

# Анализ статистической и структурной сложности суперпозиции нейронных сетей

Д. О. Перекрестенко

Научный руководитель:  
н.с. ВЦ РАН, к.ф.-м.н. В. В. Стрижов

Московский физико-технический институт  
Факультет управления и прикладной математики  
Кафедра интеллектуальных систем



- **Цель работы** — разработать метод нахождения оптимальной структурной сложности универсальной модели нейросети.
- **Мотивация** — перебор различных структур нейросети связан с вычислительно трудоемкой задачей нахождения оптимальных параметров для каждой из рассматриваемых структур нейросети.
- **Предлагается** определять оптимальную структуру нейросети без использования переборных методов и многократных процедур оптимизации параметров.
- **Идея** — оценить структурную сложность одной модели по структурной сложности другой модели. При этом считается, что получение структурной сложности второй модели требует меньшего объема вычислений.

# Предлагается

- 1 Задать критерий сложности выборки
- 2 Задать критерий структурной сложности нейросети
- 3 Найти связь между геометрической и структурной сложностями на множестве выборок.

# Постановка задачи

Задана выборка  $D$  из генеральной совокупности  $D_{\text{gen}}$ :

$$D = \{\mathbf{x}_i, y_i\}_{i=1}^m,$$

где  $\mathbf{x}_i \in \mathbb{R}^n$  — вектор, признаковое описание  $i$ -го объекта, а  $y_i \in \{1, 2, \dots, k\}$  — метка класса из номинальной шкалы. Требуется найти модель:

$$\mathbf{f} : (\mathbf{x}, \mathbf{w}) \rightarrow c$$

$$\mathbf{f} : \mathbb{R}^n \times \mathbb{W} \rightarrow \{1, \dots, k\}$$

из множества  $\mathfrak{F}$  нейронных сетей, которая классифицирует генеральную совокупность  $D_{\text{gen}}$ .

## Определение 1

Назовем функцию  $g : \mathbb{W} \rightarrow \mathbb{R}$  *структурной сложностью* модели  $A = \{\mathbf{f}(\mathbf{x}, \mathbf{w}) | \mathbf{w} \in \mathbb{W}\}$ , если  $g(\mathbf{w})$  возрастает с ростом  $N$ , где  $N$  — математическое ожидание числа элементарных шагов алгоритма настройки модели к параметрам  $\mathbf{w}$  из случайно заданного начального приближения  $\mathbf{w}_0$ .

## Определение 2

Назовем  $\gamma$ -*геометрической сложностью* выборки  $D$  минимальное число радиальных базисных функций  $\phi_k(\mathbf{x}) = \exp(-\frac{\rho(c_k - \mathbf{x})}{a_k})$  необходимых для классификации выборки  $D$  с точностью  $\gamma$ . В данной работе  $\gamma$  принята равной 0.95.

# Автокодировщик

Автокодировщик  $\mathbf{h}$  это монотонное нелинейное отображение входного вектора свободных переменных  $\mathbf{x} \in \mathbb{R}^n$  в скрытое представление  $\mathbf{h} \in \mathbb{R}^\nu$  следующего вида:


$$\mathbf{h}(\mathbf{x}) = \sigma(\mathbf{W}\mathbf{x} + \mathbf{b}).$$

$\nu \times n$

Скрытое представление  $\mathbf{h}$  создает линейную реконструкцию вектора  $\mathbf{x}$ :

$$\mathbf{r}(\mathbf{x}) = \mathbf{W}'\mathbf{h} + \mathbf{b}'.$$

$n \times \nu$



Структура автокодировщика

Параметры автокодировщика

$$\lambda = \{\mathbf{W}', \mathbf{W}, \mathbf{b}', \mathbf{b}\}$$

оптимизированы таким образом, чтобы сделать реконструкцию  $\mathbf{r}(\mathbf{x})$  максимально близкой к  $\mathbf{x}$ . Функция ошибки автокодировщика:

$$S(\lambda) = \frac{1}{2m} \sum_{i=1}^m \|\mathbf{r}(\mathbf{x}_i) - \mathbf{x}_i\|^2 + \|\mathbf{W}\|_F^2 + \beta \sum_{j=1}^m \left[ \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \right],$$

где  $m$  — количество элементов в обучающей выборке,  $\beta$  — вес разреживающего слагаемого,  $\rho$  — параметр разреженности, желаемое среднее значение каждой компоненты скрытого представления  $\mathbf{h}$ , а  $\hat{\rho}_j$  — среднее значение  $j$ -ой компоненты вектора  $\mathbf{h}$ .

## Определение 3

Назовем *размерной сложностью* выборки  $D$  число нейронов в скрытом слое автокодировщика, задающее минимум его функции ошибки.

$$\text{DimComp}(D) = \arg \min_{\text{size}(\hat{W}, 1)} S(\hat{\lambda}|D),$$

где  $\hat{\lambda}$  — оптимальные параметры автокодировщика.

## Гипотеза

Предполагается что между сложностью выборки и структурной сложностью нейросети есть линейная связь.



# Прогнозирование структурной сложности

Пусть задано  $M$  выборок  $\{D_1, \dots, D_M\}$ , где  $D_i = \{\mathbf{x}_m^i, y_m^i\}_{m=1}^n$ , таких что для каждой из них известна оптимальная структурная сложность классифицирующей их нейронной сети. Будем восстанавливать по этим выборкам регрессию структурной сложности модели StrComp по сложности выборки Comp:

$$\hat{\chi} = \arg \min_{\chi} \sum_{i=1}^M \left( \chi_0 + \chi_1 \text{Comp}_i - \text{StrComp}_i \right)^2,$$

получив модель регрессии мы можем получать суб-оптимальные значения структурной сложности сети для заданной геометрической сложности выборки.

$$\text{StrComp}_{\text{subopt}}(\text{Comp}) = \hat{\chi}_0 + \hat{\chi}_1 \text{Comp}.$$

В данной работе модель  $\mathbf{f}$  представлена в виде суперпозиции блоков:

$$\mathbf{f} = \mathbf{a}(\mathbf{h}_N(\dots \mathbf{h}_1(\mathbf{x}))),$$

где  $\mathbf{h}_k$  — блоки-автокодировщики, вида

$$\mathbf{h}_k(\mathbf{x}) = \sigma(\mathbf{W}_k \mathbf{x} + \mathbf{b}_k),$$

а блок  $\mathbf{a}$  — классификатор мультиномиальной логистической регрессии вида

$$\mathbf{a}(\mathbf{x}) = \arg \max_l \left( \frac{1}{\sum_{j=1}^k e^{\theta_j^\top \mathbf{x}}} \begin{bmatrix} e^{\theta_1^\top \mathbf{x}} \\ e^{\theta_2^\top \mathbf{x}} \\ \vdots \\ e^{\theta_k^\top \mathbf{x}} \end{bmatrix} \cdot \mathbf{e}_l \right),$$

где  $\mathbf{e}_l$  —  $l$ -й столбец единичной матрицы  $\mathbf{E}_k$ .

Функция ошибки модели  $\mathbf{f}$ :

$$S(\alpha) = -\frac{1}{m} \sum_{i=1}^m \sum_{j=1}^k [y_i = j] \log p(\hat{y}_i = j | \mathbf{x}_i; \alpha),$$

где  $\alpha = \{\mathbf{W}_1, \dots, \mathbf{W}_N, \mathbf{b}_1, \dots, \mathbf{b}_N, \boldsymbol{\theta}\}$  — вектор состоящий из параметров всех блоков модели  $\mathbf{f}$ , а

$$p(\hat{y}_i = j | \mathbf{x}_i; \alpha) = \frac{e^{\boldsymbol{\theta}_j^T \mathbf{h}_N(\dots \mathbf{h}_1(\mathbf{x}_i))}}{\sum_{j=1}^k e^{\boldsymbol{\theta}_j^T \mathbf{h}_N(\dots \mathbf{h}_1(\mathbf{x}_i))}}.$$

Требуется найти вектор параметров  $\alpha_{\text{opt}} \in \mathbb{W}$ , который минимизирует функцию ошибки на заданной выборке  $D$ :

$$\alpha_{\text{opt}} = \arg \min_{\alpha \in \mathbb{W}} S(\alpha | D).$$

## 1 Количественная сложность:

$$\text{Comp}_1(\mathbf{f}) = k\nu_N + \sum_{i=1}^N \nu_i(\nu_{i-1} + 1),$$

где  $k$  — количество классов, а  $\nu_i$  — размер  $i$ -го блока (скрытого слоя) модели  $\mathbf{f}$ . Размерная сложность это количество параметров модели  $\mathbf{f}$ .

## 2 Графовая сложность:

$$\text{Comp}_3(\mathbf{f}) = \sum_{i=1}^M \sum_{(k,j) \in V^i} \omega_{kj},$$

где  $V^i$  —  $i$ -й подграф,  $\omega_{ij}$  — индикатор существования ребра  $(k, j)$ ,  $M$  — число вершин графа.

### 3 Взвешенная количественная сложность:

$$\text{Comp}_2(\mathbf{f}) = \|\hat{\boldsymbol{\theta}}\|_F^2 + \sum_{i=1}^N \left( \|\hat{\mathbf{W}}_i\|_F^2 + \|\hat{\mathbf{b}}_i\|_F^2 \right),$$

где  $\hat{\boldsymbol{\theta}}$  — матрица настроенных параметров классификатора, а  $\hat{\mathbf{W}}_i, \hat{\mathbf{b}}_i$  — настроенные параметры  $i$ -го блока-автокодировщика. Взвешенная размерная сложность это сумма квадратов значений всех параметров модели.

### 4 Взвешенная графовая сложность:

$$\text{Comp}_4(\mathbf{f}) = \sum_{i=1}^M \sum_{(k,j) \in V^i} w_{kj},$$

где  $V^i$  —  $i$ -й подграф,  $w_{kj}$  — вес ребра  $(k,j)$ ,  $M$  — число вершин графа.

## Утверждение 1

Количественная  $Comp_1$  и графовая  $Comp_3$  сложности являются *структурными сложностями* для слоевых нейронных сетей настраиваемых алгоритмом глубокого обучения.

## Утверждение 2

Взвешенные количественная  $Comp_2$  и графовая  $Comp_4$  сложности являются *структурными сложностями* для слоевых нейронных сетей настраиваемых алгоритмом глубокого обучения, для которых алгоритм сошелся к глобальному минимуму.

# Вычислительный эксперимент

Для вычислительного эксперимента использовалось 6 выборок:

- 1 Временные ряды акселерометра. Количество признаков — 600, классов — 4.
- 2 Синтетически сгенерированная выборка. Количество признаков — 2, классов — 2.
- 3 Распознавание сортов вин. Количество признаков — 13, классов — 3.
- 4 Распознавание ирисов. Количество признаков — 4, классов — 3.
- 5 Распознавание патологий кожного покрова груди. Количество признаков — 9, классов — 6.





# Вычислительный эксперимент

DataSet	Comp <sub>1</sub>	Comp <sub>2</sub>	Comp <sub>3</sub>	Comp <sub>4</sub>
№1	210	2.0243e+04	4800	1.0360e+05
№2	75	2.8950e+04	60	4.3208e+04
№3	85	6.2355e+03	195	3.6551e+04
№4	16	3.6485e+03	24	5.6853e+03
№5	240	1.2314e+05	810	5.1547e+05





DataSet	GeomComp	DimComp
№1	7	7
№2	9	5
№3	14	20
№4	2	2
№5	6	15




# Прогнозирование оптимальной структурной сложности модели по геометрической сложности




# Прогнозирование оптимальной структурной сложности модели по размерной сложности



# Прогнозирование оптимальной структурной сложности модели по геометрической сложности



# Прогнозирование оптимальной структурной сложности модели по размерной сложности



- Реализован и исследован алгоритм прогнозирования структурной сложности нейронной сети по сложности выборки.
- Предложены четыре критерия структурной сложности универсальной модели нейросети.
- Предложены критерии геометрической и размерной сложности выборки.
- Проведена серия численных экспериментов на модельных данных. В результате получено, что пара  $\text{Comp}_4$  и  $\text{DimComp}$  являются хорошо коррелирующими между собой. Определение структурной сложности по быстроисчисляемой размерной сложности позволяет значительно сократить перебор гиперпараметров нейросетей.