

# Доказательства в машинном обучении

---

Михаил Александрович Паутов, к.ф.-м.н.

Институт искусственного интеллекта AIRI

Институт системного программирования им. В.П. Иванникова РАН



# План

---

- 1) Дистилляция знаний и переносимые состязательные возмущения
- 2) Предсказание нейронной сети как случайная величина
- 3) Проблемы доказательств в машинном обучении



# Дистилляция знаний и переносимые состязательные возмущения


---

Совместно с К. Лукьяновым, А. Чистяковой, А. Перминовым, Д. Турдаковым

Lukyanov, K., Perminov, A., Turdakov, D., & Pautov, M. (2024). Model Mimic Attack: Knowledge Distillation for Provably Transferable Adversarial Examples. arXiv preprint arXiv:2410.15889.



# Что такое состязательная атака?



**Неформально:**

- Состязательная атака — возмущение во входных данных нейронной сети
- Возмущение, не изменяющее семантику исходного объекта настолько, чтобы повлиять на мнение человека об объекте
- Возмущение, приводящее к некорректной обработке объекта нейронной сетью

# Что такое состязательная атака?

Пусть  $f : \mathbb{R}^d \rightarrow \Delta^K$  есть нейронная сеть и  $h(f, x) = \arg \max_{i \in [1, \dots, K]} f(x)_i$  есть соответствующее правило классификации

Точка  $x' \in \mathbb{R}^d : \|x - x'\|_2 \leq \delta$  называется состязательным примером, если

$$h(f, x') \neq h(f, x)$$

Состязательный пример является переносимым между моделями  $f : \mathbb{R}^d \rightarrow \Delta^K$

и  $g : \mathbb{R}^d \rightarrow \Delta^K$ , если

$$\begin{cases} h(f, x) = h(g, x), \\ h(f, x') = h(g, x'). \end{cases}$$

# Что такое дистилляция знаний?

Пусть  $T$  есть нейронная сеть-“учитель”, развернутая как черный ящик. Тогда дистилляция знаний есть процесс обучения нейронной сети-“ученика”  $S$  путем решения следующей оптимизационной задачи:

$$S = \arg \min_{S'} \mathbb{E}_{(x,y) \sim \mathcal{D}} [\alpha \mathcal{L}(S'(x), y) + \\ + (1 - \alpha) \tau^2 KL(S'(x), T(x))]$$

Здесь  $\alpha \in [0, 1]$  есть константа,  $D$  есть набор данных для дистилляции.  $KL$  обозначает дивергенцию Кульбака-Лейблера. Отметим, что полученная таким образом нейронная сеть  $S$  представляет собой модель типа белый ящик.

# Алгоритм построения состязательных примеров на основе дистилляции знаний

Пусть есть алгоритм, позволяющий вычислять состязательные примеры для модели  $S$ . Для простоты предположим, что этот алгоритм есть PGD:

$$\begin{cases} x^{t+1} = \text{Proj}_{U_\delta(x)} [x^t + \alpha \text{sign} \nabla_{x^t} L(S, x^t, y)], \\ x^1 = x, \\ x' = x^M, \end{cases}$$

где  $U_\delta(x) = \{x' : \|x - x'\|_2 \leq \delta\}$

---

## Algorithm 1 Model Mimic Attack

---

**Require:** Black-box teacher model  $T$ , input object  $x$  of class  $y$ , distance threshold  $\delta$ , gradient step  $\alpha$ , maximum number of PGD iterations  $M$ , maximum number of distillation iterations  $N$ , hold-out dataset  $\mathcal{D}_h$ , the number  $l$  of adversarial examples to generate for the student model  $S_i$

**Ensure:** Set of student models  $\{S_1, \dots, S_N\}$ , the set  $AE(T)$  of adversarial examples for the teacher model  $T$

- 1:  $z \leftarrow (x, T(x))$  {compute the logits of  $T$  at the target point}
  - 2:  $\mathcal{D}(S) \leftarrow \{(x_i, T(x_i))\}_{i=1}^m$  {compute the training set  $\mathcal{D}(S)$  according to the Eq. (5)}
  - 3:  $\mathcal{D}(S_1) \leftarrow \mathcal{D}(S) \cup z$  {initialize the training set for the first student model  $S_1$ }
  - 4:  $AE(T) \leftarrow \emptyset$  {initialize the set of adversarial examples for the teacher model  $T$ }
  - 5: **for**  $i = 1$  to  $N$  **do**
  - 6:    $S_i \leftarrow \text{train}(\mathcal{D}(S_i))$  {train the student model  $S_i$  using  $\mathcal{D}(S_i)$ }
  - 7:   **for**  $j = 1$  to  $l$  **do**
  - 8:      $(x'_j, y'_j) \leftarrow PGD(\alpha, \delta, S_i, (x, y))$  {compute an adversarial example for the student model  $S_i$  according to (10)}
  - 9:     **if**  $h(S_i, x'_j) = h(T, x'_j)$  **then**
  - 10:        $AE(T) \leftarrow AE(T) \cup \{(x'_j, y'_j)\}$  {update the set of adversarial examples for the model  $T$ }
  - 11:     **end if**
  - 12:      $\mathcal{D}(S_{i+1}) \leftarrow \mathcal{D}(S_i) \cup \{(x'_j, T(x'_j))\}$  {update the training set for the model  $S_{i+1}$ }
  - 13:   **end for**
  - 14: **end for**
  - 15: **return**  $\{S_1, \dots, S_N\}, AE(T)$
-

# Алгоритм построения состязательных примеров на основе дистилляции знаний

Пусть состязательные примеры, построенные для нейронной сети  $S$  и не являющиеся переносимыми на  $T$ , дополняют набор данных для дистилляции на следующей итерации:

$$\mathcal{D}(S_{i+1}) \leftarrow \mathcal{D}(S_i) \cup \{(x'_j, T(x'_j))\}$$

где  $(x'_j, y'_j) \leftarrow PGD(\alpha, \delta, S_i, (x, y))$

---

## Algorithm 1 Model Mimic Attack

---

**Require:** Black-box teacher model  $T$ , input object  $x$  of class  $y$ , distance threshold  $\delta$ , gradient step  $\alpha$ , maximum number of PGD iterations  $M$ , maximum number of distillation iterations  $N$ , hold-out dataset  $\mathcal{D}_h$ , the number  $l$  of adversarial examples to generate for the student model  $S_i$

**Ensure:** Set of student models  $\{S_1, \dots, S_N\}$ , the set  $AE(T)$  of adversarial examples for the teacher model  $T$

- 1:  $z \leftarrow (x, T(x))$  {compute the logits of  $T$  at the target point}
  - 2:  $\mathcal{D}(S) \leftarrow \{(x_i, T(x_i))\}_{i=1}^m$  {compute the training set  $\mathcal{D}(S)$  according to the Eq. (5)}
  - 3:  $\mathcal{D}(S_1) \leftarrow \mathcal{D}(S) \cup z$  {initialize the training set for the first student model  $S_1$ }
  - 4:  $AE(T) \leftarrow \emptyset$  {initialize the set of adversarial examples for the teacher model  $T$ }
  - 5: **for**  $i = 1$  to  $N$  **do**
  - 6:    $S_i \leftarrow \text{train}(\mathcal{D}(S_i))$  {train the student model  $S_i$  using  $\mathcal{D}(S_i)$ }
  - 7:   **for**  $j = 1$  to  $l$  **do**
  - 8:      $(x'_j, y'_j) \leftarrow PGD(\alpha, \delta, S_i, (x, y))$  {compute an adversarial example for the student model  $S_i$  according to (10)}
  - 9:     **if**  $h(S_i, x'_j) = h(T, x'_j)$  **then**
  - 10:        $AE(T) \leftarrow AE(T) \cup \{(x'_j, y'_j)\}$  {update the set of adversarial examples for the model  $T$ }
  - 11:     **end if**
  - 12:      $\mathcal{D}(S_{i+1}) \leftarrow \mathcal{D}(S_i) \cup \{(x'_j, T(x'_j))\}$  {update the training set for the model  $S_{i+1}$ }
  - 13:   **end for**
  - 14: **end for**
  - 15: **return**  $\{S_1, \dots, S_N\}, AE(T)$
-

# Доказуемая переносимость состязательных возмущений

Предположим, что дистилляция знаний успешна:

$$\begin{cases} h(S, x_i) = h(T, x_i) = y_i, \\ \|S(x_i) - T(x_i)\|_\infty < \frac{\varepsilon}{4}, \end{cases}$$

для всех  $(x_i, y_i) \in \mathcal{D}(S)$

Дополнительно предположим, что функции  $f_i = S_i - T$  имеют ограниченный градиент в  $U_\delta(x)$  и

$$\beta = \sup_{f_i} \sup_{x' \in U_\delta(x)} \|\nabla f_i(x')\|_F$$

# Доказуемая переносимость состязательных возмущений

Тогда если алгоритм построения состязательных примеров для модели  $S_i$  находит их на каждой итерации  $i \in \mathbb{Z}_+$ , то существует  $N \in \mathbb{Z}_+$  такое, что состязательный пример переносится с модели  $S_N$  на модель  $T$

# Доказательство

Рассмотрим последовательность состоятельных примеров  $\{x'_i\}_{i=1}^{\infty}$ , где  $x'_i$  состоятельный пример, полученный для модели  $S_i$

Выделим из нее сходящуюся подпоследовательность  $\{x'_{i_j}\}_{j=1}^{\infty} = \{z_i\}_{i=1}^{\infty}$  такую, что

$$\lim_{j \rightarrow \infty} x'_{i_j} = z \in U_{\delta}(x)$$

# Доказательство

Рассмотрим последовательность состоятельных примеров  $\{x'_i\}_{i=1}^{\infty}$ , где  $x'_i$  состоятельный пример, полученный для модели  $S_i$

Выделим из нее сходящуюся подпоследовательность  $\{x'_{i_j}\}_{j=1}^{\infty} = \{z_i\}_{i=1}^{\infty}$  такую, что

$$\lim_{j \rightarrow \infty} x'_{i_j} = z \in U_{\delta}(x)$$

Вопрос: почему так можно сделать?

# Доказательство

Тогда

$$|\|f_{i+1}(x)\|_\infty - \|f_{i+1}(z_{i+1})\|_\infty| \leq \|f_{i+1}(x) - f_{i+1}(z_{i+1})\|_\infty$$

# Доказательство

Тогда

$$\begin{aligned} & |\|f_{i+1}(x)\|_\infty - \|f_{i+1}(z_{i+1})\|_\infty| \leq \|f_{i+1}(x) - f_{i+1}(z_{i+1})\|_\infty \\ & \leq \|f_{i+1}(x) - f_{i+1}(z_i)\|_\infty + \|f_{i+1}(z_i) - f_{i+1}(z_{i+1})\|_\infty \end{aligned}$$

# Доказательство

Тогда

$$\begin{aligned} & |\|f_{i+1}(x)\|_\infty - \|f_{i+1}(z_{i+1})\|_\infty| \leq \|f_{i+1}(x) - f_{i+1}(z_{i+1})\|_\infty \\ & \leq \|f_{i+1}(x) - f_{i+1}(z_i)\|_\infty + \|f_{i+1}(z_i) - f_{i+1}(z_{i+1})\|_\infty \\ & \leq \|f_{i+1}(x)\|_\infty + \|f_{i+1}(z_i)\|_\infty + \|f_{i+1}(z_i) - f_{i+1}(z_{i+1})\|_\infty \end{aligned}$$

# Доказательство

Тогда

$$\begin{aligned} & |\|f_{i+1}(x)\|_\infty - \|f_{i+1}(z_{i+1})\|_\infty| \leq \|f_{i+1}(x) - f_{i+1}(z_{i+1})\|_\infty \\ & \leq \|f_{i+1}(x) - f_{i+1}(z_i)\|_\infty + \|f_{i+1}(z_i) - f_{i+1}(z_{i+1})\|_\infty \\ & \leq \|f_{i+1}(x)\|_\infty + \|f_{i+1}(z_i)\|_\infty + \|f_{i+1}(z_i) - f_{i+1}(z_{i+1})\|_\infty \\ & \leq \frac{\varepsilon}{4} + \frac{\varepsilon}{4} + \|f_{i+1}(z_i) - f_{i+1}(z_{i+1})\|_\infty \end{aligned}$$

# Доказательство

Тогда

$$\begin{aligned} & |\|f_{i+1}(x)\|_\infty - \|f_{i+1}(z_{i+1})\|_\infty| \leq \|f_{i+1}(x) - f_{i+1}(z_{i+1})\|_\infty \\ & \leq \|f_{i+1}(x) - f_{i+1}(z_i)\|_\infty + \|f_{i+1}(z_i) - f_{i+1}(z_{i+1})\|_\infty \\ & \leq \boxed{\|f_{i+1}(x)\|_\infty + \|f_{i+1}(z_i)\|_\infty} + \|f_{i+1}(z_i) - f_{i+1}(z_{i+1})\|_\infty \\ & \leq \boxed{\frac{\varepsilon}{4} + \frac{\varepsilon}{4}} + \boxed{\|f_{i+1}(z_i) - f_{i+1}(z_{i+1})\|_\infty} \end{aligned}$$

# Доказательство

Обратим теперь внимание на то, что

$$f_{i+1}(z_i) - f_{i+1}(z_{i+1}) = \nabla f_{i+1}(\tau_{i+1})^T(z_i - z_{i+1})$$

Помимо этого, раз  $\lim_{i \rightarrow \infty} \|z_i - z_{i+1}\|_F = 0$  то  $\exists N \in \mathbb{Z}_+ : \|z_{N-1} - z_N\|_F < \frac{\varepsilon}{4\beta}$

Таким образом,

$$\|f_N(z_{N-1}) - f_N(z_N)\|_\infty \leq \|\nabla f_N(\tau_N)\|_F \|z_{N-1} - z_N\|_F < \frac{\varepsilon}{4}$$

# Доказательство

И, окончательно

$$|\|f_N(z_N)\|_\infty - \|f_N(x)\|_\infty| < \frac{3\varepsilon}{4} \implies \|f_N(z_N)\|_\infty < \varepsilon$$

# Предсказания нейронной сети как случайные величины

---

Совместно с

Н. Турсынбеком, М. Мунхоевой, Н. Муравьевым, А. Петюшко и И. Оседедцем

Pautov, M., Tursynbek, N., Munkhoeva, M., Muravev, N., Petrushko, A., & Oseledets, I. (2022, June). CC-Cert: A probabilistic approach to certify general robustness of neural networks. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 36, No. 7, pp. 7975-7983).



# Предсказания нейронной сети как случайные величины

Пусть требуется оценить устойчивость фиксированной нейронной сети к параметрическому возмущению входных данных известного типа.

# Предсказания нейронной сети как случайные величины

Пусть требуется оценить устойчивость фиксированной нейронной сети к параметрическому возмущению входных данных известного типа.

Если возмущение нетривиальной природы (как, например, аддитивные состязательные атаки), то неизвестно, каким образом предоставить гарантии устойчивости к такому возмущению.

# Предсказания нейронной сети как случайные величины

Предположим, что исходная модель – классификатор  $f : \mathbb{R}^n \rightarrow \Delta^K$


и входной объект  $x \in \mathbb{R}^n$  зафиксирован.

Пусть  $T_\theta : \mathbb{R}^n \rightarrow \mathbb{R}^n$  есть параметрическое возмущение входного объекта,  $p = f(x)$

есть предсказание на исходном объекте и  $p_t = f(T_\theta(x))$  есть предсказание на

возмущенном входном объекте. Пусть  $p_a, p_b$  есть две максимальные компоненты вектора  $p = f(x)$

Тогда, если  $\|p - p_t\|_\infty \leq d = \frac{1}{2}(p_a - p_b)$ , то  $\arg \max p = \arg \max p_t$



# Предсказания нейронной сети как случайные величины

Вероятность больших отклонений случайной величины  $Z = \|p - p_t\|_\infty$  ограничена:  $\mathbb{P}(Z > d) = \mathbb{P}(e^{tZ} > e^{td}) \leq e^{-td} \mathbb{E}(e^{tZ}), t > 0$

Таким образом, оценив сверху вероятность большого отклонения под воздействием возмущения  $T_\theta : \mathbb{R}^n \rightarrow \mathbb{R}^n$ , можно оценить, с какой вероятностью нейронная сеть устойчива в данной точке

# Предсказания нейронной сети как случайные величины

Вероятность больших отклонений случайной величины  $Z = \|p - p_t\|_\infty$  ограничена:  $\mathbb{P}(Z > d) = \mathbb{P}(e^{tZ} > e^{td}) \leq e^{-td} \mathbb{E}(e^{tZ}), t > 0$

Таким образом, оценив сверху вероятность большого отклонения под воздействием возмущения  $T_\theta : \mathbb{R}^n \rightarrow \mathbb{R}^n$ , можно оценить, с какой вероятностью нейронная сеть устойчива в данной точке

Вопрос: Что делать с математическим ожиданием в неравенстве?

# Предсказания нейронной сети как случайные величины

Вопрос: Что делать с математическим ожиданием в неравенстве?

Возможный ответ: его можно с большой вероятностью оценить сверху.

# Предсказания нейронной сети как случайные величины

Теорема:

Пусть  $Y_j = \frac{1}{ne^{td}} \sum_{i=1}^n e^{tZ_i}$  есть i.i.d. выборочные средние,  $\delta \in (0, 1)$  и  $b = \min\left(1, \frac{1}{\delta} \max(Y_1, \dots, Y_k)\right)$

Тогда  $\mathbb{P}(b < e^{-td}\mathbb{E}(e^{tZ})) \leq \left(\frac{1}{1 + \frac{n(1-\delta)^2\mu^2}{\sigma^2}}\right)^k$ ,  $\mu = \mathbb{E}(e^{tZ}), \sigma^2 = \mathbb{V}(e^{tZ})$

# Предсказания нейронной сети как случайные величины

Теорема:

Пусть  $Y_j = \frac{1}{ne^{td}} \sum_{i=1}^n e^{tZ_i}$  есть i.i.d. выборочные средние,  $\delta \in (0, 1)$  и  $b = \min\left(1, \frac{1}{\delta} \max(Y_1, \dots, Y_k)\right)$

Тогда  $\mathbb{P}(b < e^{-td} \mathbb{E}(e^{tZ})) \leq \left(\frac{1}{1 + \frac{n(1-\delta)^2 \mu^2}{\sigma^2}}\right)^k$ ,  $\mu = \mathbb{E}(e^{tZ}), \sigma^2 = \mathbb{V}(e^{tZ})$

Таким образом, с высокой вероятностью верно, что  $\mathbb{P}(Z > d) \leq \min\left(1, \frac{1}{\delta} \max(Y_1, \dots, Y_k)\right)$

# Предсказания нейронной сети как случайные величины

Доказательство:

- 1) Paley-Zygmund (1930): Пусть  $X \geq 0, \delta \in (0, 1)$ . Тогда

$$\mathbb{P}(X < \delta \mathbb{E}(X)) \leq \frac{\mathbb{V}(X)}{\mathbb{V}(X) + (1 - \delta)^2 \mathbb{E}(X)^2}.$$

- 2)  $\mathbb{P}(Y_i < \delta \mathbb{E}(Y_i)) = \mathbb{P}(Y_i < \delta \mu) \leq \frac{\mathbb{V}(Y_i)}{\mathbb{V}(Y_i) + (1 - \delta)^2 \mu^2} = \frac{1}{1 + \frac{n(1-\delta)^2 \mu^2}{\sigma^2}}$ .

# Проблемы доказательств в машинаном обучении

---



# 1) Выполнимость предположений

- 1) Достаточная способность к обучению модели  $S$  как необходимое условие успешной дистилляции

$$\begin{cases} h(S, x_i) = h(T, x_i) = y_i, \\ \|S(x_i) - T(x_i)\|_\infty < \frac{\varepsilon}{4}, \end{cases}$$

- 2) Ограничность градиента функций  $f_i = S_i - T$
- 3) Возможность построить состязательную атаку на все модели  $S_i$ ,  $i \in \mathbb{Z}_+$

# 1) Выполнимость предположений

- 1) Достаточная способность к обучению модели  $S$  как необходимое условие успешной дистилляции

$$\begin{cases} h(S, x_i) = h(T, x_i) = y_i, \\ \|S(x_i) - T(x_i)\|_\infty < \frac{\varepsilon}{4}, \end{cases}$$



- 2) Ограниченностъ градиента функций  $f_i = S_i - T$

- 3) Возможность построить состязательную атаку на все модели  $S_i$ ,  $i \in \mathbb{Z}_+$


# 1) Выполнимость предположений

- 1) Достаточная способность к обучению модели  $S$  как необходимое условие успешной дистилляции

$$\begin{cases} h(S, x_i) = h(T, x_i) = y_i, \\ \|S(x_i) - T(x_i)\|_\infty < \frac{\varepsilon}{4}, \end{cases}$$

- 2) Ограниченностъ градиента функций  $f_i = S_i - T$

- 3) Возможность построить состязательную атаку на все модели  $S_i$ ,  $i \in \mathbb{Z}_+$



накладывает  
дополнительные  
ограничения на  
соответствующий  
функциональный класс

## 2) Частный характер результатов

Обратим внимание на описание задачи:

*“Пусть требуется оценить устойчивость фиксированной нейронной сети к параметрическому возмущению входных данных известного типа.*

*Если возмущение нетривиальной природы (как, например, аддитивные состязательные атаки), то неизвестно, каким образом предоставить гарантии устойчивости к такому возмущению.”*

## 2) Частный характер результатов

Обратим внимание на описание задачи:

*“Пусть требуется оценить устойчивость фиксированной нейронной сети к параметрическому возмущению входных данных известного типа.*

*Если возмущение нетривиальной природы (как, например, аддитивные состязательные атаки), то неизвестно, каким образом предоставить гарантии устойчивости к такому возмущению.”*

Вопрос: развитие и применение каких инструментов может способствовать получению более фундаментальных теоретических результатов в машинном обучении?

---

Bcë!

