empenoso
14 окт в 05:24

Сможет ли языковая модель научиться читать биржевые графики? Эксперимент с LLM на данных Московской биржи

Средний 7 мин 12K

Open source*, Настройка Linux*, Python*, Финансы в IT, Машинное обучение*

Кейс

Представьте опытного трейдера: наверняка он не говорит котировками и не рассказывает про индикаторы — он просто говорит «сильный тренд», «пробой уровня» или «ложный отскок». Для него график это язык: свечи, объёмы и уровни складываются в понятные фразы о том, что сейчас происходит на рынке. Именно от этой человеческой интуиции я и отталкивался в своём эксперименте.

Идея была такая: а что, если научить искусственный интеллект понимать этот язык? Не подавать модели сырые числа, а переводить бары и объёмы в текстовые описания наблюдаемых паттернов и кормить ими языковую модель. Гипотеза была что в тексте уже будет содержатся достаточно данных, чтобы модель научилась связывать недавнюю торговую историю с тем, пойдёт ли цена вверх на следующий день.

Инструмент эксперимента — модель distilbert-base-uncased с Hugging Face и это облегчённая, быстрая версия BERT для понимания языка. Мне показалось это практичным выбором для прототипа — позволяет быстро проверять разные способы текстовой разметки без гигантских ресурсов. Цель была чёткая: по текстовому описанию недавней истории торгов предсказать рост цены на следующий день.

Но это исследование моя попытка представления рыночных данных как языка, а не попытка сразу создать алгоритм для автотрейдинга. Ещё важно: это мой личный эксперимент, проведённый одним человеком и выполненный однократно. Результаты дали интересные наблюдения.

Расскажу, как происходила разметка графиков в текст, какие шаблоны сработали лучше и какие метрики использовались. Также отмечу ограничения подхода и идеи для повторных экспериментов.

А ещё весь код уже на GitHub.

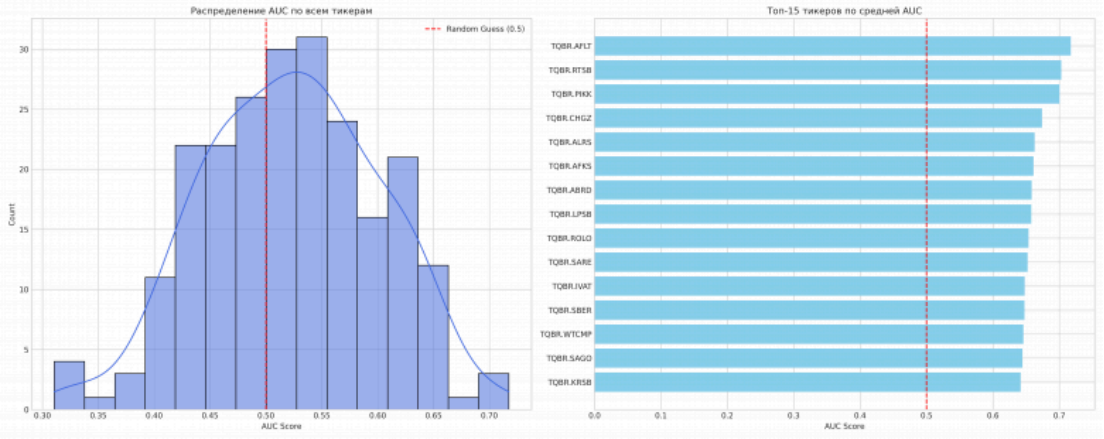

Мои результаты, о них ниже

Для трейдеров и аналитиков: суть и результаты

Для модели котировки это просто цифры без контекста. Она не знает, что вверх — хорошо, а вниз тревожный сигнал. Я переводил ряды котировок в текст. Каждые 10 дней торгов превращались в короткое описание, как если бы трейдер рассказывал что-то своему коллеге.

В основе лежали три признака:

- Краткосрочный тренд (3 дня) — рост, падение или боковик;
- Среднесрочный контекст (7 дней) — подтверждает ли он текущее движение;
- Моментум и объём — поддерживают ли рост деньги: идёт ли рост на растущих объёмах или затухает.

Если цена три дня растёт, объёмы увеличиваются, и цена близка к сопротивлению, строка выглядела так:

> *price rising strongly, volume increasing, near resistance.*

Эти описания читала модель DistilBERT. Модель не видела графиков, только текст — и должна был сказать, приведёт ли ситуация к росту или падению. Так модель «училась понимать» то, что трейдеры выражают словами.

Результат 20 бумаг в консоли

Как измерить, понимает ли она рынок

Простая точность (accuracy) ничего не говорит: можно всё время предсказывать падение и быть правым на 60%.

Поэтому я использовал AUC (Area Under Curve) — показывает, насколько хорошо модель отличает ситуации, после которых цена действительно росла, от тех, после которых она падала:

- AUC = 1.0: идеальная модель, которая никогда не ошибается.
- AUC = 0.5: бесполезная модель, ее предсказания равносильны подбрасыванию монетки.
- AUC > 0.5: модель работает лучше, чем случайное угадывание. Чем ближе к 1.0, тем лучше.
- AUC < 0.5: модель работает хуже случайного угадывания.

Эксперимент на всех акциях Московской биржи

Результат 227 бумаг в консоли

Я протестировал более 200 акций с Московской биржи. **Средний результат по всем бумагам — AUC ≈ 0.53**, что немного лучше случайного угадывания.

Лучшие случаи:

- AFLT — 0.72
- RTSB — 0.70
- PIKK — 0.70
- CHGZ — 0.67
- AFKS — 0.66

Худшие:

- PLZL — 0.33
- VJGZP — 0.33
- CHMF — 0.36
- ETLN — 0.38
- LSNG — 0.39

Разброс большой: одни бумаги ведут себя предсказуемо, другие — как шум.

Что это значит для трейдера

С практической стороны — **торговать по такой схеме нельзя**. Даже при AUC 0.6 предсказательная сила слишком слаба, чтобы покрыть комиссии. Однако сам факт, что модель хоть немного «чувствует» структуру графика без чисел и свечей, уже интересен.

Эксперимент показал: график можно описать словами, и языковая модель способна уловить логику движения — пусть пока не точно.

Нагрузка на GPU

Для технических специалистов

Проект реализован на стеке Python + PyTorch + Hugging Face Transformers с изоляцией через Docker. Контейнер собирается на базе `pytorch/pytorch:2.7.0-cuda12.8-cudnn9-devel` для совместимости с современными GPU.

Модель дообучалась (fine-tuning) на базе DistilBERT, предобученной на английском тексте (distilbert-base-uncased). То есть — это классическая дообучаемая голова классификации (`num_labels=2`) поверх всего BERT-тела. Fine-tuning проходил end-to-end, то есть обучались все слои, не только голова.

Все слои разморожены. Базовая часть DistilBERT не замораживалась. Значит, fine-tuning шёл по всей модели (весам encoder'a + классификационной голове).

Конвейер данных строится в три этапа. Пакетная загрузка: метод `load_all_data()` читает все файлы котировок за один проход и объединяет в единый DataFrame с колонкой `ticker` .

Векторизованная генерация признаков: класс `OHLCVFeatureExtractor` обрабатывает весь DataFrame целиком через `groupby('ticker').apply()` для расчёта троичных трендов, преобразование в текст идёт через `featuresto_text_vectorized()` с `np.select()` вместо циклов — прирост скорости в десятки раз. Скользящая валидация: `WalkForwardValidator` обучает модель на окне в 252 дня, тестирует на следующих 21 дне, затем сдвигает окно на 21 день вперёд.

Модель — `AutoModelForSequenceClassification` (DistilBERT) для бинарной классификации. Токенизатор `distilbert-base-uncased`, максимальная длина — 128 токенов.

Метрики формируются по каждому тикеру отдельно, на его данных OHLCV (файлы.txt в /Data/Tinkoff). В каждом тикере — несколько временных фолдов (1 год train, 1 месяц test).Потом усредняются по фолдам и по тикерам.

Финальные числа (accuracy, f1, auc) — это усреднение по: все тикеры × все временные окна (folds). В итоге в analyze_results() строится гистограмма AUC и топ-15 тикеров по качеству.

Проблемы и их решение

Изначально паттерны кодировались вымышленными словами («Кибас», «Гапот»), чтобы модель не опиралась на предобученные знания. Но это превращало BERT в обычный классификатор на случайных токенах. Решением стал переход на естественные фразы `price rising strongly`, `near resistance`. Модель теперь задействует понимание финансовой терминологии.

Моя RTX 5060 Ti (архитектура Blackwell, SM_120) оказалась слишком новой для стабильных PyTorch. Ошибка «no kernel image available» блокировала вычисления. Решением стал Docker-образ с CUDA 12.8 и nightly-сборкой PyTorch.

В процессе теста 40 бумаг

Обработка каждого файла в цикле была узким местом. Я переработал код для пакетной обработки: все котировки загружаются в единый DataFrame, а признаки генерируются одним векторизованным вызовом. Благодаря этому тесты для более чем 200 акций завершились неожиданно быстро — всего около получаса.

Несовместимость `transformers` и `tokenizers` ломала сборку Docker. Зафиксировал работающие версии: `transformers==4.35.2`, она требует `tokenizers==0.15.0`. Затем `pandas` изменил поведение `groupby.apply`, `transformers` удалил старые аргументы из API. Адаптация кода и жёсткая фиксация версий в `requirements.txt`.

В Docker контейнер создавал файлы от root. Переключение на `--user "$(id -u):$(id -g)"` решило проблему с пр��вами, но библиотеки пытались писать кэш в `/.cache` и падали с `PermissionError`. Решенил что в переменные окружения в `run.sh` перенаправляют кэши в доступные пути: `HF_HOME`, `TRANSFORMERS_CACHE` идут в `/workspace/.cache`, `MPLCONFIGDIR` — в `/tmp`.

Детали конфигурации и обучения

Конфигурация признаков: `short_window=3`, `medium_window=7`, `long_window=14`. Валидация: `train_size=252`, `test_size=21`, `step_size=21`.

Гиперпараметры: `learning_rate=2e-5`, `batch_size=32`, `epochs=2`, `weight_decay=0.01`, `fp16=True`. `EarlyStoppingCallback(patience=2)` останавливает обучение при стагнации лосса.

Оценка — усреднение метрик по 3 фолдам на тикер. Для каждого фолда: accuracy, precision, recall, F1, AUC-ROC. Финальный результат — среднее и стандартное отклонение AUC.

Выводы

Эксперимент подтвердил: идея семантического кодирования рыночных данных — рабочая и перспективная, но в текущей реализации она не дала статистически значимого результата. Модель действительно различала рыночные ситуации, но слабо — AUC в среднем по полной выборке составил около 0.53. Это слишком мало, чтобы использовать прогнозы в торговле, но достаточно, чтобы признать: языковая модель способна уловить элементарные закономерности, если данные поданы в привычной ей форме — в виде текста.

Главная ценность проекта не в точности предсказаний, а в том, что удалось пройти весь путь от сырого CSV с котировками до работающего ML-конвейера, полностью воспроизводимого в Docker. Каждый этап — от векторизации признаков до скользящей валидации — отлажен и готов к повторным экспериментам. Это не «ещё одна нейросетка для трейдинга», а инженерный прототип, на котором можно проверять новые идеи: другие схемы описания графиков, языковые модели большего масштаба, мультимодальные подходы.

Фактически проект стал мини-лабораторией по исследованию того, как LLM «видит» рынок. И если заменить DistilBERT на современные архитектуры вроде LLaMA или Mistral с дообучением на финансовых текстах, потенциал подхода может проявиться гораздо сильнее.

Повторите мой путь: код на GitHub

Я специально оформил всё так, чтобы любой мог запустить эксперимент у себя. Достаточно скачать архив котировок, собрать контейнер и запустить run.sh — среда поднимется автоматически с нужными версиями библиотек и CUDA.

Проект открыт:
👉 github.com/empenoso

Если вы хотите повторить эксперимент, улучшить разметку или попробовать другую модель — все инструменты уже готовы. Мой результат — это не финальный ответ, а отправная точка для следующего шага: сделать так, чтобы языковая модель действительно читала графики, а не просто угадывала направление.

Автор: Михаил Шардин
🔗 Моя онлайн-визитка
📢 Telegram «Умный Дом Инвестора»

14 октября 2025

Теги: BERT, cuda, rtx 5060, алгоритмическая торговля, sm_120

Хабы: Open source, Настройка Linux, Python, Финансы в IT, Машинное обучение

Публикации

ЛУЧШИЕ ЗА СУТКИ ПОХОЖИЕ

pilot_artem
19 часов назад

Почему в самолетах нет парашютов и про другие способы спасти пассажиров

11 мин 5.2K

Обзор

+39 21 127

inetstar
20 часов назад

Хрупкий == надёжный? Идея «хрустального кода»

Средний 9 мин 2.4K

Мнение

+32 20 31

iezhv
20 часов назад

«Взяли лучшее и объединили»: философия сервера Selectel

8 мин 1.4K

Обзор

+26 3 8

cnet
17 часов назад

Не смотрите вниз

8 мин 2.1K

+22 11 2

EfimkinDM
21 час назад

Портативный СВЧ-детектор

Средний 7 мин 1.7K

+19 24 4

masha_na_gore
17 часов назад

«Почему тут Маклахлен? Преза не та?» Сделали 150 слайдов для 2500 зрителей конференции Гроуинг в Минске

Простой 8 мин 361

Кейс

+14 4 1

GeeksCat
17 часов назад

Малоизвестные игровые журналы и газеты нулевых

Простой 17 мин 921

Ретроспектива

+13 7 3

master_program
4 часа назад

Вводная глава учебника по матанализу нового типа

Простой 49 мин 2K

Туториал

+12 41 18

kmoseenk
19 часов назад

Клавиатура с датчиком отпечатков на ESPHome

Средний 6 мин 1.5K

Туториал Перевод

+12 17 1

skovalev
1 час назад

Дайджест железа за октябрь: ARM, Intel и материнские платы Selectel

10 мин 176

Дайджест

+10 2 0

Для тех, кто в тяжелой цифре и тех, кто про нее думает: опрос о выборе карьеры

Опрос

Показать еще

ИСТОРИИ

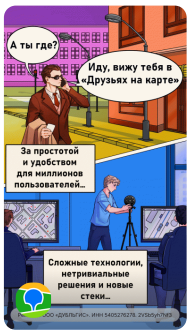

Как устроен мир по ту сторону карты

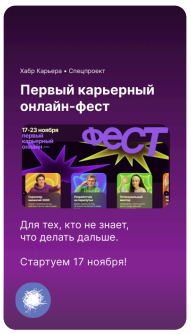

Первый карьерный онлайн-фест

Road to Highload

Годнота из блогов компаний

На мороз!

ВАКАНСИИ

Python Developer/ DevOps (trading)
от 250 000 ₽ · Рестадвайзер · Москва · Можно удаленно

Backend developer (Python, FastAPI)
до 4 000 $ · BCraft · Можно удаленно

Python разработчик
от 200 000 ₽ · АВ Софт · Москва

Сетевой инженер, OpenWrt, Linux
от 20 000 до 60 000 ₽ · Ростовский завод электроники · Санкт-Петербург · Можно удаленно

Backend Python Developer Middle/Senior
до 3 000 $ · AppRoute · Можно удаленно

Больше вакансий на Хабр Карьере

МИНУТОЧКУ ВНИМАНИЯ

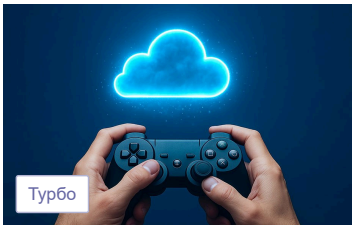

Три способа управления облаком

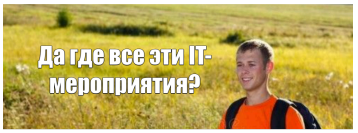

Не знаете, куда идти? Загляните в Календарь IT-мероприятий

Ты можешь забрать хорошие скидки, но до сих пор не забрал?

БЛИЖАЙШИЕ СОБЫТИЯ

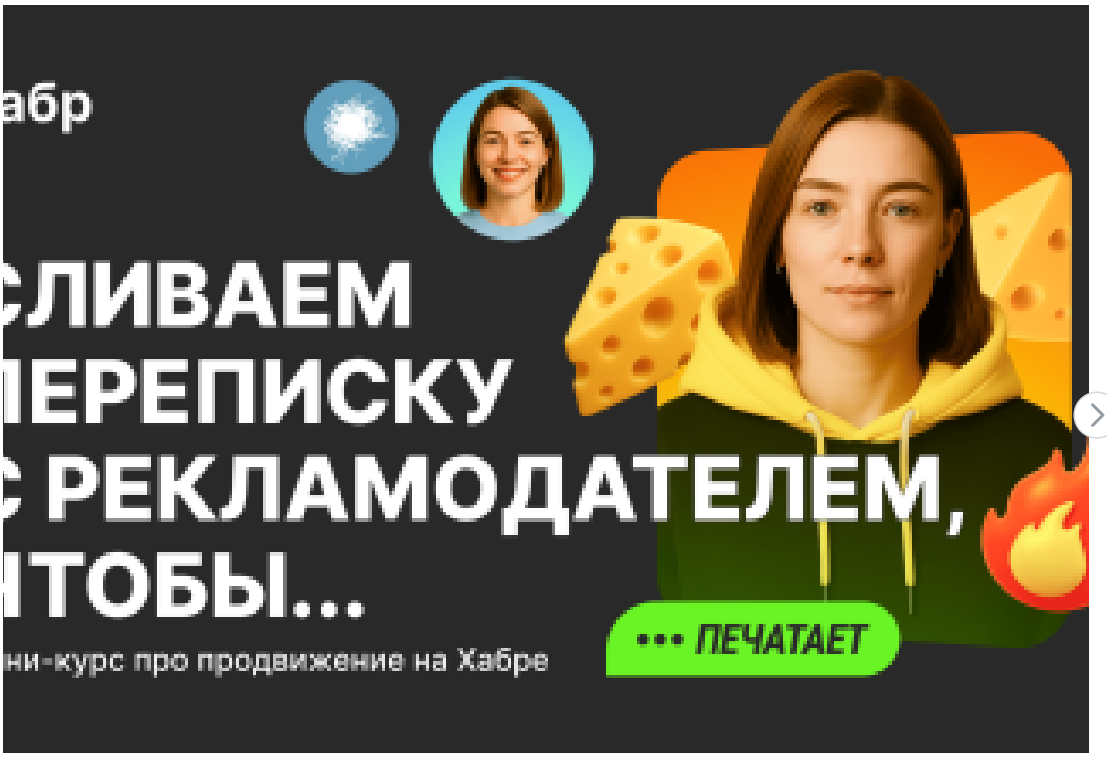

23 сентября – 31 декабря

Бесплатный мини-курс: как продвигаться на Хабре, если вы — не IT-бренд

Онлайн

Маркетинг

Больше событий в календаре

Хабр

Настройка языка

Техническая поддержка