



Центр когнитивных нейронаук

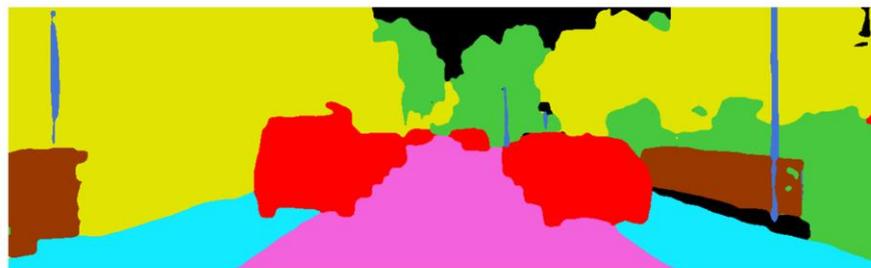
Пермь

U-Net для определения очага инсульта на МРТ снимках

Полякова И.Ю., стажер-исследователь

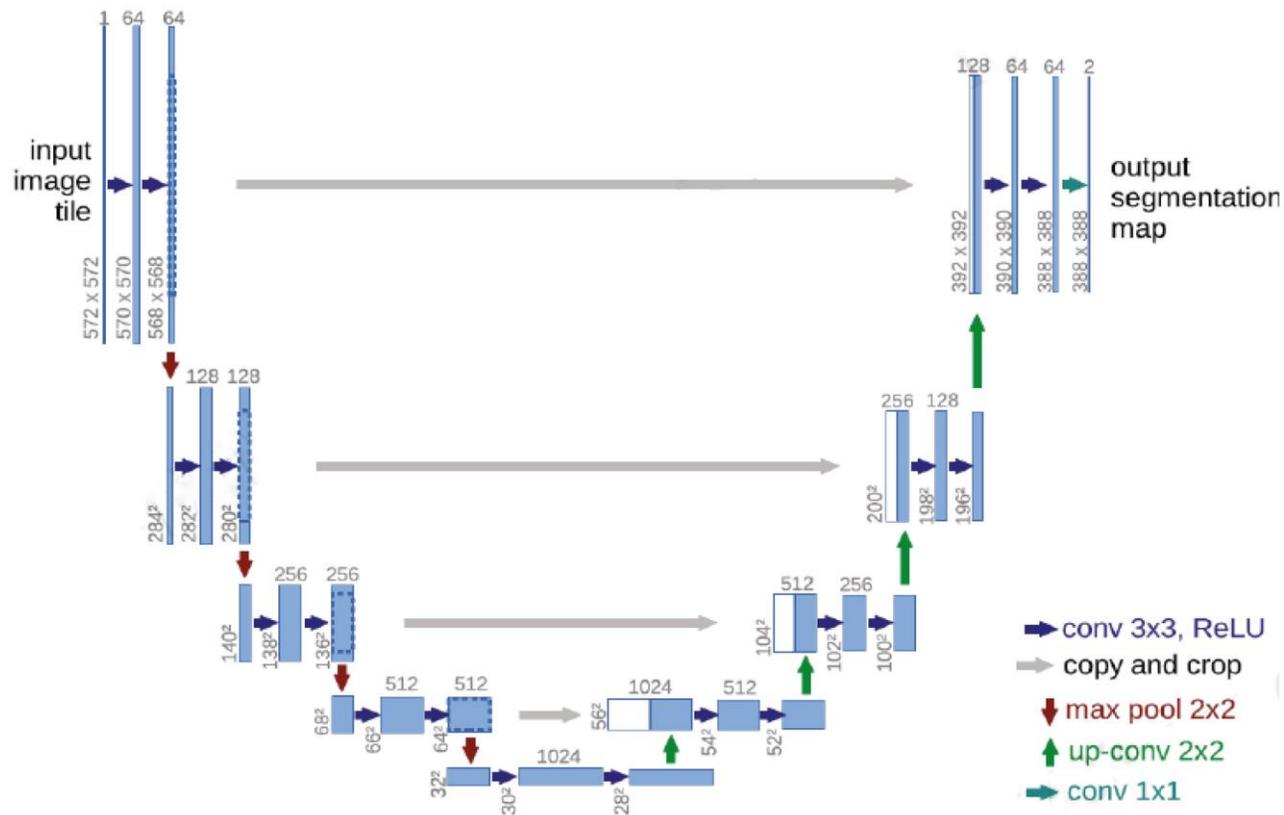


Двумерная семантическая сегментация - это задача компьютерного зрения, которая включает в себя разделение картинки на семантически значимые части или области.



 Road	 Sidewalk	 Building	 Fence
 Pole	 Vegetation	 Vehicle	 Unlabel

Архитектура



Архитектура U-net (пример изображения с разрешением 32x32 пикселя – самым низким). Каждый синий квадрат соответствует многоканальной карте свойств. Количество каналов приведено в верхней части квадрата. Размер x-y приведен в нижнем левом краю квадрата. Белые квадраты представляют собой копии карты свойств. Стрелки обозначают различные операции.



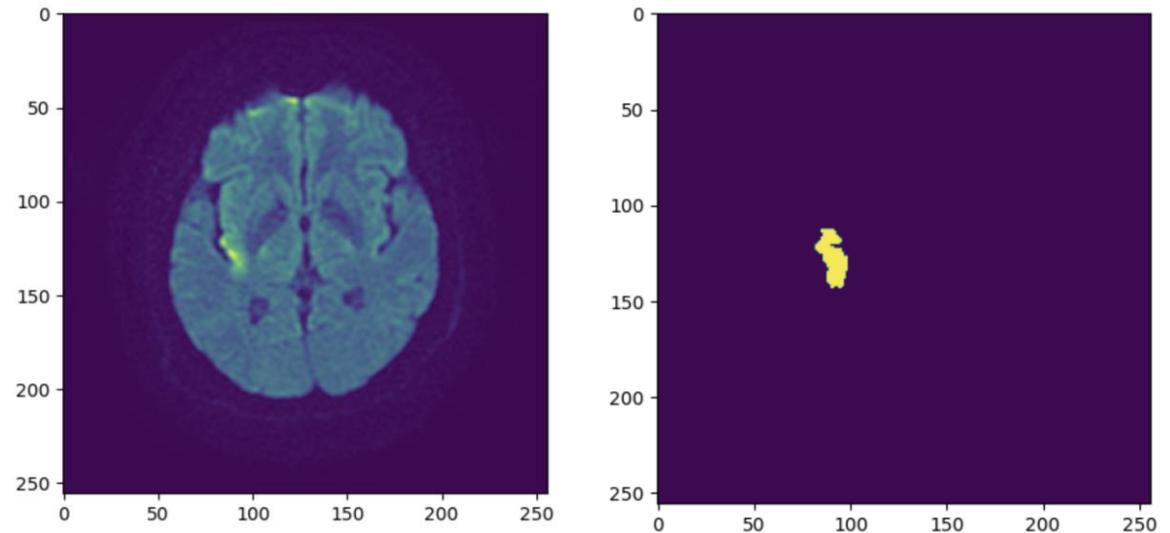
Encoder: ResNet50

Optimizer: SGD (lr=0.001,
momentum =0.9)

Loss: BCELoss

Epoch: 10-20

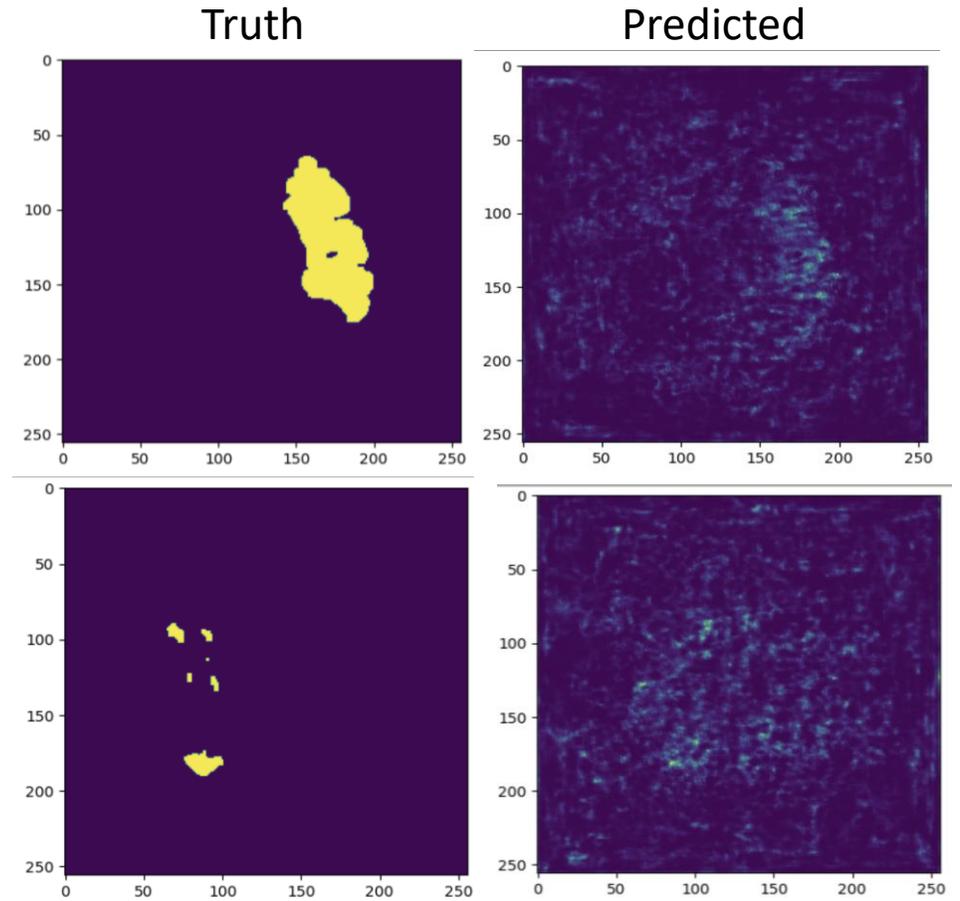
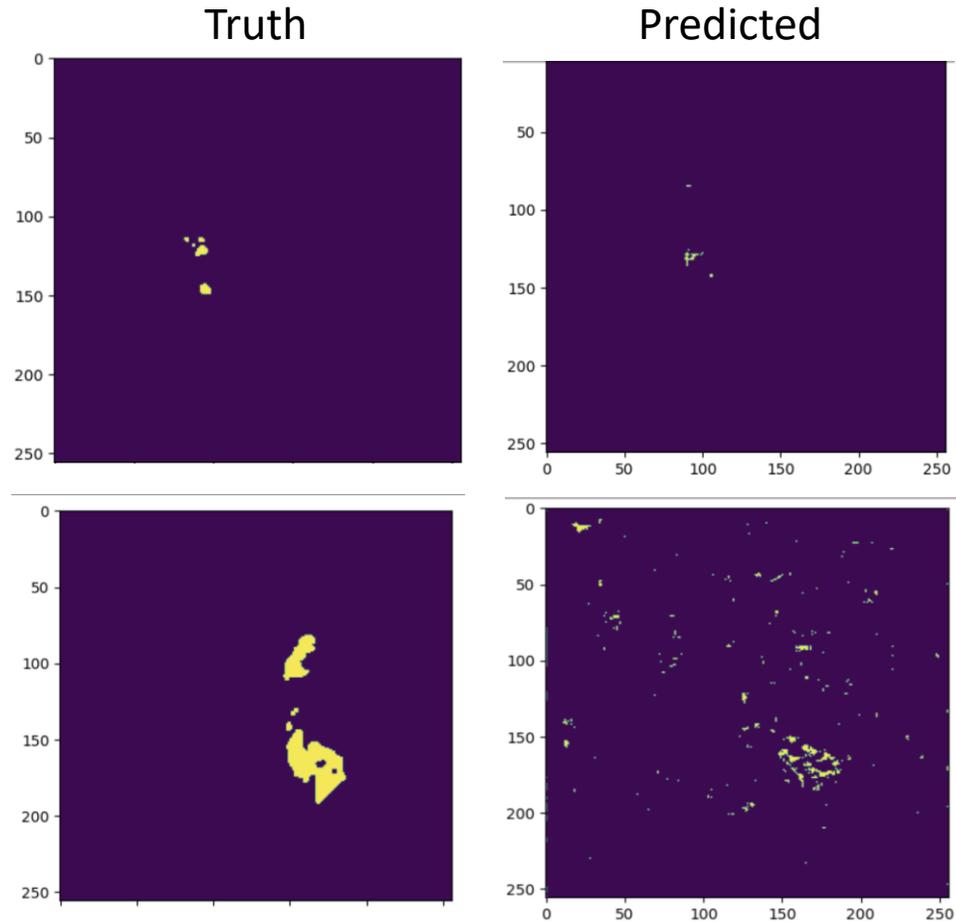
Выборка: 131 МРТ-сканирование и
размеченные маски в формате .niftii



Важно! Для текущей модели я взяла по одному срезу
с каждого наблюдения



Пример результатов



Без порога

*метрика IoU очень низкая, даже выводить не стала



До понедельника:

- Результаты работы трехмерного U-Net
- Двумерного на датасете из 20-ти срезов с каждого из 131-го наблюдения



БОНУС



Как я съездила на Fall into ML 2024



Что было?

[Мини-курс «Современные методы генеративного моделирования на основе сопоставления потоков и диффузионных мостов»](#)

Принцип работы диффузионной модели: превращение шума в выборку данных/синтетическую выборку данных.

MAIN IDEA: reverse the data noising process.

Forward diffusion (noising SDE)

Take a data distribution $x_0 \sim p_0$ and gradually turn it to noise distribution $x_T \sim p_T = \mathcal{N}(0, \sigma^2 I)$.



Reverse diffusion (denoising SDE)

Sample from noise distribution $x_T \sim p_T$ and reverse the diffusion to get $x_0 \sim p_0$:



Что было?

[Мини-курс «Современные методы генеративного моделирования на основе сопоставления потоков и диффузионных мостов»](#)

The Key Limitation of Diffusion Models: Time-Consuming Inference

What we have

Not straight (deterministic or stochastic) trajectories, which are HARD to simulate.



What we want

Straight (deterministic?) trajectories, which are EASY to simulate.



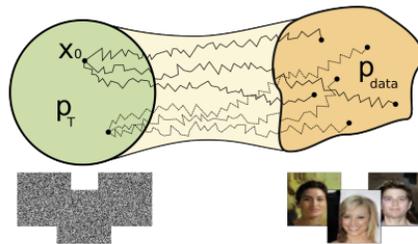
Что было?

Мини-курс «Современные методы генеративного моделирования на основе сопоставления потоков и диффузионных мостов»

Flow matching vs. Diffusion Models: Key Differences

Diffusion models framework (2019)

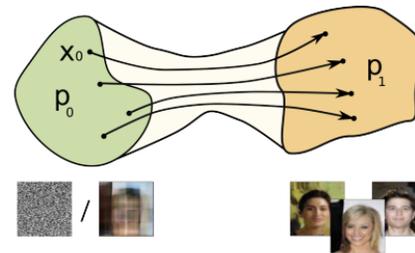
- maps given complex data distribution to the **normal** distribution.



- uses pre-defined **noising process**.
- (theoretically) requires **infinite** time horizon $[0, T]$.
- based on SDEs (\Rightarrow **complex** stuff).

Flow matching framework (2023)

- maps **arbitrary** distribution p_0 to **arbitrary** distribution p_1 .



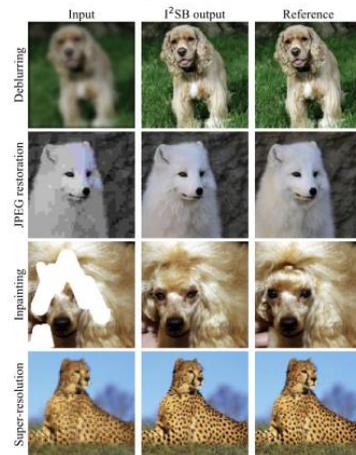
- no pre-defined process**.
- finite** time horizon $[0, 1]$.
- based on ODEs. $\frac{\parallel}{\tau}$

Что было?

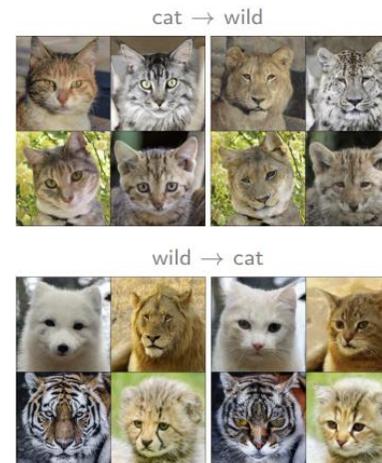
[Мини-курс «Современные методы генеративного моделирования на основе сопоставления потоков и диффузионных мостов»](#)

Examples of Bridge Matching Models for Images¹³¹⁴

Image-to-image Schrodinger Bridge
for various image restoration problems



Diffusion Schrodinger Bridge Matching
for unpaired image-to-image translation





Что было?

[Мини-курс «Современные методы генеративного моделирования на основе сопоставления потоков и диффузионных мостов»](#)

Новизна: авторы доказали, что в определенной постановке решение задачи оптимального транспорта эквивалентно поиску моста Шредингера

Еще придумали **быстрый алгоритм поиска** этого самого моста, но который пока работает только на данных с маленькой размерностью

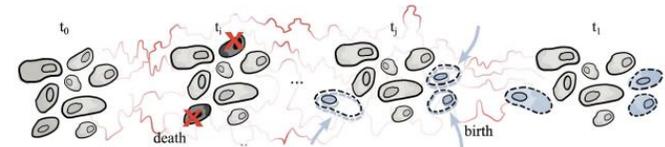
Что было?

Мини-курс «Современные методы генеративного моделирования на основе сопоставления потоков и диффузионных мостов»

Applications of Schrödinger Bridge

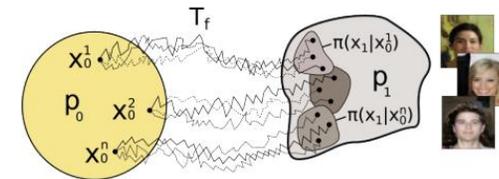
Single-cell biological data.⁹

Solving SB allows to reconstruct the most likely cell trajectories.



Generation and Domain Translation.¹⁰

Solving SB between noise and data with small ϵ gives diffusion with "straighter" trajectories.



$$T_f : dX_t = f(X_t, t)dt + \sqrt{\epsilon}dW_t, \quad X_0 \sim p_0,$$

⁹Hugo Lavenant et al. (2024). "Toward a mathematical theory of trajectory inference". In: *The Annals of Applied Probability* 34.1A, pp. 428–500. DOI: 10.1214/23-AAP1969.

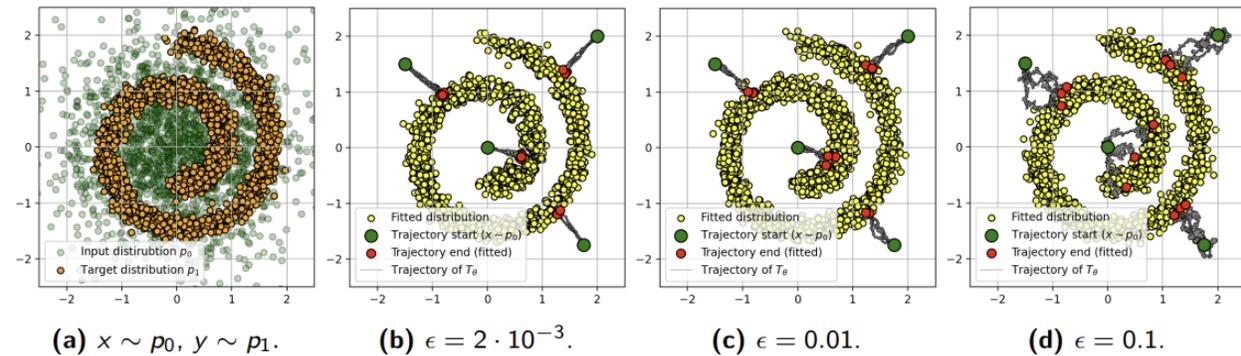
¹⁰Valentin De Bortoli et al. (2021). "Diffusion schrödinger bridge with applications to score-based generative modeling". In: *Advances in Neural Information Processing Systems* 34, pp. 17695–17709.

Что было?

[Мини-курс «Современные методы генеративного моделирования на основе сопоставления потоков и диффузионных мостов»](#)

Experimental results

1. **Qualitative** results of our algorithm applied to 2D model distributions ("Gaussian" → "swiss-roll").



2. **Quantitative** results of our solver on the standard benchmark for the Schrödinger bridge problem.

	$\epsilon = 0.1$				$\epsilon = 1$				$\epsilon = 10$			
	$D=2$	$D=16$	$D=64$	$D=128$	$D=2$	$D=16$	$D=64$	$D=128$	$D=2$	$D=16$	$D=64$	$D=128$
Best from the existing methods	1.94	13.67	11.74	11.4	1.04	9.08	18.05	15.23	1.40	1.27	2.36	1.31
Our method	0.03	0.08	0.28	0.60	0.05	0.09	0.24	0.62	0.07	0.11	0.21	0.37
	± 0.01	± 0.04	± 0.02	± 0.02	± 0.003	± 0.006	± 0.007	± 0.007	± 0.02	± 0.01	± 0.01	± 0.01

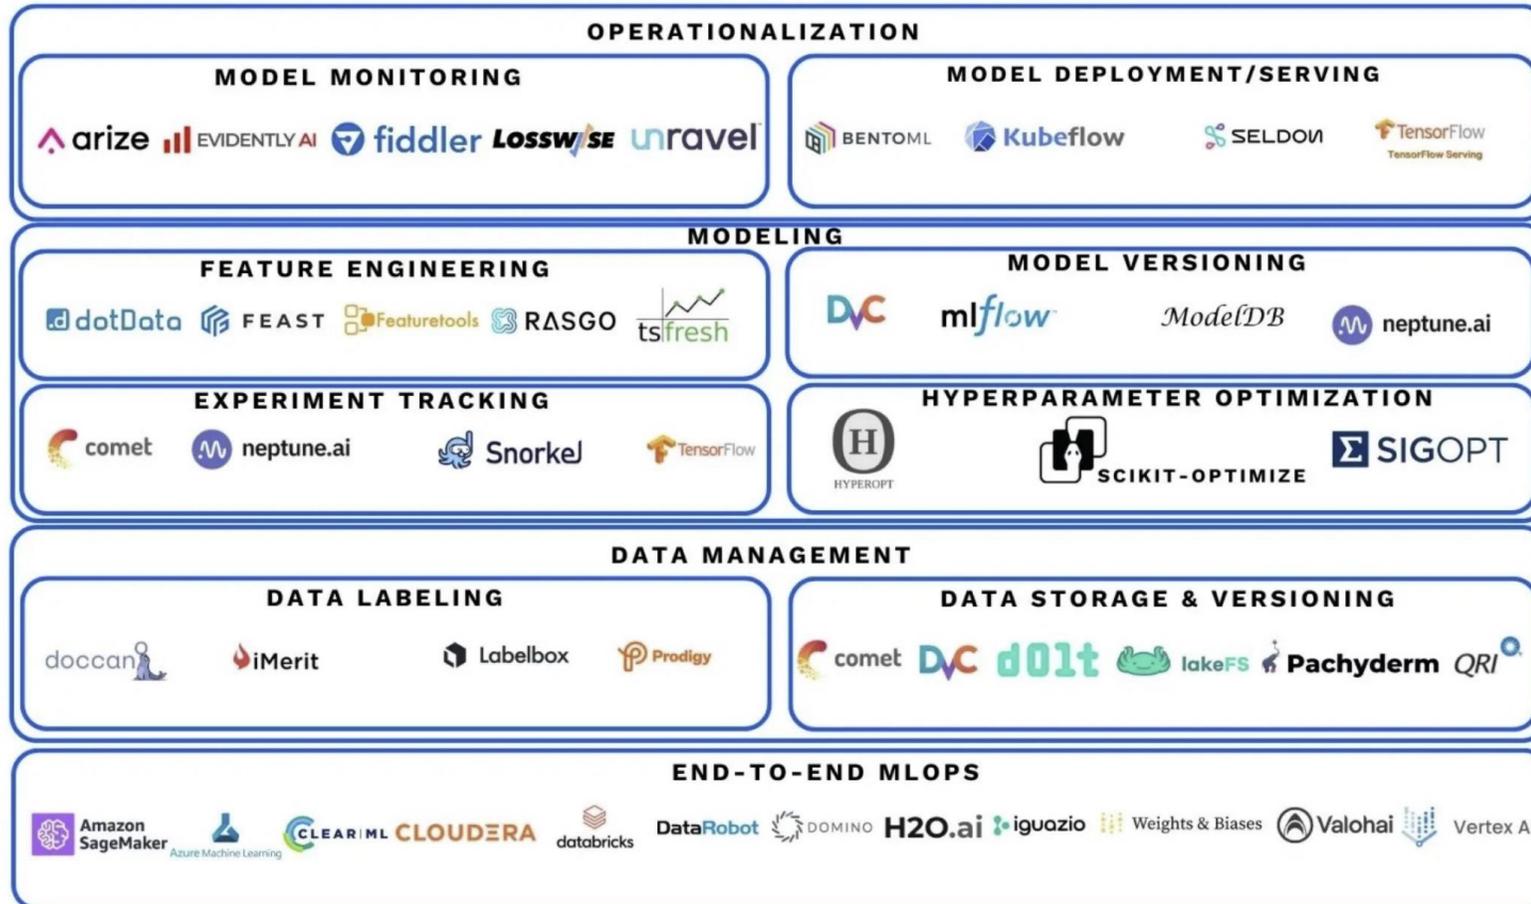
*The metric cBW-UVP is used for comparing build schrödinger bridge with ground-truth bridge (lower=better).



Воркшоп Наука для бизнеса: вызовы и ИИ-решения



Распространенные MLOps-инструменты





Основные инструменты



15

Версионирование и отслеживание экспериментов: MLflow, DVC (Data Version Control), WANDB

CI/CD пайплайны: Jenkins, GitLab CI, CircleCI, Kubeflow Pipelines

Контейнеризация и оркестрация: Docker, Kubernetes

Мониторинг: Prometheus, Grafana, AWS CloudWatch, Azure Monitor

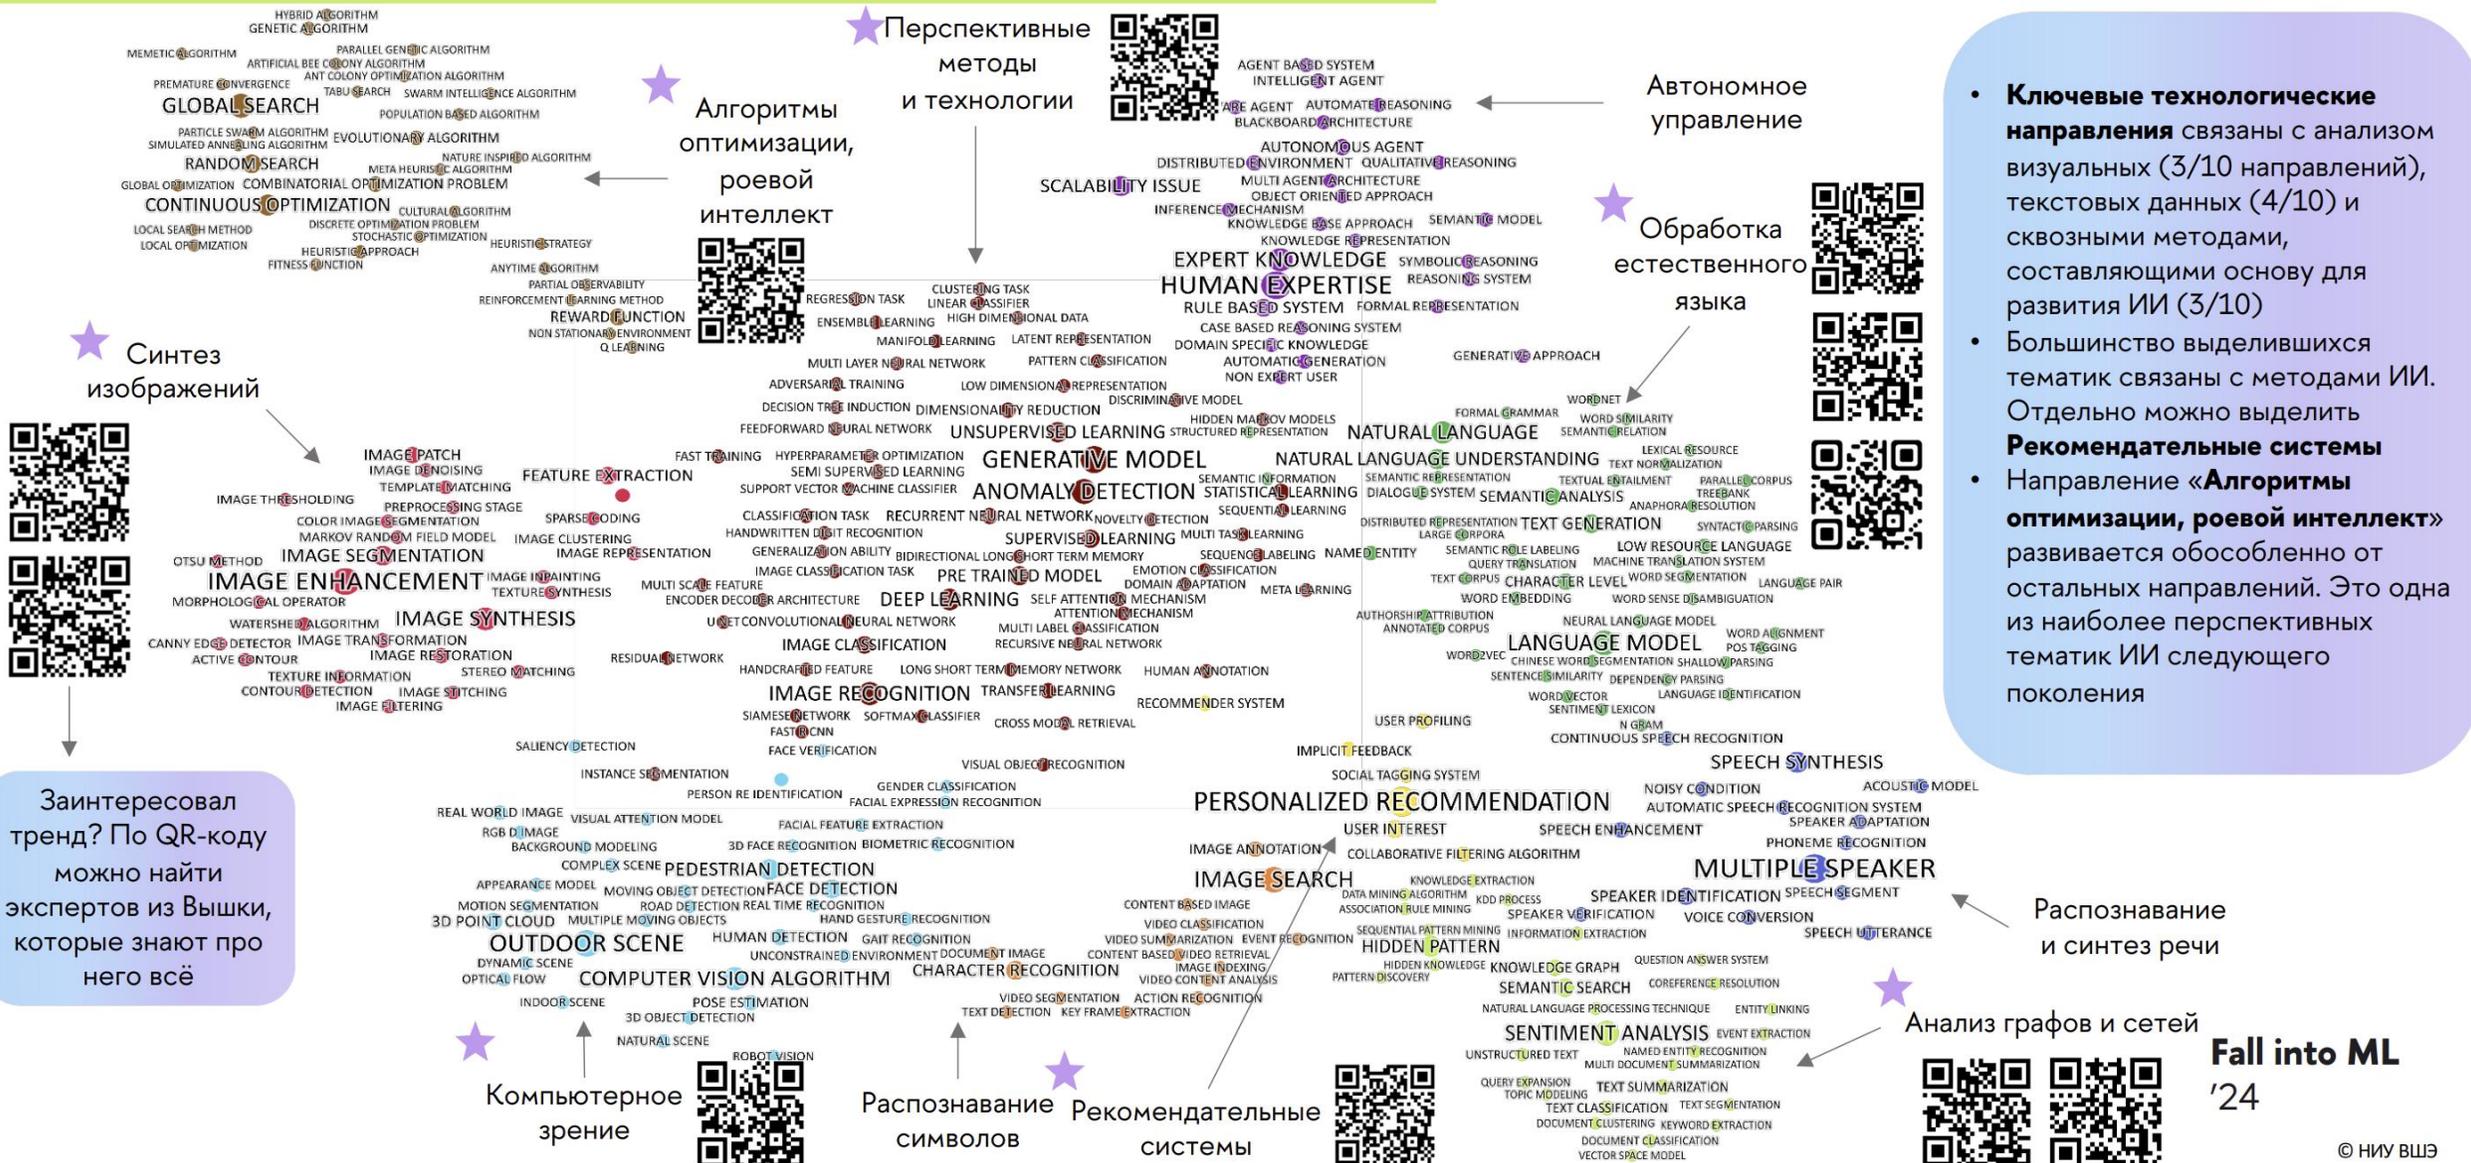
DataOps: Apache Airflow, Prefect, Kafka, DBT

ML Платформы: Weights & Biases, Neptune.ai, ClearML.

Сервинг моделей: TensorFlow Serving, TorchServe, Flask, FastAPI, KServe, Nvidia Triton, Nuclio (Serveless)

Картирование тематического ландшафта

Кейс: выявление направлений развития ИИ



- **Ключевые технологические направления** связаны с анализом визуальных (3/10 направлений), текстовых данных (4/10) и сквозными методами, составляющими основу для развития ИИ (3/10)
- Большинство выделившихся тематик связаны с методами ИИ. Отдельно можно выделить **Рекомендательные системы**
- Направление «**Алгоритмы оптимизации, роевой интеллект**» развивается обособленно от остальных направлений. Это одна из наиболее перспективных тематик ИИ следующего поколения

Заинтересовал тренд? По QR-коду можно найти экспертов из Вышки, которые знают про него всё

Fall into ML '24

Выявление и оценка технологических трендов

Кейс: выявление наиболее перспективных цифровых технологий

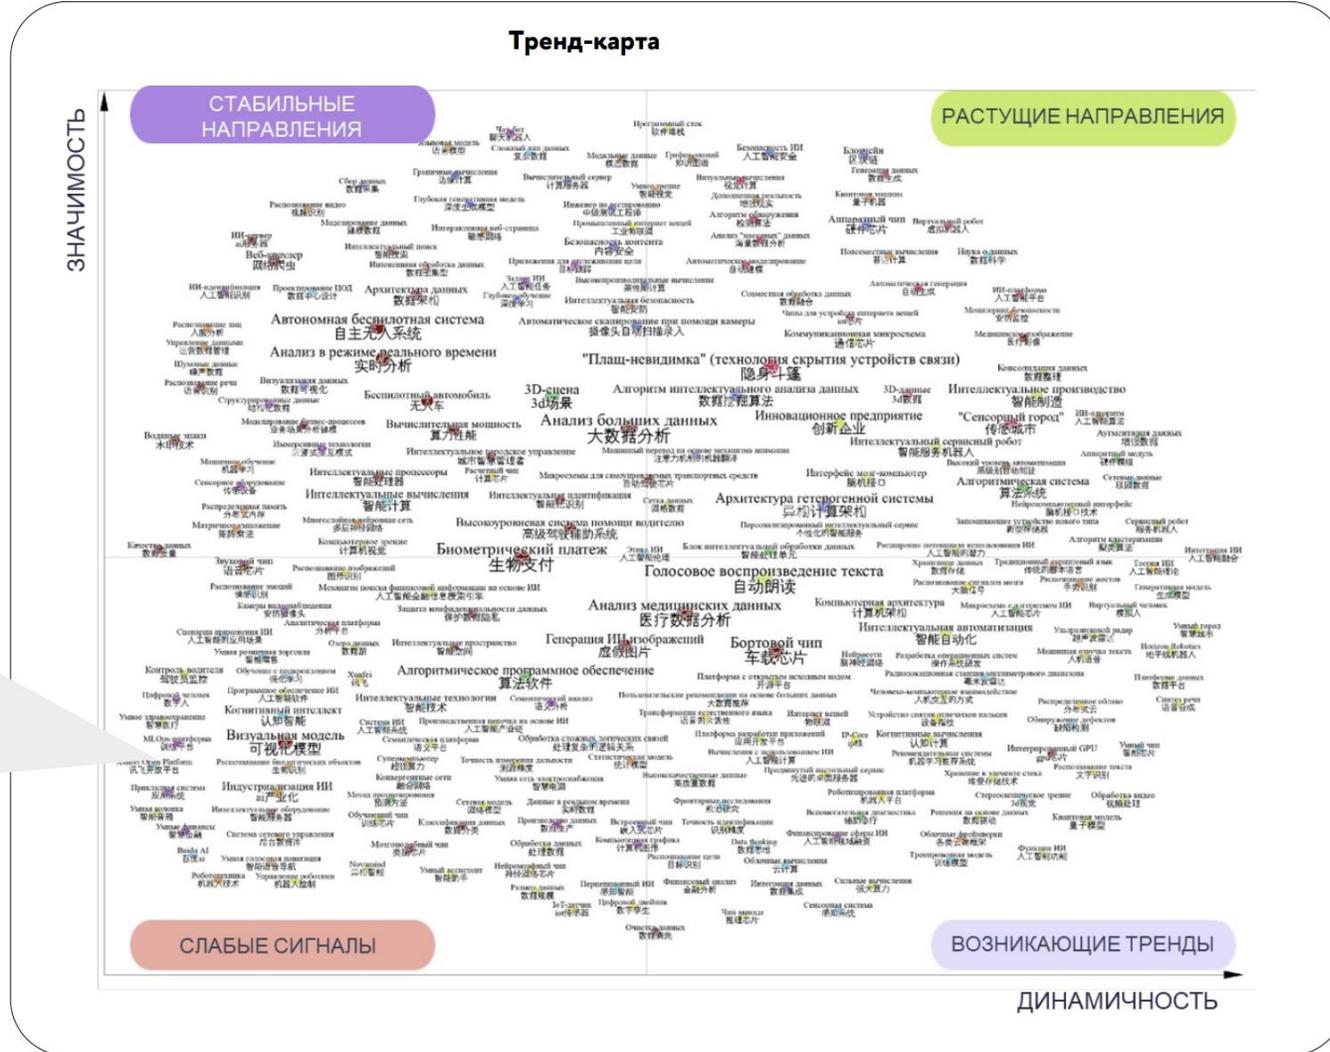
Задача: Отбор наиболее перспективных трендов и технологических направлений

Решение: Извлечение из текстов на китайском языке ключевых тематик по семантическим показателям, оценка их значимости и динамичности на тренд-карте

Эффект: Определение потенциальных «точек роста» для компании на основе объективной оценки развития трендов, выбор стратегии

В зависимости от комбинации значимости и динамичности технологические разработки могут быть классифицированы по **четырем типам тренда**

Приоритетами для дальнейшего анализа являются разработки с **высокой значимостью и динамичностью**

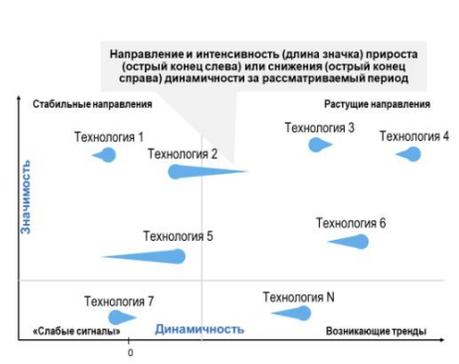


Другие варианты визуализации

Ранг	Технологии	Индекс значимости	Уровень динамичности	Сроки массового внедрения
1	Интернет медицинских вещей (IIoT)	1.00	→	3-5 лет
2	Трендовые вычисления и облачный Интернет вещей	0.97	→	3-5 лет
3	Мобильный Интернет вещей	0.81	→	3-5 лет
4	Искусственный интеллект вещей (IIoT)	0.70	→	3-5 лет
5	Интернет вещей для умного города / дома	0.58	→	3-5 лет
6	Интернет вещей для умного транспорта	0.23	→	3-5 лет
7	Ступенчатый Интернет вещей	0.21	→	4-6 лет
8	Новый Интернет вещей	0.16	→	3-5 лет
9	Интернет Интернет вещей и периферийных устройств	0.12	→	3-5 лет
10	Интернет вещей на транспорте	0.09	→	3-5 лет

Легенда:
→ Стабильные
→ Растущие
→ Быстрорастущие

Дополнительные возможности: картирование направления динамики трендов



**Серия докладов
ИИ в финансах**

«Мультимодальные эмбединги»



MULTIMODALITY FOR EMBEDDINGS

THE USE OF ADDITIONAL DATA (MODALITIES) ENHANCES THE QUALITY OF CUSTOMER EMBEDDINGS

MULTIMODAL EMBEDDINGS CAN BE APPLIED TO THE SAME TASKS AS TRADITIONAL EMBEDDINGS BUT PERFORM BETTER

EXAMPLES OF MODALITIES

- PURCHASE HISTORY
- FINANCIAL OPERATIONS
- TRANSFERS
- CUSTOMER COMMUNICATIONS
- WEBSITE AND APP ACTIVITY
- RECEIPTS

IMPROVEMENTS FOR INDIVIDUAL SOURCES

- RAW, NOISY DATA
- LARGE CATEGORY DICTIONARIES
- RARE EVENTS WITH LIMITED COVERAGE

NEW TYPES OF DATA

- GEOLOCATION DATA
- GRAPHS
- TEXT

MULTIMODAL BANKING DATASET

THE LARGEST OPEN-SOURCE MULTIMODAL BANKING DATASET

DATA FROM 2 MILLION CLIENTS HAS BEEN COLLECTED AND ANONYMIZED

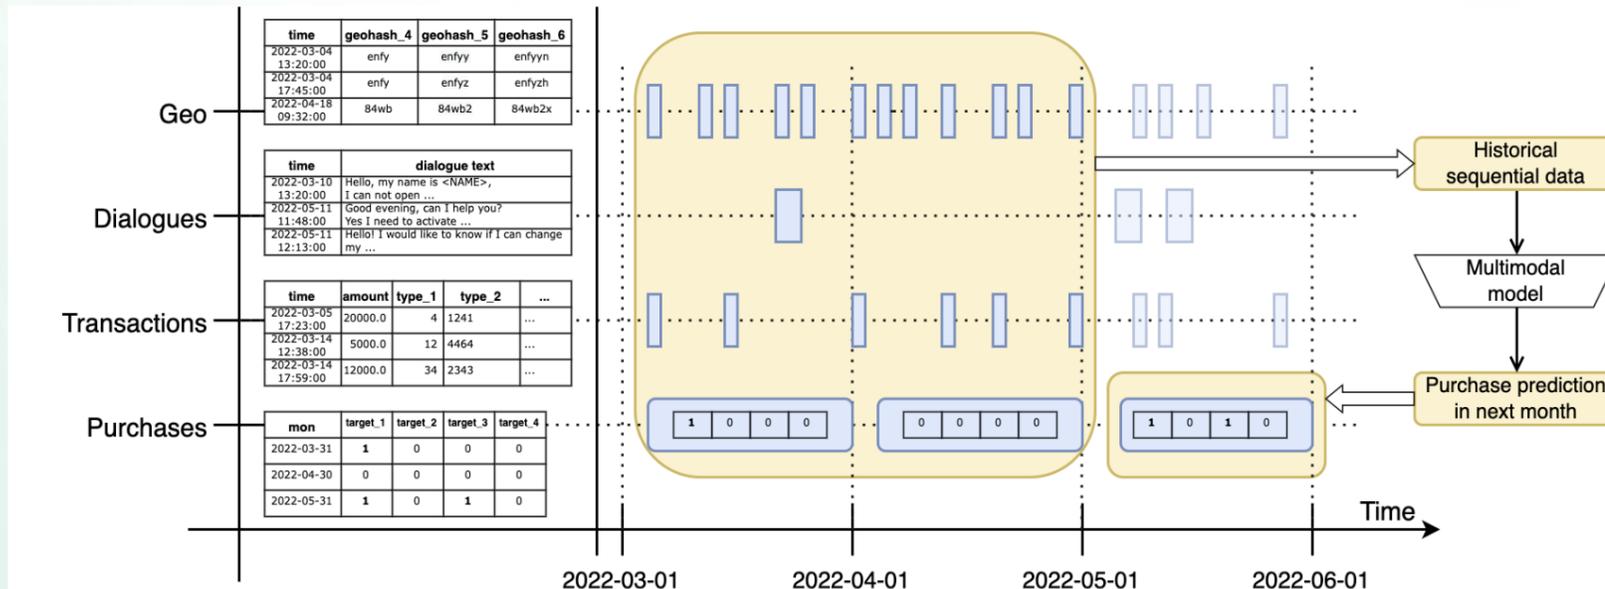
MODALITIES:

- TRANSACTIONS
- DIALOGUES
- GEOSTREAM

TASK:

PREDICTING THE PURCHASE OF 4 PRODUCTS FOR THE NEXT MONTH

LINK ON
HUGGING FACE:



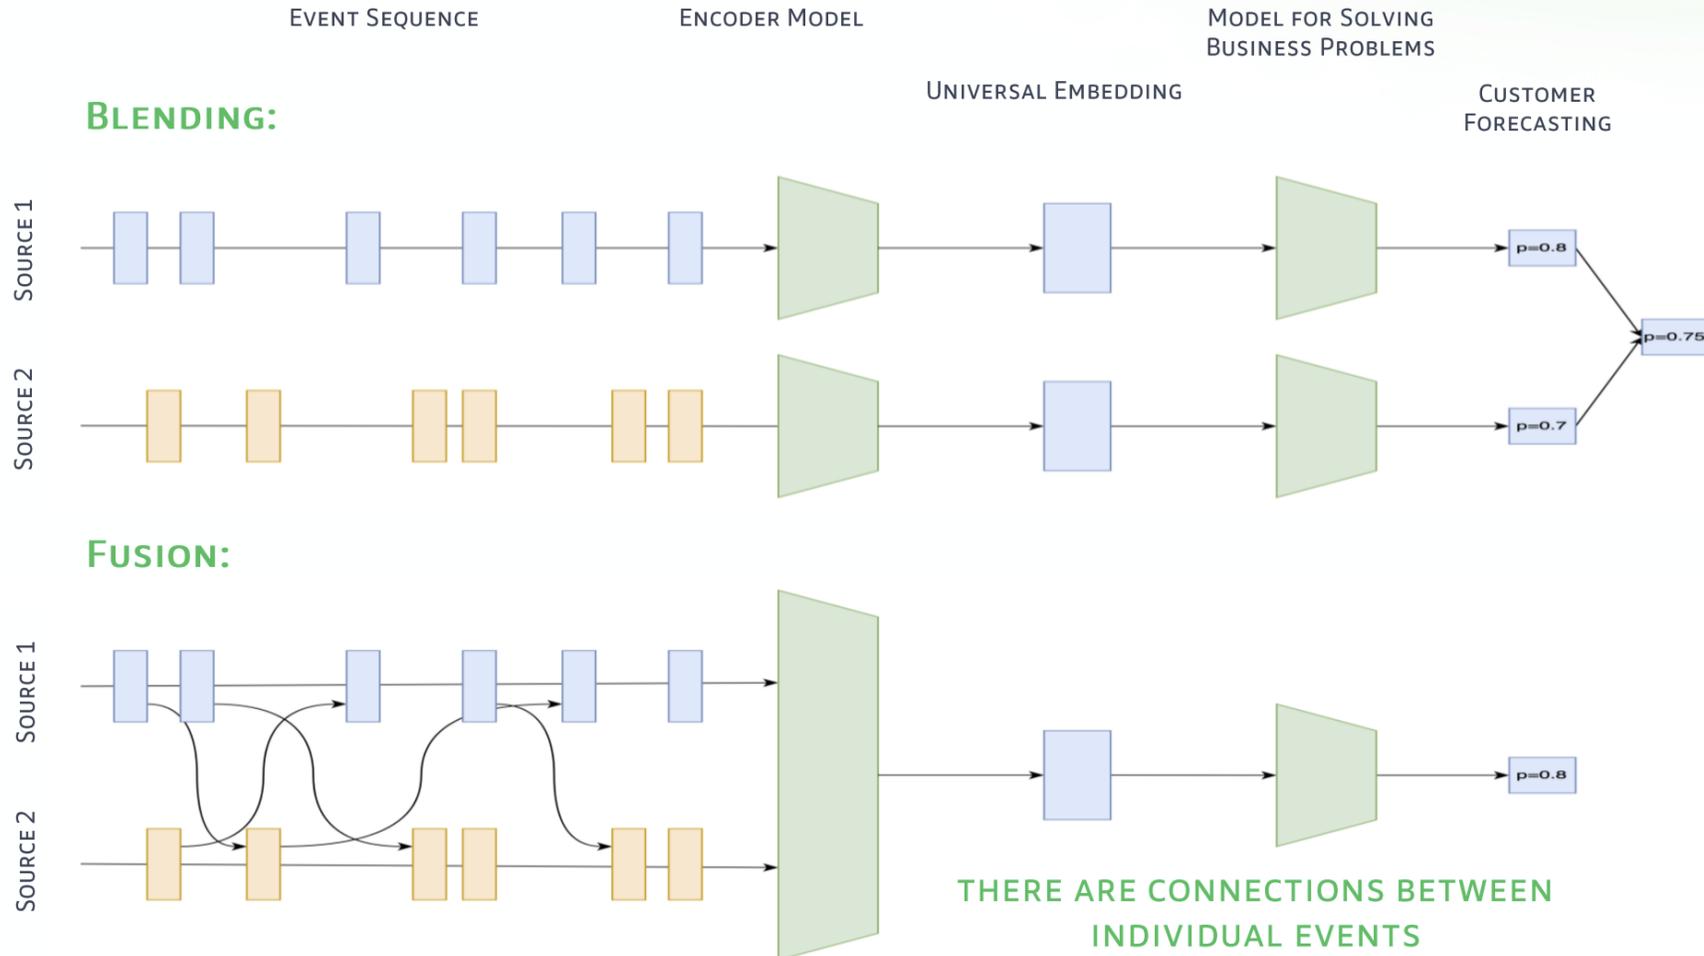
[HTTPS://ARXIV.ORG/ABS/2409.17587](https://arxiv.org/abs/2409.17587)

DEEPER UTILIZATION OF ADDITIONAL DATA RESULTS IN HIGHER QUALITY

OPTIONS FOR COMBINING MODALITIES:

- WITHOUT USING ADDITIONAL DATA
- BLENDING
- LATE FUSION
- EARLY FUSION
- MID FUSION

FUSION OF MODALITIES - ACCOUNTING FOR DEEP RELATIONSHIPS

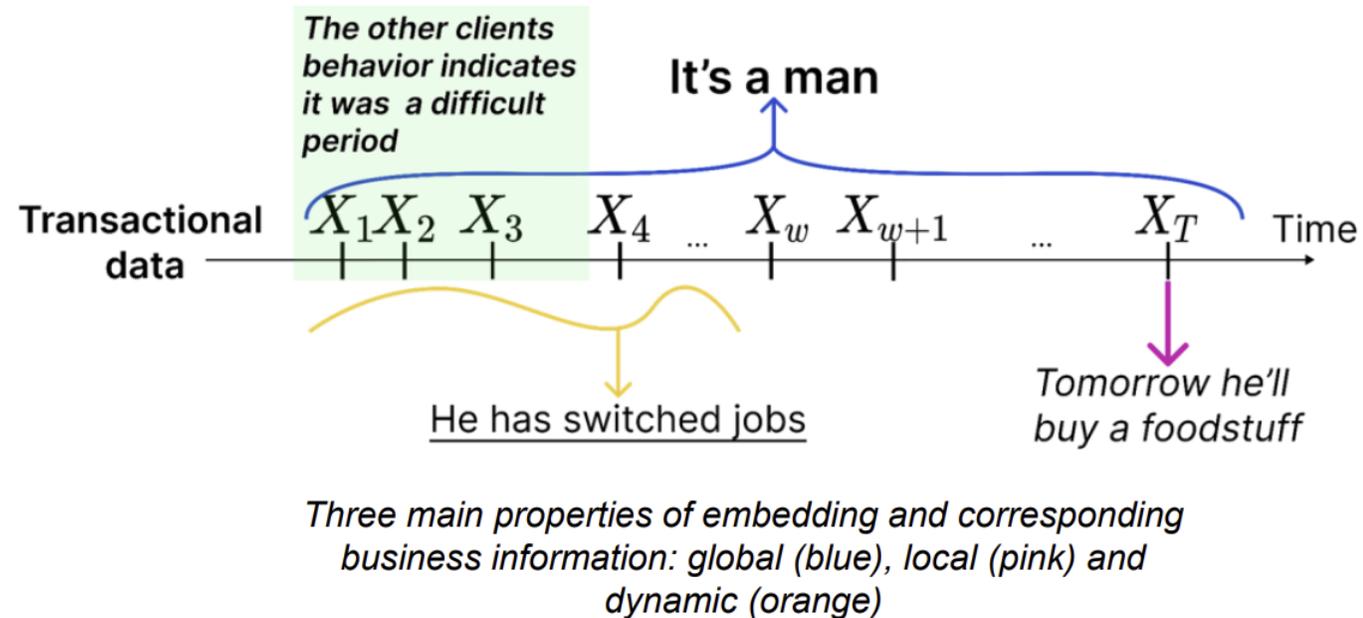


Properties of event sequence embeddings

Goal: to obtain a good encoder for transactional data

Three main properties of local embedding for transactional data:

1. **Global property** - describe a client in general;
2. **Local property** – describe a client's state at a particular moment in time;
3. **Dynamic property** - the embeddings should change with time, reflecting the changes in the client's behavior.



**Серия докладов
ИИ в финансах**

**«Продвинутый Event-study на примере
фарм-компаний»**

Problem statement



Our goal is to predict price change after influential events

Published paper

New drugs and stock market: a machine learning framework for predicting **pharma market** reaction to clinical trial announcements

Time Series



Events



1. Sentiment polarity extraction from clinical announcements

**Positive
Announcements**

Keywords: “approve”,
“meets”, “show”

**Negative
Announcements**

Keywords: “failed”,
“halted”, “did not reach”

**Neutral
Announcements**

1. Compose dictionaries with keywords that reflect the announcement polarity
2. Train BERT on announcement texts and a rule-based markup
3. Complement dictionaries with keyword from mistakenly classified texts

1. Sentiment polarity extraction from clinical announcements

Positive Announcements

Keywords: “approve”,
“meets”, “show”

+

“demonstrate”,
“potential”, “accepted”,
“encouraging”

Negative Announcements

Keywords: “failed”,
“halted”, “did not reach”

+

“terminated”,
“discontinued”,
“insufficient”, “paused”

Neutral Announcements

2. Construction of feature space

Market features

- NASDAQ biotechnology index
- Mean number of trading volume peaks per year
- Stock price trend for the last 30 days before the event

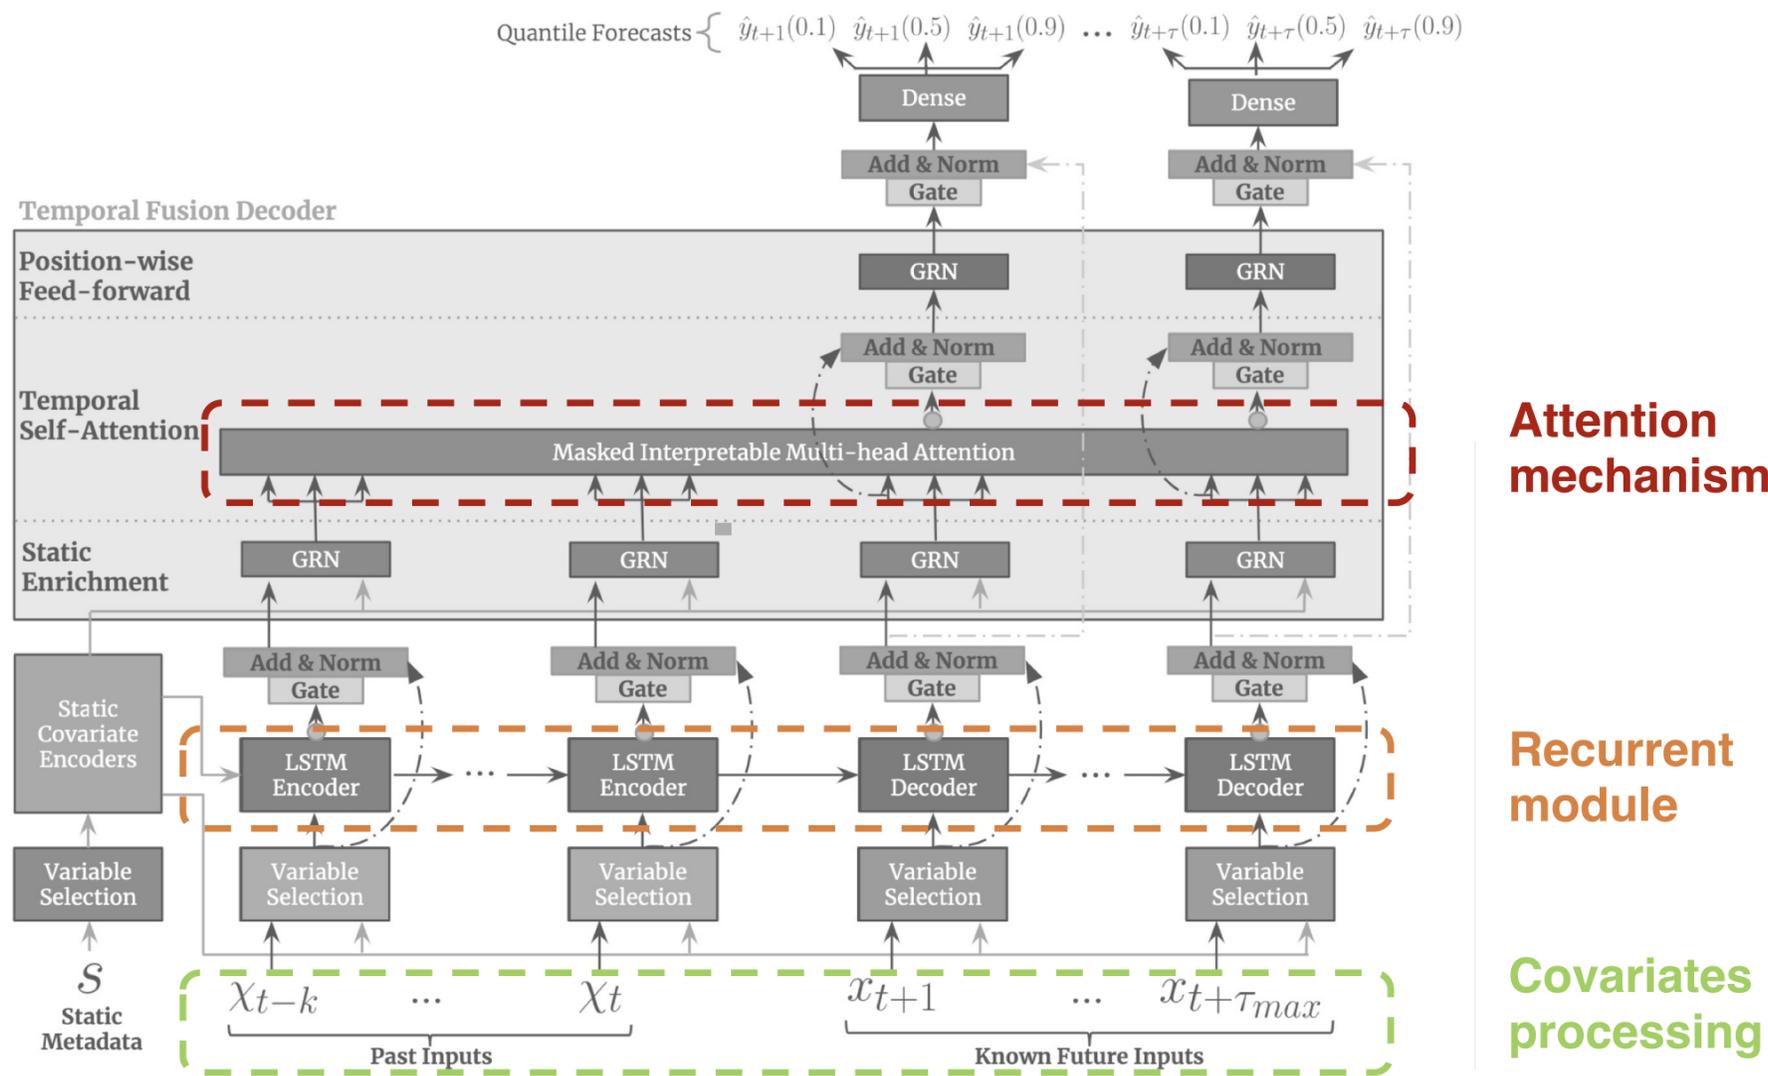
Company features

- Income statement
- Full-Time Employees
- Cash flow

Announcement features

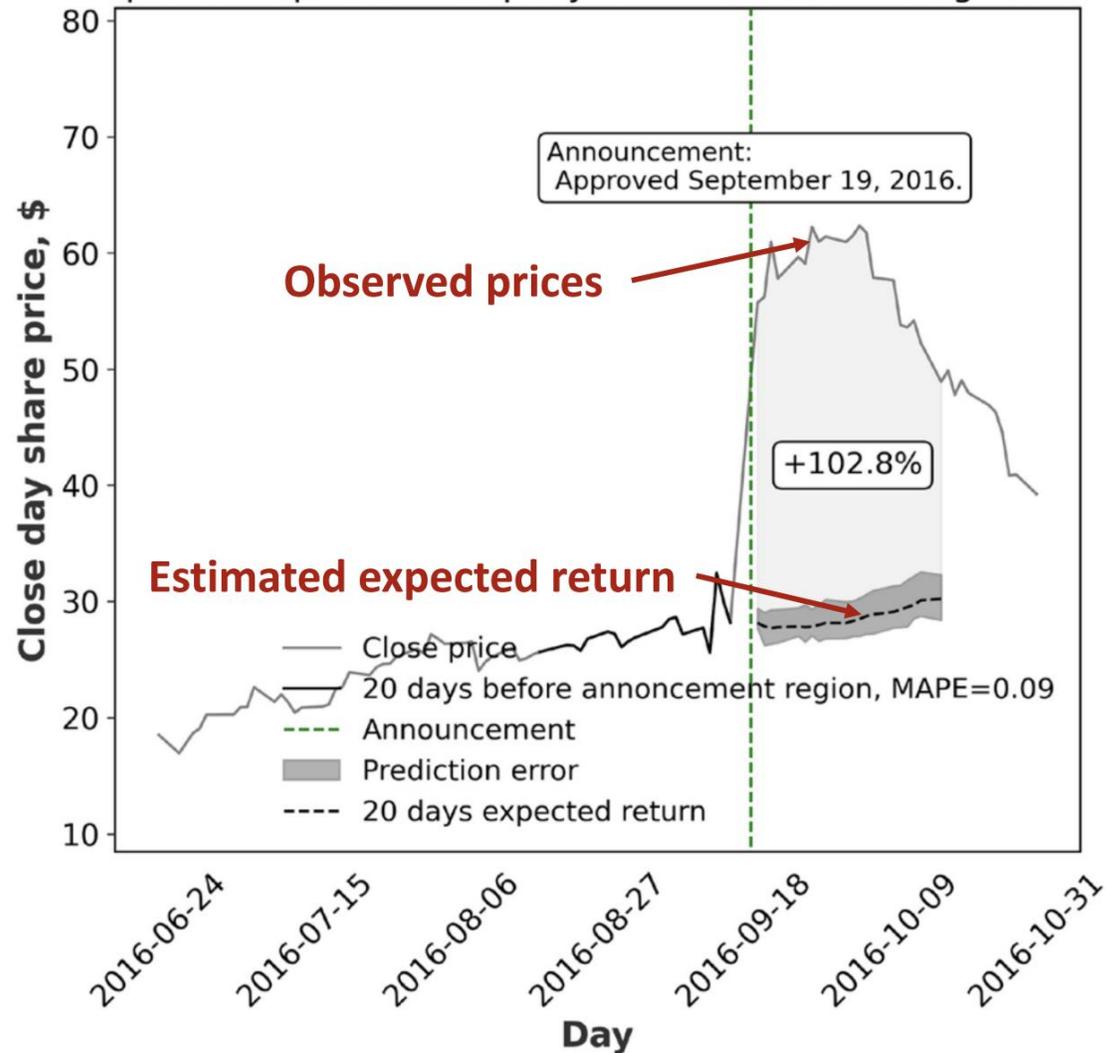
- Announcement sentiment polarity
- ICD-10 codes

3. Evaluation of expected return



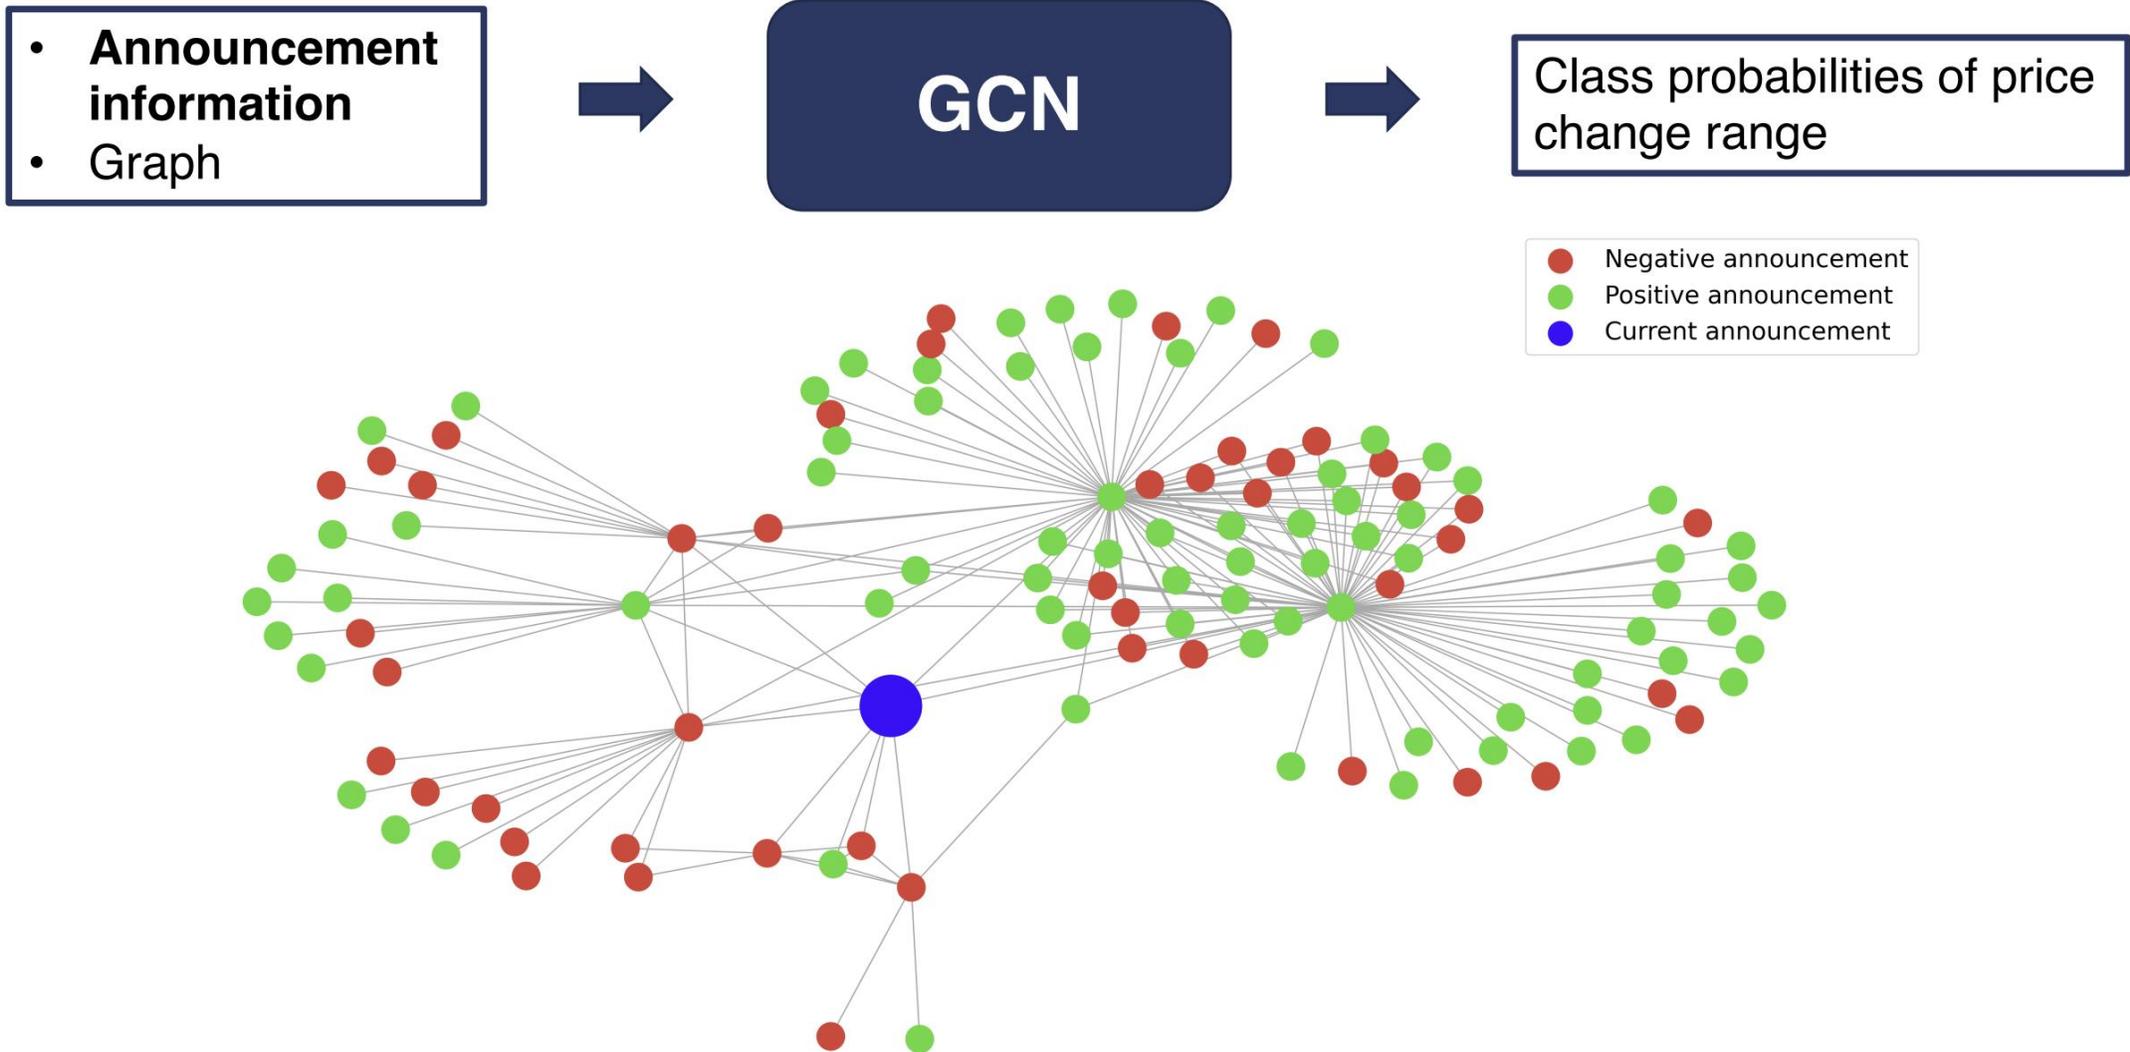
3. Evaluation of expected return

The Sarepta Therapeutics company with news about drug 'EXONDYS 51

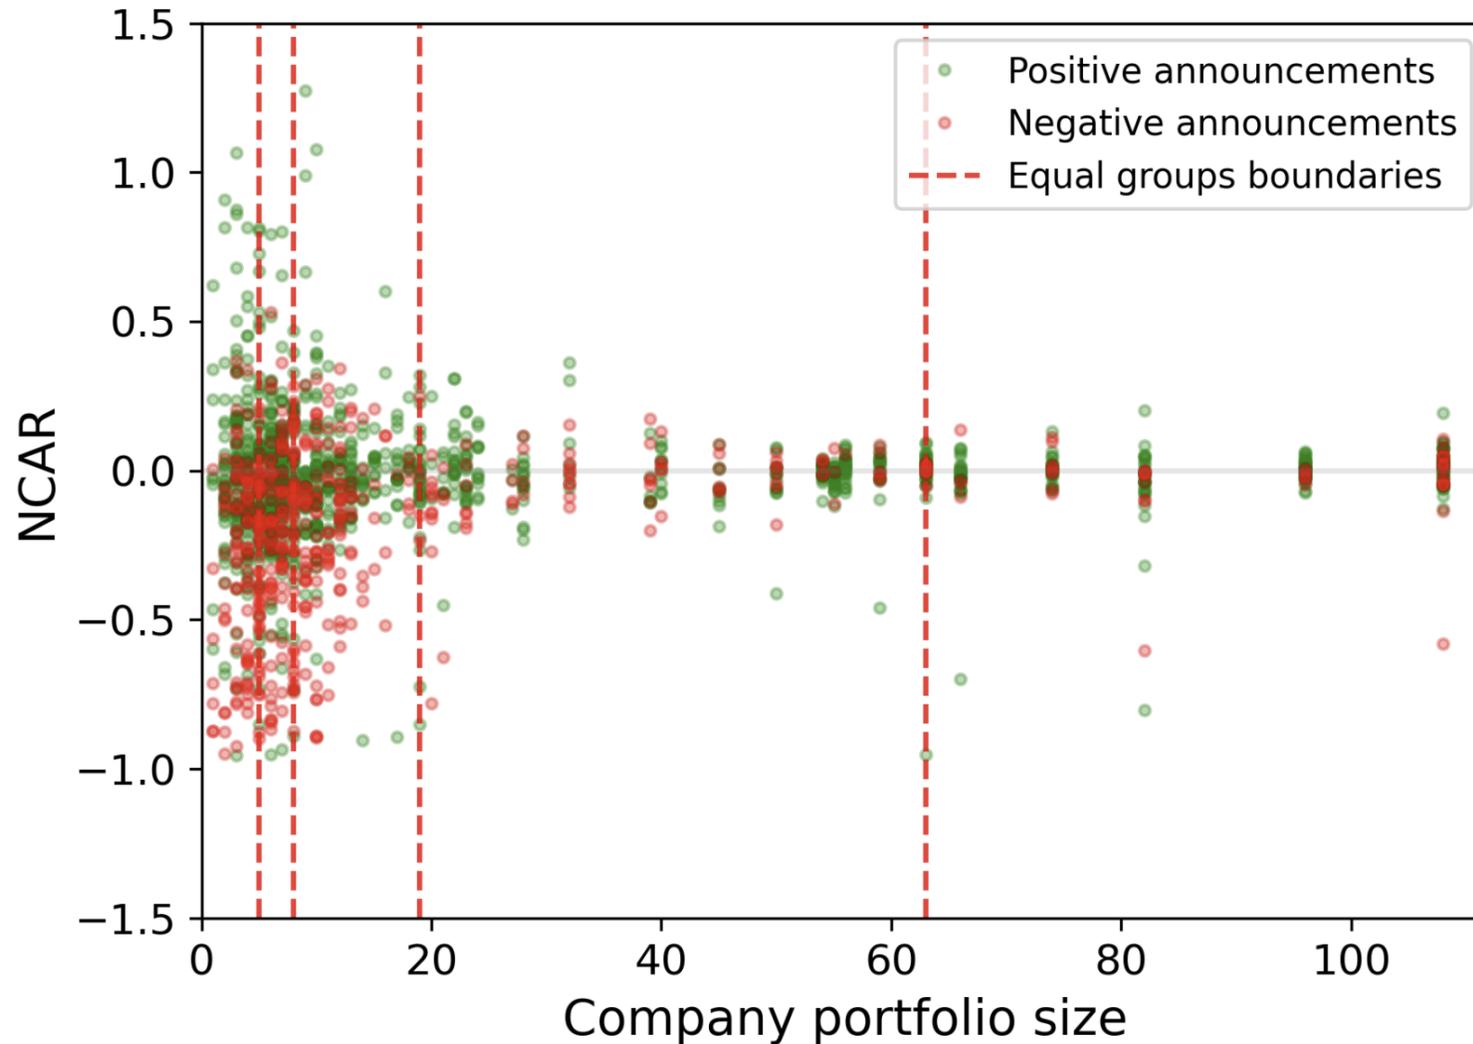


Expected return estimation allows calculating a target value, NCAR_20

Adoption of GCN

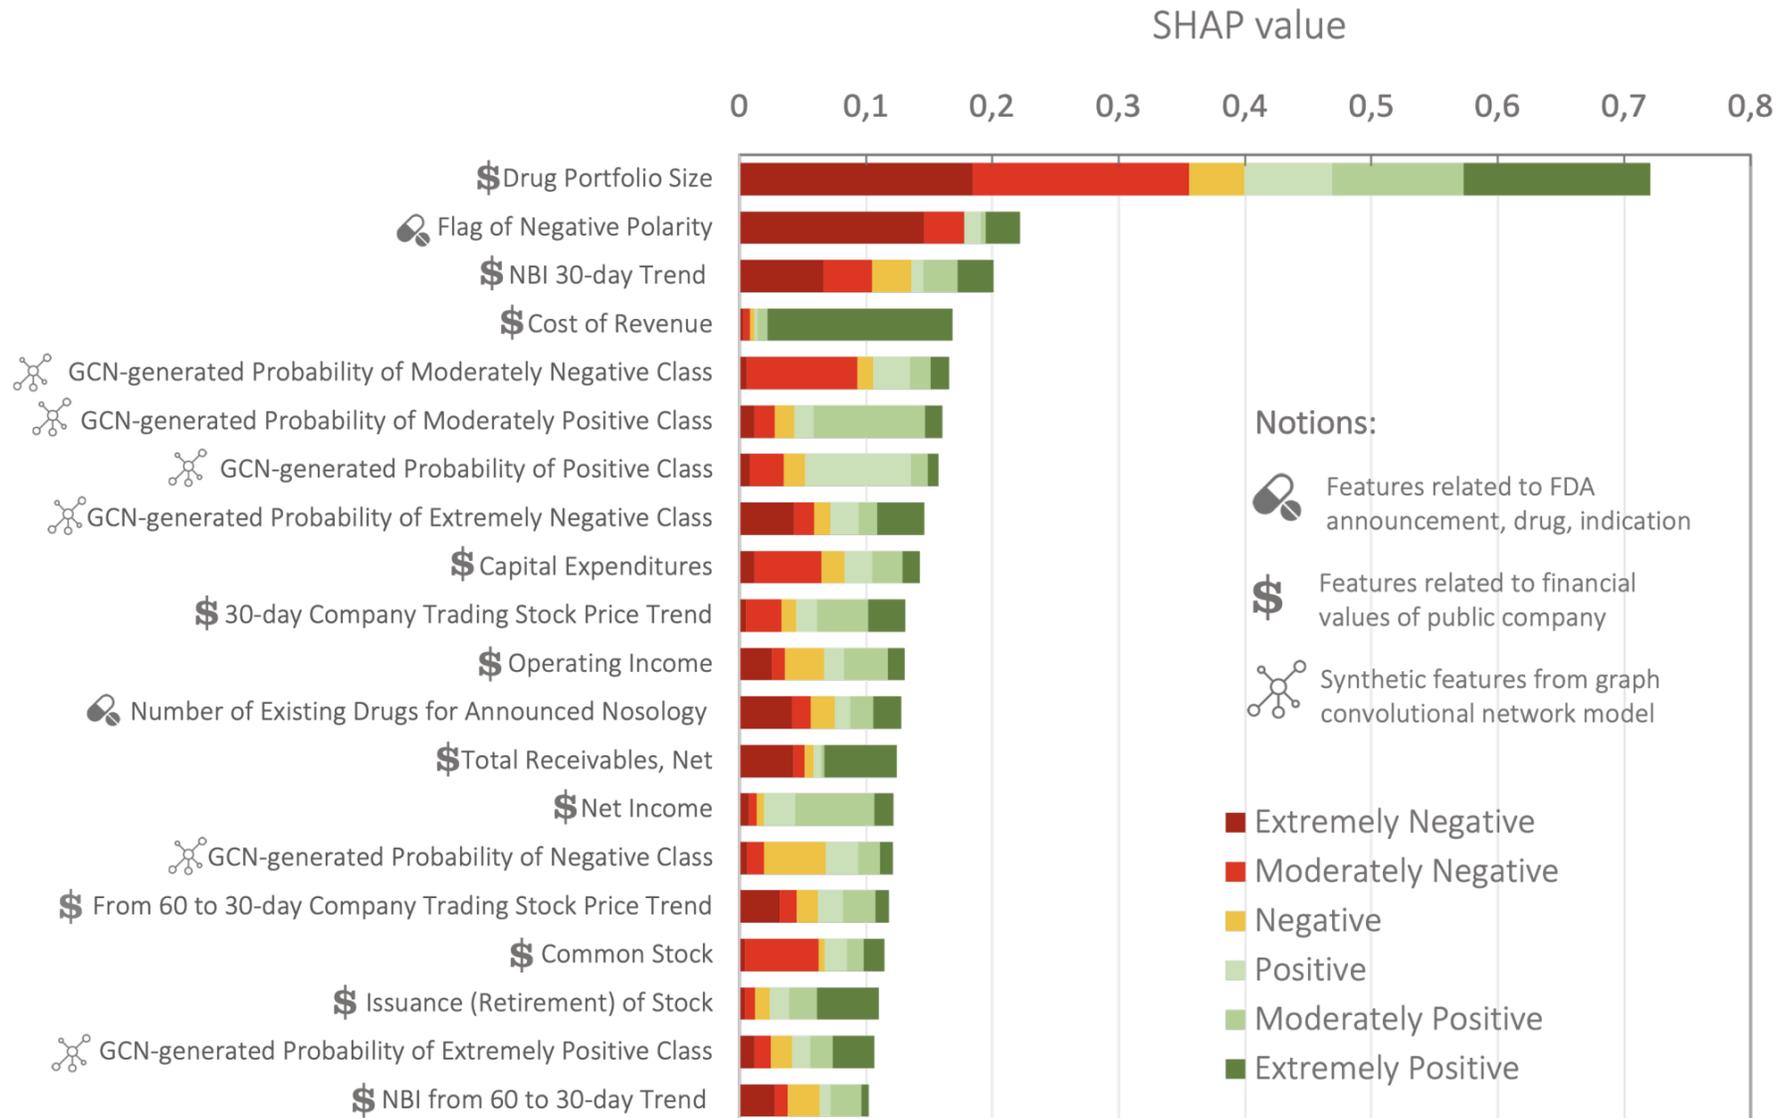


Impact of company background on stock prices



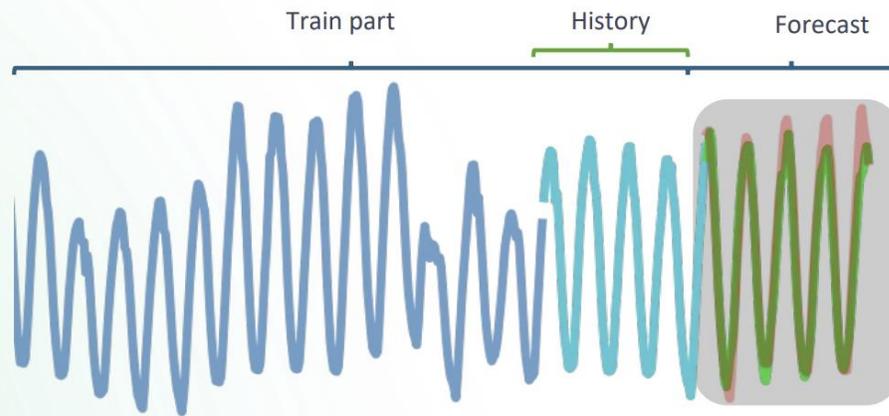
Generation of diverse feature space is important

Feature importance analysis

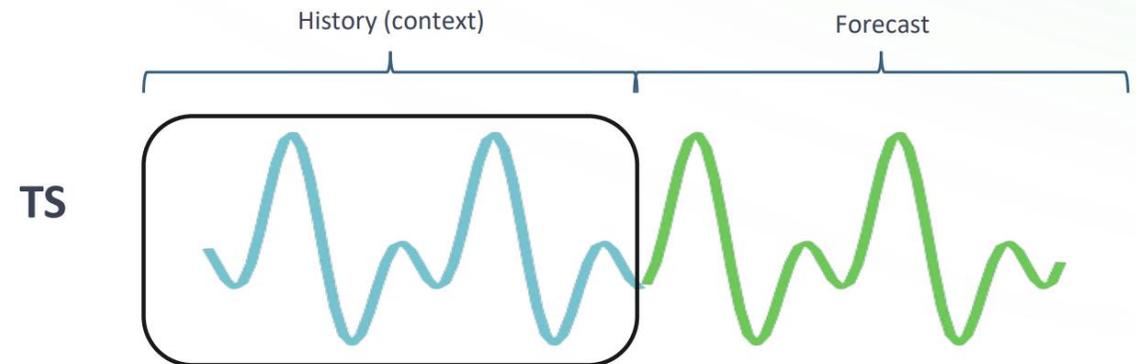


Supervised vs Zero-shot models

Supervised: Train the model to predict labels for new data based on patterns identified in the **training data**.



Zero-shot: Train the model to predict labels for new data **without training on the target dataset**, based on patterns identified in the unrelated data.

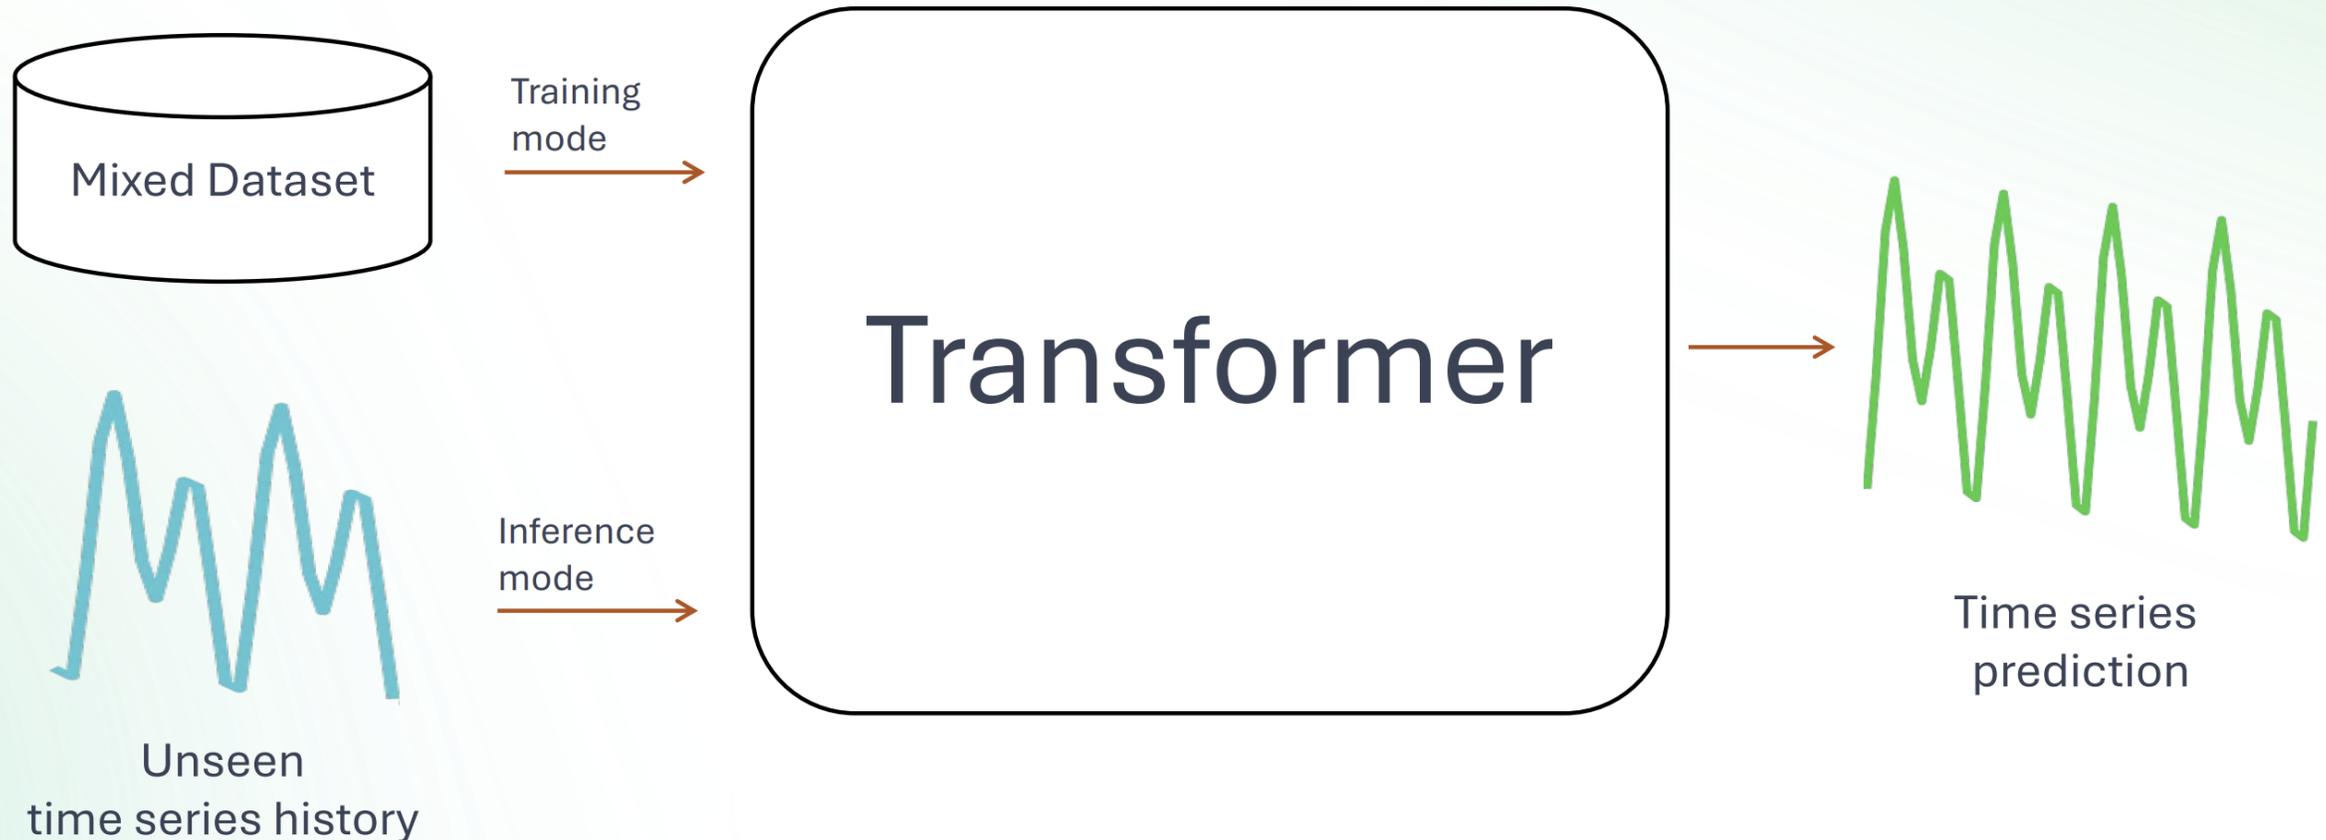


Серия докладов ИИ в финансах

«Zero-shot метод прогнозирования временных рядов»

Zero-shot models

- Zero-shot models for time series are mainly Transformers
- They require a large and diverse dataset for pretraining



How does Zero-shot fit the requirements from data?

Let's return to our table

Methods Group	Data scarcity	Flexibility and adaptability	Exogenous variables
Naive methods	+	-	-
Statistical methods	+	-	+ -
ML methods	+ -	+ -	+
DL methods	-	+	+
Zero-shot	+	+	+

The variety of Zero-shot models

Zero-shot models for time series are an actively developing area

LLM

Non-adapted LLM

- [LSTPrompt](#)
- [PromptCast](#)
- [LLMTime](#)

Adapted LLM

- [Time-LLM](#)
- [FPT](#)
- [Chronos](#)
- [UniTS](#)
- [DAM](#)

Specialized

Using synthetic data

- [ForecastPFN](#)

Using real data

- [GPHT](#)
- [MOIRAI](#)
- [Moment](#)

