
ИССЛЕДОВАНИЕ И МОДЕЛИРОВАНИЕ НЕЙРОСЕТЕВОГО МЕТОДА ОБНАРУЖЕНИЯ И КЛАССИФИКАЦИИ СЕТЕВЫХ АТАК

Адиль Тимофеев, Александр Браницкий

Аннотация: Рассматриваются возможности и перспективы применения нейросетевых технологий для распознавания сетевых атак. Значительное внимание уделяется методологии имитационного моделирования нейронных сетей для обнаружения и классификации сетевых атак и экспериментальным результатам.

Keywords: нейронные сети, методы обнаружения и классификации, сетевые атаки.

ACM Classification Keywords: E.4 CODING AND INFORMATION THEORY

Введение

Одним из наиболее эффективных средств массового распараллеливания и ускорения процессов обработки и передачи потоков данных в задачах обнаружения закономерностей, распознавания образов и классификации данных являются искусственные нейронные сети (НС). Естественным прототипом искусственных НС является биологический мозг и центральная нервная система человека и животных. Возможности искусственных и биологических НС могут значительно расшириться при коллективном (мультиагентном) решении сложных интеллектуальных задач (data mining, knowledge discovery и т.п.).

Высокая сложность и размерность многих задач обнаружения закономерностей, распознавания образов и классификации данных, а также часто возникающая необходимость их решения в реальном времени требуют массового параллелизма и самоорганизации распределённых вычислений на базе НС. С этой точки зрения особый интерес представляют самоорганизующиеся гомогенные и гетерогенные полиномиальные нейронные сети (ПНС) и их разновидности [1–9].

Основные идеи, математические модели, методы обучения и принципы самоорганизации гомогенных и гетерогенных НС были описаны и развиты в [2–9]. К гомогенным НС прежде всего относятся трёхслойные перцептроны и НС Хопфилда [1]. Особенности ПНС заключаются в следующем: архитектура ПНС гетерогенна и многослойна; наличие слоя полиномиальных нейронных элементов (П-нейронов); возможность и целесообразность самоорганизации архитектуры ПНС различных типов; детерминированные и вероятностные методы обучения и самоорганизации гетерогенных ПНС; принципы минимальной сложности и высокой экстраполяции гетерогенных ПНС; алгебраическое требование диофантовости (целочисленности синаптических весов) гетерогенных ПНС [2–9].

Архитектура НС представляет собой иерархическую последовательность нескольких однородных слоёв (непересекающихся подмножеств) параллельно работающих нейроэлементов (НЭ) различных типов. В различных слоях НС могут использоваться разные НЭ, но каждый слой (подмножество НЭ) является однородным (гомогенным). При этом обработка информации в каждом слое НЭ осуществляется параллельно.

Каналы связи между предыдущим и последующим слоями гетерогенной НС являются однонаправленными и имеют регулируемые веса (синаптические параметры). Эти веса каналов связи настраиваются в процессе обучения и самоорганизации архитектуры НС по имеющимся экспериментальным данным или прецедентам.

Традиционно гомогенные или гетерогенные НС используются для автономного принятия решений в задачах обнаружения закономерностей, распознавания образов, диагностики состояний, классификации данных и т.п. По существу эти НС являются обучаемыми интеллектуальными агентами, которые настраиваются на индивидуальное (одно-агентное) решение конкретных задач по обучающим базам данных (ОБД).

В то же время существует большой класс интеллектуальных задач, требующий не только индивидуальных (одно-агентных), но и коллективных (мульти-агентных) решений. Классическим примером этого могут служить особенно сложные и ответственные задачи медицинской диагностики, когда врачи вынуждены прибегать к помощи своих коллег для совместной постановки окончательного диагноза. При этом формируется "консилиум", т.е. профессиональная группа врачей, интегрирующая знания и опыт входящих в неё членов для коллективного принятия наиболее правильных и сбалансированных диагностических решений.

Другим примером сложных задач, требующих коллективных решений, являются глобальные задачи, допускающие естественную (например, иерархическую или мультифрактальную) декомпозицию на множество локальных задач. В этом случае решение сложной (глобальной) задачи может быть распределено между интеллектуальными НС-агентами, специализирующимися на решении N частных (локальных) задач. Параллельная работа N таких НС-агентов может значительно ускорить обработку информации и повысить надежность решения общей (глобальной) задачи.

Специальные агенты-координаторы могут принимать коллективные (мультиагентные) решения на основе локальных (одно-агентных) решений остальных НС-агентов с помощью мажоритарных принципов или процедур голосования (например, по "большинству голосов") [7–9]. При этом все локальные решения принимаются параллельно, что ускоряет принятие глобального (коллективного) решения в N раз.

В ряде случаев глобальная самоорганизация НС-агентов обеспечивается иерархической, фрактальной или мультифрактальной декомпозицией общей задачи на N подзадач. При этом степень внешнего (глобального) параллелизма в мульти-агентной нейросетевой системе определяется параметром N , характеризующем одновременную работу N локальных НС-агентов. Предлагаемые иерархические гетерогенные архитектуры и быстрые алгоритмы обучения ПНС разных типов обеспечивают высокий параллелизм и самоорганизацию нейровычислений в процессе решения интеллектуальных задач. Они успешно применялись для решения ряда прикладных задач (распознавание деталей на конвейере, классификация дорожных ситуаций, диагностика и оценка эффективности лечения артритов, векторная диагностика и расшифровка гастритов, прогнозирование исхода черепно-мозговых травм и т.д.) и нейросетевого представления генетического кода [1–9].

Аккумулируемые в гомогенных и гетерогенных НС с самоорганизующейся архитектурой "нейрообразы" и решающие (классифицирующие и идентифицирующие) правила обеспечивают массовый параллелизм, хорошую экстраполяцию и высокое быстроедействие при принятии оптимальных или субоптимальных решений. Коллективное (мультиагентное) использование гетерогенных ПНС в качестве нейросетевых

агентов позволяет дополнительно распараллелить и распределить между локальными НС-агентами процессы решения сложных (глобальных) задач распознавания образов, анализа изображений и сцен, расширенной (векторной) диагностики состояний и адаптивной маршрутизации и классификации информационных потоков.

1. Проблемы и методы защиты информации

Бурное развитие компьютерных сетей и информационных технологий порождает множество проблем, связанных с безопасностью информационных ресурсов. В связи с несовершенством существующих методов защиты компьютерных систем от сетевых атак разработка новых методов защиты информации, позволяющих повысить уровень защищенности компьютерных систем от несанкционированного воздействия, является актуальной и востребованной [10].

Существует три основных подхода, используемых при обнаружении и классификации сетевых атак [10–13]:

- статистический анализ;
- экспертные системы;
- нейронные сети.

Кроме того, развиваются подходы, основанные на и генетических алгоритмах и иммуноклеточных методах.

Статистический анализ находит применение, как правило, при обнаружении аномального поведения. Отклонение от среднего значения (т. е. дисперсия) профиля нормального поведения дает сигнал администратору о том, что зафиксирована атака. Средние частоты и величины переменных вычисляются для каждого типа нормального поведения (например, количество входов в систему, количество отказов в доступе, время суток и т. д.). О возможных атаках сообщается, когда наблюдаемые значения выпадают из нормального диапазона, т. е. превышают заданный порог [10–13].

Экспертная система — это система, которая в контексте обнаружения атак принимает решение о принадлежности того или иного события к классу атак на основании имеющихся правил. Эти правила основаны на опыте специалистов и хранятся в специальном хранилище. В большинстве случаев правила экспертной системы опираются на так называемые сигнатуры, которые и ищутся в контролируемом пространстве [10].

Во введении к данной работе представлен краткий обзор основных типов НС и их особенностей при решении проблем интеллектуального характера. К этим проблемам относятся и задачи обнаружения и классификации сетевых атак. Значительный интерес представляют описываемые ниже исследования и средства их реализации и методом анализа сетевого трафика на наличие аномальных соединений с целью обнаружения и классификации атак на базе трёхслойных НС, обучаемых с помощью алгоритма обратного распространения ошибки.

2. Сетевые атаки и их классификация.

Удалённой сетевой атакой будем называть информационное разрушающее воздействие на распределённую компьютерную сеть, осуществляемое программно по доступным каналам связи. Конкретные разновидности сетевых атак представлены в базе данных (БД) KDD-99 [11]. В качестве обучающего множества выступает база KDD-99 [4]. Эта БД содержит около 5000000 записей о соединениях. Каждая запись представляет собой образ сетевого соединения, включает 41 параметр сетевого трафика и промаркирована как „атака" или „не атака". В базе представлены 22 типа атаки. При этом атаки делятся на 4 основные категории: DoS, U2R, R2L и Probe [10–12].

DoS атаки — это сетевые атаки, направленные на возникновение ситуации, когда на атакуемой системе происходит отказ в обслуживании. Данные атаки характеризуются генерацией большого объема трафика, что приводит к перегрузке и блокированию сервера. Выделяют шесть DoS атак: back, land, neptune, pod, smurf, teardrop.

U2R атаки предполагают получение зарегистрированным пользователем привилегий локального суперпользователя (сетевого администратора). Выделяют четыре типа U2R атак: buffer_overflow, loadmodule, perl, rootkit.

R2L атаки характеризуются получением доступа незарегистрированного пользователя к компьютеру со стороны удаленного компьютера. Выделяют восемь типов R2L атак: ftp_write, guess_passwd, imap, multihop, phf, spy, warezclient, warezmaster.

Probe атаки заключаются в сканировании сетевых портов с целью получения конфиденциальной информации. Выделяют четыре типа Probe атак: ipsweep, nmap, portsweep, satan. Согласно источнику [11] для обнаружения и классификации 9 из 22 типов атак достаточно 29 параметров, характеризующих сетевые соединения. Список этих параметров приведен в табл. 1.

Параметр	Описание параметра
1. duration	Продолжительность соединения
3. service	Служба
4. flag	Флаг терминального состояния IP-соединения
5. src_byte	Количество байт, переданных от источника к приемнику
6. dst_byte	Количество байт, переданных от приемника к источнику
7. land	Равенство порта отправителя порту получателя
8. wrong fragment	Количество отброшенных пакетов
9. urgent	Число пакетов с флагом URG
10. hot	Количество hot-индикаторов
11. count	Количество соединений между удаленным хостом и локальным хостом
12. srv_count	Количество соединений к локальной службе
13. serror rate	Процентное число соединений с ошибкой типа syn для данного

	хоста-источника
14. srv_serror_rate	Процентное число соединений с ошибкой типа SYN для данной службы источника
15. rerror_rate	Процентное число соединений с ошибкой типа REJ для данного хоста-источника
16. srv_rerror_rate	Процентное число соединений с ошибкой типа REJ для данной службы источника
17. same_srv_rate	Процентное число соединений к службе
18. diff_srv_rate	Процентное число соединений к различным службам
19. srv_diff_host_rate	Процентное число соединений к различным хостам
20. dst_host_count	Количество соединений к локальному хосту, установленных удаленной стороной
21. dst_host_srv_count	Количество соединений к локальному хосту, установленных удаленной стороной и использующих одну и ту же службу
22. dst_host_same_srv_rate	Процентное число соединений к локальному хосту, установленных удаленной стороной и использующих одну и ту же службу
23. dst_host_diff_srv_rate	Процентное число соединений к локальному хосту, установленных удаленной стороной и использующих различные службы
24. dst_host_same_src_port_rate	Процентное число соединений к данному хосту при текущем номере порта источника
25. dst_host_srv_diff_host_rate	Процентное число соединений к службе разных хостов
26. dst_host_serror_rate	Процентное число соединений с ошибкой типа syn для данного хоста-приемника
27. dst_host_srv_serror_rate	Процентное число соединений с ошибкой типа SYN для данной службы приемника
28. dst_host_rerror_rate	Процентное число соединений с ошибкой типа REJ для данного хоста-приемника
29. dst_host_srv_rerror_rate	Процентное число соединений с ошибкой типа REJ для данной службы приемника

Таблица 1. Параметры сетевых соединений.

3. Исследование нейросетевой технологии обнаружения и классификации сетевых атак

Обычно для обучения и тестирования НС имеющиеся экспериментальные данные разбиваются на обучающую БД и контрольную БД. В проведенных исследованиях в качестве обучающей БД с параметрами сетевых соединений, представляющая собой 10% subset KDD CUP. 99. Она представляет собой обычный текстовый файл, разбитый на несколько файлов, каждый из которых содержит набор

параметров определённого типа атаки или нормального соединения. Полученные файлы преобразуются в файлы, содержащие числовые эквиваленты, соответствующие определённому параметру соединения.

В целях ускорения обучения, тестирования и дальнейшего запуска применялся алгоритм, реализующий метод главных компонент. Вычисление вариационной матрицы главных компонент сводится к вычислению собственных векторов и собственных значений ковариационной матрицы исходных данных. Найденные собственные векторы представляют собой коэффициенты, задающие линейное преобразование для исходных векторов, а соответствующие им собственные числа выступают в роли критерия (меры) информативности новой системы. Из набора сжатых векторов с помощью генератора случайных чисел формируется обучающая БД, мощность которой составляет 10% от полной KDD CUP. 99.

Элементы этой БД поочередно подаются на вход НС для настройки весовых (синаптических) параметров. Весовые коэффициенты каждой НС сохраняются в соответствующих файлах для возможной их дальнейшей загрузки при очередном запуске системы обнаружения вторжений.

По завершении этих этапов НС полностью готовы к этапу запуска, который заключается в обнаружении и классификации активных аномальных и нормальных IP-соединений.

При эмулировании сетевых соединений данные считываются из полной базы KDD Cup 99, которая рассматривалась как контрольная БД. Записи из полной контрольной БД подавались на обученные НС. На основании результатов этого этапа определяется статистика и даётся анализ эффективности НС по критериям качества распознавания типов аномальных соединений и наличию ложных срабатываний (когда нормальное соединение принимается за атаку).

Процесс обучения и тестирования НС показан на рис. 1, а процесс запуска НС представлен на рис. 2.

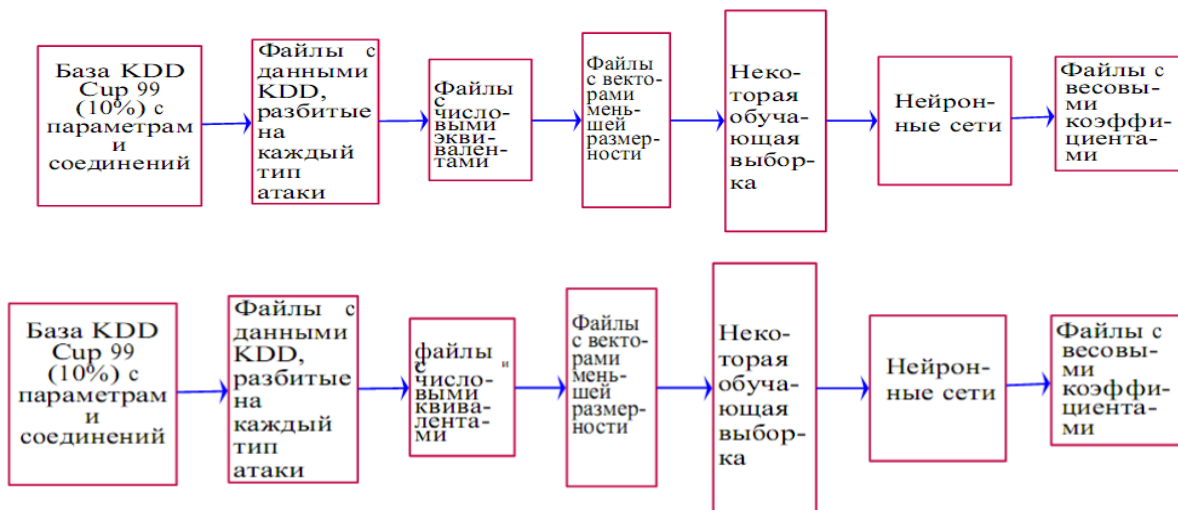


Рис. 1: Процесс обучения и тестирования НС



Рис. 2: Процесс запуска НС

Пакеты, поступающие на сетевую карту, перехватываются и обрабатываются анализатором пакетов (сниффером). Из поля данных и заголовка каждого пакета выделяются и вычисляются необходимые для классификации соединений параметры. Собираются некоторые статистические сведения об активных в данный момент соединениях. После сбора всех необходимых показаний о каждом запущенном соединении набор вычисленных параметров "подвергается" текстовой обработке: каждая отдельная составляющая набора параметров отображается в соответствующий ей числовой эквивалент согласно таблице, заданной в программе. Опционально (т. е. необязательно) полученный набор параметров сжимается по методу главных компонент.

Преобразованные векторы подаются на вход обученных НС, которые в свою очередь формируют линейную комбинацию каждого вектора со своими весовыми параметрами, выступающей в роли аргумента функции активации НС. На основании полученного значения принимается решение о принадлежности конкретного соединения тому или иному классу атак.

Следует отметить, что существенное значение в успешности обнаружения и определения злоупотреблений является правильно заданная планка, выступающая в роли "водораздела" между типичными атаками и нормальными соединениями. Слишком малое значение этого барьера означает возможность пропуска атак и принятия их за нормальные соединения, а слишком большое значение увеличивает число ложных срабатываний. Тем самым большое количество типично нормальных соединений будет приниматься за аномальные.

Каждая НС в отдельно созданном для нее потоке обучается параллельно с остальными для распознавания нормального соединения и одного типа атаки. Для их обучения используются равные по размеру выборки положительного и отрицательного трафиков. По завершении стадии обучения происходит барьерная синхронизация всех потоков (основной поток дожидается завершения выполнения созданных потоков).

Программная реализация НС имеет вид:

```
struct neural_network {
struct fann *ann;
enum type_attack attack;
pthread_t thread;
int index;
};
enum type_attack {back, neptune, pod, smurf, teardrop, ipsweep, nmap, portsweep, satan, normal};
```

Она состоит из следующих полей:

- указателя ann на структуру struct fann, которая определена в библиотеке FANN (Fast Artificial Neural Network) [13];
- переменной attack типа перечисления enum type_attack, задающей тип атаки, которую обучена распознавать данная нейросеть;
- переменной thread типа pthread_t, которая служит в роли идентификатора потока, в котором выполняется данная нейронная сеть;

• переменной `index` типа `int`, которая задает положение (индекс) данной переменной типа `struct neural_network` в статическом массиве.

Для обучения НС применяется алгоритм обратного распространения ошибки (итеративный градиентный алгоритм, который используется с целью минимизации ошибки работы многослойного перцептрона и получения желаемого выхода) с симметричной сигмоидальной функцией активации.

4. Результаты вычислительных экспериментов

НС, которые обнаружили подозрительную сетевую активность, сигнализируют об этом и записывают параметры аномального соединения в журнал регистрации.

При проведении этапа эмулирования сетевых атак были получены следующие результаты, представленные в табл. 2. Здесь левый столбец – тип эмулируемого соединения, верхняя строка – тип нейронной сети, их пересечение – процентное количество правильно распознанных атак соответствующего типа соответствующими НС.

	back	neptune	pod	smurf	teardrop	ipsweep	nmap	portsweep	satan
back	99.7%	0%	0%	0%	0%	0%	0%	0%	0.2%
neptune	7.9%	100%	0%	0%	0%	0%	80.8%	100%	19.1%
pod	0.4%	0.4%	99.6%	0%	32.1%	1.5%	1.9%	0.4%	1.5%
smurf	0%	0%	0%	99.8%	0%	0%	99.9%	0%	100%
teardrop	0%	0%	77.3%	0.1%	99.9%	0%	0.1%	0%	0.1%
ipsweep	0%	0%	0%	0%	0%	99.8%	92.2%	1.5%	1.7%
nmap	0%	44.6%	0%	0%	0%	44.1%	99%	44.6%	3%
portsweep	0.4%	9.9%	0%	0%	0%	0%	0.1%	99.6%	90.2%
satan	0%	88.6%	0%	0%	0.1%	0.1%	3.6%	88.7%	99.5%
normal	0.4%	0%	0%	0%	0%	0.5%	1.1%	0.1%	1.3%

Таблица 2: Показатели эффективности обнаружения атак НС

Заключение

Исследование и имитационное моделирование гомогенных НС на экспериментальных данных KDD Cup 99 в задачах обнаружения и классификации сетевых атак свидетельствует об эффективности нейросетевых технологий. Естественно ожидать, что при использовании гетерогенных НС полиномиального и диофантового типа, а также их коллективов результаты распознавания сетевых атак могут быть улучшены. Перспективным представляется также частично исследованный авторами метод обнаружения и классификации сетевых атак, основанный на иммуно-клеточном подходе.

Работа выполнена при частичной поддержке гранта по Программе № 14 Президиума РАН (GRID) и издательского гранта РФФИ № 12-08-07022-д.

Литература

- [1] С.Хайкин. Нейронные сети. Полный курс.– М.: Издательский дом “Вильямс”, 2006, 1104 с.
 [2] Каляев А. В., Тимофеев А. В. Методы обучения и минимизации сложности когнитивных нейро-модулей нейрокомпьютера с программируемой архитектурой. - Доклады АН, 1994, т. 237, с. 180-183.

- [3] Тимофеев А.В. Методы синтеза диофантовых нейросетей минимальной сложности. - Доклады АН , 1995, т.301, № 3, с.1 106-1109.
- [4] Тимофеев А.В., Шибзухов З.М. Методы синтеза и минимизации сложности диофантовых нейронных сетей над конечным полем. Автоматика и телемеханика, 1997, № 4, с. 204-212.
- [5] Тимофеев А. В. Оптимальный синтез и минимизация сложности генно-нейронных сетей по енетическим базам данных. Нейрокомпьютеры: разработка и применение, № 5-6, 2002, с. 34-39.
- [6] Тимофеев А. В., Шибзухов З. М., Шеожев А. М. Синтез нейросетевых архитектур по многозначному дереву решений. – Нейрокомпьютеры:разработка и применение, № 5-6, 2002, с. 44-49.
- [7] Timofeev A. V. Polynomial Neural Network with Self-Organizing Architecture. - International Journal on Optical Memory and Neural Networks, 2004, N 2.
- [8] Timofeev A. V. Parallelism and Self-Organization in Polynomial Neural Networks for Image Recognition. - Pattern Recognition and Inage Analysis, 2005, vol. 15, No.1, pp. 97 - 100.
- [9] Тимофеев А.В. Иерархические самоорганизующиеся нейронные сети и алгоритмы мульти-агентного принятия решений – Материалы 4-й Всероссийской мульти-конференции по проблемам управления МКУ-2011 (Россия, Дивноморское, 28 сентября – 7 октября 2011 г.), т.1, с. 43–45.
- [10] А.В. Лукацкий. Обнаружение атак. 2-е изд., перераб. и доп. – СПб.: БХВ-Петербург, 2003.
- [11] KDD Cup 1999 Data <http://kdd.ics.uci.edu/databases/kddcup99/kddcup99.html>
- [12] Технологии обнаружения сетевых атак. <http://www.bstu.by/~opo/ru/uni/bstu/science/ids/>.
- [13] Fast Artificial Neural Network.<http://leenissen.dk/fann/up>

Сведения об авторах



Тимофеев Адиль Васильевич – заведующий лабораторией информационных технологий в управлении и робототехнике Санкт-Петербургского института информатики и автоматизации Российской академии наук, Профессор кафедры информатики математико-механического факультета Санкт-Петербургского государственного университета, доктор технических наук, профессор, Заслуженный деятель науки РФ, 199178, Россия, Санкт-Петербург, 14-я линия, д. 39, СПИИРАН, tav@ias.spb.su



Браницкий Александр Александрович – студент кафедры информатики Математико-механического факультета Санкт-Петербургского государственного университета, дипломник, alexander.branitskiy@gmail.com