

КОНСТРУКТИВНЫЙ TOWER АЛГОРИТМ ДЛЯ ОБУЧЕНИЯ НЕЙРОННЫХ СЕТЕЙ ИЗ $\Sigma\Pi$ НЕЙРОНОВ

Шибзухов З.М.

Научно-исследовательский институт прикладной математики и автоматизации
Кабардино-Балкарского научного центра РАН, ул. Шортанова 89А, г. Нальчик, 360000,
КБР, РОССИЯ, e-mail: sz@zmail.ru

Аннотация

Предлагается конструктивный Tower алгоритм для построения нейронной сети (НС), представляющей собой последовательность $\Sigma\Pi$ -нейронов. Прототипом для него явился конструктивный Tower алгоритм для построения НС, представляющей собой последовательность формальных нейронов (Σ -нейронов), первоначально предложенный в [1]. В отличие от своего предшественника, он имеет более высокую скорость сходимости процесса конструктивного обучения.

1. Введение

Конструктивный Tower алгоритм для классификации (в случае 2-х классов) был первоначально предложен в [1]. С его помощью строится последовательность Σ -нейронов (Рис. 1) с функцией преобразования вида:

$$\text{sgn}(\theta + \mathbf{w} \cdot \mathbf{x}),$$

где $\mathbf{x} \in \{0, 1\}^n$ — вектор входов, $\theta \in \mathbb{Z}$, $\mathbf{w} \in \mathbb{Z}^n$ — вектор весов Σ -нейрона, $\mathbf{w} \cdot \mathbf{x}$ — скалярное произведение \mathbf{w} и \mathbf{x} ,

$$\text{sgn}(x) = \begin{cases} 1, & \text{если } x \geq 0, \\ 0, & \text{если } x < 0. \end{cases}$$

Входы первого нейрона связаны только с входами НС, входы всех остальных нейронов связаны с выходом предыдущего нейрона и входами НС. При конструктивном обучении НС по алгоритму Tower последовательно добавляются в конец Σ -нейроны и обучаются до тех пор, пока не будет достигнута требуемая точность

классификации. Обучение каждого нового Σ -нейрона осуществляется при помощи алгоритма Pocket [1, 2]. Этот алгоритм является модификацией классического алгоритма обучения перцептрона для поиска оптимального вектора весов, при котором правильно классифицируется наибольшая часть примеров. Известно, что такая задача принадлежит к классу задач экспоненциальной сложности [3]. Поэтому в алгоритме Pocket задается верхняя граница для времени поиска оптимального набора весов Σ -нейрона.

Недостатки Tower алгоритма, в основном, являются следствием ограничений, связанных с моделью Σ -нейрона, а также недостатков алгоритмов его обучения.

Переход от модели Σ -нейронов к модели $\Sigma\Pi$ -нейронов, которые описываются полилинейными функциями, позволяет снять большую часть недостатков. Хотя модель $\Sigma\Pi$ -нейрона является более сложной, однако для неё можно построить простые алгебраические рекуррентные алгоритмы обучения по специальному образом упорядоченным обучающим последовательностям.

2. Последовательности $\Sigma\Pi$ нейронов

Рассмотрим НС с аналогичной архитектурой, но построенные на основе $\Sigma\Pi$ -нейронов с функцией преобразования вида:

$$\text{spn}(\mathbf{x}) = f(\text{spu}(\mathbf{x})), \quad (1)$$

$$\text{spu}(\mathbf{x}) = \sum_{k=1}^R w_k \prod(\mathbf{x}; \mathbf{i}_k), \quad (2)$$

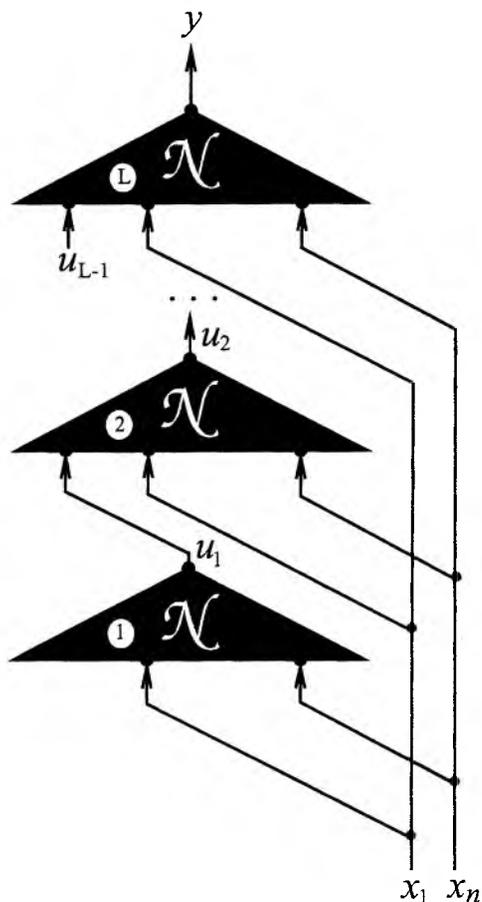


Рисунок 1: Архитектура НС.

где $f : \mathbb{Z} \rightarrow \{0, 1\}$ — скалярная функция выхода, $\mathbf{x} \in \{0, 1\}^n$ — вектор логических входов, $w_0, w_k \in \mathbb{Z}$ — весовые коэффициенты, $\mathbf{i}_k \subseteq \{1, \dots, n\}$ — мультииндексы,

$$\prod(\mathbf{x}; \mathbf{i}_k) = \prod_{i \in \mathbf{i}_k} x_i.$$

Далее символ spr будем использовать для обозначения $\Sigma\Pi$ -форм вида (2), а символ spr для обозначения функции преобразования $\Sigma\Pi$ -нейронов вида (1)-(2).

Введем два показателя сложности $\Sigma\Pi$ -форм нейронов:

$$\begin{aligned} \Sigma\text{-сложность} : \quad c_{\Sigma}(\text{spr}) &= R; \\ \Pi\text{-сложность} : \quad c_{\Pi}(\text{spr}) &= \max_{k=1, R} |\mathbf{i}_k|. \end{aligned}$$

Σ -сложность характеризует число мультипликативных слагаемых, а Π -сложность — наи-

большее число сомножителей в слагаемых $\Sigma\Pi$ -формы (2).

Рассматриваемые НС представляют собой последовательности $\Sigma\Pi$ -нейронов, в которых осуществляется цепочка преобразований:

$$\begin{aligned} u_1 &= \text{spr}_1(\mathbf{x}), \\ u_{\ell} &= \text{spr}_{\ell}(u_{\ell-1}, \mathbf{x}), \quad \ell = 2, \dots, L-1, \\ y &= \text{spr}_L(u_{L-1}, \mathbf{x}), \end{aligned}$$

где $\text{spr}_1, \dots, \text{spr}_L$ — функции преобразования $\Sigma\Pi$ -нейронов, L — количество нейронов в последовательности. При этом, предполагаем, что все нейроны в последовательности имеют ограниченную Σ -сложность, т.е. $c_{\Sigma}(\text{spr}_{\ell}) \leq M$.

Рассмотрим НС с логическими входами и выходами, содержащие логические $\Sigma\Pi$ -нейроны, т.е. $\mathbf{x} \in \{0, 1\}^n$, $u_1, \dots, u_L \in \{0, 1\}$, $y \in \{0, 1\}$. Такие НС реализуют логические функции от n переменных. Заметим, что если нет ограничения на $c_{\Sigma}(\text{spr})$ и $c_{\Pi}(\text{spr})$ (на число слагаемых и число сомножителей в слагаемых $\Sigma\Pi$ -формы, соответственно), то любую логическую функцию можно реализовать при помощи единственного $\Sigma\Pi$ -нейрона.

3. Tower алгоритм для конструктивного обучения последовательностей $\Sigma\Pi$ нейронов

Обучение НС осуществляем на основе последовательности входных логических векторов $\mathbf{X} = \{\mathbf{x}_k : k = \overline{1, N}\}$ и, соответствующей ей последовательности ожидаемых на выходе логических значений $\mathbf{Y} = \{y_k : k = \overline{1, N}\}$. Предполагаем, что \mathbf{X} является \neq -упорядоченной последовательностью, т.е. для каждой пары $1 \leq j < k \leq N$ найдется индекс $1 \leq t \leq n$ такой, что $x_{jt} < x_{kt}$.

В процессе обучения строим последовательность $\Sigma\Pi$ -форм:

$$\text{spr}_1(\mathbf{x}), \text{spr}_2(u_1, \mathbf{x}), \dots, \text{spr}_{\ell}(u_{\ell-1}, \mathbf{x}), \dots \quad (3)$$

где $u_{\ell} = \text{spr}_{\ell}(u_{\ell-1}, \mathbf{x})$, $\text{spr}_{\ell} = f(\text{spr}_{\ell})$, $1 < \ell \leq L$, L — количество нейронов. Как будет показано ниже, $L \leq \lfloor \frac{N}{M} \rfloor + 1$.

Последовательность (3) строится таким образом, чтобы выполнялось условие:

А) для всех $j = \overline{1, N_{\ell-1}}$ имело место равенство $\text{spr}_{\ell}(u_{\ell-1,j}, \mathbf{x}_j) = u_{\ell-1,j}$ (при $\ell > 1$);

В) для всех $j = \overline{N_{\ell-1}+1, N_{\ell}}$ имело место равенство $y_j = \text{spr}_{\ell}(\text{NN}_{\ell-1}(\mathbf{x}_j), \mathbf{x}_j)$ (при всех ℓ),

где $N_0 = 0, 1 < N_1 < \dots < N_{\ell-1} < N_{\ell} < N$,

$$u_{\ell-1,j} = \text{NN}_{\ell-1}(u_0, \mathbf{x}_j),$$

$$\text{NN}_1(\mathbf{x}) = \text{spr}_1(u_0, \mathbf{x}), \dots,$$

$$\text{NN}_{\ell}(\mathbf{x}) = \text{spr}_{\ell}(\text{NN}_{\ell-1}(\mathbf{x}), \mathbf{x}), \dots$$

Очередная ℓ -ая $\Sigma\Pi$ -форма $\text{spr}_{\ell}(u_{\ell-1}, \mathbf{x})$ строится по \mathbf{X} и $\mathbf{U}_{\ell} = \{u_{\ell-1,j} : j = \overline{1, N}\}$.

Легко видеть, что в этом случае для всех $j = \overline{1, N_{\ell}}$ будет иметь место равенство $\text{NN}_{\ell}(\mathbf{x}_j) = y_j$.

Таким образом, задача построения последовательности $\Sigma\Pi$ -нейронов (3) разделяется на L последовательных задач конструктивного обучения $\Sigma\Pi$ -нейронов.

Первый $\Sigma\Pi$ -нейрон строится по последовательности входных логических векторов \mathbf{X} , последовательности ожидаемых логических значений \mathbf{Y} , каждый ℓ -ый ($\ell > 1$) $\Sigma\Pi$ -нейрон строится по последовательности входных логических векторов \mathbf{X} , последовательности ожидаемых логических значений \mathbf{Y} и последовательности логических величин \mathbf{U}_{ℓ} так, чтобы выполнялись условия А и В. Построение каждого $\Sigma\Pi$ -нейрона НС основано на следующем утверждении.

Теорема. Пусть задана $\not\leq$ -упорядоченная последовательность логических векторов \mathbf{X} , последовательность логических величин \mathbf{Y} , последовательность логических величин $\mathbf{U} = \{u_k \in \{0, 1\} : k = \overline{1, N}\}$ такая, что для всех $j = \overline{1, N_0}$ ($N_0 > 0$) имеет место равенство $y_j = u_j$. Тогда существует $\Sigma\Pi$ -форма $\text{spr}(u, \mathbf{x})$ с $c_{\Sigma}(\text{spr}) \leq M$ такая, что

1) для всех $j = \overline{1, N_0}$ будет иметь место равенство $\text{spr}(u_j, \mathbf{x}_j) \equiv u_j$;

2) для всех $j = \overline{N_0+1, N_1}$, где $N_1 \geq M+N_0$, будет иметь место равенство $y_j = \text{spr}(u_j, \mathbf{x}_j)$.

Доказательство. Доказательство теоремы вытекает из следующей конструкции. Строим рекуррентную последовательность $\Sigma\Pi$ -форм:

$$\left. \begin{aligned} \text{spr}^0(u, \mathbf{x}) &\equiv g(u) \\ \text{spr}^k(u, \mathbf{x}) &\equiv \text{spr}^{k-1}(u, \mathbf{x}) + w_k \prod(\mathbf{x}; \mathbf{i}_k), \\ &\quad \text{если } \text{spr}^{k-1}(u_k, \mathbf{x}_k) \neq y_k, \\ \text{spr}^k(u, \mathbf{x}) &\equiv \text{spr}^{k-1}(u, \mathbf{x}), \\ &\quad \text{если } \text{spr}^{k-1}(u_k, \mathbf{x}_k) = y_k, \\ \text{spr}^{k-1}(u, \mathbf{x}) &= f(\text{spr}^{k-1}(u, \mathbf{x})), \\ w_k &= \hat{z}_k - \text{spr}^{k-1}(u_k, \mathbf{x}_k), \end{aligned} \right\} (4)$$

где

\hat{z}_k — такое число, что $f(\hat{z}_k) = y_k, k = 1, 2, \dots$,

$g(u)$ — линейная скалярная функция, такая что $f(g(u)) = u$.

Например, если $f(s)$ — пороговая функция со значениями в $\{0, 1\}$, то $g(u) = 2u - 1$, или если $f(s) = s \pmod{2}$, то $g(u) = u$.

Мультииндекс \mathbf{i}_k строится, исходя из $\mathbf{i}_k^0 = \{i : x_{ki} = 1\}$ путём последовательного исключения несущественных индексов. Индекс $i \in \mathbf{i}_k$ является несущественным, если для каждого $j = \overline{1, k-1}$ найдётся $t = t(j) \in \mathbf{i}_k$ и $t \neq i$ такой, что $x_{jt} < x_{kt}$ (x_{jt} и x_{kt} — t -ая компоненты \mathbf{x}_j и \mathbf{x}_k , соответственно). Строится последовательность мультииндексов $\mathbf{i}_k^0, \dots, \mathbf{i}_k^p, \dots$, в которой \mathbf{i}_k^p получается из \mathbf{i}_k^{p-1} путём исключения какого-нибудь одного несущественного индекса. При некотором p мультииндекс \mathbf{i}_k^p не будет содержать несущественных индексов. В этом случае полагаем $\mathbf{i}_k = \mathbf{i}_k^p$. Использование процедуры исключения несущественных индексов (или, что то же самое, исключения несущественных сомножителей) позволяет в принципе строить $\Sigma\Pi$ -формы с значениями $c_{\Sigma}(\text{spr})$, близкими к минимальному.

В этом случае выполняются два важных свойства:

i) для любой пары j, k такой, что $1 \leq j < k \leq N$ имеет место равенство $\prod(\mathbf{x}_j; \mathbf{i}_k) = 0$;

ii) для любого k такого, что $1 \leq k \leq N$, имеет место равенство $\prod(\mathbf{x}_k; \mathbf{i}_k) = 1$.

Поэтому для каждого k будут выполняться условия:

1) при $j \leq N_0$ выполняется равенство $\text{spr}^k(u_j, \mathbf{x}_j) = u_j = y_j$ (согласно условию леммы);

2) если для всех $N_0 < j \leq k-1$ выполняется равенство $\text{spr}^{k-1}(u_j, \mathbf{x}_j) = y_j$, то

для всех $N_0 < j \leq k$ также будет выполняться равенство $\text{spr}^k(u_j, \mathbf{x}_j) = y_j$.

Последовательность (4) обрывается на некотором шаге k_1 ($N_0 < k_1 < N$), если $c_\Sigma(\text{spr}^{k_1-1}(u, \mathbf{x})) = M$, а $\text{spr}^{k_1-1}(u_{k_1}, \mathbf{x}_{k_1}) \neq y_{k_1}$. Полагаем $\text{spr}(u, \mathbf{x}) \equiv \text{spr}^{k_1-1}(u, \mathbf{x})$. Если при некотором $k = N$ и количество слагаемых $\leq M$, то $\text{spr}(u, \mathbf{x}) \equiv \text{spr}^N(u, \mathbf{x})$ и $N_1 = N$. Что и доказывает настоящее утверждение. \square

Рекуррентная процедура построения $\Sigma\Pi$ -нейрона по \mathbf{X} , \mathbf{Y} и \mathbf{U} является модификацией аналогичной рекуррентной процедуры построения порогово-полиномиальных функций по упорядоченным табличным данным [4–6] и развитием рекуррентного алгоритма обучения $\Sigma\Pi$ -нейрона по упорядоченной паре последовательностей \mathbf{X} , \mathbf{Y} [7].

Теперь приступим к построению последовательности (3).

Строим сначала первый $\Sigma\Pi$ -нейрон так, чтобы выполнялось условие В ($\ell = 1$).

Затем последовательно строим $\Sigma\Pi$ -формы $\text{spr}_\ell(u_{\ell-1}, \mathbf{x})$ ($\ell = 2, 3, \dots$) так, чтобы выполнялись условия А и В.

Процесс построения сети завершаем, когда $N_\ell = N$.

Корректность и сходимость данной рекуррентной процедуры построения последовательности (3) вытекает из приведенного выше утверждения.

Обученные $\Sigma\Pi$ -формы удовлетворяют следующим требованиям:

- 1) для каждого $\ell = \overline{1, L}$ $c_\Sigma(\text{spr}_\ell) \leq M$;
- 2) для всех $j = \overline{1, N_1}$ $\text{spr}_1(\mathbf{x}_j) = y_j$;
- 3) при каждом $\ell = \overline{2, L}$ для всех $j = \overline{1, N_\ell}$ имеет место равенство $\text{spr}_\ell(u_{\ell-1, j}, \mathbf{x}_j) = y_j$, где $u_{\ell-1, j} = \text{NN}_{\ell-1}(\mathbf{x}_j)$.

4. Заключение

Таким образом, в результате получаем последовательность $\Sigma\Pi$ -нейронов, образующих НС , такую что для каждого $\mathbf{x}_j \in \mathbf{X}$ на выходе НС получается ожидаемое значение $y_j \in \mathbf{Y}$.

Каждый $\Sigma\Pi$ -нейрон имеет ограниченную Σ -сложность. Последовательность мультииндексов каждого $\Sigma\Pi$ -нейрона состоит из элементов, содержащих только существенные ин-

дексы. Это означает, что Π -сложность нейронов близка к минимально возможной.

При построении каждого $\Sigma\Pi$ -нейрона используется не менее M элементов обучающей последовательности \mathbf{X} , поэтому $L \leq \lfloor \frac{N}{M} \rfloor + 1$.

Работа выполнена при поддержке гранта РФФИ No. 01-01-00142, а также при поддержке Комиссии РАН по работе с молодежью.

Литература

- [1] GALLANT S. Perceptron based learning algorithms. *IEEE Transactions on Neural Networks*. 1(2): 179–191. 1990.
- [2] GALLANT S. *Neural network learning algorithms*. MIT Press. Cambridge. MA. 1993.
- [3] GAREY M., JOHNSON D. *Computers and intractability*. W.H. Freeman. New York. 1979.
- [4] Тимофеев А.В., Пшибихов А.В. Алгоритмы обучения и минимизации сложности полиномиальных распознающих систем. // *Изв. АН СССР. Техн. кибернетика*. 1974. №5. С.214–217.
- [5] Каляев А.В., Тимофеев А.В. Методы обучения и минимизации сложности когнитивных нейромодулей супер-макро-нейрокомпьютера с программируемой архитектурой. // *Доклады РАН*. 1994. Т.337. №2. С.180–183.
- [6] Шибзухов З.М. Рекуррентная схема построения кортежей многозначных функций и обучения нейронных сетей. // *Доклады Адыгской академии наук*. Нальчик. 1998. Т.3. №2. С.45–51.
- [7] Шибзухов З.М. Конструктивные рекуррентные алгоритмы синтеза $\Sigma\Pi$ -нейронных сетей. // *Доклады Адыгской академии наук*. Нальчик. 2000. Т.5. №1. С.72–77