

ИСПОЛЬЗОВАНИЕ ТЕХНОЛОГИИ ГЛУБОКОГО МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПОСТРОЕНИЯ ИНС-МОДЕЛИ ПРОФЕССИОНАЛЬНОЙ ПРЕДРАСПОЛОЖЕННОСТИ

А. А. Арзамасцев¹, e-mail: arz_sci@mail.ru

Н. А. Зенкова², e-mail: natulin@mail.ru

О.В. Крючин², e-mail: kryuchov@gmail.com

¹*Воронежский государственный университет*

²*Тамбовский государственный университет им. Г.Р. Державина*

Аннотация. Обсуждаются результаты глубокого машинного обучения искусственной нейронной сети на массиве данных, представляющих собой результаты тестирования более тысячи школьников города Тамбова в плане их профессиональной предрасположенности. В работе использована авторская программа, позволяющая автоматически определять архитектуру сети на основе конструктивного алгоритма. В докладе обсуждаются возможности использования указанного приема для извлечения новых знаний об объекте (Data Mining) и разработке компьютерных систем профессионального тестирования.

Ключевые слова: искусственные нейронные сети, машинное обучение, алгоритмы и методы глубокого обучения, ИНС-модель, анализ больших данных, извлечение знаний из данных, системы профессионального тестирования.

Введение

В настоящее время наблюдается значительный рост числа объектов из области естественных наук, информационных технологий, а также социальной сферы, требующих изучения посредством исследования их математических моделей. В случае, если информация о подобных объектах представлена массивами эмпирических данных, общая методология таких исследований базируется на традиционных приемах построения математических моделей, их параметрической идентификации с последующим изучением модели аналитическими или компьютерными методами.

Значительные возможности и универсализм в плане построения моделей на основе эмпирических данных предоставляет аппарат искусственных нейронных сетей - ИНС-модели [1-4]. Развитие математического обеспечения для научных исследований на базе языка Python в настоящее время позволяет исследователю сосредоточиться на понимании проблемы и использовать готовые, хорошо отлаженные и адаптированные алгоритмы и методы оптимизации [1], позволяющие в полной мере использовать потенциал нейронных сетей для создания генеративных ИНС-моделей [2]. Использование таких моделей уже приносит значительные результаты в науках о живых объектах - геномике, биологии,

медицине [3], и вполне может быть использовано для объектов социальной сферы.

Ранее авторами данного доклада были построены ИНС-модели для различных систем психологического тестирования, позволившие вскрыть систему внутренних связей тестов, а также были разработаны методики психологического и профессионального тестирования, базирующиеся на обучении ИНС-моделей с использованием эмпирических данных для значительного числа респондентов и их независимых оценок [5].

В качестве инструмента получения знаний использовали аппарат искусственных нейронных сетей (ИНС-модели), включающий в себя конструктор структур, который позволяет оперативно изменять структуру ИНС-моделей и алгоритмы машинного обучения, что позволяет успешно решать задачи параметрической идентификации [5].

Выбор архитектуры сети является наиболее существенной проблемой при построении ИНС-модели какого-либо объекта [1]. На практике при конструировании архитектуры сети, предназначенной для описания некоторых эмпирических данных могут быть использованы следующие подходы: интуитивное представление о структуре связей объекта; теоремы Колмогорова о представимости функции многих переменных в виде суперпозиций и сумм функций одной переменной; возможность разложения функции многих переменных в ряд Тейлора; конструктивные (наращивание структуры сети от минимальной до оптимальной) или деструктивные (сокращение структуры сети от некоторой избыточной до оптимальной) алгоритмы.

В наших первых работах 2005-2010 года мы использовали архитектуры ИНС-моделей, вытекающие из классических теорем Вейерштрасса и Колмогорова, а также из разложения функции многих переменных в ряд Тейлора. Практика использования такого подхода показала, что полученные модели имеют следующие недостатки: аппроксимативный характер, не позволяющий увидеть "тонкие" стороны рассматриваемого объекта; незначительное число скрытых слоев, не позволяющее достичь глубокого обучения. В дальнейших работах мы использовали конструктивный алгоритм, обеспечивающий постепенное наращивание нейронов в скрытом слое и числа скрытых слоев, что позволяло получать многослойные полносвязные структуры и избегать переобучения ИНС-моделей ввиду поэтапного наращивания сети.

Конструктивный алгоритм модификации архитектуры ИНС-модели

Данный алгоритм использует полносвязные ИНС-модели с прямым распространением сигнала. Он базируется на двух эмпирических феноменах обучения ИНС-модели, которые обычно наблюдаются при изменении числа нейронов в скрытом слое и количества скрытых слоев (см. рис. 1 а,б).

На рис. 1 а) показано как изменяется ошибка обучения сети при изменении числа нейронов в скрытом слое. Видно, что вначале, при добавлении новых нейронов ошибка убывает. Однако, начиная с некоторого числа нейронов, она стабилизируется так, что дальнейшее увеличение их количества не приводит к снижению ошибки обучения. По всей видимости, речь здесь может идти о непреодолимой погрешности, которую можно связать с несоответствием структуры ИНС-модели и моделируемого объекта. Можно сделать вывод, что увеличивать число нейронов в слое целесообразно лишь до тех пор, пока это приводит к уменьшению ошибки обучения (на рис. 1 а это число – 4 или 5).

На рис. 1 б) показано, как изменяется ошибка обучения сети при увеличении числа скрытых слоев, при условии, что выбор количества нейронов в каждом слое производится так, как это показано на рис. 1 а). Из этого рисунка видно, что ошибка обучения сети быстро убывает до остаточного значения $F_{ост}$, которое не может быть уменьшено в дальнейшем. Такое значение $F_{ост}$ может быть связано с погрешностью эмпирических данных, используемых при обучении ИНС-модели. Из рис. 1 б) также хорошо видно, что информацию об уменьшении $F_{ост}$ можно использовать для выбора числа скрытых слоев. Так, ошибка обучения практически не меняется при использовании 3-х или 4-х скрытых слоев, следовательно такая величина и может быть выбрана для ИНС-модели (рис. 1. б)).




Рис. 1. К алгоритму выбора числа нейронов в скрытом слое – а) и количества скрытых слоев – б) ИНС-модели.

Рассмотренная феноменология обучения ИНС использована нами для конструирования алгоритма самоорганизации структуры. Суть алгоритма заключается в постепенном наращивании числа нейронов в каждом слое и числа скрытых слоев до тех пор, пока ошибка обучения сети $F_{ост}$ не перестанет уменьшаться.

В блоке 1 задают число входов ИНС-модели – n (определяется постановкой задачи и зависит от числа факторов, оказывающих влияние на моделируемый объект), число выходов – k (определяется как число факторов, являющихся результатом моделирования и интересующих пользователя системы); начальное число слоев – S принимается равным единице.

В блоках 2 и 3 задаются начальные условия: начальная лучшая невязка для нейрона ($BestError$) – максимальное число используемого типа; начальная лучшая невязка для слоя ($LayerBestError$) – максимальное число используемого типа; начальная лучшая невязка для всей сети ($NetBestError$). В процессе конструирования сети данные невязки будут изменяться и достигать своего минимального значения.

Также пользователем задается величина $delta$ – несущественное изменение невязки. Если разница между двумя невязками (полученной в настоящий момент времени и предыдущей) становится меньше величины $delta$, то построение слоя (в случае несущественного изменения $BestError$) или построение всей сети (в случае несущественного изменения $LayerBestError$) будет прекращено.

В блоке 4 задается первоначальное число нейронов в каждом из предполагаемых слоев ИНС равным нулю.

В блоке 5 при переходе к построению нового слоя нейронов невязка сети получает то значение, которое получилось в конце построения предыдущего нейронного слоя.

В блоке 6 в начале построения нового нейронного слоя счетчик слоев в сети - S увеличивается на единицу.

В блоке 7 при подборе нового нейрона в текущем слое счетчик нейронов в этом слое – i увеличивается на единицу.

В блоке 8 при подборе нового нейрона в текущем слое невязка данного слоя получает то значение, которое получилось в результате подбора предыдущего нейрона в слое.

В блоке 9 при подборе активационной функции каждого нового нейрона в текущем слое осуществляется перебор всех уже имеющихся в наличии слоев ИНС.

В блоке 10 осуществляется перебор всех нейронов в каждом из уже построенных слоев ИНС.

В блоке 11 осуществляется перебор всех имеющихся в распоряжении пользователя активационных функций нейронов. Таким образом, имеется возможность не просто подобрать активационную функцию только для одного (рассматриваемого в данный момент времени) нейрона при закрепленных активационных функциях остальных нейронов в сети, а произвести перебор всех имеющихся нейронов и, если это приведет к уменьшению значения невязки, поменять активационные функции некоторых из них.

В блоке 12 производится обучение сети по определенному алгоритму (один из методов определения минимума функции многих переменных) и находится значение лучшей текущей невязки - e_j .

Блок 13. Если произошло уменьшение лучшей текущей невязки - e_j по сравнению с лучшей невязкой для подбираемого в данный момент времени нейрона - $BestError$, то управление передается к блоку 14, в противном случае осуществляется переход к новой активационной функции нейрона (блок 11).

В блоке 14 номер активационной функции, при которой произошло уменьшение e_j , записывается в массив $FBest$ в строку с номером S (этот номер соответствует номеру слоя) и в столбец с номером i (этот номер соответствует номеру нейрона, активационная функция которого подбирается в данный момент времени).

В блоке 15 значение невязки e_j записывается в переменную $BestError$ – теперь это значение будет лучшим для подбираемого нейрона.

В блоке 16 осуществляется запись текущих значений коэффициентов синаптических связей.

Блок 17. Если произошло существенное уменьшение (на величину, большую, чем δ) величины лучшей невязки последнего нейрона ($BestError$) относительно лучшей невязки для последнего построенного слоя ($LayerBestError$), то можно добавить в текущий слой еще хотя бы один нейрон (см. блоки 18 и 19). В противном случае (если существенного уменьшения невязки не произошло), то добавление нового нейрона в текущий слой, вероятнее всего, не приведет к дальнейшему существенному уменьшению лучшей невязки, т.е. необходимо перейти к блоку 20.

В блоке 18 осуществляется запись количества нейронов на последнем построенном слое.

В блоке 19 производится восстановление начальных коэффициентов синаптических связей и осуществляется переход к блоку 7.

Блок 20. Если произошло существенное уменьшение (на величину, большую, чем δ) величины лучшей невязки последнего построенного слоя ($LayerBestError$) относительно лучшей невязки сети ($NetBestError$), то можно добавить в сеть еще хотя бы один нейронный слой: перейти к пункту 4. В противном случае (если существенного уменьшения невязки не произошло), то добавление нового слоя в сеть не приведет к дальнейшему уменьшению лучшей невязки сети, т.е. необходимо перейти к блоку 21.

Блок 21. Сеть построена.

Данный алгоритм реализован в виде нескольких программ [7, 8], которые позволяют осуществлять следующие функции:

- ввод исходных данных для обучения сети (векторы x и y) из отдельных файлов; в программе реализуется концепция «обучение с учителем»;
- обучение ИНС по методам сканирования, Монте-Карло и градиентному;
- выбор передаточной функции нейронов (линейная, параболическая второй степени, параболическая третьей степени, сигмоид);
- визуализацию ошибки обучения сети по мере увеличения числа нейронов в слое и увеличения числа слоев;
- визуализацию структуры сети в виде схемы;
- запись в соответствующие файлы результатов обучения сети: ее структуры, коэффициентов передачи (синаптических связей), функций нейронов и погрешностей обучения.

Глубокое обучение ИНС-модели на эмпирических данных по профессиональной предрасположенности школьников

Программа и алгоритм использованы для построения компьютерной модели профессиональной предрасположенности школьников старших классов города Тамбова на основе значительного по объему эмпирического материала [6]. Обучающая выборка, являющаяся результатом анкетирования более чем тысячи школьников, представляла собой прямоугольную матрицу размером 1052 строки и 253 столбца. Строки представляли собой записи, соответствующие респонденту, столбцы – варианты ответа респондентов на вопросы анкеты, касающейся предрасположенности к дальнейшему образованию в университете по различным профилям. В качестве выходной переменной использовали независимую оценку личностных качеств каждого респондента.

Обучение ИНС-модели проводили таким образом, что архитектура сети выбиралась автоматически по описанному ранее алгоритму. При этом приведенная погрешность на контрольной выборке составила не более 10%, что позволило считать ИНС-модель адекватной реальному объекту (в данном случае объектом являлся социум, включающий учащихся старших классов школ г. Тамбова). Общая структура полученной сети показана на рис. 2, а ее коэффициенты синаптических связей приведены в табл. 1- 4.




Рис. 2. Структура ИНС-модели. 1-58, 60-65, 69, 71 – входные нейроны и нейроны с линейной активационной функцией, 59, 66, 67, 68 – нейроны с активационной функцией типа «сигмоид» - $(f(s)=1/(1+s^2))$, 70 – нейрон с параболической активационной функцией $(f(s)=s^2)$, 78 – выходной нейрон с параболической активационной функцией $(f(s)=s^3)$. Общее число связей (весовых коэффициентов сети) – 444.

Табл. 1.

Коэффициенты связей нейронов входного и первого скрытого слоев ИНС-модели.

Номера нейронов, от которых осуществляется передача сигнала	Номера нейронов, к которым осуществляется передача сигнала						
	59	60	61	62	63	64	65
1	0,010	0,073	0,016	0,077	0,067	0,074	0,093
2	0,047	0,088	0,089	0,016	0,057	0,063	0,098
3	0,024	0,033	0,046	0,059	0,020	0,075	0,081
4	0,026	0,010	0,008	0,052	0,071	0,093	0,024
5	0,025	0,026	0,056	0,022	0,035	0,040	0,086
6	0,017	0,047	0,098	0,096	0,062	0,017	0,030
7	0,092	0,014	0,001	0,007	0,095	0,026	0,058
8	0,066	0,048	0,094	0,010	0,044	0,038	0,051
9	0,023	0,086	0,028	0,053	0,088	0,092	0,078
10	0,010	0,058	0,080	0,018	0,015	0,070	0,080
11	0,087	0,047	0,037	0,005	0,065	0,076	0,038
12	0,029	0,099	0,067	0,080	0,034	0,032	0,027
13	0,064	0,059	0,057	0,056	0,028	0,010	0,070
14	0,086	0,013	0,013	0,058	0,041	0,072	0,094
15	0,050	0,078	0,023	0,062	0,026	0,061	0,052
16	0,070	0,094	0,027	0,049	0,022	0,081	0,019
17	0,001	0,005	0,092	0,013	0,003	0,070	0,010
18	0,046	0,090	0,045	0,070	0,060	0,055	0,014
19	0,004	0,084	0,040	0,046	0,041	0,001	0,014
20	0,047	0,063	0,025	0,035	0,007	0,021	0,013
21	0,060	0,017	0,019	0,060	0,075	0,062	0,037
22	0,098	0,089	0,039	0,058	0,061	0,092	0,028
23	0,024	0,013	0,031	0,022	0,074	0,062	0,088
24	0,080	0,074	0,019	0,078	0,039	0,099	0,058
25	0,068	0,052	0,082	0,008	0,078	0,018	0,087
26	0,021	0,060	0,095	0,086	0,090	0,009	0,083
27	0,077	0,086	0,084	0,013	0,091	0,035	0,037
28	0,086	0,074	0,097	0,067	0,079	0,059	0,037
29	0,047	0,072	0,097	0,099	0,005	0,038	0,086
30	0,073	0,072	0,039	0,079	0,007	0,069	0,051
31	0,092	0,049	0,081	0,084	0,085	0,051	0,072
32	0,031	0,074	0,009	0,083	0,040	0,053	0,037
33	0,015	0,084	0,077	0,060	0,069	0,001	0,084
34	0,038	0,049	0,028	0,099	0,008	0,018	0,086
35	0,061	0,022	0,083	0,045	0,085	0,085	0,060

Номера нейронов, от которых осуществляется передача сигнала	Номера нейронов, к которым осуществляется передача сигнала						
	59	60	61	62	63	64	65
36	0,005	0,020	0,032	0,008	0,044	0,078	0,029
37	0,052	0,043	0,044	0,090	0,021	0,025	0,016
38	0,062	0,042	0,083	0,025	0,050	0,061	0,008
39	0,059	0,060	0,091	0,013	0,095	0,045	0,058
40	0,040	0,014	0,097	0,055	0,095	0,054	0,054
41	0,050	0,002	0,070	0,004	0,031	0,056	0,071
42	0,022	0,014	0,067	0,094	0,036	0,067	0,032
43	0,090	0,018	0,046	0,058	0,039	0,044	0,094
44	0,042	0,084	0,028	0,078	0,082	0,022	0,030
45	0,041	0,075	0,094	0,033	0,053	0,032	0,032
46	0,093	0,003	0,098	0,034	0,006	0,094	0,072
47	0,074	0,097	0,030	0,060	0,069	0,023	0,056
48	0,055	0,050	0,007	0,046	0,069	0,091	0,042
49	0,002	0,022	0,071	0,046	0,006	0,087	0,079
50	0,056	0,040	0,052	0,019	0,057	0,043	0,005
51	0,024	0,005	0,097	0,082	0,098	0,088	0,006
52	0,002	0,048	0,016	0,011	0,008	0,079	0,069
53	0,001	0,089	0,100	0,043	0,097	0,089	0,093
54	0,026	0,088	0,038	0,087	0,016	0,016	0,061
55	0,064	0,073	0,074	0,032	0,052	0,091	0,008
56	0,038	0,053	0,099	0,043	0,026	0,032	0,028
57	0,043	0,067	0,005	0,007	0,092	0,048	0,022
58	0,037	0,029	0,099	0,009	0,063	0,010	0,076

Табл. 2.

Коэффициенты связей нейронов первого и второго скрытых слоев ИНС-модели.

Номера нейронов, от которых осуществляется передача сигнала	Номера нейронов, к которым осуществляется передача сигнала			
	66	67	68	69
59	0,030	0,012	0,014	0,081
60	0,021	0,041	0,001	0,068
61	0,004	0,035	0,080	0,009
62	0,083	0,008	0,016	0,056
63	0,019	0,013	0,089	0,091
64	0,085	0,032	0,003	0,030
65	0,073	0,079	0,024	0,030

Табл. 3.

Коэффициенты синаптических связей нейронов второго и третьего скрытых слоев ИНС-модели.

Номера нейронов, от которых осуществляется передача сигнала	Номера нейронов, к которым осуществляется передача сигнала	
	70	71
66	0,010	0,079
67	0,013	0,007
68	0,004	0,094
69	0,014	0,077

Табл. 4.

Коэффициенты синаптических связей нейронов третьего скрытого и выходного слоев ИНС-модели.

Номера нейронов, от которых осуществляется передача сигнала	Номера нейронов, к которым осуществляется передача сигнала	
	78	
70	0,049	
71	0,084	

Заключение

Таким образом, на основе значительного массива эмпирических данных нами получена многослойная ИНС-модель профессиональной предрасположенности. Из рис. 2 видно, что данная модель имеет четыре скрытых внутренних слоя, содержащих как линейные, так и нелинейные элементы, которые были найдены автоматически в соответствии с приведенным алгоритмом. Данные обстоятельства, а также значения весовых коэффициентов, приведенные в табл. 1-4 позволяют классифицировать модель как нелинейную со значительным количеством связей между входными и внутренними параметрами.

Полученная ИНС-модель может использоваться и в качестве генеративной, т.к. обобщая эмпирические данные с погрешностью, не превышающей 10%, она может предсказывать выходные значения для респондентов, результаты тестирования которых не содержатся в обучающей выборке.

Эти и другие свойства полученной ИНС-модели позволили говорить о ее глубоком обучении в данной предметной области. Указанные обстоятельства позволяют использовать ее как для извлечения новых знаний об объекте (Data Mining), так и в качестве ядра при разработке компьютерных систем профессионального тестирования.

Список литературы

1. Будума Н. Основы глубокого обучения. Создание алгоритмов для искусственного интеллекта следующего поколения / Нихиль Будума, Николас Локашо ; пер. с англ. А. Коробейникова; [науч. ред. А. Созыкин]. — М. : Манн, Иванов и Фербер, 2020. — 304 с.
2. Фостер Д. Генеративное глубокое обучение. Творческий потенциал нейронных сетей. — СПб.: Питер, 2020. — 336 с.
3. Рамсундар Б., Истман П., Уолтерс П., Панде В. Глубокое обучение в биологии и медицине / пер. с англ. В. С. Яценкова. – М.: ДМК Пресс, 2020. – 200 с.
4. Харрисон М. Машинное обучение: карманный справочник. Краткое руководство по методам структурированного машинного обучения на Python. : Пер. с англ. - СПб. : ООО "Диалектика", 2020 - 320 с.
5. Арзамасцев А.А., Зенкова Н.А. Моделирование в психологии на основе искусственных нейронных сетей. – Тамбов: ИМФИ ТГУ им. Г.Р. Державина, 2003. – 106 с.
6. Арзамасцев А.А., Безрученко И.Е., Зенкова Н.А. Личностные качества и профессиональная предрасположенность школьников старших классов города Тамбова. – Тамбов: ИМФИ ТГУ имени Г.Р. Державина, 2004. – 103 с.
7. Свидетельство о государственной регистрации программы для ЭВМ № 2007610622. Многофункциональный программный комплекс для компьютерного моделирования на основе искусственной нейронной сети с самоорганизацией структуры / А.А. Арзамасцев, О.В. Крючин, А.Н. Королев, Н.А. Зенкова. - 08.02.2007.
8. Свидетельство о государственной регистрации программы для ЭВМ № 2017619671. Программный комплекс для моделирования нейронных сетей с параметрически изменяющимися активационными функциями нейронов / А.А. Арзамасцев, М.А. Кисляков, Н.А. Зенкова. - 01.09.2017.