

ИНВАРИАНТНОСТЬ ПО СКАЛЯРНОМУ КРИТЕРИЮ РАСПОЗНАВАНИЯ ОБРАЗОВ

П.В. ЧЕТЫРБОК

Построено изоморфное отображение множества распознаваемых образов на множество вещественных чисел из интервала $[0, 1]$, которое позволяет связать классификацию распознаваемых образов с поведением скалярного критерия в пространстве ошибок. Предложенный в статье функционал и решающее правило (скалярный критерий для распознавания образов) позволяют создать модель нейронной сети инвариантной к трансформациям распознаваемых образов.

ВВЕДЕНИЕ

Из известных методов обучения нейронных сетей наиболее широкое применение имеют градиентные методы со случайным изменением начальных условий [1, 3, 4]. Недостатком этих методов являются трудности распознавания образов в случае близости по норме Евклида сравниваемых образов.

Существует также множество подходов к определению степени сходства входных сигналов. Один из них применяется для определения степени подобия входных образов для нейронных сетей на основе Евклидова расстояния [1].

Пусть существует некоторый вектор x размерности m :

$$x_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T.$$

Элементы вектора — действительные числа, а обозначение «Т» указывает на транспонирование матрицы. Вектор x_i определяет некоторую точку в m -мерном Евклидовом пространстве (R^m). Евклидово расстояние между парой m -мерных векторов x_i и x_j вычисляется по формуле:

$$d(x_i - x_j) = \|x_i - x_j\| = \left[\sum_{k=1}^m (x_{ik} - x_{jk})^2 \right]^{1/2},$$

где x_{ik} и x_{jk} — k -е элементы векторов x_i и x_j соответственно. Чем ближе друг к другу отдельные элементы векторов x_{ik} и x_{jk} , тем меньше Евклидово расстояние. В данной работе рассматривается подход к определению степени сходства образов, который основывается на скалярном критерии распознавания образов нейронной сетью, построенный на идее скалярного произведения векторов.

ПОСТАНОВКА ЗАДАЧИ

Цель работы — построить отображение множества распознаваемых образов на множество действительных чисел из интервала $[0, 1]$ так, чтобы задавая определенные интервалы для этих чисел, можно было бы группировать

образы, распознавать, сравнивать и анализировать их. Сходные входные сигналы от схожих классов должны формировать единое представление в нейронной сети. Исходя из этого, они должны быть классифицированы как принадлежащие к одной категории [1, 2]. Необходимо также определить степень сходства, используя скалярный критерий для распознавания образов [5].

Нейронные сети обладают естественной способностью классификации образов. Эту способность можно использовать для обеспечения инвариантности сети к трансформациям. Сеть обучается на множество примеров одного и того же объекта, при этом в каждом примере объект подается в несколько измененном виде (например, снимки с разных ракурсов). Если количество таких примеров достаточно велико и если нейронная сеть обучена отличать разные точки зрения на объект, можно ожидать, что эти данные будут обобщены и сеть сможет распознать ракурсы объекта, которые не использовались при обучении. Однако с технической точки зрения инвариантность по обучению имеет два существенных недостатка:

- во-первых, если нейронная сеть научена распознавать трансформации объектов некоторого класса, то совсем не обязательно, что она будет обладать инвариантностью по отношению к трансформациям объектов других классов;
- во-вторых, такое обучение является очень ресурсоемким, особенно при большой размерности пространства признаков.

Скалярный критерий распознавания образов можно получить с помощью вектора ошибок, полученного при распознавании нейронной сетью входного образа, и вектора ошибок, полученного при распознавании нейронной сетью эталонного образа. Если за эталонные образы взять образы трансформации объектов, то получим алгоритм их распознавания. То есть, каждому образу трансформации объекта будет отвечать свое значение скалярного критерия. Поскольку вычисление скалярного критерия не изменяет значения весовых коэффициентов нейронной сети, то нейронная сеть может распознавать трансформацию объектов нескольких классов одновременно и при этом расчет скалярного критерия является не расходным по ресурсам.

ПОСТРОЕНИЕ СКАЛЯРНОГО КРИТЕРИЯ РАСПОЗНАВАНИЯ ОБРАЗОВ СИГНАЛОВ

Построим модель нейронной сети в виде: $y_i = Wx_i$, где $y_i = \begin{pmatrix} y_i^1 \\ y_i^2 \\ \dots \\ y_i^m \end{pmatrix}$ — век-

торы выхода; $x_i^T = (x_i^1; x_i^2; \dots; x_i^m)$ — векторы входных воздействий; m — размерность пространства образов; $i=1, \dots, n$, где n — число обучаемых образов.

Матрица весовых коэффициентов нейронной сети, обученной распознавать образ y_1 , будет иметь вид:

$$W_1 = \begin{pmatrix} y_1^1 x_1^1 \dots y_1^1 x_1^m \\ y_1^2 x_1^1 \dots y_1^2 x_1^m \\ \dots \\ y_1^m x_1^1 \dots y_1^m x_1^m \end{pmatrix}; \quad y_1 = \begin{pmatrix} y_1^1 (x_1^1 x_1^1 + x_1^2 x_1^2 + \dots + x_1^m x_1^m) \\ y_1^2 (x_1^1 x_1^1 + x_1^2 x_1^2 + \dots + x_1^m x_1^m) \\ \dots \\ y_1^m (x_1^1 x_1^1 + x_1^2 x_1^2 + \dots + x_1^m x_1^m) \end{pmatrix}.$$

Необходимым и достаточным условием для точного воспроизведения эталонного выхода является ортогональность и ортонормированность входных векторов сигналов при обучении нейронной сети.

Пусть отклонение на этапе распознавания образа на входе будут равны:

$$\Delta x_i^T = (\Delta x_i^1; \Delta x_i^m; \dots; \Delta x_i^m).$$

Тогда

$$y + \Delta y = W \begin{pmatrix} x_i^1 + \Delta x_i^1 \\ x_i^2 + \Delta x_i^2 \\ \dots \\ x_i^m + \Delta x_i^m \end{pmatrix}.$$

Для отклонений на выходе можно записать:

$$\Delta y_1 = \begin{pmatrix} y_1^1 (x_1^1 \Delta x_1^1 + x_1^2 \Delta x_1^2 + \dots + x_1^m \Delta x_1^m) \\ y_1^2 (x_1^1 \Delta x_1^1 + x_1^2 \Delta x_1^2 + \dots + x_1^m \Delta x_1^m) \\ \dots \\ y_1^m (x_1^1 \Delta x_1^1 + x_1^2 \Delta x_1^2 + \dots + x_1^m \Delta x_1^m) \end{pmatrix}.$$

Оценим ошибку на выходе:

$$E2 = \sqrt{\sum_{i=1}^m \Delta y_1^i}, \quad i = 1, \dots, m;$$

$$E3 = \sum_{i=1}^m |\Delta y_1^i|, \quad i = 1, \dots, m;$$

$$E4 = \max(\Delta y_1^i), \quad i = 1, \dots, m.$$

Построим функционал, который равен скалярному произведению нормированных векторов ошибок $E = (E2, E3, E4)$, $X = (X1, X2, X3)$ при распознавании нейронной сетью сигналов и соответствующих им элементов. Скалярный критерий распознавания образов (сигналов) вычислим следующим образом:

$$\cos(\lambda) = \frac{(\bar{E}, \bar{X})}{\|E\|_c \|X\|_c},$$

где E — вектор ошибок в пространстве ошибок, полученный при распознавании нейронной сетью входного образа; X — вектор ошибок, полученный при распознавании нейронной сетью эталонного образа.

Для распознавания двух векторов сигналов $x_1^T = (x_1^1; x_1^2; \dots; x_1^m)$ и $x_2^T = (x_2^1; x_2^2; \dots; x_2^m)$ найдем:

$$W_1 = \begin{pmatrix} y_1^1 x_1^1 \dots y_1^1 x_1^m \\ y_1^2 x_1^1 \dots y_1^2 x_1^m \\ \dots \\ y_1^m x_1^1 \dots y_1^m x_1^m \end{pmatrix}; \quad W_2 = \begin{pmatrix} y_2^1 x_2^1 \dots y_2^1 x_2^m \\ y_2^2 x_2^1 \dots y_2^2 x_2^m \\ \dots \\ y_2^m x_2^1 \dots y_2^m x_2^m \end{pmatrix}.$$

Учитывая, что $y_1 = Wx_1^T$ и $y_2 = Wx_2^T$ получим $W = W_1 + W_2$, откуда находим W . Для обучения распознавания трех образов получим условие $W = W_1 + W_2 + W_3$ и в общем случае $W = \sum_{i=1}^n W_i$, где n — число обучаемых образов.

Таким образом, построено отображение множества входных сигналов на множество действительных чисел. Это отображение разбивает множество векторов входных сигналов на классы. Отображение является отношением эквивалентности, то есть оно рефлексивно, симметрично и транзитивно. Отображение разбивает множество векторов входных сигналов на непересекающиеся классы. Отображение состоит из композиции двух отображений. Сначала множество векторов входных сигналов (конечное множество) отображается в трехмерное векторное пространство ошибок, а затем конечное множество векторов ошибок отображается на конечное подмножество множества действительных чисел.

КОМПЬЮТЕРНАЯ МОДЕЛЬ НЕЙРОННОЙ СЕТИ

Нейронная сеть обучена распознавать 128 двоичных 7-ми разрядных входных образов с помощью пакета программ «Универсальная система интеллектуального анализа данных, распознавания и прогноз INTENSIV» [5], которая включает в свой состав программу обучения, программу самообучения нейронной сети и программу распознавания образов. Для обучения используем 8 двоичных образов: 10000000, 01000000, 00100000, 00010000, 00001000, 00000100, 00000010, 00000001. В результате работы программы сформирован массив весовых коэффициентов, то есть нейронная сеть обучена распознавать 8 образов (рассчитан скалярный взвешенный критерий). Далее с помощью программы самообучения обучаем нейронную сеть распознавать остальные 120 образов, при этом их двоичные коды и коды их эталонов, берем из таблицы. Программа самообучения в отличие от программы обучения не изменяет весовые коэффициенты, а только рассчитывает скалярный коэффициент близости образов. В результате обучения и самообучения нейронной сети получена таблицы, которая используется программой распознавания образов. Программа распознавания образа, которая согласно скалярного критерия $\cos(\lambda)$ из таблицы распознает произвольный входной двоичный образ, поданный на вход нейронной сети одновременно может служить классификатором, в котором за вектора ядер

классов образов (объектов) взять вектора (10000000, 01000000, 00100000, 00010000, 00001000, 00000100, 00000010, 00000001). Они расположены друг от друга на Хемминговом расстоянии равном 2. Тогда 128 образов будут разбиты на 8 классов. Так, например, к 5-му классу относятся образы (объекты) для которых скалярный взвешенный критерий $\cos(\lambda)$ принадлежит интервалу (0,941047928053614–0,943743056402821). Изменяя количество классов (ядер) получаем новый набор интервалов изменения взвешенного критерия, тем самым получаем новую классификацию образов.

Т а б л и ц а . Классификатор 128 двоичных 7-ми разрядных образов

Двоичный код образа	Эталон образа	$\cos(\lambda)$	Код ASCII образа	Расстояние Хемминга
1	2	3	4	5
10000000	10000000	0,826060581600673		7
10100000	01000000	0,936690872552962	Пробел	6
11000000	01000000	0,937353881522576	@	6
10001000	01000000	0,939245716842437		6
10000010	01000000	0,939263409282480		6
10000100	01000000	0,939304982387979		6
10000001	01000000	0,939647045540305		6
10010000	01000000	0,940389901624390		6
10100010	00100000	0,941047928053614	"	5
...		
10100110	00010000	0,956128458420992	&	4
...		
11101010	00001000	0,958826663453392	<i>j</i>	3
...		
10111101	00000100	0,969290551841973		2
...		
11110111	00000010	0,975981352716797	<i>w</i>	1
11111110	00000010	0,976329462651463		1
11111011	00000010	0,976432641051323		1
10111111	00000010	0,976457343732489		1
11101111	00000010	0,976467676878091	<i>o</i>	1
11111111	00000001	0,979024638356988		0

Из анализа результатов, представленных в таблицы (классификатор 128 двоичных 7-ми разрядных образов) образы классифицированные по расстоянию Хемминга компактно расположены на скалярной оси величин $\cos(\lambda)$ и не наблюдается случаев, когда нарушалась бы однозначность отображения множества значений расстояний между образами по Хеммингу и множества значений скалярного произведения векторов отклонения от эталонных. При таком отображении сохраняется не только однозначность, но и компактность ядра образов и гладкость отображения. Если сравнить с сетью Хопфилда, которая используется для ассоциативной памяти, то можем утверждать что предложенный алгоритм обучения НС позволяет построить более надежную память. Для сети Хопфилда число запоминаемых

образов m не должно превышать величины, примерно равной $0,15n$. Кроме того, если два образа A и B сильно похожи, они, возможно, будут вызывать у сети перекрестные ассоциации, то есть предъявление на входы сети вектора A приведет к появлению на ее выходах вектора B и наоборот. Ассоциативная память, построенная с помощью скалярного критерия надежно запоминает 2^n образов, где n — размерность пространства входных образов и никогда не распознает образ, ранее невиденный.

Традиционные искусственные нейронные сети оказались не в состоянии решить проблему стабильности-пластичности. Очень часто обучение новому образу уничтожает или изменяет результаты предшествующего обучения. В некоторых случаях это не существенно. Если имеется только фиксированный набор обучающих векторов, они могут предъявляться при обучении циклически. Рассмотренные нейронные системы не адаптированы к решению этой задачи. Так, например, многослойный персептрон, обучающийся по методу обратного распространения, запоминает весь пакет обучающей информации, при этом образы обучающей выборки предъявляются в процессе обучения многократно. Попытки затем обучить персептрон новому образу приведут к модификации синаптических связей с неконтролируемым разрушением структуры памяти о предыдущих образах. Таким образом, персептрон не способен к запоминанию новой информации, и необходимо полное переобучение сети. Аналогичная ситуация имеет место и в сетях Кохонена и Хемминга, обучающихся на основе самоорганизации. Данные сети всегда выдают положительный результат при классификации. Тем самым, эти нейронные сети не в состоянии отделить новые образы от искаженных или зашумленных версий старых образов.

В реальной ситуации сеть будет подвергаться постоянно изменяющемуся воздействию; она может дважды не увидеть один и тот же обучающий вектор. При таких обстоятельствах сеть, скорее всего, не будет обучаться; она будет непрерывно изменять свои веса, не достигая удовлетворительных результатов. Более того, приведены примеры сети, в которой только четыре обучающих вектора, предъявляемых циклически, заставляют веса сети изменяться непрерывно, иногда не сходясь. Такая временная нестабильность явилась одним из главных факторов, заставивших Гроссберга и его сотрудников исследовать радикально отличные конфигурации [1]. Адаптивная резонансная теория (АРТ) является одним из результатов исследования этой проблемы. Нейронные сети АРТ, при всех их замечательных свойствах, имеют ряд недостатков. Один из них — большое количество синаптических связей в сети, в расчете на единицу запоминаемой информации. При этом многие из весов этих связей оказываются после обучения нулевыми. Эту особенность следует учитывать при аппаратных реализациях. Сеть АРТ-1 приспособлена к работе только с битовыми векторами. Это неудобство преодолевается в сетях АРТ-2 и АРТ-3. Однако в этих архитектурах, равно как и в АРТ-1, сохраняется главный недостаток АРТ — локализованность памяти. Память нейронной сети АРТ не является распределенной, и некоторой заданной категории отвечает вполне конкретный нейрон слоя распознава-

ния. При его разрушении теряется память обо всей категории. Эта особенность, не позволяет говорить о сетях адаптивной резонансной теории как о прямых моделях биологических нейронных сетей. Память последних является распределенной. Скалярный критерий позволяет создать модель распределенной памяти.

ВЫВОДЫ

Каждому образу, распознаваемому многослойным персептроном в многофакторном пространстве ошибок соответствует свое значение скалярного критерия $\cos(\lambda)$. В данной работе построено изоморфное отображение множества распознаваемых образов на множество действительных чисел из интервала $[0,1]$, которое позволяет связать классификацию распознаваемых образов с поведением $\cos(\lambda)$ в многофакторном пространстве ошибок. Задавая определенные интервалы для значений $\cos(\lambda)$ мы можем группировать образы, распознавать, сравнивать и анализировать их. Построено решающее правило для классификации образов в виде утверждений: каждому образу, распознаваемому многослойным персептроном в многофакторном пространстве ошибок будет соответствовать свое значение $\cos(\lambda)$. Образ тем ближе к эталону, чем больше скалярный критерий.

Предложенный в статье функционал и решающее правило (скалярный критерий для распознавания образов) позволяют создать модель нейронной сети инвариантной к трансформациям распознаваемых образов. Если за эталонные образы взять образы трансформации объектов, то получим алгоритм их распознавания. Т.е. каждому образу трансформации объекта будет отвечать свое значение скалярного критерия. Поскольку вычисление скалярного критерия не изменяет значения весовых коэффициентов нейронной сети, то нейронная сеть может распознавать трансформацию объектов нескольких классов одновременно, и при этом расчет скалярного критерия является не расходным по ресурсам.

ЛИТЕРАТУРА

1. Хайкин С. Нейронные сети: полный курс. — 2-е изд., пер. с англ. — М.: Изд. дом «Вильямс», 2006. — 1104 с.
2. Згуровський М.З., Панкратова Н.Д. Основи системного аналізу. — Київ: Видав. група ВНУ, 2007. — 544 с.
3. Горбань А.Н. Обучение нейронных сетей. — М.: Изд. СССР-США СП «Параграф», 1990. — 160 с.
4. Кохонен Т. Ассоциативная память. — М.: Мир, 1980. — 240 с.
5. Четырбок П.В. Скалярный критерий распознавания образов — функционал качества системы // Штучний інтелект. — 2009. — № 4. — С. 100–103.

Поступила 29.05.2009