

ИНДЕКС 3649

Препринт ЕФИ-1950(45)-91

ԵՐԵՎԱՆԻ ՖԻԶԻԿԱՅԻ ԻՆՍՏԻՏՈՒՏ
ЕРЕВАНСКИЙ ФИЗИЧЕСКИЙ ИНСТИТУТ
YEREVAN PHYSICS INSTITUTE

А. А. ЧИЛИНГАРЯН

МАТЕМАТИЧЕСКИЕ МОДЕЛИ НЕЙРОННЫХ СЕТЕЙ КАК СИСТЕМЫ
РАСПОЗНАВАНИЯ ОБРАЗОВ



ЕРЕВАНСКИЙ ФИЗИЧЕСКИЙ ИНСТИТУТ

ЦНИИАтоминформ

ЕРЕВАН - 1991

A.A.CHILINGARIAN

NEURAL NET CLASSIFICATION OF THE γ - AND P- IMAGES
REGISTERED WITH ATMOSPHERIC CHERENKOV TECHNIQUE, RANDOM
SEARCH LEARNING IN FEED-FORWARD NETWORKS

A new method of data analysis, based on mathematical models of neural nets (artificial neural nets) is applied for background rejection in γ -ray astronomy experiments. The results prove advantages of proposed technique compared to Bayesian approach.

Yerevan Physics Institute
Yerevan 1991

1. Введение

Нейро-анатомические исследования послужили основанием для создания модели нейронных сетей как системы соединенных многочисленными связями простых процессорных элементов - нейронов [1]. Нейроны, в зависимости от величины входного сигнала, могут переходить из одного возможного состояния в другое. Эти состояния, в зависимости от значения мембранного потенциала, называют активными или пассивными, ставя им в соответствие числа +1 или 0(-1). Таким образом, состояние одного нейрона кодируется одним битом информации, а системы из N нейронов - двоичным кодом длины N [2]. Следовательно, всего возможно 2^N состояний:

$$\vec{s} = (s_1, s_2, \dots, s_N), s_i = \pm 1. \quad (1.1)$$

Динамика системы нейронов может быть задана как движение в пространстве состояний. Для выделения близких состояний удобно ввести в этом пространстве метрику - расстояние Хэмминга:

$$R_H = (1 - \sum_{i=1, N}^N s_i^\mu s_i^\nu / N) / 2, \quad (1.2)$$

где s^μ , s^ν - состояния сети, а N - число нейронов. Для одинаковых состояний расстояние Хэмминга равно нулю, а для полностью различных - единице.

Пространство состояний с определенной таким образом метрикой

назовем пространством Хэмминга, а динамика системы нейронов может быть описана как релаксация во времени "возбужденного" состояния к одному из базовых (устойчивых) состояний, а именно к тому, до которого расстояние Хэмминга меньше.

Динамику системы определяют многочисленные межнейронные связи, и уже на этом, первом, этапе определения модели нейронных сетей сети можно разделить на два класса: рекуррентные сети, в которых все нейроны равноправны и соединены со всеми остальными, и последовательные (многослойные), в которых нейроны разделены по слоям, и взаимодействуют между собой только соседние слои.

В рамках каждого класса возможны разнообразные топологические структуры, отличающиеся как числом нейронов и слоев, так и их возможными соединениями.

Рассмотрим сначала рекуррентные сети, основной характеристикой которых является матрица связей (весовых коэффициентов), на которую обычно накладывают стандартные ограничения:

$$J_{i,j} = J_{j,i} \cdot J_{i,i} = 0 \quad (1.3)$$

Динамика системы задается следующим образом:

$$S_i(t+1) = \operatorname{sgn} \left(\sum_{j=1, N}^N J_{i,j} S_j \right) = \begin{cases} +1 & \text{if } \left(\sum_{j=1, N}^N J_{i,j} S_j \geq 0 \right) \\ -1 & \text{if } \left(\sum_{j=1, N}^N J_{i,j} S_j < 0 \right) \end{cases} \quad (1.4)$$

Каждый нейрон вычисляет взвешенную сумму состояний всех остальных нейронов и, в зависимости от знака этой суммы, переходит в новое состояние, то есть действует как пороговый элемент. Таким образом модифицируются все нейроны сети.

Отметим, что в приведенной конфигурации сети линейные межнейронные связи обеспечивают глобальный обмен информацией между нейронами, а нелинейное суммирование этой информации в каждом нейроне аналогично нетривиальной интерпретации этой информации [3].

Поэтому, несмотря на очевидную схематичность модели, она оказывается способной к "интеллектуальной" деятельности, а именно, к распознаванию образов. Эта способность обеспечивается такими свойствами сети, как распределенная обработка информации, являющаяся естественным следствием коллективной динамики сети, крайняя простота функционирования отдельных нейронов, а также конкурентность вычислительных процессов в узлах сети (нейронах).

Эти свойства делают возможным проводить обучение сети [4], то есть наделяют модель возможностью проявлять свойства, схожие с поведением биологических сетей. Обучение заключается в предъявлении сети некоторых фиксированных состояний - образов-прототипов (двоичных N-мерных векторов) и такой последующей модификации межнейронных связей, что эти состояния оказываются выделенными в пространстве Хэмминга. Вокруг них образуется некая область притяжения, и пробные вектора (искаженные образы), попавшие в одну из этих областей, идентифицируются сетью как один из запомненных прототипов.

Свойство узнавать (вспоминать) по неполной, искаженной информации является основой интеллектуальной деятельности и присуще живым организмам. Существуют многочисленные описания наблюдений животных и детей, показывающих решающую роль обучения в развитии этого свойства.

Конечно, трудно ожидать, что настолько упрощенная модель достаточно точно имитирует способы распознавания, присущие живой природе, в том числе и человеку, однако сама способность моделей нейронных сетей к такому сложному поведению, помимо утилитарных технических достоинств, указывает на ее схожесть с биологическими сетями в каких-то главных деталях и может служить и для исследования процессов высшей нервной деятельности. Как мы увидим ниже, искусственные нейронные сети способны моделировать такую трудно управляемую в психологических опытах величину, как размер области аттрактивности или, другими словами, "силу" желания вспомнить.

Способность "вспоминания" возникает как спонтанное свойство динамики сети, то есть релаксация в дискретном времени искаженного образа приводит к одному из прототипов.

Для конкретизации закона движения (1.4) необходимо выбрать очередность модификации нейронов. Здесь возможны три варианта:

- а) синхронная схема - одновременное изменение состояния всех нейронов (параллельные вычисления);
- б) последовательная модификация по заранее определенному порядку;
- в) выбор случайной последовательности нейронов.

Исследования показали, что в случае а) временная эволюция сети часто сводится к осцилляциям - переключениям между двумя состояниями. Схема в) предпочтительнее схемы б), так как невозможно обосновать выделенность какой-либо фиксированной последовательности нейронов.

Нейронную сеть можно представить как универсальный декодер для кода, состоящего из M ключевых слов. Обычно емкость памяти - максимальное число прототипов способных быть запомненными - характеризуют параметром α :

$$M = \alpha N. \quad (1.5)$$

Отметим, что α может быть больше 1.

Второй характеристикой памяти является величина области аттрактивности - максимальное искажение прототипов (в метрике Хэмминга), когда образы еще могут быть распознанными.

Оказалось, что существуют схемы обучения, способные управлять величиной этой области, и зависимость "качества" распознавания от величины этой области имеет нетривиальный характер.

Прежде чем перечислить вопросы, рассматриваемые в настоящей работе, сделаем одно замечание. Основные теоретические результаты и оценки сделаны до настоящего времени для максимально возможных значений параметра α . Однако в приложениях обработки данных физики высоких энергий важны случаи малых α (основные приложения заключаются в распознавании сигнала на уровне фона). С другой

стороны, вряд ли следует ожидать, что биологические сети работают на пределе своих возможностей, так как многочисленные исследования показали, что возможности мозга используются далеко не полностью.

Поэтому основное внимание мы уделим реалистическим случаям малых α .

Во втором параграфе будут рассмотрены способы обучения нейронных сетей. Будет сформулировано условие стационарности образа, и будут приведены результаты исследований различных алгоритмов обучения рекуррентных сетей. В третьем параграфе описывается динамика многослойных последовательных сетей и результаты экспериментов с ними. Четвертый параграф посвящен возможным применениям нейронных сетей в экспериментах физики высоких энергий и космических лучей.

2. Обучение рекуррентных сетей

Термин обучение применяется к широкому спектру проблем, связанных с конструированием нейронных сетей. Возможность обучения в живой природе основана на удивительно гибком адаптивном поведении биологических нейронных сетей. Возможно, эта пластичность и есть тот единственный нетривиальный элемент, который удалось перенести в модели нейронных сетей.

Как мы уже говорили во введении, образы, не изменяющиеся при преобразовании (1.4), действуют как аттракторы и проецируют "искаженный" - пробный двоичный N -мерный вектор - на одно из базовых (запомненных) состояний, а именно, на то, до которого

расстояние Хемминга наименьшее.

Для того, чтобы прояснить не вполне ясный вопрос о величине области аттрактивности, определим, следуя работе [5], в каждом узле сети локальное поле:

$$h_i^\mu = \sum_{j=1}^N J_{i,j} S_j^\mu \quad (2.1)$$

Для того, чтобы образ S^μ был стабильным, необходимо, чтобы для всех нейронов выполнялось условие:

$$h_i^\mu S_i^\mu > 0, \quad i=1, N. \quad (2.2)$$

Логично предположить, что чем больше выравнивающее локальное поле (2.2), тем сильнее притяжение к образу S^μ и тем больше область притяжения.

Однако заметим, что уравнение (1.4) инвариантно относительно умножения $J_{i,j}$ на любую константу того же знака, так как динамика сети определяется не величиной, а знаком суммы $\sum J_{i,j} S_j^\mu$. Поэтому величина выравнивающего поля (2.2) не определяет область притяжения. Вместо нее предложен [6] следующий нормированный параметр стабильности:

$$\gamma_i^\mu = \frac{h_i^\mu S_i^\mu}{|J_i|}, \quad |J_i| = \left(\sum_{j=1}^N J_{i,j}^2 \right)^{1/2}, \quad (2.3)$$

который служит индикатором величины области притяжения. Для увеличения области аттрактивности необходимо увеличить γ_i^μ , $i=1, N$, то есть решающее значение приобретает функция распределения

параметра стабильности. Задачу обучения можно формализовать в виде, допускающем управление величиной области аттрактивности: найти такую матрицу весовых коэффициентов $J_{i,j}$, которая обеспечит условие $\gamma_i^\mu > G$ для всех $i=1, N$, где G некоторая константа, определяющая величину области притяжения образа S^μ . Конечно, величина области аттрактивности будет зависеть и от числа запомненных образов, и от размеров сети. Однако возможность варьировать важнейшим параметром ассоциативной памяти открывает широкие возможности для понимания механизмов, лежащих в основе интеллектуальных способностей моделей нейронных сетей.

Рассмотрим сначала схемы разового обучения: после предъявления прототипов вычисляется матрица $J_{i,j}$, которая в дальнейшем и используется для распознавания. Примером таких алгоритмов являются алгоритм Хопфилда [7]:

$$J_{i,j} = - \sum_{\mu=1}^M S_i^\mu S_j^\mu, \quad (2.4)$$

и декоррелирующий алгоритм [8]:

$$J_{i,j} = \sum_{\mu, \nu} (R_{\mu\nu})^{-1} S_i^\mu S_j^\nu, \quad (2.5)$$

$$R_{\mu\nu} = N \sum_{i=1}^N S_i^\mu S_i^\nu.$$

где обучение проводится по M образам сразу для всех нейронов сети. Алгоритм Хопфилда не может распознавать даже небольшое количество коррелированных прототипов без ошибок, алгоритм (2.5),

распознает до N образов безошибочно (см., напр., [9]), однако он не позволяет управлять областью притяжения, что, как было сказано выше, имеет решающее значение при построении распознающих систем.

Основной особенностью другого класса обучающих алгоритмов является вычисление параметра стабильности (2.3) для всех нейронов, затем, в зависимости от выполнения условия $\gamma_i^\mu > G$, - модификация элементов матрицы связей $J_{i,j}$, и так далее до выполнения целей обучения.

Однако оказалось, что если для значений стабилизирующего параметра $G \in (0-1.5)$, обучение завершается за несколько итераций, то для значений $G > 1.5$ некоторое небольшое число нейронов обучить не удастся: в процессе итераций с некоторого момента начинают осцилляции и изменение распределения γ^μ прекращается. Поэтому мы ввели понятие надежности обучения. Если в процессе обучения оказалось, что для всех i :

$$\gamma_i^\mu > \eta G, \quad \eta \in (0-1), \quad (2.6)$$

то будем говорить, что цели обучения достигнуты с надежностью η .

Изменение коэффициентов связи происходит следующим образом: Если $\gamma_i^\mu < \eta G$, то

$$J_{i,j}(t+1) = J_{i,j}(t) + \delta J_{i,j}, \quad (2.7)$$

$$\delta J_{i,j} = f(J_{i,j}, G, \gamma_i^\mu) S_i^\mu S_j^\nu,$$

где t - номер итерации. Конкретный вид функции f выбирается для ускорения обучения, в частности, в работе [10] показано, что для больших G обучение значительно убыстряется, если величина шага

берется пропорционально разности ($\gamma_i^\mu - G$).

Для исследования распознающих возможностей рекуррентных сетей нами были проведены вычислительные эксперименты по распознаванию букв на решетке, состоящей из 100 нейронов (10×10). Уровень случайного шума варьировался от 20 до 40%, константа Гарднер от 0 до 2.5, надежность обучения была взята равной 90% ($\eta=0.9$). Вероятности ошибок вычислялись по 100 независимым экспериментам для каждого алгоритма, значения шума и "алфавита".

На рис.1 представлены прототипы и пробные (искаженные) образы. На рис.2 показана зависимость времени обучения (числа итераций) от значения стабилизирующей константы. Для несхожих букв F и T (расстояние Хэмминга $R_H = 0.28$) обучение заканчивается гораздо быстрее чем для более близких букв F и E, для которых $R_H = 0.08$. Для базовых "алфавитов", состоящих из 3 и более букв, обучение требует гораздо больше времени.

На рис.6.2 показана зависимость времени обучения (числа итераций) от значения стабилизирующей константы. Для несхожих букв F и T (расстояние Хэмминга $R_H = 0.28$), обучение заканчивается гораздо быстрее, чем для более близких букв F и E, для которых $R_H = 0.08$. Обучение для базовых "алфавитов", состоящих из 3 и более букв, требует гораздо большего времени.

Этот результат имеет некоторое сходство с психологическими теориями различения (см., напр., [11]), в которых, в частности, указывается, что при выборе между двумя объектами (в нашем примере - буквы F и T) предъявление сходного раздражителя (буквы) приводит к ухудшению качества распознавания.

Как правило, процесс вспоминания заключается в выборе из ряда возможных альтернатив, с торможением побочных, произвольно возникающих связей, а забывание и неправильное вспоминание является следствием торможения следов, оставленных в процессе обучения (запечатления) побочными (интерферирующими) воздействиями [12].

Эта теория согласуется с тем, что время обучения сети резко увеличивается при добавлении буквы E, интерферирующей с буквой F.

На рис. 6.3 представлены распределения параметра стабильности для различных алгоритмов обучения для трех прототипов. Видно, что алгоритм Хопфилда не способен безошибочно распознавать буквы, так как среди γ_i^μ есть отрицательные, то есть прототип не является инвариантом относительно динамики сети; декоррелирующий алгоритм способен безошибочно распознать все три образа, алгоритмы класса Э.Гарднер также обеспечивают условие обучения. Кроме того, для значения константы 2.5 распределение величин γ значительно правее от нуля, чем для значения константы, равной 0. Но для этого требуется большее время обучения (число итераций).

На рис.4 а),б),в) представлены вероятности ошибочной классификации в зависимости от величины константы Гарднер. С увеличением константы качество распознавания улучшается, однако если рассмотреть вероятности ошибок для отдельных букв, то окажется, что существует оптимальное значение G, после которого распознавание ухудшается. Это означает, что области аттрактивности букв уже пересекаются.

3. Последовательные многослойные сети.

Хотя рекуррентные сети и используются в ФВЭ для распознавания образов в трековых детекторах, их применение ограничено из-за фиксированности возможных состояний нейронов (± 1), что затрудняет непосредственный ввод экспериментальной информации в нейронную сеть.

Гораздо более привлекательными с этой точки зрения выглядят многослойные последовательные сети, производящие обработку произвольной численной информации. Кроме того, как будет показано ниже, эти сети имеют очень большие возможности обучения, а также допускают непосредственное сравнение с техникой непараметрической байесовской классификации и, таким образом, обеспечивают преимущество и непрерывность в разработке новых информационных технологий.

На вход сети (см. рис.5) подается численная информация об исследуемых объектах или процессах (показания детекторов, значения измеренных признаков и т.д.). Число нейронов в первом входном ряду равно числу признаков. На вход каждого нейрона последующего слоя подается взвешенная сумма "состояний" предыдущего слоя:

$$IN_i^{l+1} = \sum_{j=1}^{NODES(l)} J_{ij} OUT_j^l, \quad i = 1, NODES(l+1), \quad l = 1, L. \quad (3.1)$$

где l - номер слоя, L - число слоев в сети, $NODES(l)$ - число нейронов в этом слое, OUT_j^l - состояние (значение выходной функции) i -го нейрона слоя l . Заметим, что в отличие от

рекуррентных сетей $J_{ii} \neq 0$, то есть, помимо коэффициентов связей J_{ij} , каждый нейрон характеризуется и некоторым пороговым значением.

Выход нейрона (кроме первого слоя, который не преобразует входной сигнал) формируется с помощью нелинейной, так называемой сигмоидной функции:

$$OUT_i^l = 1 / (1 + \exp(-IN_i^l)), \quad i = 1, NODES(l), \quad l \neq 1. \quad (3.2)$$

То есть выход нейрона $OUT_i^l \rightarrow 1$, если вход существенно положителен, и $\rightarrow 0$ для входов существенно меньших нуля.

С помощью определенного таким образом соотношения вход/выход данные передаются от входного слоя через промежуточные (скрытые) слои на выходной нейрон, значение сигнала в котором и будет использовано для классификации поданной на вход информации.

Такая архитектура обработки данных, сочетающая линейное суммирование сигналов с существенно нелинейным преобразованием в скрытых слоях, позволяет, в отличие от рекуррентных сетей, учесть всю различительную информацию в многомерных экспериментальных данных, в том числе нелинейные корреляции.

Отметим, что в случае НС, состоящих из двух слоев (скрытый слой отсутствует), реализуется хорошо известный в прикладном статистическом анализе классификатор - линейная дискриминантная функция, производящая классификацию путем разделения признакового пространства с помощью кусочных гиперповерхностей.

Показано [13], что любая функция, проектирующая N

действительных переменных в M действительных переменных, может быть представлена с любой степенью точности нейронной сетью с N входами и M выходами и одним скрытым слоем.

Обучение сети производится с помощью данных известной принадлежности. Это могут быть результаты модельных или калибровочных испытаний. Начальные значения коэффициентов связей J_{ij} приравниваются к случайным числам из гауссовского распределения с нулевым средним и небольшой дисперсией. Выход такой случайно обученной сети равен для всех классов одной и той же величине: $\hat{out}(L) = 0.5$, и, естественно, классификация невозможна.

Обучение сети производится путем многократного пропуска обучающих последовательностей (выборок) с последовательной модификацией коэффициентов J_{ij} . После каждого цикла итерационного процесса вычисляется функция качества:

$$Q = \sum_{k=1}^K \sum_{i=1}^{M_k} (out_i^k - out_{true}^k)^2, \quad (3.3)$$

где out_i^k - значение выходного нейрона сети при обработке i -го события k -го класса, M_k - число событий в обучающей выборке k -го класса, K - число классов, out_{true}^k - "истинное" значение выхода для событий k -го класса. Ясно, что это значение следует брать таким образом, чтобы максимально раздвинуть альтернативные классы, поэтому положим:

$$out_{true}^k = (k-1)/(K-1). \quad (3.4)$$

В случае классификации по 2 классам ($K = 2$) значения выходов равны единице и нулю.

Минимизация функционала (3.3) обычно проводится методом обратного распространения (back propagation) [14] - малые коррекции параметров сети (коэффициентов J_{ij}) проводятся в направлении наибольшего изменения функции качества. Основным недостатком такого типа "антиградиентных" схем минимизации является сходимость к локальному, а не к глобальному минимуму.

Поэтому мы применили другую схему минимизации - случайный поиск с возвратом при неудачном шаге и с адаптацией величины случайного шага, позволяющую выходить из области локального минимума и продолжать поиск по достижении глобального минимума. Поиск ведется в пространстве параметров сети размерности $NTOT$:

$$NTOT = \sum_{l=2}^L NODES(l) + \sum_{l=1}^{L-1} NODES(l) NODES(l+1). \quad (3.5)$$

Для рассматриваемых в работе простейших конфигураций сети 4/3//1 - $NTOT = 10$, 3//3//1 - $NTOT = 16$.

Поиск наилучших параметров производится следующим образом: сначала случайно выбирается номер параметра, который будет модифицироваться, затем разыгрывается величина приращения:

$$\Delta = const f(Q) (RNDM - 0.5), \quad (3.6)$$

где $RNDM$ - случайная величина, равномерно распределенная в

интервале $(0 - 1)$, $f(q)$ - степенная функция, контролирующая величину случайного шага по мере приближения к глобальному минимуму, $const$ - нормировочная константа.

Итерационный процесс прекращается, когда практическое изменение функции Q прекращается. Полученные в процессе обучения значения коэффициентов J_{ij} используются для классификации данных неизвестной принадлежности.

Таким образом, модели нейронных сетей представляют собой специальный класс статистических классификаторов и могут анализироваться с помощью стандартной методики прикладной статистики [15]. Анализ, проведенный Ш.Раудисом, показал, что, несмотря на большое сходство, нейронные сети имеют некоторое преимущество по сравнению с алгоритмами байесовской классификации с непараметрическим оцениванием многомерной функции плотности вероятности [16].

По-видимому, эффекты малости выборок менее заметны при использовании НС-классификаторов - они более устойчивы к возможным ошибкам и отклонениям в обучающих выборках. В обучении НС участвуют все классы, тогда как в классификаторах, основанных на оценивании плотности, для каждого класса используется только своя выборка. Поэтому можно ожидать, что НС-классификаторы превзойдут статистические, особенно в случае большого числа признаков и не очень больших обучающих последовательностей (случай типичный для ФВЗ).

К сожалению, до настоящего времени нет теоретических результатов, способных помочь в конструировании НС

классификаторов. Не получена зависимость вероятной ошибки классификатора в зависимости от точности определения параметров сети, неясно влияние выбора формы нелинейной сигмоидной функции на результаты классификации. Да и вопрос выбора конфигурации сети - числа скрытых слоев и числа нейронов в них - остается открытым.

Поэтому в наших исследованиях мы выбрали простейшую конфигурацию сети с одним скрытым слоем и числом нейронов в нем, равном 3,5 или 7.

В качестве тестовой была выбрана задача оценивания байесовского риска при классификации выборок из гауссовского распределения с единичной дисперсией и средними, равными нулю и единице (теоретическое значение вероятности ошибочной классификации $ВOK = 0.3086$).

Обучение проводилось на выборках размера 500. Оценивание риска проводилось с помощью 20 независимых выборок размера по 5000 из тех же распределений. На рис.6 представлена обучающая выборка, на рис 7 - гистограмма выходов нейронной сети, а на рис. 8 - результаты классификации одной из контрольных выборок.

В процессе обучения параметры сети модифицировались таким образом, чтобы максимально раздвинуть альтернативные классы. Однако если исходные обучающие выборки значительно перекрываются, как в случае распределений $N(0,1)$ и $N(1,1)$, невозможно добиться полного разделения.

В этом случае достаточно потребовать минимизации числа ошибочных классификаций. Нейронные сети, как и байесовские классификаторы, минимизируют вероятность ошибок.

Полученное совпадение значений вероятности ошибок для классификатора на нейронных сетях ($R^{NN} = 0.3087 \pm 0.0024$) с ВОК байесовского классификатора может служить основанием для применения НС классификаторов для обработки более сложных реалистических задач.

4. Использование НС классификаторов для обработки данных ФВЗ и космических лучей.

Важность и актуальность применения НС - классификаторов в физическом эксперименте обуславливается прежде всего возможностью создания очень быстрого интеллектуального триггера, способного в реальном времени выделять сложные многочастичные события.


Кроме того, НС-классификаторы полностью используют всю доступную априорную информацию (в том числе и нелинейные корреляции признаков), а также довольно устойчивы (робастны) относительно возможных неточностей и упрощений в обучающих последовательностях.

Как уже было сказано во введении, новая физика в коллайдерных экспериментах содержится в различных струйных событиях, которые очень сильно подавлены фоном от взаимодействий частиц сталкивающихся адронных пучков. Существующие модели сильного взаимодействия недостаточно подробно разработаны, чтобы на их основе проводить стандартный статистический анализ методами максимального правдоподобия [17]. Поэтому в этих задачах новая техника анализа может оказаться самой эффективной, если не единственно возможной.

Первые применения НС-классификаторов проводились в основном

на модельных данных: то есть и для обучения, и для контроля применялись данные Монте-Карло испытаний.

Исследовалась возможность выделения каналов рождения b кварков в реакции:



при $E_{cm} = 14$ ГэВ на фоне рождения других кварков (u, d, s, c) [18]. Отношение сигнал/шум составляет 1/10. Для обучения использовалось 4000 событий, контрольная выборка состояла из 6000 событий, число используемых признаков - 5. Сеть конфигурации 5//3//1 дала несколько лучшие результаты, чем 3//2//1, и была намного лучше, чем линейная дискриминантная функция - 5//1.

Другое применение НС-классификаторов связано с задачей исследования возможности разделения кварковых и глюонных струй в e^+e^- аннигиляции при $E_{cm} = 630$ ГэВ [19]. Используя в качестве признаков показания ячеек калориметра вокруг центра струи (всего $7 \times 7 = 49$ признаков), удалось повысить достоверность выделения кварковых струй с 65% до 85%. Конфигурация используемой сети - 49//10//1.

В той же работе исследовалась возможность выделения адронных распадов W и Z бозонов с использованием 30 ячеек калориметра с наибольшим уровнем сигнала. Применяя НС-классификатор конфигурации 30//20//4//1, удалось понизить QCD фон в 20-50 раз, потеряв при этом только половину полезных событий.

По-видимому, первой попыткой применения НС-классификаторов к реальному эксперименту было определение вершины взаимодействия в $p\bar{p}$ столкновениях на Тэватроне [20] (эксперимент E375 с дрейфовой

камерой). Обучение сети проводилось с помощью 12000 специально отобранных экспериментальных данных, после 4 миллионов итераций сеть проверялась по независимой экспериментальной выборке. Точность восстановления вершины оказалась сравнимой с точностью, достигнутой в off-line анализе. Конфигурация сети - 18//128//62.

Большое число нейронов в скрытом слое обусловлено тем, что предполагается использовать серийно выпускаемый ИС чип (Intel EGANN) [21] для on-line анализа, число нейронов в слоях которого равно 128. Большое же число нейронов в выходном слое связано с тем, что решается не задача классификации - выбор одного из конечного множества вариантов, а задача оценивания - определение непрерывно распределенной величины, координаты вершины события.

Как видно из краткого обзора, применение ИС для анализа коллайдерных экспериментов дало многообещающие результаты. Хотя конфигурации используемых сетей многообразны, по-видимому, можно ограничиться трехслойными сетями с не очень большим числом нейронов в скрытом слое.

В физике космических лучей основная задача анализа также сводится к выделению событий того или иного типа. Это задачи определения массового состава первичного космического излучения по данным рентген-эмульсионных камер и широких атмосферных ливней и задача регистрации потока γ -квантов от точечных источников. В последней задаче, кроме того, важно иметь также и быстрый интеллектуальный триггер, так как интенсивность фоновых событий (изображений черенковских вспышек от Тэвских протонов и ядер) довольно высока. Для сокращения числа записываемых для

последующего анализа событий применяется электронный триггер, сокращающий область допустимых прицельных параметров и, следовательно, светосилу установки.

В последнее время нейронные сети были использованы для определения позиции оси и энергии широкого атмосферного ливня [22].

Для проверки возможности применения ИС-классификаторов для анализа данных черенковских телескопов и для сравнения методов Байесовской и ИС-классификации нами было проведено исследование возможности дискриминации изображений Черенковских вспышек от космических лучей при наблюдении потока γ -квантов от Крабовидной туманности телескопом обсерватории Whipple [23]. Так как в настоящее время нам были недоступны первичные экспериментальные данные (набор показаний ФЭУ), в качестве признаков использовались параметры восстановленного по показаниям ФЭУ эллипсоида потемнения, а именно, ширина и длина пятна потемнения и так называемая азимутальная ширина - параметр, характеризующий направленность большой оси эллипса относительно центра поля зрения телескопа. Набор этих параметров, как показали наши предыдущие исследования [24], является наилучшим для дискриминации.

Обучение проводилось с помощью данных моделирования γ -квантов [25] и реальных изображений, генерированных протонами (зарегистрированных телескопом, направленными в область звездного неба, где заведомо нет источников γ -квантов). Для обучения использовалось по 500 событий, контрольная выборка состояла из

5000 экспериментальных событий. Результаты обучения (см. рис. 9) свидетельствуют о достаточно хорошем разделении классов [26]. На рис. 10 приведены кривые эффективности регистрации полезных событий и примеси фоновых. Так как в эксперименте фон превышает сигнал на 2 порядка, то важно подавить фон более чем в 100 раз, сохранив хотя бы 50% сигнала. С помощью НС-классификатора этого удается добиться - примесь фона составила 0.4% при значении решающей границы $D = 0.07$, одновременно сохранилось более 50% γ -событий. Байесовский анализ той же контрольной выборки с той же обучающей последовательностью дал даже несколько худшие результаты - 0.6% примеси фона при 50% эффективности регистрации сигнала [27].

Конфигурация сети 3//3//1 дала несколько лучшие результаты, чем 3//5//1. Обучение закончилось через 500 итераций (см. рис. 11), что заняло приблизительно 15 минут счетного времени IBM PC-AT/386.

Время классификации одного события составило приблизительно 1 микросекунду, тогда как при применении Байесовских решающих правил с оценением функции плотности вероятности методом Парзеновских ядер на обработку одного события уходит 1 секунда.

Заключение

Алгоритмы класса Э.Гарднер могут стать основой для создания распознающих систем с регулируемой областью аттрактивности.

Применяя различные схемы обучения сети можно имитировать различные аспекты функционирования биологических нейронных сетей.


Для обработки потоков сложных событий с строящихся коллайдеров (SSC и LHC) и установок физики космических лучей

можно рекомендовать последовательные многослойные сети. Они могут обеспечить очень быстрый интеллектуальный триггер, сравнимый по всем параметрам с гораздо более трудоемким Байесовским непараметрическим анализом.

Отметим, что уже серийно выпускаются фирмой Fujitsu нейронные компьютеры совместно с математическим обеспечением для обучения сети. Нейронная плата представляет собой процессор со скоростью 4 млн. оп./сек., имеет собственную память в 4МБ, что позволяет моделировать 4-слойные сети с общим числом нейронов 1000. [28]

Информация, заключенная в тысячах событий многомерных коррелированных обучающих последовательностей, преобразуется в несколько десятков чисел - параметры нейронной сети. Микроэлектронные процессорные устройства, запрограммированные с использованием результатов обучения, обеспечат в процессе on-line анализа выделение полезных событий и режекцию фона.

Выражаю признательность коллаборации Whipple и М. Коули за предоставление возможности работы с данными наблюдения Крабовидной туманности 10-метровым рефлектором обсерватории в г. Хопкинс.



Gamma - quanta from Crab Nebula

Рис.5 Классификация данных черенковского телескопа последовательной трехслойной сетью.




Рис.6 Гистограмма 2 выборок из Гауссовского распределения, использованных для обучения нейронной сети:
 • - $N(0,1)$ - 1000 событий,
 + - $N(1,1)$ - 1000 событий,
 X - область перекрывания, вероятность ошибки = 0.3085.




Рис. 7 Гистограмма значений выхода из нейронной сети.
 • - события из выборки с нулевым средним
 x - события из выборки с единичным средним,
 X - область перекрытия, вероятность ошибки 0.3.




Рис. 8 Классификация контрольной выборки с помощью предварительно обученной сети:
 конфигурация сети 1:3:1,
 - $N(0,1)$ - 5000 событий,
 вероятность ошибки = 0.3, если точка решения 0.5.




Рис. 9 Гистограмма выхода нейронной сети:
 * - данные моделирования - γ -ливни ~ 500 событий,
 + - экспериментальные данные - P - ливни ~ 500 событий,
 используемые переменные - *width, length, azwidth.*

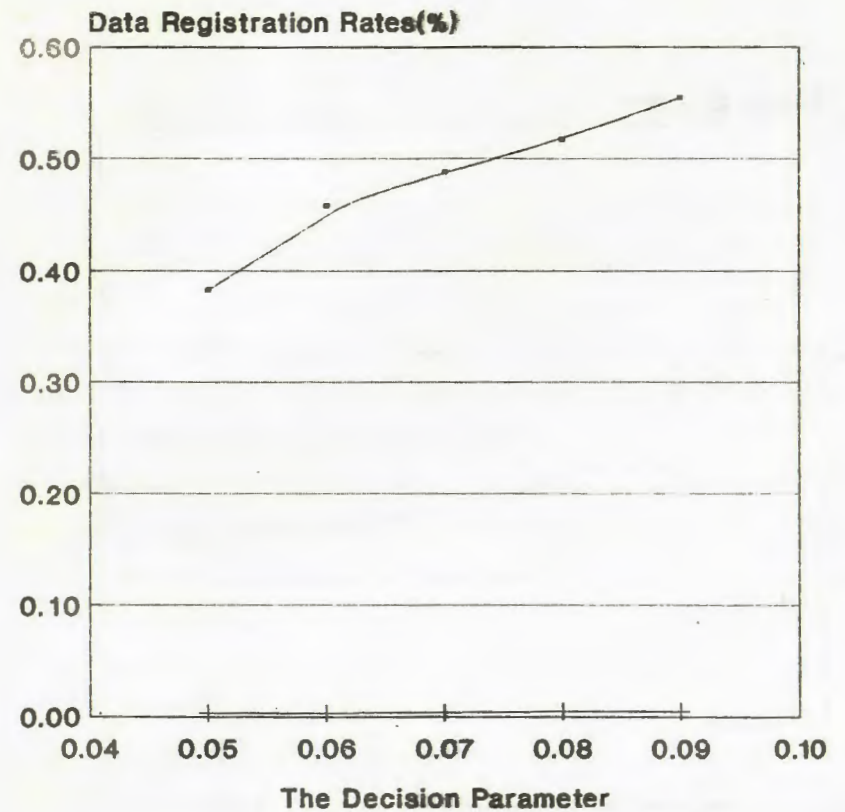


Рис.10 Результаты классификации черенковских изображений нейронной сетью:
 * - эффективность регистраций γ -квантов,
 + - примесь протонов и ядер космического излучения.

СПИСОК ЛИТЕРАТУРЫ

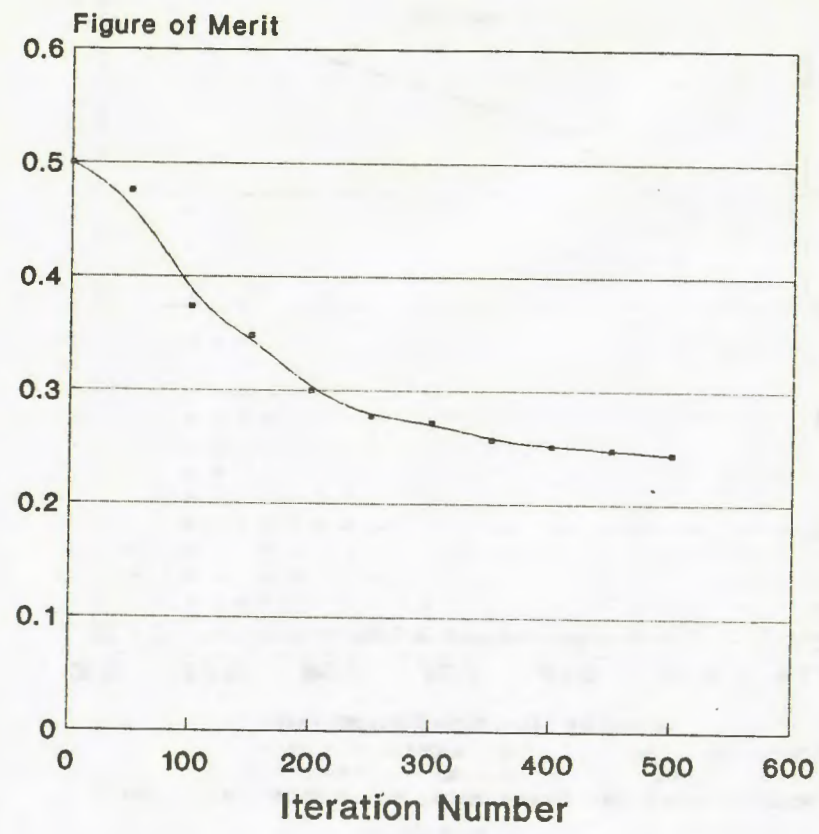


Рис.11 Время (число итераций) обучения последовательной нейронной сети минимизируется функцией качества.

1. Введенков А.А. Моделирование элементов мышления, М.: Наука, 1988.
2. McElieze R.J., Posner G. et al. The capacity of the Hopfield Associative memory, *Trans. on Inform. Th.* 1977, p.461.
3. Михайлов А.С. Аналоговая обработка информации распределенными системами, сб. Новые физические принципы оптической обработки информации под редакцией Ахманова С.А., Воронцова М.А., М.:Наука, 1990.
4. Хинтон Д.Е. Обучение в параллельных сетях, сб. Реальность и прогнозы искусственного интеллекта, М.: Мир, 1987.
5. Abbot L.F. Learning in neural network memories, Preprint BRX-174, 1990.
6. Kepler T.B., Abbot L.F. *J.Phys.* 47, 1988, p.1657.
7. Optfield J.J. *Proc. Nat. Acad. Sci. USA*, 1982, V.79, p.2584.
8. Personnas L., Guyon L., Dreyfus J. Information Storage and Retrieval in Spin-Glass like Neural Networks, *J.Psique Lett.*, 1984, v.46, p.359.
9. Philinarian A.A., Khutonyan N.O. et al. Recognition of correlated patterns with spin-glass-like models, preprint YERPHI-992(42) 87, 1987.
10. Kepler T.B., Abbot L.F. *J.Phys.* A21, 1989, p.1711.
11. Шовен Р. Поведение животных, М.: Мир, 1972.
12. Лурия А.Р. Нейропсихология памяти, М.: Педагогика, 1976.

13. Hecht-Nielsen Theory of Backpropagation Neural Networks, proc. Int. Joint. Conf. on Neural Networks, Washington, 1989 v.1, pp. 593-6059.

14. Rumelhart D.E., Hinton G.E. and Williams R.J. in Parallel Distributed Processing, MIT Press, Cambridge MA, 1986.

15. Chilingarian A.A. Statistical decisions under nonparametric a priori information, Comp.Phys.Comm., 1989, 54, pp.381-390.

16. Raudis S., Jain A.K. Problems due to small sample size in artificial neural net classifier design, Michigan State University report, 1990.

17. Gunion J.F. and Soper D.F. Statistical analysis in new-particle research, Phys.Rev., 1987, D35, p.179.

18. Gottschalk D. and Noity R., identification of Physics processes using neural network classifiers, Preprint CALT-68-1680, 1990.

19. Bhat P., Lonnblad L. et al. Using Neural Networks to identify jets in hadron-hadron collisions, Desy Preprint 90-144, 1990.

20. Lindsey C.S. and Denby B. Primary vertex finding in proton-antiproton events with a neural network simulation, Fermilab-Pub-90/192, 1990.

21. Holler et al An electronically trainable analog neural Network (ETANN) with 10240 "Floating Gate" synapses, proc. Int. Joint. Conf. on Neural Networks, Washington, 1989, v.2, p.191-196.

22. Perret J.C. and van Stekelenborg J T P M The applications of neural networks in the core location analysis of extensive air showers, J.Phys., 1991, 17, 1291.

23. Cawley M.F., Fegan D.J. et al A high resolution imaging detector for tev Gamma-ray astronomy, Exp. Astronomy, 1, 1990, p.173-193.

24. Aharonian F.A., Chilingarian A.A. et al A multidimensional analysis of the Cherenkov images of air showers induced by very high energy γ -rays and protons, Nucl. Ins.& Methods, 1991.

25. Macomb D.J. Lamb R.C. Cherenkov imaging in tev astronomy: new simulation results, proc. 21 Int. Cosmic Ray Conf., Adelaide, OG4.9-3, 1990.

26. Chilingarian A.A. et al. Neural net classification of the γ - and p - images registered with atmospheric cherenkov technique, random search learning in feed - forward networks, Proc. 22 ICRC OG 4.7-23, Dublin, 1991.

27. Cawley M.F., Chilingarian A.A. et al. Application of multivariate analysis techniques to atmospheric Cherenkov imaging data from Crab nebula, Proc. 22 Int. Cosmic Ray Conf., Dublin, OG 4.7-2

28. Стебунов А. Последние модели персональных нейрокомпьютеров, Компьютер-пресс N 1, 1991, стр. 63-67.

Рукопись поступила 25 мая 1991 г.

А. А. ЧИЛИНГАРЯН

МАТЕМАТИЧЕСКИЕ МОДЕЛИ НЕЙРОННЫХ СЕТЕЙ КАК
СИСТЕМЫ РАСПОЗНАВАНИЯ ОБРАЗОВ

Редактор Л. П. Мукаян

Технический редактор А. С. Абрамян

Подписано в печать II/ХП-91г.
Офсетная печать. Уч. изд. л. 1,8
Зак. тип. 176

Формат 60×84×16
Тираж 299 экз. Ц. 25 к.
Индекс 3649

Отпечатано в Ереванском физическом институте
Ереван-36, ул. Братьев Алиханян 2.

The address for requests:
Information Department
Yerevan Physics Institute
Alikhanian Brothers 2,
Yerevan, 375036
Armenia, USSR