

$$S_{kl}^{(1)} := 5 \cdot e_k e_k^T + 2 \cdot e_k e_l^T - 8 \cdot e_l e_k^T - 3 \cdot e_l e_l^T = \begin{matrix} & & k & & l & & \\ & & 0 & \dots & 0 & \dots & 0 & \dots & 0 \\ & & \vdots & & \ddots & & \vdots & & \vdots \\ k & & 0 & & 5 & & 2 & & 0 \\ & & \vdots & & & & \ddots & & \vdots \\ l & & 0 & & -8 & & -3 & & 0 \\ & & \vdots & & & & & & \ddots & & \vdots \\ & & 0 & \dots & 0 & \dots & 0 & \dots & 0 \end{matrix} \in M_n,$$

Для ранее зафиксированных пар $(k_i, l_i) \in \mathbb{R} \times \mathbb{R}$ чисел, удовлетворяющих неравенствам $1 \leq k_1 < l_1 < k_2 < l_2 < \dots < k_p < l_p \leq n$, обозначим через $S^{(1)} \in M_n$ и $S^{(2)} \in M_n$ матрицы

$$S^{(1)} := E + \sum_{i=1}^p S_{k_i l_i}^{(1)} - \sum_{i=1}^p (e_{k_i} e_{k_i}^T + e_{l_i} e_{l_i}^T) \text{ и } S^{(2)} := E + \sum_{i=1}^p S_{k_i l_i}^{(2)} - \sum_{i=1}^p (e_{k_i} e_{k_i}^T + e_{l_i} e_{l_i}^T).$$

Теорема 8. Матрица $\bar{E} \in M_n$ представляется в виде $\bar{E} = S^{(1)} \cdot S^{(2)}$.

Теорема 9. Для любых числа $\rho > 0$ и матрицы $G \in M_n$, удовлетворяющей оценке $\det G > \rho > 0$, найдутся такие число $\rho_1 = \rho_1(\rho) > 0$ и строго ρ_1 -положительно регулярные матрицы $H_i \in M_n$, $i = 1, 5$, при которых справедливо разложение $G = \prod_{i=1}^5 H_i$.

Следствие 3. Для любых числа $\rho > 0$ и матрицы $G \in M_n$, удовлетворяющей оценке $|\det G| > \rho > 0$, существуют такие строго регулярные матрицы $H_i \in M_n$, $i = 1, 3$, что выполняется соотношение $G = H_3 H_2 H_1$.

Заключение. Полученные результаты в дальнейшем могут быть использованы при построении управляющих воздействий, обеспечивающих решения различных задач управляемости асимптотических инвариантов линейных динамических (дискретных и непрерывных) систем. Также установленные утверждения имеют и самостоятельную ценность и значимость, поскольку могут найти свое применение в таких разделах математики как теория матриц, вычислительные методы алгебры. Кроме того, отметим, что полученные результаты были промоделированы на языке Python и получена соответствующая компьютерная программа. Работа выполнялась в рамках Государственной программы научных исследований на 2020-2025 годы «Конвергенция - 2025».

1. Хорн, Р. Матричный анализ / Р. Хорн, Ч. Джонсон. – М.: Мир, 1989. – 655 с.
2. Тыртышников Е.Е., Методы численного анализа. - Москва, 2006. – 291 с.

НЕЧЕТКАЯ НЕЙРОННАЯ СЕТЬ ДЛЯ ИДЕНТИФИКАЦИИ БИОЛОГИЧЕСКИХ ОБЪЕКТОВ НА ИЗОБРАЖЕНИЯХ

*Е.А. Корчевская, Л.В. Маркова
Витебск, ВГУ имени П.М. Машерова*

Большинство входных параметров, характеризующих контур рассматриваемых биологических объектов, по своей природе являются нечеткими. Например: “более вытянутый”, “менее вытянутый”, “более выпуклый”, “менее выпуклый”, “более некруглый”, “менее некруглый” и т.д. Поэтому для идентификации биологических объектов по форме наиболее оптимальный результат может быть достигнут с помощью нечеткой нейронной сети. Модель нейрона нечеткой нейронной сети оперирует не значениями идентификационных параметров, характеризующих объекты, как предложено в работах [1; 2], а значениями функций принадлежности к определенной группе нечетких характеристик.

Целью работы является разработка рекомендаций по использованию нечеткой нейронной сети для распознавания биологических объектов по цифровым изображениям.

Материал и методы. В качестве материалов использованы цифровые изображения следующих биологических объектов: *E.alabamensis*, *E.auburnensis*, *E.brasillensis*, *E.bukindonensis*, *E.ellipsoidales*, *E.cylindrika*, *E.canadensis*, *E.subherika*, *E.wyomingensis*, *E.zurnii*, *E.bovis*. В работах [1-2] были созданы методики, позволяющие с помощью разработанных идентификационных показателей распознавать указанные объекты. В нечеткой нейронной сети выводы осуществляются на основе аппарата нечеткой логики, но соответствующие функции принадлежности подстраиваются с использованием алгоритмов обучения нейронных сетей, например, алгоритма обратного распространения ошибки или генетического алгоритма. Такие системы не только используют априорную информацию, но могут приобретать новые знания в процессе и для пользователя являются логически прозрачными.

Результаты и их обсуждение. Реализованная нечеткая нейронная сеть состоит из пяти слоев:

1. Всякий элемент первого слоя является одним термом с функцией принадлежности. Входы сети связаны только со своими термами. Количество узлов данного слоя складывается из суммы мощностей терм-множеств входных данных. Выходом узла является степень принадлежности значения входной переменной соответствующему нечеткому терму:

$$\mu_A(x) = \frac{1}{1 + \left(\frac{x-c}{\sigma}\right)^{2b}}.$$

Данный слой является параметрическим с параметрами b , c , σ , которые

будут модифицированы в процессе обучения сети.

2. Узлы второго слоя соединены с теми узлами первого слоя, которые формируют антецеденты соответствующего нечеткого правила. Количество узлов второго слоя совпадает с числом правил. Данный слой выполняет агрегирование отдельных переменных x_i , определяя результирующую степень принадлежности w_k вектора X условиям k -го правила.

3. В третьем слое определяются значения $y_k = p_{k0} + \sum_{j=1}^N p_{kj} \cdot x_j$, где параметры p_{k0} и p_{kj} подлежат модификации в процессе обучения.

4. В четвертом слое вычисляется взвешенная сумма сигналов $y_k(x)$ и сумма весов $\sum_{k=1}^M w_k$, где M – количество правил.

5. Пятый слой – выходной, в котором вычисляется нормализованный сигнал

$$y_k = \frac{\sum_{k=1}^M w_k y_k(x)}{\sum_{k=1}^M w_k}.$$

Обучение нечеткой нейронной сети осуществлялось методом обратного распространения ошибки, который основывается на минимизации ошибки $E = \frac{1}{L} \sum_{j=1}^L (y_j - d_j)^2$, где y_j – полученный выход сети, а d_j – желаемый выход сети. Модификация параметров нейронной сети осуществляется по следующим формулам:

$$c^{(n+1)} = c^{(n)} - \eta \frac{\partial E(n)}{\partial c}, \quad \sigma^{(n+1)} = \sigma^{(n)} - \xi \frac{\partial E(n)}{\partial \sigma}, \quad b^{(n+1)} = b^{(n)} - \nu \frac{\partial E(n)}{\partial b}$$

Для нахождения параметров p_{k0} , p_{kj} необходимо решить системы уравнений:

$$d^j = \frac{\sum_{k=1}^M \omega_k y_k(x^j)}{\sum_{k=1}^M \omega_k}.$$

Заключение. В результате работы разработаны рекомендации по применению нечеткой нейронной сети для распознавания биологических объектов по цифровым изображениям.

1. Мироненко, В.М. Использование нейронных сетей для идентификации ооцист эймерий крупного рогатого скота/ В.М. Мироненко, Е.А. Корчевская // Веснік Віцебскага дзяржаўнага ўніверсітэта. – 2014. – №2(80), С. 54-59.

2. Паразитозы животных в Национальном парке «Припятский» и меры борьбы с ними с использованием IT-технологий: монография / Е.А. Корчевская [и др.]. - Витебск: ВГУ имени П.М. Машерова, 2014. – 42с.

СВЕРТОЧНЫЕ И РЕКУРРЕНТНЫЕ НЕЙРОННЫЕ СЕТИ ДЛЯ КЛАССИФИКАЦИЙ ИНСТРУКЦИЙ ВЕБ-ДРАЙВЕРА

*А.В. Кухарев, В.А. Евневич
Витебск, ВГУ имени П.М. Машерова*

Задача обработки текстов на естественном языке возникает во многих практических приложениях: автоматический перевод, фильтрация спама, классификация новостей, анализ тональности, вопросно-ответные и поисковые системы, а также в процессе взаимодействия пользователей с компьютером на уровне пользовательского интерфейса. Например, к этому относится обработка запросов пользователей мобильных устройств [1].

Selenium – это инструмент для тестирования веб-приложений. Одним из его компонентов является веб-драйвер, который позволяет выполнять операции над веб-приложением, имитируя действия пользователя. Для выполнения команд необходимо вызывать функции библиотеки Selenium из скриптов, написанных на языке Python. Таким образом, создание тестов требует от тестировщика определенных знаний языков программирования.

Для упрощения создания тестов могут использоваться методы машинного обучения. В работе [2] предложен подход автоматизации тестирования на основе обработки текстов на естественном языке. Тестировщик пишет инструкции на английском языке, после чего они преобразуются в спецификации на формальном языке. Подход включает в себя распознавание частей речи и семантический анализ текста.

До недавнего времени рекуррентные нейронные сети LSTM и GRU считались наиболее подходящей архитектурой для работы с последовательностями, в частности с текстовыми данными. Сверточные же нейронные сети использовались преимущественно в задачах распознавания изображений, где они добились высоких результатов благодаря использованию операции двумерной свертки. В работе [3] было предложено использовать сверточные нейронные сети с одномерной сверткой для классификации текстов.

В настоящей работе мы проведем сравнение эффективности сверточных и рекуррентных нейронных сетей в задаче классификации инструкций веб-драйвера, написанных на английском языке.

Материалы и методы. Набор данных для обучения и тестирования моделей был сгенерирован на основе документации к командам веб-драйвера Selenium [3]. Набор данных включает в себя 35 классов. Каждый класс соответствует определенному виду операции над веб-сайтом, например CLICK, ENTER, SELECT, OPEN, WAIT, SET_WINDOW_SIZE и другие. Часть этих операций повторяет команды Selenium, однако взаимно-однозначного соответствия нет. Разные команды Selenium могут относиться к одному классу. И наоборот, одна инструкция может соответствовать последовательности различных команд Selenium.

Отметим, что на естественном языке одна и та же инструкция может быть записана множеством способов, используя, в частности, замену слов синонимами или добавление второстепенных слов, не изменяющих смысл предложения. Например, инструкции «Open google.com» и «Navigate to the website google.com» относятся к одному классу OPEN. В то же время один и тот же глагол может использоваться в инструкциях, относящихся к разным классам. Например, инструкция «Assert that the current URL is google.com» относится к классу ASSERT_URL, а инструкция «Assert that alert exists» – к классу ASSERT_WINDOW.

Для классификации инструкций будем использовать две архитектуры нейронных сетей: 1) рекуррентная нейронная сеть архитектуры LSTM, и 2) сверточная нейронная сеть CNN.