

Сдвиги в данных, OOD и MLOps



Рындин Максим ИСП РАН

SentiRuEval 2016

- сентимент постов из соцсетей о банках
- между сбором train и test 3-4 месяца
- смена аннотаторов
- разгар кризиса
=>
- train 85%+
- test 60%-

Что делать

- мониторинг и дообучение
- автоматизация
- дополнительные обратные переходы в жизненном цикле
- дополнительная инфраструктура

ML Pipeline

- постановка задачи
- исследование
- первые эксперименты
- эксперименты
- анализ
- вывод в production

Что мы можем автоматизировать?

- постановка задачи

- исследование

- первые эксперименты


- + эксперименты

- + анализ

- + вывод в production


Эксперименты

- **воспроизводимость и изолированность экспериментов**
- версионирование активов
- управление ресурсами
- унификация процессов разработки в команде
- обеспечение доверия



Эксперименты

- воспроизводимость и изолированность экспериментов
- **версионирование активов**
- управление ресурсами
- унификация процессов разработки в команде
- обеспечение доверия



Эксперименты

- воспроизводимость и изолированность экспериментов
- версионирование активов
- **управление ресурсами**
- унификация процессов разработки в команде
- обеспечение доверия



Эксперименты

- воспроизводимость и изолированность экспериментов
- версионирование активов
- управление ресурсами
- **унификация процессов разработки в команде**
- обеспечение доверия



Эксперименты

- воспроизводимость и изолированность экспериментов
- версионирование активов
- управление ресурсами
- унификация процессов разработки в команде
- **обеспечение доверия***



Анализ

- аналитика результатов



Вывод в production

- **деплой, масштабирование**
- обеспечение доверия
- мониторинг
- мониторинг устаревания



Вывод в production

- деплой, масштабирование
- **обеспечение доверия**
- мониторинг
- мониторинг устаревания



Вывод в production

- деплой, масштабирование
- обеспечение доверия
- **мониторинг**
- мониторинг устаревания



Вывод в production

- деплой, масштабирование
- обеспечение доверия
- мониторинг
- **мониторинг устаревания**



Проблемы при ML-разработке

Эксперименты и анализ:

- воспроизводимость и изолированность экспериментов
- версионирование активов
- аналитика результатов
- управление ресурсами
- унификация процессов разработки в команде
- обеспечение доверия

Production:

- деплой, масштабирование
- обеспечение доверия
- мониторинг
- мониторинг устаревания

MLOps

- практики и инструменты для автоматизации и упрощения процессов жизненного цикла моделей машинного обучения (ML)

The logo for mlflow, featuring the text "mlflow" in a stylized font where "ml" is white and "flow" is blue, set against a black rectangular background.The logo for CLEAR ML, featuring a stylized "C" made of concentric blue and green arcs to the left of the text "CLEAR | ML" in a bold, dark blue sans-serif font, all on a white rectangular background.The logo for Kubeflow, featuring a purple geometric icon resembling a cluster of nodes to the left of the text "Kubeflow" in a purple sans-serif font, all on a white rectangular background.The logo for comet, featuring a stylized orange and red comet tail icon to the left of the text "comet" in a dark grey sans-serif font, all on a white rectangular background.The logo for RAY, featuring a white network diagram icon to the left of the text "RAY" in a grey sans-serif font, all on a blue rectangular background.The logo for DVC, featuring the letters "DVC" in a stylized font where "D" is teal, "V" is purple, and "C" is orange, all on a light grey rectangular background.

...

Связь проблемы и инженерии

- умеем автоматизировать обучение и др. => можем автоматизировать мониторинг, дообучение и др.
- даже если есть понимание как поддерживать модели, нужна инфраструктура
- заботимся об устаревании => повышаем уровень разработки

Подзадачи непрерывного обучения

- когда предпринимать действия: ~OOD/AD/etc.
- (опционально) как получить разметку: ~active learning
- как дообучиться, если есть разметка: ~online/multitask learning
- как дообучиться, если нет разметки: ~domain adaptation

Отличие: цель – хорошо работать на всех классах

Зоопарк задач

- AD – Anomaly Detection
- ND – Novelty Detection
- OSR – Open Set Recognition
- OOD – Out Of Distribution (detection)
- OD – Outlier Detection

AD

- Inference time + внешний
- Нет ограничений на ID performance
- feature+concept drift
- supervised
- Собственный confidence “нормальности” примера
- TPR, FPR, AUROC, AUPR at confidence level

ND

Почти как AD, но

- только concept drift
- unsupervised

OSR

- Только для классификации
- внутри модели => max joint ID+OOD performance
- unsupervised
- обычно eval на разных частях одного набора данных

OOD

OSR без ограничений

- не только классификация
- может быть supervised
- обычно eval на разных наборах данных
- $FPR@TPRx$

OD


- не про “отказ от классификации”, а про подготовку/очистку данных
- `unsupervised` не по тому, как работает, а по духу

OOD: baselines

- Inference time
 - output based
 - distance based
- Train time
 - явные потери

OOD: почему сложно

- Нейронные сети склонны к overconfidence
 - Deep Neural Networks are Easily Fooled: High Confidence Predictions for Unrecognizable Images, Nguyen et al




OOD: почему сложно

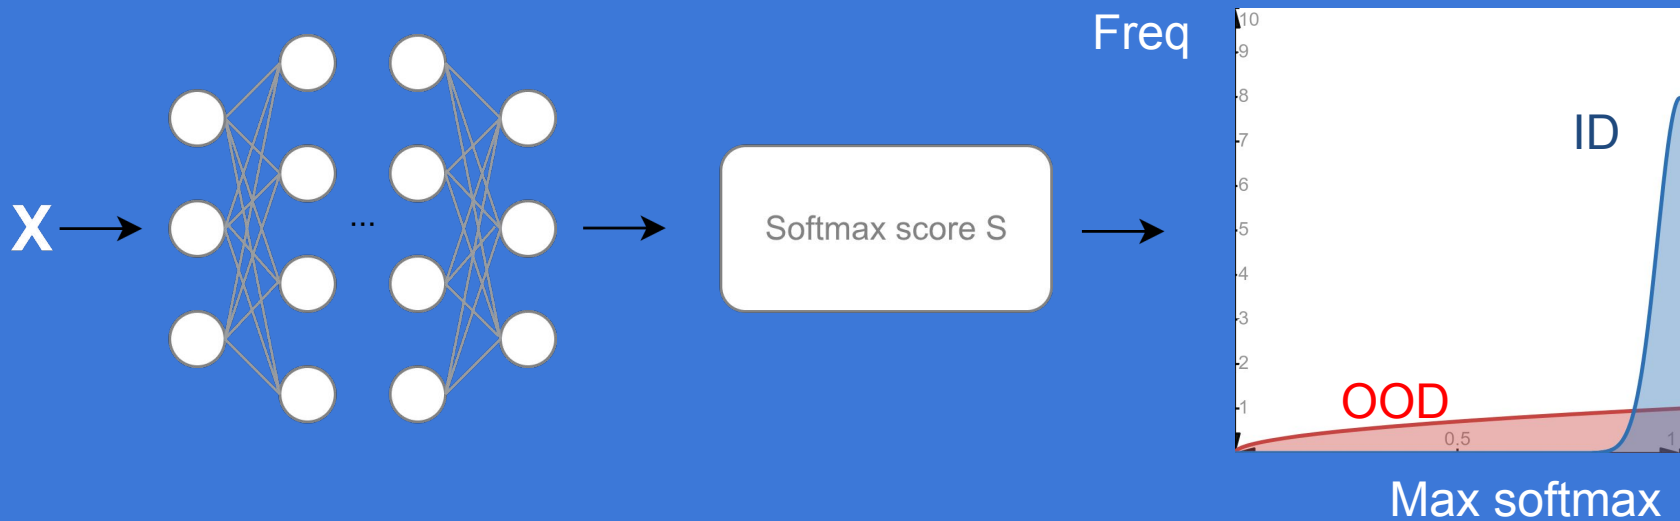
- Нейронные сети склонны к overconfidence
- OOD примеры сложно придумать
- OOD примеры сложно собирать
- Часто задача не на уровне примеров, а на уровне объектов

Inference time OOD

- Конструирование scoring function S



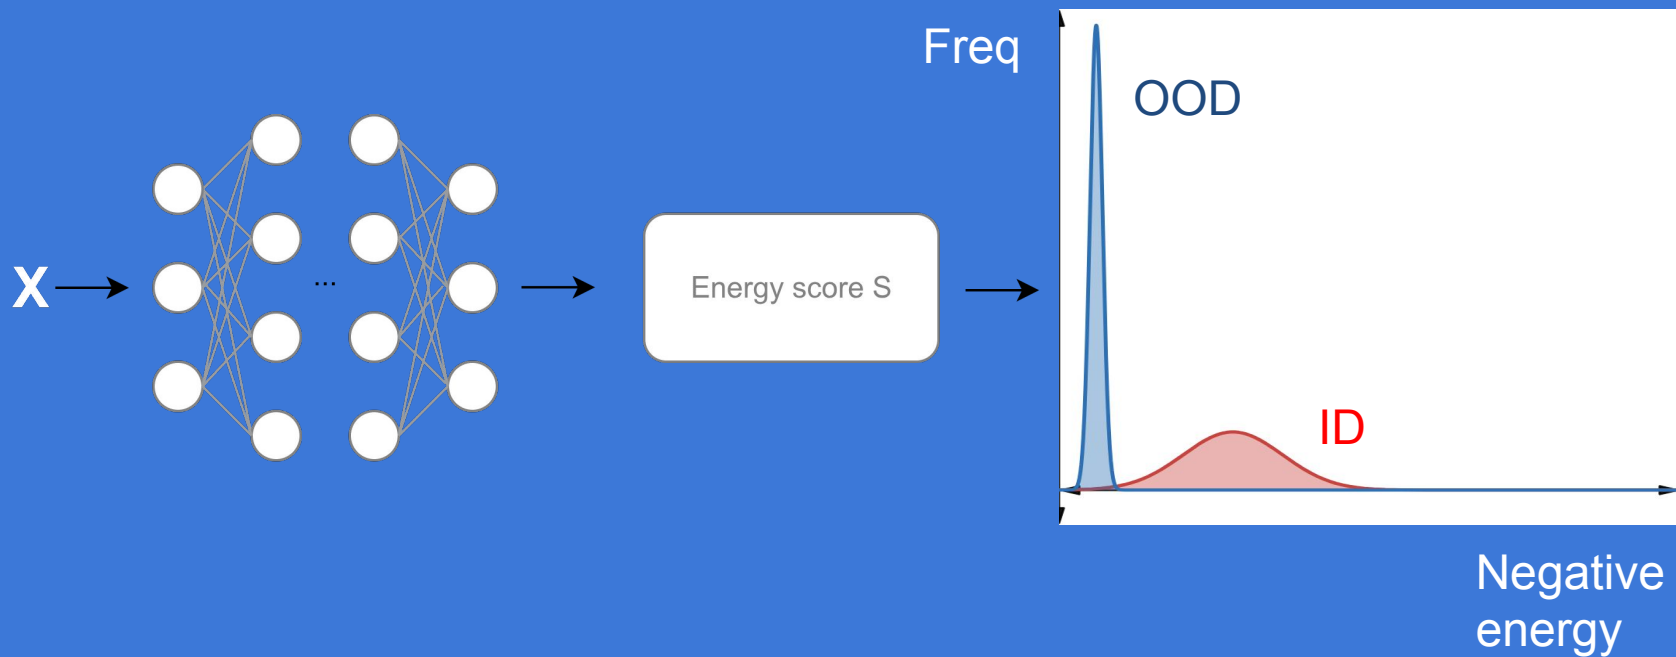
Softmax baseline



Softmax baseline



Energy baseline



Energy

- **Функция от x и y**
 - тем меньше чем более “совместимы” вход и выход
 - какая-то скалярная, может быть невероятностая
 - распределение Гиббса – вероятность, что x ассоциирован с y

$$p(y|x) = \frac{e^{-E(x,y)/T}}{\int_{y'} e^{-E(x,y')/T}} = \frac{e^{-E(x,y)/T}}{e^{-E(x)/T}}$$

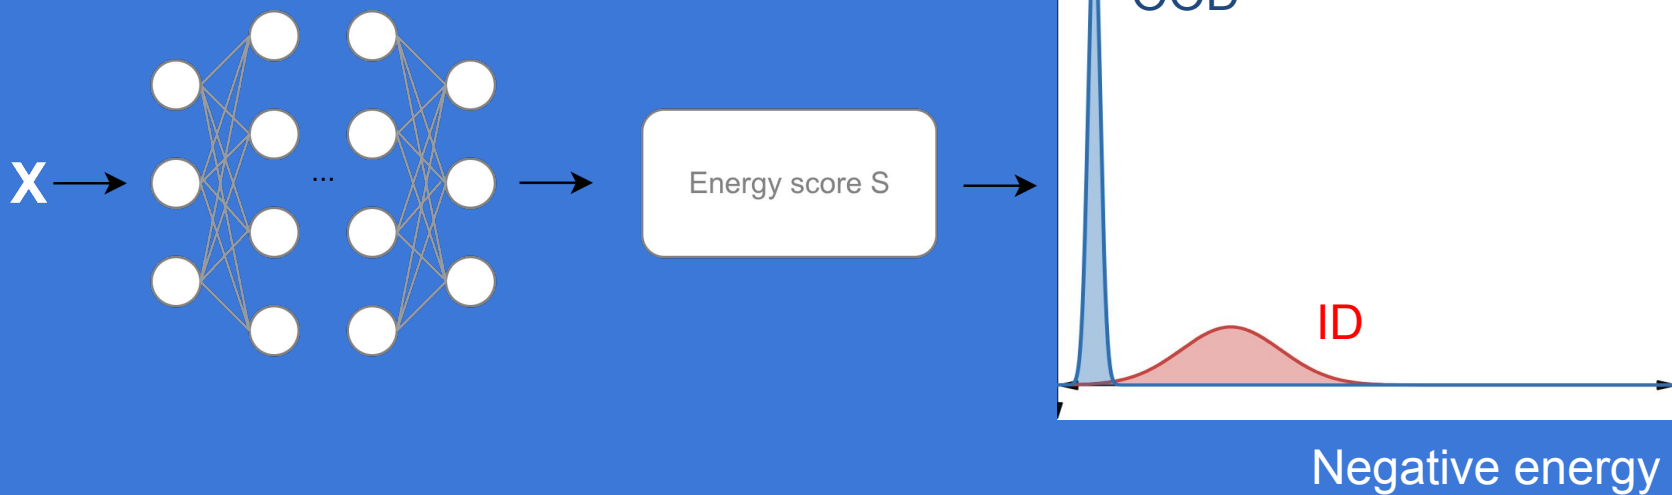
Energy

$$p(y|x) = \frac{e^{f_y(x)/T}}{\sum_i e^{f_i(x)/T}}$$

$$p(y|x) = \frac{e^{-E(x,y)/T}}{\int_{y'} e^{-E(x,y')/T}}$$

Energy


$$E(x, f) = -T \log \sum e^{f_i(x)/T}$$



Distance baseline

- Работаем в пространстве признаков
 - обычно последний слой до софтмакса
- Принимаем решение по расстоянию до ближайшей центроиды (ID близко, OOD равномерно далеко)

Distance baseline



Mahalanobis distance

$$M(f, x) = \max_i - (x - \mu_i)^T \Sigma^{-1} (x - \mu_i)$$

- Параметрическое
- Предполагает гауссовость фичей, если не похожи – сабоптимально
- Фичи из сети => оптимальны для целевой задачи, но неоптимальны для OOD

Снимаем ограничения

- kNN для снятия предположений о распределении
- учим фичи получше (contrastive learning/etc.)
 - Cider – все фичи на сфере
 - максимизируем угол между классами (обеспечиваем кластеризуемость)
 - малая дисперсия в кластере

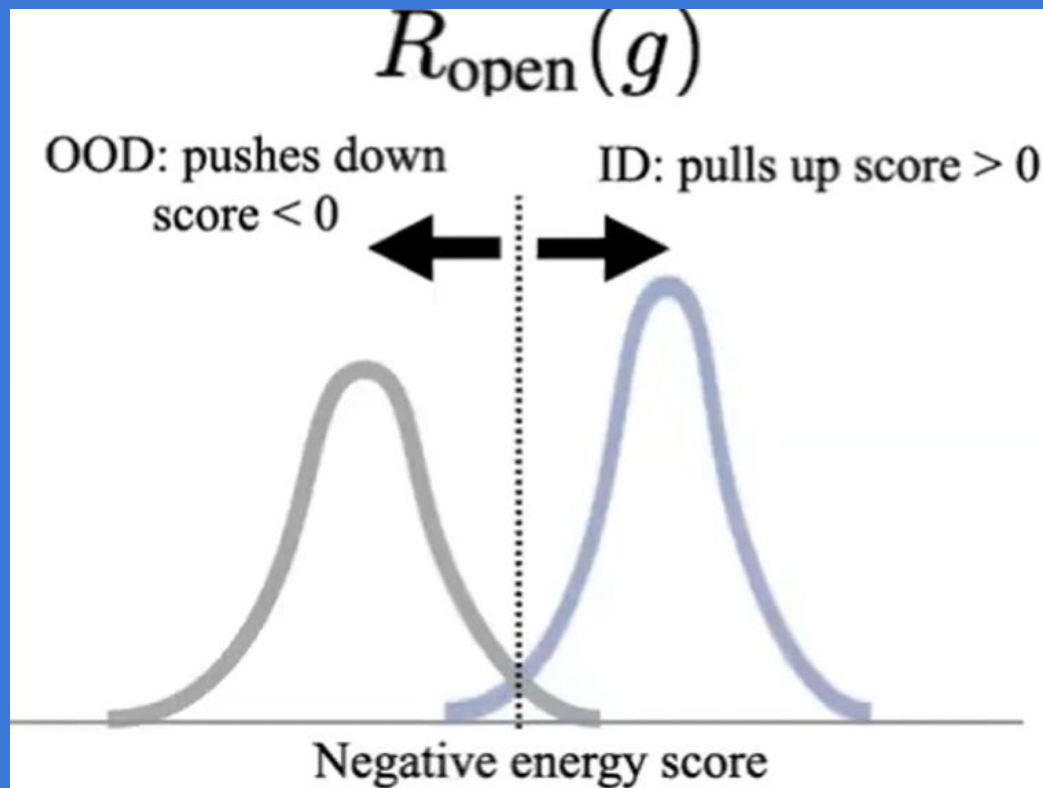
OOD: baselines

- Inference time
 - output based
 - distance based
- Train time
 - явные потери

OOD loss

$$\operatorname{argmin} \left[\underbrace{R_{\text{closed}}(f)}_{\text{Classification error on ID}} + \alpha \cdot \underbrace{R_{\text{open}}(g)}_{\text{Error of OOD detector}} \right]$$


OOD loss



OOD: baselines

- Inference time
 - output based
 - distance based
- Train time
 - явные потери
 - синтез OOD данных

OOD: синтетика



$$p_{\theta}(h(x, b)|y = k) = N(\mu_k, \Sigma)$$

$$\nu_k = \{v_k | \frac{1}{(2\pi)^{m/2}|\hat{\Sigma}|^{1/2}} e^{-\frac{1}{2}(v_k - \hat{\mu}_k)^T \hat{\Sigma}^{-1} (v_k - \hat{\mu}_k)}\}$$

OOD: сертифицируемые потери

- будем бороться с overconfidence
 - кросэнтропия с равномерным распределением
- для надежности хотим равномерность не в точке, а в окрестности
- плохо сходится, но доказуемо