

Московский Государственный Университет им. М.В.Ломоносова
Механико-математический факультет
Кафедра общих проблем управления

Дипломная работа

Численное моделирование в задаче определения оптимальных
архитектур нейронных сетей

Выполнил:
Студент 6 курса 632 группы
отделения математики
механико-математического факультета
Карасев Алексей Александрович

Научный руководитель:
доктор физико-математических наук,
профессор
Локуцкий Лев Вячеславович

Москва, 2018

Введение

В наш информационный век все большее применение в промышленности находит технология искусственного интеллекта, а именно, такой ее раздел как машинное обучение. С практической точки зрения машинное обучение заключается в создании алгоритма для решения поставленной задачи, используя опыт от решения задач, схожих по своей природе поставленной.

В данной работе рассматриваются алгоритмы машинного обучения, в основе которых лежат модели искусственных нейронных сетей и обучающие методы обеспечения их корректного функционирования. Определяется сущность искусственных нейронных сетей и процесс их обучения с помощью метода обратного распространения ошибки, основанного на методе градиентного спуска. Изучается вопрос о нахождении оптимальной архитектуры нейронных сетей на множестве архитектур, состоящих из одинакового числа нейронов, с некоторыми ограничивающими условиями.

В качестве приложения исследуется вопрос о численном моделировании в двух задачах нахождения оптимальной архитектуры нейронных сетей, на множестве архитектур, состоящих из двух и из трех промежуточных нейронов, с ограничивающими условиями, аппроксимирующих функции из пространства многочленов степени не больших 5, с коэффициентами, принадлежащими отрезку $[-1; 1]$, в метрике L_2 .

Цель данной работы - выяснить насколько критично с точки зрения точности выдаваемых нейронной сетью результатов предсказаний использовать архитектуры нейронных сетей с неполным набором связей, для уменьшения вычислительной сложности алгоритма обучения нейронной сети.

Модель искусственной нейронной сети

Искусственные нейронные сети (нейросети) являются математическими моделями сетей нервных клеток живых организмов. Нейросеть представляет собой систему соединенных и взаимодействующих друг с другом искусственных нейронов: узлов, которые, по сути, являются простыми процессорами.

На рис.1 рассмотрен общий вид искусственного нейрона, где:

- 1) Нейроны, выходные сигналы которых поступают на вход данному;
- 2) Веса входных сигналов;
- 3) Коэффициент смещения;
- 4) Сумматор входных сигналов и коэффициента смещения;
- 5) Вычислитель функции активации;
- 6) Выходной сигнал нейрона.




Рис. 1: Вид искусственного нейрона.


В данной работе в качестве топологической структуры (архитектуры) нейросети используется модель в виде ориентированного графа без циклов и петель, в котором вершинами являются искусственные нейроны, ребрами – синапсы, связывающие их в единую систему.

Нейроны бывают трех типов:

- Нейроны входа – принимают исходные данные (круг, i);
- Промежуточные нейроны – выполняют вычислительные операции: сумматор, функция активации (прямоугольник, h);
- Нейроны выхода – выполняют вычислительные операции: сумматор; представляют собой выходы сети (ромб, o).

В скобках указано, каким образом в данной работе обозначается нейрон, принадлежащий тому или иному типу, в виде вершины графа.

Рассмотрим пример топологической структуры нейросети:



Введем обозначения, используемые в данной работе:

N - граф (нейросеть);

$A = \{a_1, \dots, a_q\}$ - множество ребер (синапсов);

$I = \{i_1, \dots, i_k\}$ - множество нейронов входа;

$H = \{h_1, \dots, h_p\}$ - множество промежуточных нейронов;

$O = \{o_1, \dots, o_m\}$ - множество нейронов выхода;

$V = I \sqcup H \sqcup O = \{v_1, \dots, v_s\}$ - множество вершин (нейронов), где $s = k + p + m$;

$B = \{b_1, \dots, b_{p+m}\}$ - множество коэффициентов смещения;

Вершина $v \in V$ - вычислима, если в нее входят ребра точно из вычисляемых ребер. Считаем, что $v \in I$ вычислима.

Граф N - вычислим, если все его вершины вычислимы.

Если граф N - вычислим, то множество его вершин V разбивается на множество слоев $L_t \subset V$, $t = 0, \dots, n + 1$:

1) $L_0 = I$;

2) слои L_t , $t = 1, \dots, n$ итеративно образуются промежуточными нейронами множества H , таким образом, что слой L_t , $t = 1, \dots, n$ состоит из вершин, в которые ведут ребра только из слоев с номерами строго меньше t ;

3) $L_{n+1} = O$.

Утверждение:

$$V = \bigsqcup_{t=0}^{n+1} L_t$$

Считаем, что:

1) \forall вершине $v \in H$ соответствует ее функция активации $F_v : R \rightarrow R$;

2) \forall ребру $a \in A$ соответствует его вес $c_a \in R$;

3) \forall коэффициенту смещения $b \in B$ соответствует его вес $c_b \in R$;

4) \forall ребра $a \in A$ $\exists!$ вершины $l(a), r(a) \in V$ - левый и правый конец ребра;

Таким образом, \forall ребру $a \in A$ ставится в соответствие пара вершин $(l(a), r(a))$, обозначим как $l(a) \rightarrow r(a)$.

\forall вершины $v \in V$ N_v - минимальная вычисляемая подсеть графа N , содержащая v .

\forall вычисляемому графу N ставим в соответствие вектор-функцию $N(x, c) : R^k \times R^{q+p+m} \rightarrow R^m$, порожденную его топологической структурой.

$$N(x, c) = \begin{pmatrix} N_{o_1}(x, c) \\ \dots \\ N_{o_m}(x, c) \end{pmatrix}, \quad N_{o_t}(x, c) = \sum_{v \rightarrow o_t} c_{v \rightarrow o_t} N_v(x, c) + c_{b_{o_t}}$$

Как видим, функция $N(x, c)$ зависит от вектора переменных $x = (x_1, \dots, x_k)^T$

и вектора параметров $c = (c_{a_1}, \dots, c_{a_q}, c_{b_1}, \dots, c_{b_{p+m}})^T$.

Рассмотрим явное вычисление частных производных функций $N_{o_t}(x, c)$ по координатам вектора параметров c :

$$\frac{\partial N_{o_t}(x, c)}{\partial c_{a_j}} = \begin{cases} \sum_{c_{v \rightarrow o_t}} \frac{\partial N_v(x, c)}{\partial c_{a_j}} + \begin{cases} N_{l(a)}(x, c), & \text{если } r(a) = o_t \\ 0, & \text{если } r(a) \neq o_t \end{cases} \\ 0, \text{ если } a_j \notin N_{o_t} \end{cases}$$

$$\frac{\partial N_{o_t}(x, c)}{\partial c_{b_j}} = \begin{cases} \sum_{c_{v \rightarrow o_t}} \frac{\partial N_v(x, c)}{\partial c_{b_j}} + \begin{cases} 1, & \text{если } b_j = b_{o_t} \\ 0, & \text{если } b_j \neq b_{o_t} \end{cases} \\ 0, \text{ если } b_j \notin N_{o_t} \end{cases}$$

Обучение нейронных сетей

С математической точки зрения, постановка задачи обучения нейронных сетей выглядит как построение функции, задаваемой фиксированной архитектурой нейронной сети, подобранными весами синапсов и коэффициентами смещения нейронов, которая аппроксимирует функцию/класс функций из заданного пространства. Таким образом, поставленная задача сводится к решению многопараметрической задачи нелинейной оптимизации по весам синапсов и коэффициентами смещения нейронов.

$$\max_{\varphi \in \mathcal{F}} \min_{c \in \mathcal{C}} \|N(x, c) - \varphi(x)\|$$

Численные методы для обучения нейронных сетей

В данной работе в качестве численного обучения нейронных сетей используется метод обратного распространения ошибки, основанный на градиентном спуске. Градиентный спуск опирается на факт математического анализа о том, что антиградиент функции в точке указывает направление наиболее быстрого убывания функции в данной точке.

В качестве исходных данных для обучения выступает обучающая выборка – d -мерный вектор пар $[(X, Y = f(X))]^T = [(X_1^T, Y_1^T), \dots, (X_d^T, Y_d^T)]^T$, где $X_j = (x_1, \dots, x_k)^T$ – k -мерный вектор переменных (признаков), $Y_j = (y_1, \dots, y_k)^T$ – k -мерный вектор значений функции $\varphi(X)$, которая аппроксимируется искомой нейросетью.

Обучение нейросети происходит по следующему алгоритму:

0) Фиксируется архитектура сети;

1) Случайным образом задаются начальные значения весов синапсов и коэффициентов смещения нейронов. Таким образом, указывается начальная нейросеть $N(X, c_0)$;

2) Выполняется эпоха - цикл по i от 1 до d (длина выборки):

Прямое распространение:

- на вход сети подается вектор признаков X_i ;
- вычисляется значение нейросети $N(X_i, c_j)$, где c_j - вектор значений весов синапсов и коэффициентов смещения нейронов в данный момент;

Обратное распространение:

- вычисляется антиградиент функции ошибки в точке (X_i, c_j) :

$$g(X_i, c_j) = -grad(\|N(X, c) - \varphi(X)\|)(X_i, c_j);$$

- вычисляются новые значения весов синапсов и коэффициентов смещения нейронов: $c_{j+1} = c_j + \alpha * g$, где α - параметр шага градиентного спуска (чаще всего наперед заданное значение);

3) Находится ошибка нейросети с полученными после выполнения эпохи значениями вектора $c = c_{j+1}$: $\gamma(X, c_{j+1}) = \|N(X, c_{j+1}) - \varphi(X)\|$;

4) Последовательно выполняется несколько эпох, пока значение ошибки $\gamma(X, c_{j+1})$ не станет меньше наперед заданного допустимого значения ε .

Оптимальной архитектура нейронных сетей

В данной работе также рассматривается задача нахождения оптимальной архитектуры нейронной сети на некотором множестве архитектур. Таким образом, рассматриваемая задача имеет вид:

$$\min_{N \in \mathcal{N}} \max_{\varphi \in \mathcal{F}} \min_{c \in \mathcal{C}} \|N(x, c) - \varphi(x)\|$$

Приложение к практике

В качестве приложения рассматривается вопрос о численном моделировании в задаче нахождения оптимальной архитектуры нейронной сети на множестве архитектур, состоящих из одного нейрона входа и одного нейрона выхода, а также а) из двух; б) из трех промежуточных нейронов, с ограничивающими условиями, аппроксимирующих функции из пространства многочленов степени не больших 5, с коэффициентами, принадлежащими отрезку $[-1; 1]$, в метрике L_2 . В данной работе в качестве ограничений на множество

архитектур \mathcal{N} используется запрет на наличие синапсов, которые связывают нейроны входа с нейронами всех слоев, кроме первого; а так же нейроны выхода с нейронами всех слоев, кроме n -го.

Таким образом получаем задачи вида:

$$\min_{N \in \mathcal{N}} \max_{\varphi \in M_5^{[-1;1]}} \min_{c \in R} \int_0^1 |N(x, c) - \varphi(x)|^2 dx \quad (1)$$

Для численного моделирования данной задачи нахождения оптимальной архитектуры нейронной сети и их численного обучения используем машинный код, написанный на языке программирования **Python**, и его компиляцию на ЭВМ.

Для написания кода задачи численного моделирования задач вида (1) на языке программирования **Python** используем следующий алгоритм:

- 1) Генерируем набор значений X_{test} , каждый элемент которого принадлежит $[0, 1]$, для валидации всех моделей;
- 2) Генерируем случайную функцию $\varphi(X)$, принадлежащую множеству $M_5^{[-1;1]}$;
- 3) Инициализируем случайную обучающую выборку ($X_{train}, Y_{train} = \varphi(X_{train})$);
- 4) Используем цикл по множеству \mathcal{N} , перебирая, таким образом, все архитектуры, принадлежащие данному множеству:
Обучаем нейросеть, соответствующую каждой архитектуре;
- 5) Среди обученных нейросетей, соответствующих каждой архитектуре, находим нейросеть, имеющую наименьшее значение метрики ошибки на валидирующей выборке X_{test} .

Считаем архитектуру, соответствующую данной нейросети, оптимальной на множестве архитектур \mathcal{N} .

Далее рассмотрим все архитектуры нейросетей, соответствующие множествам \mathcal{N} , с ограничениями, заявленными выше, для случаев а) с двумя; б) с тремя промежуточными нейронами. А также, архитектуры нейросетей, содержащие полный набор связей.

В данной работе индексы архитектур нейросетей N_{ij} , для удобства использования, пронумерованы следующим образом:

- i - количество промежуточных нейронов в архитектуре;
- j - номер архитектуры на множестве архитектур, содержащих одинаковое число промежуточных нейронов.

Индексы весов синапсов a_{ijk} и коэффициентов смещения b_{ijk} , для удобства использования, пронумерованы следующим образом:

- i - номер соответствующей архитектуры нейросети;
- j - номер слоя, которому принадлежит $r(a_{ijk})$;
- k - номер нейрона соответствующего слоя.

а) Два промежуточных нейрона:

$$1) N_{21}(X, c) = a_{121}f(a_{111}X + b_{111}) + a_{122}f(a_{112}X + b_{112}) + b_{121}$$




Рис. 2: 2 промежуточных нейрона (Архитектура 1).

$$2) N_{22}(X, c) = a_{231}f(a_{221}f(a_{211}X + b_{211}) + b_{221}) + b_{231}$$




Рис. 3: 2 промежуточных нейрона (Архитектура 2).

$$3) N_{23}(X, c) = a_{333}f(a_{322}f(a_{311}X + b_{311}) + a_{321}X + b_{321}) + a_{332}f(a_{311}X + b_{311}) + a_{331}X + b_{331}$$



Рис. 4: 2 промежуточных нейрона (Архитектура 3 (Полный набор связей)).

b) Три промежуточных нейрона:

$$1) N_{31}(X, c) = a_{131}f(a_{121}f(a_{111}X + b_{111}) + b_{121}) + a_{132}f(a_{122}f(a_{111}X + b_{111}) + b_{122}) + b_{131}$$




Рис. 5: 3 промежуточных нейрона (Архитектура 1).

$$2) N_{32}(X, c) = a_{241}f(a_{231}f(a_{221}f(a_{211}X + b_{211}) + b_{221}) + b_{231}) + b_{241}$$



Рис. 6: 3 промежуточных нейрона (Архитектура 2).

$$3) N_{33}(X, c) = a_{321}f(a_{311}X + b_{311}) + a_{322}f(a_{312}X + b_{312}) + a_{323}f(a_{313}X + b_{313}) + b_{331}$$




Рис. 7: 3 промежуточных нейрона (Архитектура 3).

$$4) N_{34}(X, c) = a_{431}f(a_{421}f(a_{411}X + b_{411}) + a_{422}f(a_{412}X + b_{412}) + b_{421}) + b_{431}$$




Рис. 8: 3 промежуточных нейрона (Архитектура 4).

$$5) N_{35}(X, c) = a_{541}f(a_{531}f(a_{521}f(a_{511}X + b_{511}) + b_{521}) + a_{532}f(a_{511}X + b_{511}) + b_{531}) + b_{541}$$




Рис. 9: 3 промежуточных нейрона (Архитектура 5).

$$6) N_{36}(X, c) = a_{644}f(a_{633}f(a_{622}f(a_{611}X + b_{611}) + a_{621}X + b_{621}) + a_{632}f(a_{611}X + b_{611}) + a_{631}X + b_{631}) + a_{643}f(a_{622}f(a_{611}X + b_{611}) + a_{621}X + b_{621}) + a_{642}f(a_{611}X + b_{611}) + a_{641}X + b_{641}$$



Рис. 10: 3 промежуточных нейрона (Архитектура 6 (Полный набор связей)).

Вывод.

После компиляции программного кода языка **Python** на ЭВМ получаем следующие значения метрики ошибки на валидирующей выборке:

а) Два промежуточных нейрона:

N_{21} : 0.024 (оптимальная, не считая, полносвязной архитектуры)
 N_{22} : 0.038
 N_{23} : 0.022

б) Три промежуточных нейрона:

N_{31} : 0.019
 N_{32} : 0.183
 N_{33} : 0.018
 N_{34} : 0.011 (оптимальная, не считая, полносвязной архитектуры)
 N_{35} : 0.032
 N_{36} : 0.01

Таким образом, из результатов исследования делаем вывод, что **не критично** с точки зрения точности результатов предсказаний, выдаваемых нейронной сетью с двумя или тремя промежуточными нейронами, использовать оптимальные архитектуры нейронных сетей из множества архитектур с ограничивающими условиями, описанными в данной работе, для уменьшения вычислительной сложности алгоритма обучения нейронной сети.

Список литературы

- |1| М.Б. Беркинблит. Нейронные сети. // М.: МИРОС и ВЗМШ РАО, 1993. - 96 с.
- |2| А.Н. Горбань. Обучение нейронных сетей. // М. СССР-США СП "Параграф 1990. - 160 с.