт к снижению производительности используемых нейросетевых методов. Проблема отличия исходного и целевого доменов данных существует в сфере обработки и классификации как изображений, так и временных рядов, например, распознавании деятельности человека [3],[8] и задачах классификации фаз сна [4]. Доменная адаптация направлена на компенсацию различий в вероятностных распределениях, присущих исходному и целевому доменам [9],[10]. Для этого

¹ Работа выполнена в рамках Гранта РФФИ № 22-19-00364 в теоретической части, Государственного задания ФНИЦ «Кристаллография и фотоника» РАН в части экспериментального исследования.

применяются различные методы, такие как комбинирование инвариантных и специфических признаков домена [9], хэширование [11] или согласовывание распределений признаков двух разных доменов [12]. Различают доменную адаптацию без учителя [3],[9],[13],[14], для случая, когда для целевого домена разметка отсутствует, и доменную адаптацию с учителем, в случае, когда для части целевого домена разметка известна [15],[16]. Также доменная адаптация к малому набору реальных данных может быть выполнена на основе различных подходов обучения по выборкам малого и нулевого размера (few-/zero- shot learning) [17],[18]. В настоящей работе предложен метод доменной адаптации с учителем на основе нескольких шагов крупношагового метаобучения для случая, когда для небольшой выборки из целевого домена разметка задана. Такой подход, в частности, позволит выполнять адаптацию нейросетевых моделей для анализа качества при исследовании конкретного человека.

2. АЛГОРИТМ КРУПНОШАГОВОГО МЕТАОБУЧЕНИЯ В НЕСКОЛЬКО ШАГОВ

Для обучения нейросетевых моделей в условиях малого количества реальных данных в настоящей работе разработана технология трехэтапного обучения с доменной адаптацией нейросетевой модели под конкретную задачу на основе алгоритма метаобучения [19]. Применяемый подход отличается от метаобучения с усреднением градиентов функций потерь на каждом шаге [19] и использует усреднение параметров модели в несколько шагов, впервые предложенный в работе, посвященной реконструкции изображений в дифракционно-оптических системах [20]. В настоящей работе предложена схема многошагового метаобучения с использованием предварительного обучения на синтезированных данных (Рис. 1), состоящая из следующих трех этапов:

1) На первом этапе модель обучается на большом объеме данных синтезированных на основе реальных. В результате обучения получается начальный вектор параметров нейросетевой модели — w_0 .

2) Второй этап выполняется на небольшом количестве предварительно размеченных наборах реальных данных. Для N наборов выполняется дообучение, начиная из начального вектора параметров модели w_0 независимо друг от друга обучается N моделей, и получается N векторов параметров нейросетевой модели $w_1 \dots w_N$. По набору состояний получается средний результирующий вектор параметров модели w_M :

$$w_M = \frac{1}{N} \sum_{k=1}^N w_k, \quad (1)$$

где w_M — результирующий вектор параметров нейросетевой модели, N — количество векторов параметров после дообучения на N малых наборах данных, w_k — k -ый вектор параметров состояния модели в наборе. Полученные N векторов соответствуют дообучению по N различным малым выборкам для различающихся доменов.

3) На третьем этапе выполняется доменная адаптация модели на основе обучения модели по малой части реальных данных (few-shot обучение), соответствующей конкретному эксперименту. Тестирование полученного результате обучения проводится на оставшейся части данных.

Полученная итоговая модель третьего этапа используется на первом этапе метаобучения, чтобы вновь пройти процедуру дообучения на N различных наборах реальных данных. Дообученное состояние первого шага $w_{M,1}$ становится новым состоянием w_0 и после дообучения и усреднения формируется новое результирующее состояние $w_{M,2}$.

В ранней работе было приведено обоснование крупношагового метаобучения на основе усреднения параметров набора моделей [21]. Конечное полученное выражение является основной формулой для оценки крупношагового метаобучения.

$$w_k = \left(1 - \frac{\beta}{\alpha} N\right) w_0 + \frac{\beta}{\alpha} \sum_{i=1}^N w_{i,k}, \quad (2)$$

где N — количество выборок различных доменов, w_M — результирующая средняя модель, w_0 — модель первого этапа, K — номер слоя нейросетевой модели w .

При расчёте первого шага метаобучения параметр $\frac{\beta}{\alpha}$ заменяется на $\gamma = \frac{1}{N}$, что обеспечивает формирование результирующей нейросетевой модели без смешивания с моделью, обученной на синтетических данных. Следующий шаг крупношагового метаобучения уже использует значения γ в интервале от 0 до $\frac{1}{N}$

$$w_k = (1 - \gamma N) w_0 + \gamma \sum_{i=1}^N w_{i,k}, \quad (3)$$

где $w_{M,2}$ — результирующая средняя модель второго шага, $w_{M,1}$ — результирующая средняя модель первого шага, γ — параметр в интервале $[0, \frac{1}{N}]$.

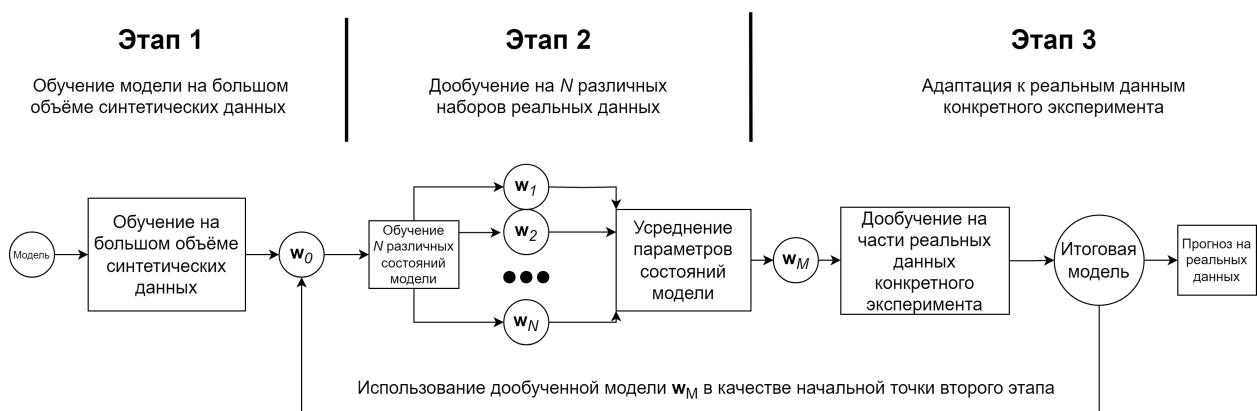


Рис. 1. Схема алгоритма многошагового метаобучения моделей обнаружения аномалий с использованием синтетических данных. w_0 — вектор параметров начального состояния нейросетевой модели, N — количество реальных сигналов первого измерения и количество получаемых на втором этапе состояний модели, $w_1 \dots w_N$ — набор векторов параметров модели после дообучения из начального состояния, w_M — результирующий вектор параметров модели.

3. РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТОВ

Для оценки прироста точности второго шага крупношагового метода метаобучения использовалась свёрточно-рекуррентная нейросетевая модель для обнаружения ступенчатых аномалий в данных движения головы участника эксперимента с применением функционального МРТ [22]. Выборка данных состояла из 15 сигналов движения головы до и после проведения основного эксперимента. Данные первого набора (до) использовались на вторых этапах обоих шагов, а данные второго набора (после) на третьих этапах с применением поэлементной кросс-валидации, описанной ранее в [22]. В качестве входных данных для нейросетевой модели использовались интервалы в 10, 15 и 24 отсчёта, полученные после сегментации сигналов.

Второй этап первого шага метаобучения проводился со скоростью обучения 10^{-3} и размером батча 128 на протяжении 100 эпох. Третий этап с параметрами 10^{-6} и 128 на протяжении 50 эпох. На втором шаге метаобучения была использована опция ранней остановки по достижению максимума F1-метрики. На втором этапе второго шага данная характеристика отслеживалась 75 эпох, а на третьем этапе — 25 эпох. Скорость обучения была снижена до 10^{-5}

и 10^{-7} соответственно. Параметр γ на третьем этапе второго шага изменялся от 0,010 до $\frac{1}{N}$ с шагом 0,010 на протяжении всей процедуры кросс-валидации ($N=14$).

Для оценки эффективности предлагаемого метода использовалась сбалансированная точность, рассчитываемая по следующей формуле:

$$\text{Сбалансированная точность} = \frac{\text{Чувствительность} + \text{Специфичность}}{2}. \tag{4}$$

На рисунке 2 представлена зависимость среднего прироста сбалансированной точности от параметра γ для интервалов различной длины. В таблице 1 также представлены средние значения сбалансированной точности.

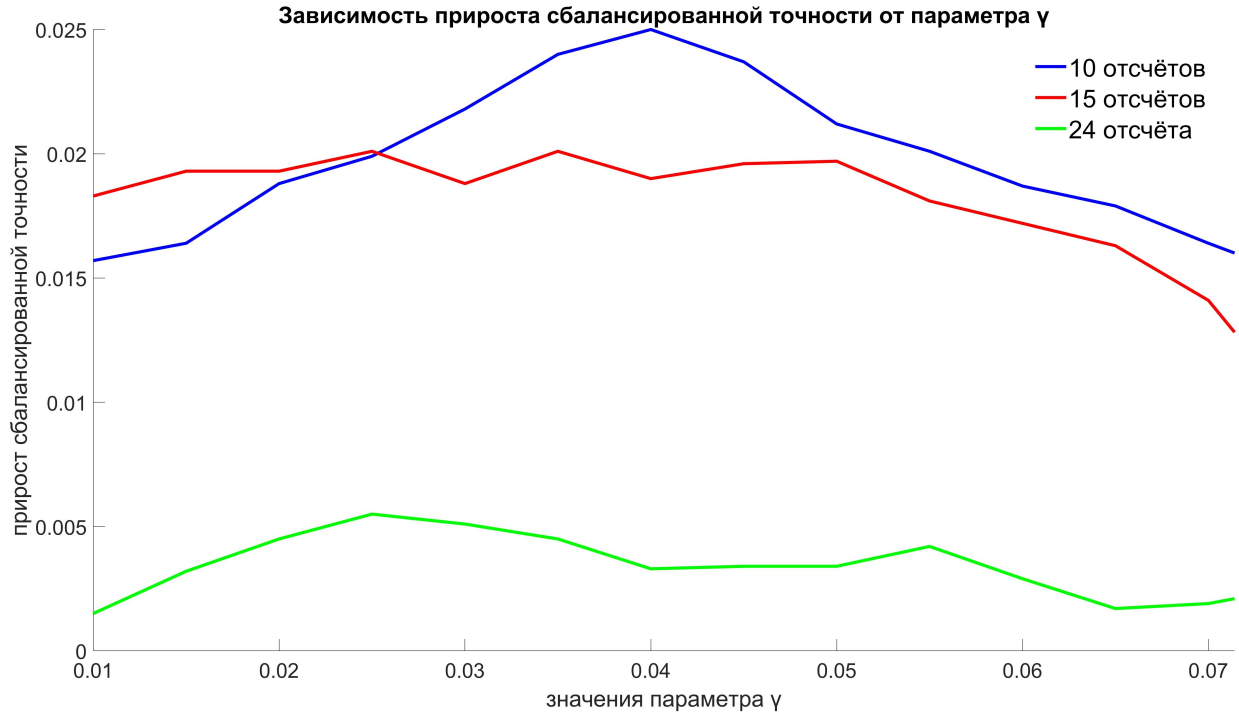


Рис. 2. Зависимость прироста сбалансированной точности от параметра γ на разных длинах рассматриваемых интервалов.

Таблица 1. Прирост сбалансированной точности после второго шага метаобучения для различных длин интервалов и значений параметра γ .

Длина \ Гамма	0,010	0,015	0,020	0,025	0,030	0,035	0,040	0,045	0,050	0,055	0,060	0,065	0,070	1/N
10 отсчётов	0,016	0,016	0,019	0,020	0,022	0,024	0,025	0,024	0,020	0,020	0,019	0,018	0,016	0,016
15 отсчётов	0,018	0,019	0,019	0,020	0,019	0,020	0,019	0,020	0,020	0,018	0,017	0,016	0,014	0,013
24 отсчёта	0,002	0,003	0,005	0,006	0,005	0,005	0,003	0,003	0,003	0,004	0,003	0,002	0,002	0,002

4. ЗАКЛЮЧЕНИЕ

В данной работе использование подхода на основе нескольких шагов крупношагового метаобучения с усреднением параметров моделей и их смешиванию на втором шаге позволило

увеличить сбалансированную точность обнаружения аномалий на реальных данных движения головы на втором шаге. Наибольший средний прирост получил набор данных, состоящий из интервалов в 10 отсчётов — 2,5% в сбалансированной точности. Набор данных из интервалов в 15 отсчётов получил прирост сбалансированной точности в 2% и наименьший прирост точности получил набор данных из интервалов в 24 отсчёта — 0,6%.

Представленный метод может быть распространён на дальнейшие шаги, увеличивая количество смешиваемых моделей и, возможно, улучшая финальную точность, однако данный метод требует дополнительных вычислительных затрат на тренировку моделей на втором и последующих шагах. Возможные развитие подхода может включать использование определённых признаков, выделяемых из интервалов или же пост-обработка и дополнительный анализ классифицированных интервалов.

СПИСОК ЛИТЕРАТУРЫ

1. Ismail Fawaz H., Forestier G., Weber J., Idoumghar L., Muller P.-A. Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*, 2019, vol. 33, № 4, pp. 917-963.
2. Lines J., Taylor S., Bagnall A. Time Series Classification with HIVE-COTE: The Hierarchical Vote Collective of Transformation-Based Ensembles. *ACM Trans. Knowl. Discov. Data*, 2018, vol. 12, № 5, article 52.
3. Chang Y., Mathur A., Isopoussu A., Song J., Kawsar F. A Systematic Study of Unsupervised Domain Adaptation for Robust Human-Activity Recognition. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2020, vol. 4, pp. 1-30.
4. Eldele E., Ragab M., Chen Z., Wu M., Kwoh C. K., Li X., Guan C. ADAST: Attentive Cross-Domain EEG-Based Sleep Staging Framework With Iterative Self-Training. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2023, vol. 7, № 1, pp. 210-221.
5. Time-Series Representation Learning via Temporal and Contextual Contrasting, 2021.
6. Li Y., Li K., Chen C., Zhou X., Zeng Z., Li K. Modeling Temporal Patterns with Dilated Convolutions for Time-Series Forecasting. *ACM Trans. Knowl. Discov. Data*, 2021, vol. 16, № 1, Article 14.
7. Sharma A. K., Verma N. K. Quick Learning Mechanism With Cross-Domain Adaptation for Intelligent Fault Diagnosis. *IEEE Transactions on Artificial Intelligence*, 2022, vol. 3, № 3, pp. 381-390.
8. Wilson G., Doppa J. R., Cook D. J. Multi-Source Deep Domain Adaptation with Weak Supervision for Time-Series Sensor Data. *Multi-Source Deep Domain Adaptation with Weak Supervision for Time-Series Sensor Data*, 2020, pp. 1768-1778.
9. Jin X., Park Y., Maddix D. C., Wang B., Yan X. Domain Adaptation for Time Series Forecasting via Attention Sharing. *International Conference on Machine Learning*, 2021.
10. Wang C., Xu C., Tao D. Self-Supervised Pose Adaptation for Cross-Domain Image Animation. *IEEE Transactions on Artificial Intelligence*, 2020, vol. 1, № 1, pp. 34-46.
11. Venkateswara H., Eusebio J., Chakraborty S., Panchanathan S. Deep Hashing Network for Unsupervised Domain Adaptation, 2017, pp. 5385-5394.
12. Ganin Y., Ustinova E., Ajakan H., Germain P., Larochelle H., Laviolette F., Marchand M., Lempitsky V. Domain-Adversarial Training of Neural Networks. Cham: Springer International Publishing, 2017, pp. 189-209.
13. Niu S., Liu Y., Wang J., Song H. A Decade Survey of Transfer Learning (2010-2020). *IEEE Transactions on Artificial Intelligence*, 2020, vol. 1, № 2, pp. 151-166.
14. Wu H., Ng M. Multiple Graphs and Low-Rank Embedding for Multi-Source Heterogeneous Domain Adaptation. *ACM Transactions on Knowledge Discovery from Data*, 2022, vol. 16, pp. 1-25.
15. Aytar Y., Zisserman A. Tabula rasa: Model transfer for object category detection. *2011 International Conference on Computer Vision*, 2011, pp. 2252-2259.

16. Bruzzone L., Marconcini M. Domain Adaptation Problems: A DASVM Classification Technique and a Circular Validation Strategy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, vol. 32, № 5, pp. 770-787.
17. Ravi S., Larochelle H. Optimization as a Model for Few-Shot Learning. *International Conference on Learning Representations*, 2016.
18. Wang W., Zheng V., Yu H., Miao C. A Survey of Zero-Shot Learning: Settings, Methods, and Applications. *ACM Transactions on Intelligent Systems and Technology*, 2019, vol. 10, pp. 1-37.
19. Meta-Transfer Learning for Zero-Shot Super-Resolution, 2020.
20. Evdokimova V. V., Bibikov S. A., Nikonorov A. V. Meta-Learning Approach in Diffractive Lens Computational Imaging. *Pattern Recognit. Image Anal*, 2022, vol. 32, № 3, pp. 466-468.
21. Евдокимова В. В., Рябов В. Д., Алексеев А. А., Никоноров А. В. Исследование метаобучения для нейросетевой реконструкции изображений в дифракционно-оптических системах. *Информационные процессы*, том 23, №3, 2023, стр. 335-342.
22. Давыдов Н. С., Евдокимова В.В., Серафимович П.Г., Проценко В.И., Храмов А.Г., Никоноров А.В. Нейросетевая технология обнаружения ступенчатых аномалий в параметрах движения головы для функциональной МРТ с адаптацией на основе метаобучения. *Компьютерная оптика*, 2023, том 47, № 6, стр. 1-18.

Domain adaptation of neural network models based on large-step meta-learning in the problem of anomaly detection

N.S. Davydov, E.I. Ershov, A.V. Nikonorov

Currently, the problem of adapting neural network models trained and used on data from different domains is especially acute in areas where the amount of real data available for training is small. Training data is usually synthesized with parameters transferred from real data to match the distributions of two different domains, but real data can also be very different from each other, making it necessary to adapt neural network model to each new data set. This article proposes a method for domain adaptation of neural network models for detecting step anomalies in a signal based on several steps of large-step meta-learning using mixing parameters of the first and second step models.

KEYWORDS: domain adaptation, anomaly detection, large-step meta-learning, zero-sample learning.