

**УЛУЧШЕНИЕ НЕЙРОСЕТЕВЫХ МЕТОДОВ  
ПРЕДСКАЗАНИЯ ФУНКЦИИ РАСПРЕДЕЛЕНИЯ ДЛЯ  
ПРИМЕНЕНИЯ В ЗАДАЧАХ ГЛУБОКОГО МАШИННОГО  
ОБУЧЕНИЯ**

*Мишустина Маргарита Владимировна*

*Студент*

*Факультет ВМК МГУ имени М. В. Ломоносова, Москва, Россия*

*E-mail: mishustina.rita@yandex.ru*

*Научный руководитель — Китов Виктор Владимирович*

В задачах традиционного и глубокого машинного обучения часто необходимо исследовать распределения признаков. Полезным инструментом для работы с распределением является функция распределения. С помощью функции распределения признака можно, например, бинаризовать значения фактора по квантилям, а затем заменить эти значения на обучаемые квантили ([1]). Кроме того, значения многомерной функции распределения могут быть использованы для поиска выбросов (то есть таких объектов, которые существенно отличаются от остальных): объект, чья функция распределения будет выходить за границы определенных по валидации квантилей (например,  $q_5$  и  $q_{95}$ ) – считаются выбросами.

В работе улучшается существующий непараметрический нейросетевой метод оценки распределений с помощью изменения способа сэмплирования целевой переменной. Разработанный метод позволяет добиться уменьшения значения функции потерь на синтетических данных, сгенерированных из различных распределений (например, нормальное распределение, многомерное нормальное распределение, распределение Коши и тд). Обновленная схема работа выглядит так:

1.  $t = 1, x_1 \leq x_2 \leq \dots \leq x_N, x_i \in \mathbb{R}^1, \forall i \in 1, \dots, N$  – берем точки из минибатча,
2.  $u_1 \leq u_2 \leq \dots \leq u_N \sim U[0, 1]$  – генерируем таргеты
- 3.

$$J = \sum_{n=1}^N \left[ H(x_n, w) - u_n \right]^2 +$$

$$+ \lambda \underbrace{\sum_{k=1}^K \mathbb{I}(H(y_k, w) > H(y_k + \Delta, w)) \left[ H(y_k, w) - H(y_k + \Delta, w) \right]^2}_{\text{штраф за монотонность}},$$

– оптимизируем функцию потерь где  $y_1, y_2, \dots, y_K$  — любой набор точек из обучающего набора данных,  $\Delta > 0$  – гиперпараметр,  $\lambda$  – коэффициент регуляризации.

4.  $t = t + 1$

В силу естественного ограничения на монотонность функции распределения, в исходном алгоритме используется дополнительная регуляризация, отвечающая за то, чтобы результирующая нейронная сеть представляла собой неубывающую функцию. В работе предлагается способ избавиться от этой регуляризации путем наложения ограничения на архитектуру и веса модели. В предложенной модели используются линейные слои и регуляризация (композиция данных слоев является монотонной при условии неотрицательности весов линейных слоев), при этом неотрицательность весов контролируется, например, таким образом:  $\hat{W} = \max(W, 0)$ . Данная модификация позволяет несколько ускорить абсолютное время сходимости метода.

Кроме того, новый метод обобщается на многомерный случай. Пример работы обобщенного метода для смеси нормальных распределений представлен в разделе «иллюстрации». Схема обобщенного метода выглядит следующим образом:

1.  $t = 1, x_1, x_2, \dots, x_N, x_i \in \mathbb{R}^D, \forall i \in 1, \dots, N$  – берем точки из мини-батча ( $D$  – размерность пространства),

2.

$$J = \sum_{n=1}^N \left[ H(x_n, w) - t_n \right]^2 +$$

$$+ \lambda \sum_{d=1}^D \sum_{k=1}^K \mathbb{I}(H(y_{k1}, \dots, y_{kd} + \Delta, \dots, y_{kD}), w) >$$

$$> H((y_{k1}, \dots, y_{kd}, \dots, y_{kD}), w)) \cdot$$


$$\cdot \left[ H((y_{k1}, \dots, y_{kd} + \Delta, \dots, y_{kD}), w) - H((y_{k1}, \dots, y_{kd}, \dots, y_{kD}), w) \right]^2,$$

– оптимизируем обобщенную функцию потерь, где  $y_1, y_2, \dots, y_K$  — любой набор точек из обучающего набора данных,  $\Delta > 0$ ,  $\lambda$  — коэффициент регуляризации.

3.  $t = t + 1$ .

Преимущество нового метода перед традиционным статистическим методом показывается не только на синтетических данных, упомянутых ранее, но также и в практических задачах машинного обучения - обнаружении выбросов и кодировании вещественных признаков через эмбединги.

### Иллюстрации



Пример работы разработанного обобщения для смеси нормальных распределений.

### Литература

1. Gorishniy Y., Rubachev I., Babenko A. On embeddings for numerical features in tabular deep learning //arXiv preprint arXiv:2203.05556. – 2022.
2. Nonparametric Density Estimation for High-Dimensional Data - Algorithms and Applications (<https://arxiv.org/pdf/1904.00176.pdf>)