



Рисунок 2 – Список несоответствий проверенного документа правилам оформления

Среди преимуществ приложения можно отметить: возможность реализации мульти-процессорной обработки для увеличения эффективности работы приложения, широкий круг потенциальных пользователей, удобство пользования, благодаря использованию популярного формата текстовых документов docx, интеллектуальное обучение на основе заранее подготовленного образца, а также высокую гибкость при ручной настройке файла, содержащего правила оформления для проверки документов.

Список цитированных источников

1. Балдин, Е.М. Компьютерная типография LaTeX [Текст]: учебное пособие / Е.М. Балдин. – СПб.: Изд-во «БХВ-Петербург», 2008. – 304 с.
2. Standard EPMA-376 Office Open XML File Formats [Электронный ресурс] // Standard EPMA-376: [сайт]. – Электрон. текстов. дан. – [Б.м.], 2012. – Режим доступа: <http://www.ecma-international.org/publications/standards/Ecma-376.html>. – Загл. экрана.

УДК 004.056.2

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ДЕКОДИРОВАНИЯ БЛОЧНЫХ КОДОВ

Драко А.М.

Белорусский государственный технологический университет, г. Минск

Увеличение количества потребителей информации приводит к необходимости увеличения пропускной способности каналов, а также к увеличению помех в уже используемых системах передачи. Серьезной проблемой становится защита каналов связи от помех. Одним из наиболее удачных методов защиты от помех является помехоустойчивое кодирование.

За более чем 70 лет существования помехоустойчивого кодирования было создано множество методов кодирования информации, однако основную нагрузку испытывает декодер. Сейчас существует множество способов получить от стандартного кода больше, чем в него было заложено изначально. Одним из примеров является «мягкое» декодирование, которое позволяет обнаружить и исправить большее количество ошибок, чем стандартные методы декодирования. Современная наука ищет новые подходы к декодированию, и одним из таких подходов может стать использование нейронных сетей.

Нейронные сети стали эталоном алгоритмов для решения нестандартных задач, таких как аппроксимация и распознавание образов. Одной из таких задач может стать декодирование линейных блочных кодов. Декодирование можно рассматривать как процесс перехода от вторичного отображения сообщения к первичному алфавиту. Фактически оно сводится к задаче классификации или определении принадлежности входного образа, представленного вектором признаков, к одному или нескольким предварительно определенным классам.

При конструировании нейронного декодера необходимо решить ряд задач. Правильный выбор объема сети имеет большое значение. Построить небольшую и качественную модель часто бывает просто невозможно, а большая модель будет просто запоминать примеры из обучающей выборки и не производить аппроксимацию, что, естественно, приведет к некорректной работе классификатора. Существуют два основных подхода к построению сети – конструктивный и деструктивный. При первом из них вначале берется сеть минимального размера, и постепенно увеличивается до достижения требуемой точности. При деструктивном подходе вначале берется сеть завышенного объема, и затем из нее удаляются узлы и связи, мало влияющие на решение. Число примеров в обучающем множестве должно быть больше числа настраиваемых весов. Иначе вместо обобщения сеть просто запомнит данные и утратит способность к классификации – результат будет неопределенный для примеров, которые не вошли в обучающую выборку. В нашем случае количество примеров имеет строго ограниченный характер и определено количеством информационных символов в сообщении. Поэтому объем сети имеет строго определенный размер.

При выборе архитектуры сети обычно опробуется несколько конфигураций с различным количеством элементов. При этом основным показателем является объем обучающего множества и обобщающая способность сети. Наиболее известными нейронными сетями являются сети обратного распространения, сети Ворда, а также случайные нейронные сети Геленбе. При использовании различной архитектуры сети нейронная сеть может обнаружить и исправить разный тип ошибок, что обязует при разработке нейронного декодера использовать все архитектуры сети. Тогда по полученным статистическим данным можно будет сказать, для каких условий подходит использование того или иного нейронного декодера.

Работа с данными в нейронной сети сводится к составлению примеров из закодированного сообщения и ожидаемых выходных значений сети, что является обучающим множеством. Тестовым множеством будет выступать набор переданных по каналу связи сообщений, содержащие различные типы ошибок, такие как одиночные и группирующиеся.

Для нейронной сети необходимо выбрать систему признаков, характерных для данной задачи, и преобразовать данные соответствующим образом для подачи на вход сети. Однако в случае переданного сообщения мы подаем на вход отдельные битовые значения, что не требует дополнительной нормировки.

В зависимости от системы кодирования выходным значением может быть класс или исходное информационное сообщение. Наиболее простым способом представления выходных данных в таком случае является вектор, компоненты которого соответствуют различным номерам классов, при этом сеть будет иметь число выходов, соответствующее числу классов. Более сложным будет выходной вектор, представляющий собой номер кластера, записанный в двоичной форме, что позволяет уменьшить количество выходов, и одновременно результат будет соответствовать декодированному сообщению.

Топология сети должна соответствовать двум критериям. Первым критерием выступает минимизация количества нейронов, так как передача данных в сетях требует максимальной скорости декодирования. Входной слой нейронов состоит из N нейронов, равный количеству бит переданного сообщения. Выходной слой в целях минимизации будет равен количеству бит требуемых для записи номера кластера в двоичной форме.

Так как в нейронной сети будет использоваться двоичная форма представления данных, то в качестве функции активации нейронов можно использовать «единичный скачок» или «гистерезис». Однако предпочтительно использование сигмоидальной функции в пределах от 0 до 1. В случайных нейронных сетях Геленбе не используется понятие «функции активации», что делает их более универсальными и не требует изучения влияния различных активационных функций.

Алгоритм обучения сети в задачах классификации всегда является обучением с учителям. Переданным по каналам связи сообщениям задаются ожидаемые результаты в соответствии от системы кодирования выходных значений.

Оптимизация нейронного декодера весьма затруднительна в условиях однозначного количества факторов, влияющих на решение сети. Уменьшить топологию сети за счет уменьшения входных данных невозможно, однако при использовании сети Ворда или двух параллельных нейронных сетей и рассмотрения отдельно информационных и контрольных бит переданного сообщения можно добиться уменьшения количества связей в нейронной сети, что означает меньшее количество операций или большую скорость декодирования сетью.

Нейронный декодер является малоизученным методом, который только начинает свое развитие, что открывает широкие возможности для его дальнейшего изучения. Одним из важнейших его преимуществ перед другими типами декодеров является универсальность использования его с любыми линейными блочными кодами. Для работы с другим кодом необходимо только подстроить количество нейронов под переданное сообщение и выходные данные, а также провести новое обучение сети. Также нельзя не отметить, что нейронная сеть может работать параллельно, что во много раз увеличивает скорость ее работы. Суммируя вышесказанное, можно сказать, что нейронный декодер при детальном изучении и развитии может стать одним из наиболее востребованных декодеров в современном помехоустойчивом кодировании.

УДК 004.032.26

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ГЛУБОКОГО ДОВЕРИЯ В ИНТЕЛЛЕКТУАЛЬНОМ АНАЛИЗЕ ДАННЫХ

Крощенко А.А.

Брестский государственный технический университет, г. Брест
Научный руководитель: Головки В.А., д.т.н., профессор

Введение

Наиболее известным и широко используемым на текущий момент подходом в обучении нейронных сетей глубокого доверия является метод, предложенный Дж. Хинтоном в 2006 году [1]. Ключевой идеей этого метода является использование «жадного» алгоритма послойного обучения (greedy layer-wise algorithm).

Нами был предложен и исследован альтернативный метод послойного предобучения нейронных сетей глубокого доверия, базирующийся на минимизации суммарной квадратичной ошибки восстановления образов на каждом слое [2]. Функция ошибки определяется согласно формуле (1):

$$E_s = \frac{1}{2} \frac{L}{e} \frac{m}{e} \frac{k}{e} \sum_{l=1}^L \sum_{j=1}^m \sum_{p=1}^k (y_j^l(p) - y_j^l(p-1))^2 + \frac{1}{2} \frac{L}{e} \frac{n}{e} \frac{k}{e} \sum_{l=1}^L \sum_{i=1}^n \sum_{p=1}^k (x_i^l(p) - x_i^l(p-1))^2, \quad (1)$$

где L – количество входных образов, m – количество нейронов в скрытом слое, n – количество нейронов в видимом слое, k – стадийность метода.

В случае CD-1 суммарная квадратичная ошибка примет вид:

$$E_s = \frac{1}{2} \frac{L}{e} \frac{m}{e} \sum_{l=1}^L \sum_{j=1}^m (y_j^l(1) - y_j^l(0))^2 + \frac{1}{2} \frac{L}{e} \frac{n}{e} \sum_{l=1}^L \sum_{i=1}^n (x_i^l(1) - x_i^l(0))^2. \quad (2)$$