

# DATA meetUp

 **click**

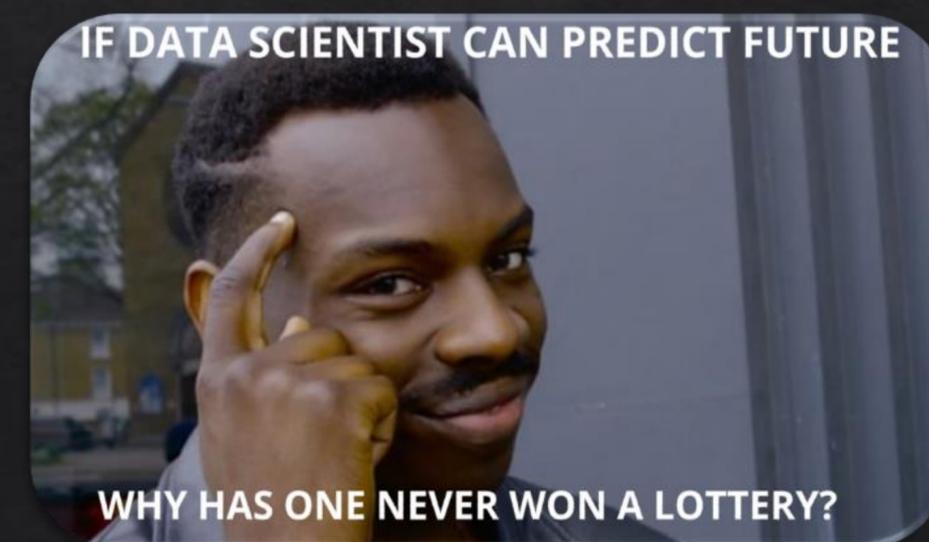
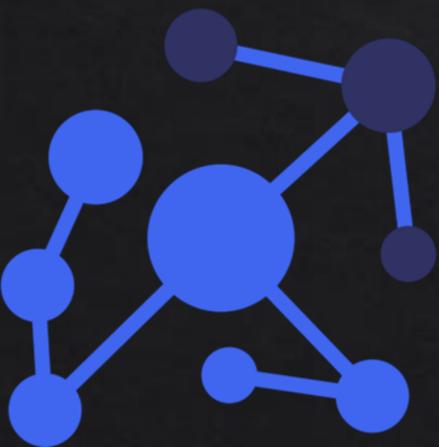
 **online**

 **offline**

# Как предсказать будущее? Временные ряды без мистики.

## Арсенал дата саентиста: от ARIMA до трансформеров

1. Временные ряды: гадание или наука?
2. Классика vs. Современность: что выбрать?
3. Инструменты предсказания будущего: чем пользуются дата саентисты?



# Дониёр Умаров

Data Scientist @Click



 стек: Python, SQL, TS, RecSys, NLP

 Люблю данные и делать с ними что-то интересное

 Хобби: Спорт, путешествия, музыка

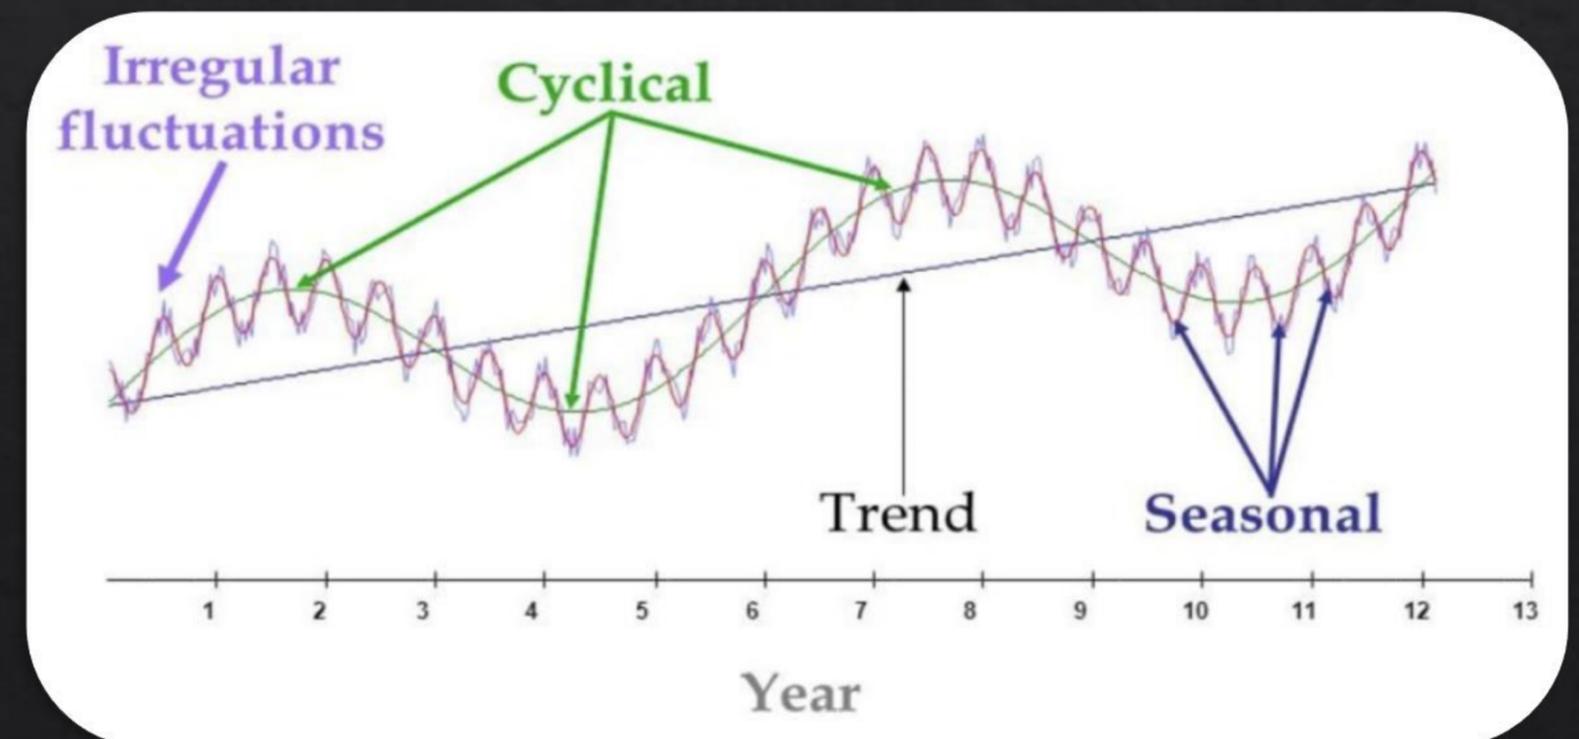
# Временные ряды — гадание или наука?

Варим суп из данных: что входит в состав временного ряда?

**Временной ряд** — значения меняющихся во времени признаков, полученные в некоторые моменты времени.

**Свойства временных рядов:**

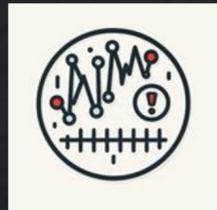
- Тренд
- Сезонность
- Цикл(ы)
- Ошибки (шум)
- Стационарность



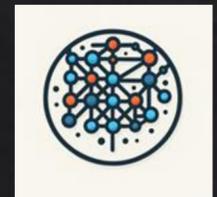
# Классы задач в Time Series:



1 - Прогнозирование



2 - Детекция аномалий



3 - Кластеризация

# Где временные ряды уже применяются:



 Финансы – прогноз курсов валют, планирование бюджета, управление рисками



 Маркетинг – анализ трафика, прогноз продаж, оптимизация запасов, анализ сезонности спроса



 Производство - предиктивное обслуживание оборудования, прогнозирование спроса на энергию



# Классика vs. Современность

Почему классика никогда не вымрет?

## Мало данных — нейросеть бессильна

- Классические модели (ARIMA, Holt-Winters, ETS) могут работать даже на **30–50** точках.

## Интерпретируемость — классика понятна

- ARIMA → можно разобрать тренд, сезонность, лаги.
- Holt-Winters → наглядно видно вклад каждой компоненты.
- DL → «чёрный ящик» (особенно без XAI).

## Быстрота и простота

- Настроить ARIMA можно за 2 минуты (особенно с [auto\\_arima](#)).
- Holt-Winters и ETS обучаются **почти мгновенно**

## Хорошо работает при "чистой сезонности" и тренде

- Если ряд описывается простой формулой: тренд + сезонность + шум → классика работает **идеально**.
- DL не даст прироста, а может даже проиграть.

|  |  |
|--|--|
|   | LSTM,<br>N-BEATS, RNN,<br>Autoencoders,<br>TSMixer |
|  | HoltWinters,<br>SARIMAX,<br>ARIMA                  |

# А когда НС начинают рулить?

Если модель видит всё — даже то, чего не видим мы

## Сложные и нелинейные зависимости:

- Нейронные сети эффективны при моделировании сложных, нелинейных зависимостей в данных, где традиционные методы могут быть недостаточно точными.
- Способны учитывать **неочевидные взаимодействия между признаками** и их комбинации.
- Признаки вроде **новостного фона, тональности, индикаторов настроения** не всегда напрямую коррелируют с целевым рядом, но нейросеть может уловить **скрытую связь**.

## Долгосрочный прогноз — нейросети в преимуществе

- DL может делать **direct forecasting** (весь горизонт за раз).
- Меньше накопления ошибок, чем при пошаговом прогнозе.
- TS-Mixer и N-BEATS показывают хорошие результаты на горизонтах 30+.

## Устойчивость к шумам и выбросам

- Использование **батчей** и **итеративного обновления весов** → меньше шансов "запомнить" шум.
- **Регуляризация, dropout и ранняя остановка** помогают не переобучаться на шумных участках.
- DL-модели легко обогащаются признаками (moving average, rolling std, external context), которые **сглаживают шум**, но при этом сохраняют важные сигналы.



# Инструменты предсказания будущего: чем пользуются дата сантиссты?

DATA  
meetUp



## Статистические библиотеки

- **Statsmodels** — классика  
→ Подходит для простых задач и быстрых baseline-прогнозов.
- **Prophet (Meta)** — удобный API, автообнаружение сезонностей и праздников.  
→ Быстрый старт, гибкость.

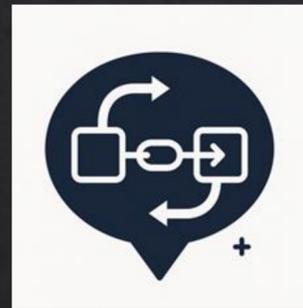


## ML & DL-фреймворки:

- **GluonTS, Darts** — фреймворки с поддержкой нейросетей и бустинга.  
→ Поддержка DeepAR, N-BEATS, TFT и других моделей.
- **PyTorch, TensorFlow, Keras** — когда нужна максимальная гибкость.

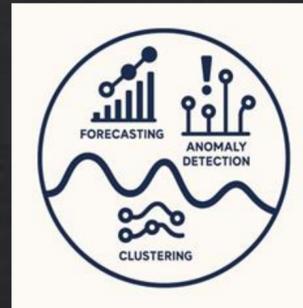
# ETNA - Современный комбайн для широкого спектра задач

## Преимущества ETNA:



### Единый конвейер (pipeline)

- end-to-end процесс
- Преобразование и генерация признаков
- Обучение и сохранение моделей



### Широкий спектр задач

- Прогнозирование
- Детекция аномалий
- Кластеризация



### Богатый выбор моделей

- Классические алгоритмы
- ML модели
- Современные НС для ts

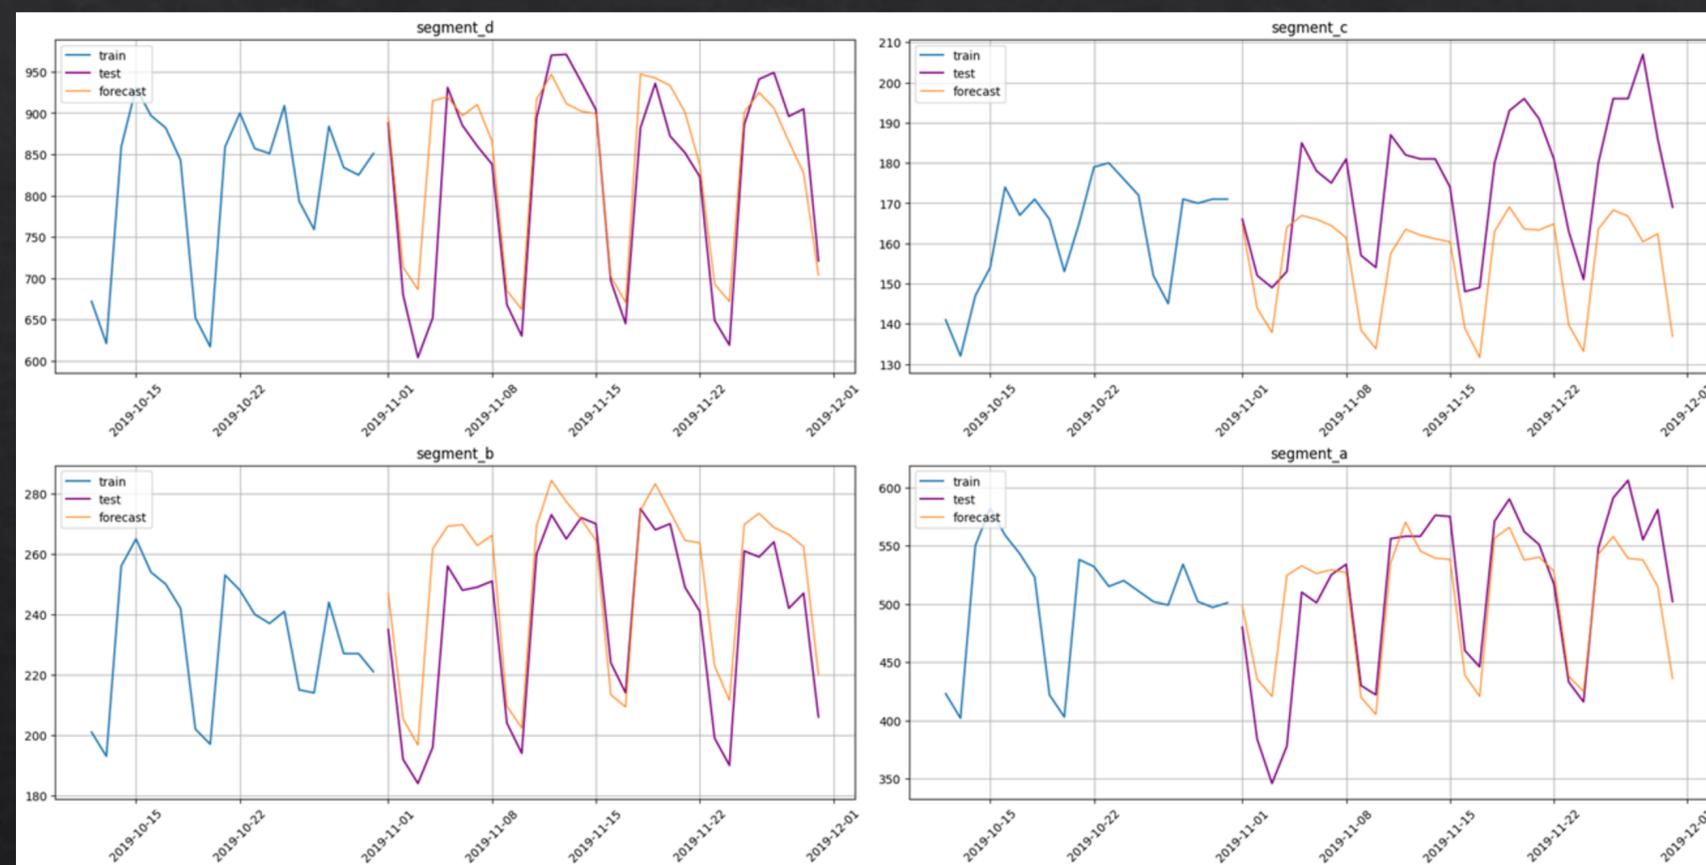
# Все серии под контролем.

Или как использование ETNA ускорила нашу работу с рядами

## Поддержка мультисейринности

Библиотека позволяет обучать модель сразу на нескольких временных рядах и получать одновременный прогноз по ним.

Специальная структура данных `TSDataset` хранит сразу несколько серий и сопутствующие признаки, упрощая работу с *multiseries* данными



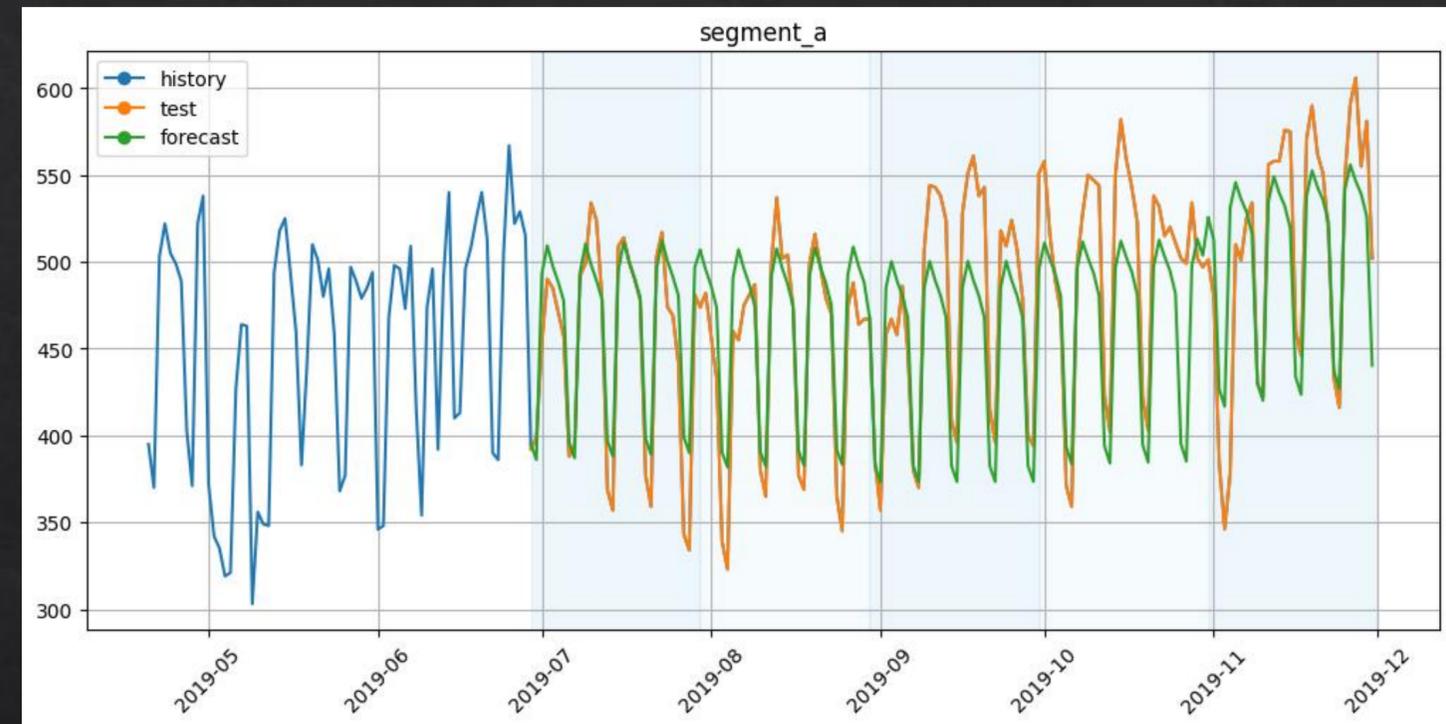
# Скользим по истории — проверяем будущее

## Встроенный backtest упростил работу с валидацией

**ETNA** - имеет средства для автоматизированного бэктестинга что упрощает проверку моделей на валидации.

Поддержка двух стратегий валидации:

- **Expanding window** - Обучающее окно растёт с каждой итерацией.
- **Constant window** - Обучающее окно фиксированной длины.



# Прогноз - это легко и понятно

## Как объяснить прогноз: инструменты интерпретации в ETNA

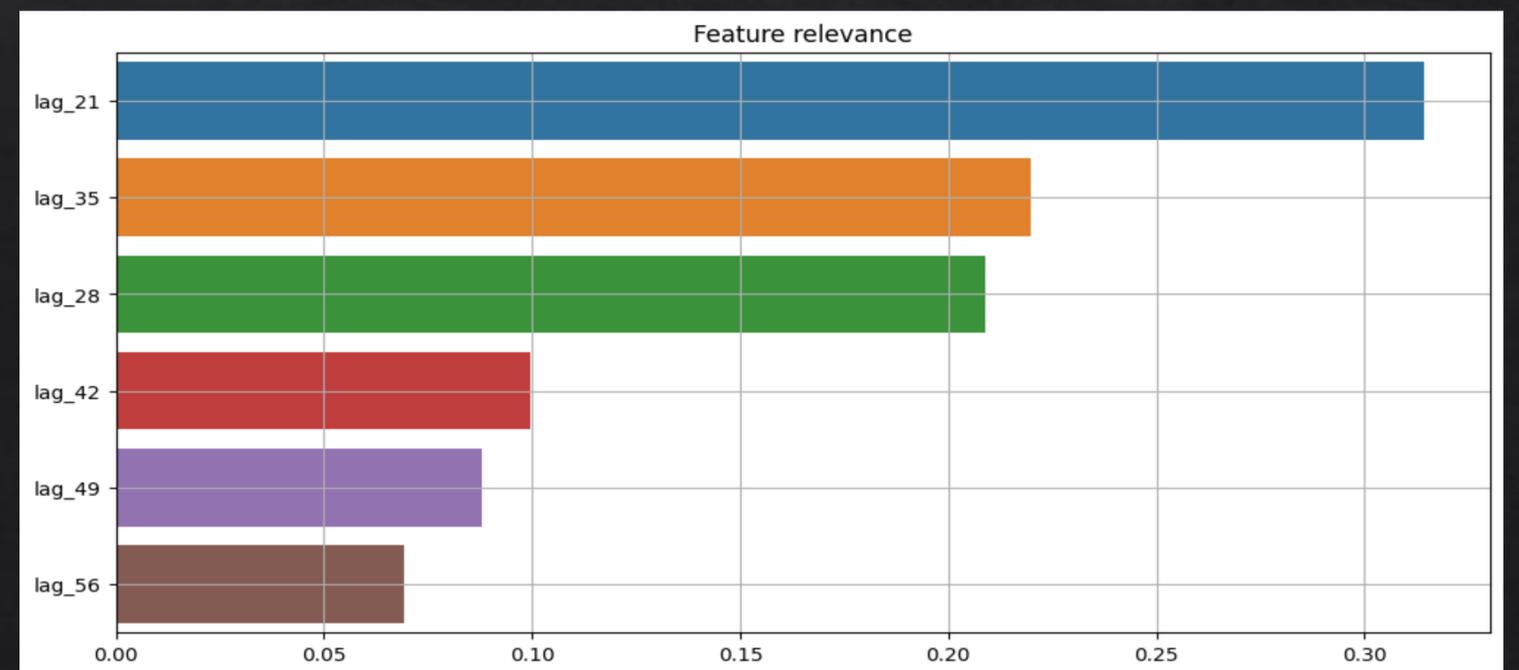
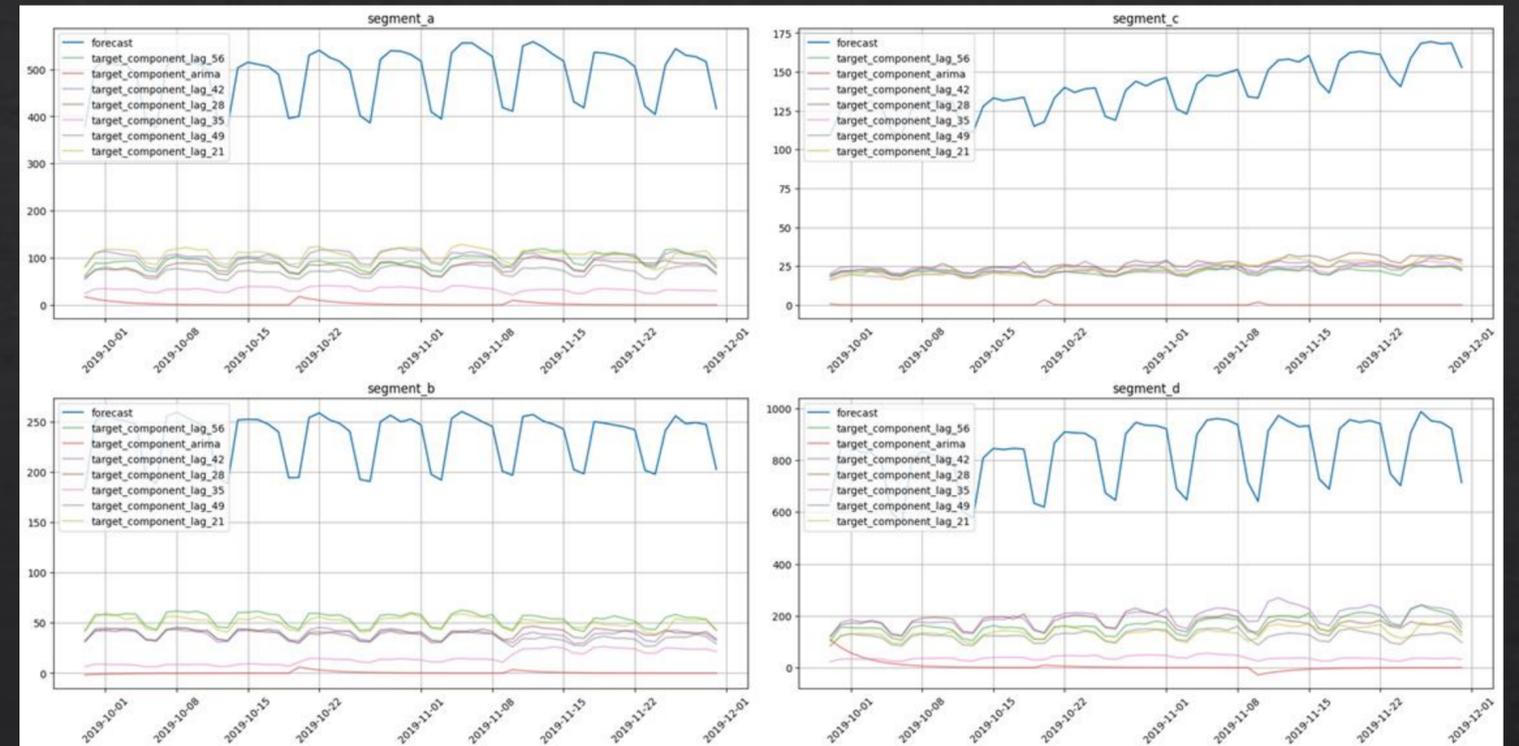
### Различные методы интерпретации прогнозов

#### - Forecast Decomposition

(model-specific decomposition  
model-agnostic decomposition)

#### - Feature importance

#### - SHAP



# ETNA следит за трендами

Zero-Shot прогноз, когда ChronosBolt уже всё знает

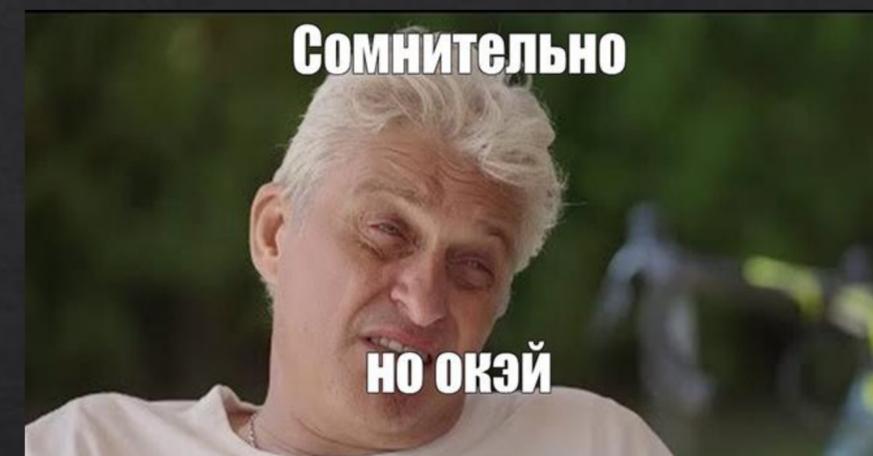
## ChronosBoltModel

— это предобученная нейросеть для прогнозирования временных рядов, интегрированная в ETNA.

Она использует архитектуру из Darts и модель от Hugging Face, что позволяет делать **zero-shot прогнозы** — без обучения на конкретном датасете.

## Интеграция с ETNA Pipeline

ChronoBoltModel - можно использовать как любую другую модель — с backtesting и мультисерийностью



# Как быть в тренде?

<https://paperswithcode.com/task/time-series-forecasting>

Time Series

## Time Series Forecasting

652 papers with code • 86 benchmarks • 43 datasets

**Time Series Forecasting** is the task of fitting a model to historical, time-stamped data in order to predict future values. Traditional approaches include moving average, exponential smoothing, and ARIMA, though models as various as RNNs, Transformers, or XGBoost can also be applied. The most popular benchmark is the ETTh1 dataset. Models are typically evaluated using the Mean Square Error (MSE) or Root Mean Square Error (RMSE).

( Image credit: [ThaiBinh Nguyen](#) )

### Benchmarks

Add a Result

These leaderboards are used to track progress in Time Series Forecasting

| Trend   | Dataset                  | Best Model  | Paper   | Code  | Compare                 |
|---|--------------------------|-------------|---|---|-------------------------|
|  | ETTh1 (336) Multivariate | D-PAD       |  |  | <a href="#">See all</a> |
|  | ETTh1 (720) Multivariate | DiPE-Linear |  |  | <a href="#">See all</a> |
|  | ETTh2 (336) Multivariate | xPatch      |  |  | <a href="#">See all</a> |
|  | ETTh2 (720) Multivariate | RLinear     |  |  | <a href="#">See all</a> |
|  | ETTh1 (192) Multivariate | PatchMixer  |  |  | <a href="#">See all</a> |
|  | ETTh2 (96) Multivariate  | PatchMixer  |  |  | <a href="#">See all</a> |

Edit



### Content

- [Introduction](#)
- [Benchmarks](#)
- [Datasets](#)
- [Subtasks](#)
- [Libraries](#)
- [Papers](#)
  - Most implemented
  - Social
  - Latest
  - No code

# Q&A