

Значения средних полученных результатов паропроницаемости влагозащитного материала находятся в пределах границ регулирования, такие данные свидетельствуют о стабильности результатов. Таким образом, с помощью контрольных карт Шухарта размахов и средних значений измерений были оценены показатели стабильности (прецизионность и правильность) результатов паропроницаемости, полученных по методике, позволяющей определить паропроницаемость в условиях близких к эксплуатационным на устройстве контроля паропроницаемости. Данные результаты свидетельствуют о приемлемости и являются доказательством, подтверждающим компетентность как в отношении смещений, так и в повторяемости измерений.

Список используемых источников

1. Кирюхин, С. М. Текстильное материаловедение: учеб. пособия / Кирюхин С. М., Шустов Ю. С. / под общ. ред. И. С. Тарасова. – М.: КолосС, 2011. – 360 с.
2. Буркин, А. Н. Эксплуатационные свойства текстильных материалов монография / А. Н. Буркин, А. Н. Махонь, Д. К. Панкевич // под общ. ред. А.Н. Буркина. – УО «ВГТУ». – Витебск, 2019. – 218 с.
3. Ивашко, Е. И. Методика определения паропроницаемости водозащитных материалов / Е. И. Ивашко, А. Н. Буркин // Вестник Витебского государственного технологического университета. – 2023. – № 3 (45). – С. 9-16.
4. Устройство для контроля паропроницаемости: патент РБ № 13087, МПК G01N3/20 / Буркин, А. Н., Панкевич, Д. К., Борозна, В. Д., Ивашко, Е. И., Терентьев А. А. – Опубликовано 30.12.2022, Бюл. № 6.
5. СТБ ИСО 5725-6 -2002 Точность (правильность и прецизионность) методов и результатов измерений. Часть 6. Использование значений точности на практике, введ. 01.07.2003, (2002), Минск, Госстандарта, 48 с.

4.5 Информационные системы и технологии

УДК 004.032.26

СРАВНЕНИЕ РАЗЛИЧНЫХ МНОЖИТЕЛЕЙ К ФУНКЦИИ АКТИВАЦИИ LEAKYRELU НА ДАТАСЕТЕ MNIST

Монтик Н.С., асс.

*Брестский государственный технический университет,
г. Брест, Республика Беларусь*

Реферат. В статье рассмотрено сравнение различных коэффициентов для функции активации LeakyReLU, в т. ч. и ReLU. Определение правильно подобранного коэффициента имеет важное значение для точности классификации и скорости обучения нейронной сети. В качестве датасета для проверки будет использоваться классический датасет MNIST.

Ключевые слова: нейронная сеть, ReLU, MNIST, задача классификации.

Датасет MNIST (Modified National Institute of Standards and Technology) – набор данных, используемый в области машинного обучения и компьютерного зрения. Он представляет собой образцы оцифрованных рукописных цифр от 0 до 9, написанных различными людьми.

Датасет состоит из 70000 изображений, 60000 из которых предназначены для тестирования, а 10000 – для обучения. Он содержит 10 классов, по одному на каждую цифру. Все изображения представлены в виде матрицы размером 28x28 пикселей, где каждый пиксель хранит значение интенсивности оттенка серого (от 0 до 255).

Функция активации нейрона – это математическое правило, которое определяет выходной сигнал нейрона на основе взвешенной суммы его входов. Нелинейная функция активации позволяет сети выражать сложные зависимости между входами и выходами. Без функций

активации нейронная сеть сводится к линейной модели. Наиболее распространенными функциями активации являются следующие: сигмоидная, ReLU (Rectified Linear Unit) и её вариации, гиперболический тангенс и SoftMax. В данной работе будет рассмотрена функция активации LeakyReLU и влияние различных коэффициентов при использовании разных алгоритмов оптимизации.

ReLU (Rectified Linear Unit) – функция активации, которая определена следующим образом:

$$f(x) = \max(0, x), \quad (1)$$

где x – входное значение, \max – функция максимального значения.

Если входное значение x положительное, то ReLU возвращает такое же значение, а если отрицательное или равно нулю, то возвращается ноль. Графически это выглядит как линия, совпадающая с осью X , а затем проходящая через угол в 45 градусов в точке отсчета координат.

Преимущества ReLU включают в себя простоту вычислений и способность к быстрой сходимости во время обучения. Главным недостатком является проблема «мертвых нейронов», при которой нейроны могут перестать обновлять свои веса в процессе обучения и всегда выводить ноль. Для решения этой проблемы были предложены модификации, такие как LeakyReLU и Parametric ReLU, ELU.

LeakyReLU (Leaky Rectified Linear Unit) – вариант функции активации ReLU, который, в отличие от ReLU, использует небольшой коэффициент k . Данный коэффициент применяется, когда значение x меньше или равно нулю. Это позволяет избежать проблемы «мертвых нейронов».

LeakyReLU определяется следующим образом:

$$f(x) = \begin{cases} x, & x > 0 \\ kx, & x \leq 0 \end{cases}, \quad (2)$$

где k – коэффициент умножения.

Функция потерь в нейронной сети представляет собой меру различия между предсказанными значениями модели и истинными значениями. Она измеряет, насколько хорошо модель справляется с поставленной задачей, и является ключевым критерием для обучения нейронной сети.

Цель обучения нейронной сети состоит в минимизации значения функции потерь. Для различных задач используются различные функции потерь: среднеквадратичная ошибка (MSE – Mean Squared Error), кросс-энтропия и её варианты и т. д. В данной работе будет использоваться MSE.

Алгоритмы оптимизации используются для настройки параметров модели таким образом, чтобы минимизировать функцию потерь в процессе обучения. Оптимизация означает поиск оптимальных значений параметров, которые приводят к наилучшей производительности модели на задаче обучения. Примерами являются следующие алгоритмы: Adam, Adamax, Adagrad, Adadelta, RMSProp, SGD и т. д.

Архитектура нейронной сети взята из [1] и является следующей: 28x28(784)-500-500-2000-10 нейронов в каждом слое, сеть полносвязная, на слоях используется функция активации LeakyReLU. Размером батча было выбрано значение 500, так как оно продемонстрировало наивысшее значение точности при тестировании (использовался $k = 0,5$, оптимизатор Adam, 100 эпох).

Выбор коэффициента для функции активации LeakyReLU имеет большое значение для точности классификации нейронной сети, а также на скорость обучения сети. Сравнение будет проводиться различными коэффициентами k , в том числе и $k = 0$, то есть ReLU.

Для реализации поставленной задачи будет использоваться язык программирования python, библиотека pytorch. Инициализация весов стандартная, все алгоритмы оптимизации также используют стандартные параметры, для сива было установлено значение 68690064390100. В качестве значения точности выбирается максимальное значение за 100 эпох. Сравнение будет проводиться с использованием оптимизаторов Adam, Adamax, Adadelta, так как остальные либо продемонстрировали относительно низкую точность (для SGD точность составила менее 97 %), либо некорректно обучали сеть на данной архитектуре при стандартной инициализации весов.

Результаты сравнения представлены в таблице 1.

Как видно из сравнения, наибольшая средняя и максимальная точность классификации была продемонстрирована при использовании коэффициента $k = 0,025$, а наименьшая – при использовании ReLU и большого коэффициента k .

Таблица 1 – Сравнение точности классификации сети при различных коэффициентах k

Оптимизатор	Точность, %						
	$k = 0$ (ReLU)	$k = 0,5$	$k = 0,25$	$k = 0,1$	$k = 0,05$	$k = 0,025$	$k = 0,01$
Adam	78,92	98,12	98,33	98,32	98,48	98,4	98,31
Adamax	78,4	96,54	98,43	98,54	98,52	98,49	98,31
Adadelta	98,37	98,12	98,49	98,61	98,62	98,63	98,48
Среднее	85,23	97,6	98,42	98,49	98,55	98,5	98,37
Максимум	98,37	98,12	98,49	98,61	98,62	98,63	98,48

Таким образом, можно сделать вывод, что использование как слишком маленький, так и слишком больших коэффициентов ухудшает точность работы сети.

Список использованных источников

1. A fast learning algorithm for deep belief nets [Electronic resource] / Hinton G. E., Osindero S., The Y.-W. // University of Toronto. – 2006. – Mode of access: <https://www.cs.toronto.edu/~hinton/absps/fastnc.pdf/>. – Data of access: 10.03.2024.

УДК 004.4+651

ЭВОЛЮЦИЯ ТЕХНОЛОГИЧЕСКИХ РЕШЕНИЙ В СИСТЕМАХ ЭЛЕКТРОННОГО ДОКУМЕНТООБОРОТА

*Попова Е.Э., ст. преп., Поддевалина Я.А., асп.
Белорусский государственный университет,
г. Минск, Республика Беларусь*

Реферат. В статье представлена история развития технологий, используемых в системах электронного документооборота. Выделены факторы, повлиявшие на появление и изменение технологий, а, следовательно, и функциональных возможностей систем. Приводятся примеры реализаций технологических решений в конкретных системах электронного документооборота.

Ключевые слова: система электронного документооборота, технологические решения.

Системы электронного документооборота (СЭД) появились на рынке программного обеспечения (ПО) относительно недавно, но в настоящее время прочно заняли свое место в информационной структуре многих организаций. Первоначально в их задачу входила исключительно простая автоматизация документооборота, то есть помощь делопроизводителям в выполнении их прямых обязанностей. С течением времени возрастает и количество возлагаемых на данный вид систем функций. На сегодняшний день это не просто программа, выполняющая базовые делопроизводственные задачи (создание документов, автоматическая регистрация документов, поиск документов и т. п.), система электронного документооборота становится ядром ИТ-инфраструктуры, связывающим специальное программное обеспечение организации в единую сеть.

Факторами, которые повлияли на появление новых технологических решений, являются: изменение концепций в менеджменте, развитие ИТ и соответствующего сегмента рынка, изменение условий функционирования организаций и требований пользователей. Первые программные продукты, которые можно отнести к системам электронного документооборота появились в западных странах в 70-х гг. XX века [1]. В СССР развитие подобных систем берет начало в 1980-х гг. [2]. Изначально такие системы разрабатывались индивидуально в конкретной организации силами ее внутренних ресурсов, вследствие чего они обладали несколькими преимуществами: полностью встраивались в информационную инфраструктуру организации