

УДК: 519.2, 612.087, 621.319.7

Сериков А.В., Иванов А.И.

Перспектива создания нейросетевых идентификаторов уровня слабых корреляционных связей с большим числом сетей и выходных состояний

Следует отметить, что появление первого стандартизованного алгоритма обучения больших нейронных сетей ГОСТ Р 52633.5 [1] в 2011 году является знаковым событием. До этого момента научно-технической общественностью было создано несколько сотен различных алгоритмов обучения нейронных сетей [2, 3, 4]. На начало этого века известные алгоритмы обучения не были упорядочены и любой автор имел право излагать их в какой угодно последовательности. Естественно, что самой простой является хронологическая последовательность обзора алгоритмов [2], однако, и она дает существенные сбои. Так в хронологическом порядке первым научился обучать многослойные сети Галушкин А.И. [5], предложив еще в 1974 году метод «обратного распространения ошибок». Однако, предложение Галушкина на тот момент было трудно реализуемо технически. Положение изменилось только в начале этого века [6] силами Джеффри Хинтона. Именно он снял технические ограничения на глубину нейронной сети, воспользовавшись машиной Больцмана.

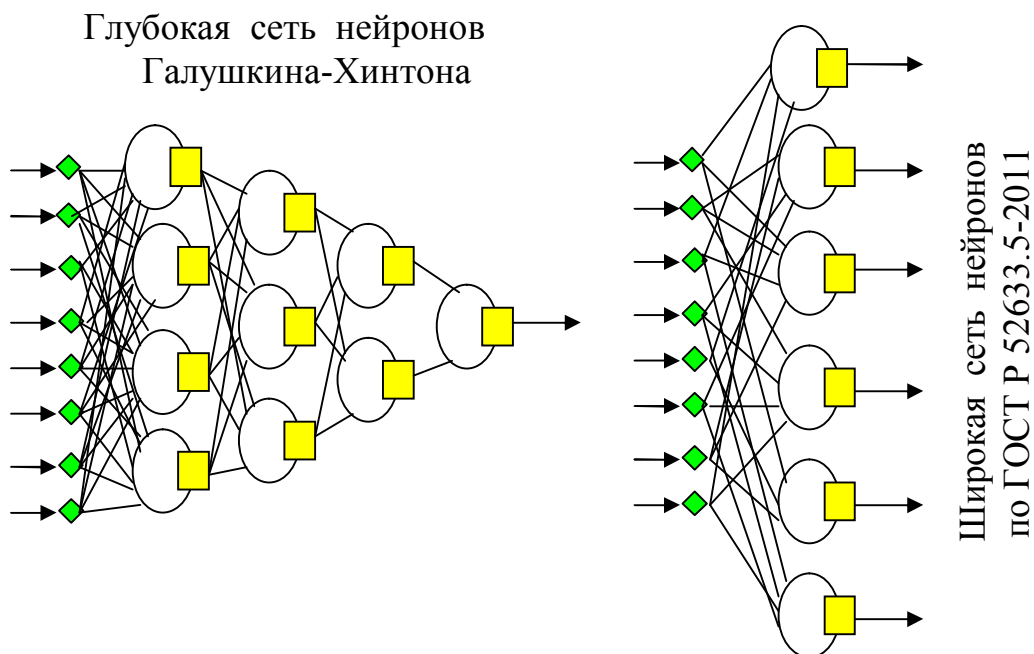


Рис. 2. Два типа архитектуры нейронных сетей: «глубокие» нейронные сети и «широкие» нейронные сети

На сегодняшний день, так называемые, «глубокие» нейронные сети широко используются Интернет поисковиками изображений и «цифровыми» фотоаппаратами. Практически все цифровые фотоаппараты имеют функцию

поиска лиц людей в текущем кадре, которая реализуется, через обучение «глубокой» нейронной сети Галушкина-Хинтона (смотри рисунок 1).

Формально поиск лиц людей в кадре – это некоторая биометрическая функция для роботов. Она действительно встраивается не только в цифровые фотоаппараты, но и в средства биометрической идентификации личности человека.

К сожалению, обучение глубоких искусственных нейронных сетей является вычислительно сложной задачей. Для того, чтобы заново обучить глубокую нейронную сеть, потребуется порядка 10 000 примеров лиц людей, сама процедура обучения будет занимать несколько часов непрерывной работы порядка 100 серверов. Столь высокая вычислительная сложность алгоритма обучения является очевидным препятствием применения глубоких нейронных сетей в биометрии.

При реализации алгоритмов биометрической аутентификации [6, 7] необходимо использовать полностью автоматический алгоритм обучения нейросетевого преобразователя биометрия-код с минимальной вычислительной сложностью. Именно совокупность автоматического обучения (абсолютной устойчивости вычислительных алгоритмов) и их приемлемой вычислительной сложности и потребовало разработки совершенно нового алгоритма обучения, который позднее стандартизован [1]. В итоге пришлось перейти от парадигмы «глубоких» нейронных сетей к альтернативной парадигме «широких» нейронных сетей со структурой, представленной на рисунке 1. Видимо смена парадигмы и позволила, в конечном итоге, уменьшить обучающую выборку с 10 000 примеров до 10 примеров (на три порядка) при одновременном снижении вычислительной сложности с экспоненциальной до линейной.

Важнейшим технологическим моментом является то, что при синтезе алгоритма обучения ГОСТ Р 52633.5-2011 [1] снижение вычислительной сложности операций с экспоненциальной до линейной не являлось самоцелью. Цель была одна – добиться абсолютной устойчивости вычислений, при этом какая в конечном итоге станет вычислительная сложность, играет второстепенное значение. Даже если вычислительная сложность будет выше линейной, процедуры обучения будут продолжать оставаться востребованными.

Последнее означает, что следующая модификация алгоритма обучения ГОСТ Р 52633.5-2011 [1] вполне может иметь квадратичную вычислительную сложность, если удастся сохранить абсолютную устойчивость вычислений. В связи с этим, начались исследования квадратичных форм [8, 9], сетей Баеса-Хэмминга [10, 11] и иных статистических функционалов [12, 13], способных обогащать биометрические данные [14].

Суть технической проблемы состоит в том, что квадратичные формы, многомерные функционалы Байеса и иные подобные преобразования используют коэффициенты парной корреляции или коэффициенты корреляции более высоких порядков. Однако, уже при вычислении коэффициентов парной корреляции на малой обучающей выборке, результаты имеют очень высокую погрешность. На рисунке 2 приведены распределения значений коэффициентов корреляции, полученные на малых выборках.

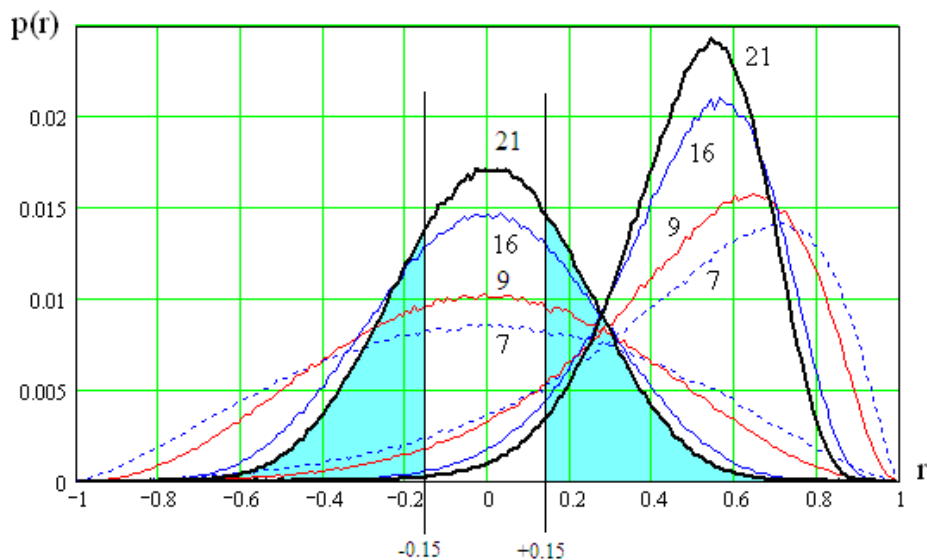


Рис. 2. Распределения значений коэффициентов корреляции, для выборок из 7, 9, 16, 21 примеров при двух заданных значениях коэффициентов корреляции $r = 0$ и $r = 0.5$

Из рисунка 2 видно, что наихудшей является ситуация «измерения» малых значений коэффициентов корреляции. Так при 21 примере в тестовой выборке вместо $r = 0$ редко, но все-таки могут появляться значения $r = \pm 0.65$. Чем больше число примеров в выборке, тем точнее результат расчетов, однако, увеличивать размер выборки не всегда возможно. В связи с этим возникает задача оценки связи погрешности вычисления коэффициентов корреляции $-\Delta r(n)$, как функции числа использованных данных – n . Это необходимо для последующего решения задачи корректировки составляющих этой погрешности [15, 16, 17].

В связи с тем, что задача «изменения» коэффициентов корреляции является некорректной, ее нужно регуляризовать. В частности может быть использована нейросетевая регуляризация. Например, мы можем заранее задаться дискретной шкалой состояний коэффициентов корреляции – $-0.5, -0.4, \dots, 0.0, \dots, +0.5$ (11 состояний). Далее следует задаться размером тестовой выборки, например, $n=21$. Кроме этого все биометрические данные, как правило, имеют близкий к нормальному закон распределения значений. То есть, мы можем воспользоваться гипотезой нормальности закона распределения значений двумерных выборок биометрических данных $\{\bar{v}_1, \bar{v}_2\}$.

Для того, чтобы снять неопределенность и сделать вычисления более корректными, нам достаточно создать 11 нейронных сетей и обучить их распознаванию образов, характерных для биометрических данных различного уровня коррелированности. Например, это могут быть образы положения 21 точки в пространстве возможных состояний двух контролируемых параметров, как это показано на рисунке 3.

Очевидно, что образы положения точек с нулевой корреляцией (рисунок 3) и образы положения точек с корреляцией $r=0.7$ (рисунок 4), имеют существенные отличия.




Рис. 3. Примеры образов распределения данных с нулевой корреляцией




Рис. 4. Примеры образов распределения данных с корреляцией $r = 0.7$

Очевидно, что следует обучить 11 нейронных сетей распознаванию образов, характерных для одной из градаций коэффициентов корреляции. Решение подобной задачи в рамках линейной алгебры некорректно. Для нелинейной алгебры нейросетевых функционалов подобная задача вполне корректна. Она может быть решена как в парадигме «глубоких» нейронных сетей, так и в парадигме «широких» нейронных сетей. За счет большего объема нейросетевых вычислений, мы вполне можем снизить ошибку вычисления коэффициентов корреляции [17].

ЛИТЕРАТУРА:

1. ГОСТ Р 52633.5-2011 «Защита информации. Техника защиты информации. Автоматическое обучение нейросетевых преобразователей биометрия-код доступа».
2. Галушкин А.И., Цыпкин Я.З. Нейронные сети: история развития. М. Радиотехника, 2001 г., 840 с.
3. Саймон Хайкин. Нейронные сети: полный курс. М.: «Вильямс», 2006. — С. 1104.
4. Галушкин А. И. Синтез многослойных систем распознавания образов. — М.: «Энергия», 1974.
5. Geoffrey E. Hinton Training Products of Experts by Minimizing Contrastive Divergence, Gatsby Computational Neuroscience Unit, University College London, 2002.
6. Язов Ю.К. и др. Нейросетевая защита персональных биометрических данных. //Ю.К.Язов (редактор и автор), соавторы В.И. Волчихин, А.И.

- Иванов, В.А. Фунтиков, И.Г. Назаров // М.: Радиотехника, 2012 г. 157 с. ISBN 978-5-88070-044-8.
7. Ахметов Б.С., Иванов А.И., Фунтиков В.А., Безяев А.В., Малыгина Е.А. Технология использования больших нейронных сетей для преобразования нечетких биометрических данных в код ключа доступа. Монография, Казахстан, г. Алматы, ТОО «Издательство LEM», 2014 г. -144 с., находится в открытом доступе (<http://portal.kazntu.kz/files/publicate/2014-06-27-11940.pdf>)
 8. Ахметов Б.Б., Иванов А.И. Многомерные статистики существенно зависимых биометрических данных, порождаемые нейросетевыми эмуляторами квадратичных форм: Монография. Казахстан – Алматы. Изво LEM, 2016. 86 с.
 9. Качайкин Е.И., Иванов А.И. Идентификация авторства рукописных образов с использованием нейросетевого эмулятора квадратичных форм высокой размерности. «Вопросы кибербезопасности» № 4(12) 2015 с. 42-47.
 10. Иванов А.И., Ложников П.С., Качайкин Е.И. Идентификация подлинности рукописных автографов сетями Байеса-Хэмминга и сетями квадратичных форм. «Вопросы защиты информации» №2 2015 г., с. 28-34.
 11. Иванов А.И., Ложников П.С., Качайкин Е.И., Сулавко А.Е. Биометрическая идентификация рукописных образов с использованием корреляционного аналога правила Байеса. «Вопросы защиты информации» №3 2015 г., с. 48-54.
 12. Иванов А. И., Газин А.И., Вятчанин С.Е., Перфилов К.А. Сравнение мощности хи-квадрат критерия и критерия Крамера-фон Мезиса для малых тестовых выборок биометрических данных «Надежность и качество сложных систем» №2 (14), 2016 с 67-72.
 13. Иванов А. И., Перфилов К. А., Малыгина Е.А. Многомерный статистический анализ качества биометрических данных на предельно малых выборках с использованием критериев среднего геометрического, вычисленного для анализируемых функций вероятности // Измерение. Мониторинг. Управление. Контроль. Пенза. №2 (16) 2016, с. 58-66.
 14. Иванов А.И. Многомерная нейросетевая обработка биометрических данных с программным воспроизведением эффектов квантовой суперпозиции. Издательство АО «ПНИЭИ», Пенза-2016 г., 133 с. Свободный доступ <http://пниэи.рф/activity/science/BOOK16.pdf>
 15. Волчихин В.И., Иванов А.И., Серикова Ю.И. Компенсация методических погрешностей вычисления стандартных отклонений и коэффициентов корреляции, возникающих из-за малого объема выборок. Известия высших учебных заведений. Поволжский регион. Технические науки. – Пенза: ПГУ, №1, 2016 с. 45-49.
 16. Кулагин В.П., Иванов А.И., Серикова Ю.И. Корректировка методических и случайных составляющих погрешностей вычисления коэффициентов корреляции, возникающих на малых выборках биометрических данных // Информационные технологии. Москва, №9 Том. 22 -2016 г. с.705-710.
 17. Волчихин В.И., Иванов А.И., Ахметов Б.Б., Серикова Ю.И. Фрактально-корреляционный функционал, используемый при поиске пар слабо зависимых биометрических данных в малых выборках. // Вестник высших учебных заведений. Поволжский регион. Технические науки» №4, 2016 г.

Статья поступила 12.11.2016, опубликована 27.11.2016
по положительной рецензии к.т.н. Зефирова С.Л.