

Один из вариантов реализации системы контроля доступа автотранспортных средств на охраняемую территорию

Т. М. Татарникова¹, В. В. Цехановский², Ф. Бимбетов
Санкт-Петербургский государственный электротехнический университет
«ЛЭТИ» им. В.И. Ульянова (Ленина)
¹tm-tatarn@tandex.ru, ²vvcehanovsky@mail.ru ³fbimbetov@gmail.com

Аннотация. Предлагается один из вариантов решения автоматического контроля доступа на охраняемую территорию автотранспортных средств, основанный на применении сети Хопфилда, реализующей распознавание регистрационных номеров. Средствами автоматического контроля доступа возможно фиксировать время заезда в конкретной зоне, организовывать автоматический въезд и выезд автомобилей, контролировать наличие автомобилей в зоне обслуживания. Система может эксплуатироваться на больших территориях парковок и контроля закрытых зон, запрещенных к въезду автотранспорта.

Ключевые слова: распознавание образов; нейронная сеть Хопфилда; система контроля доступа; обучение

I. ВВЕДЕНИЕ

Одним из перспективных инструментов решения задач анализа данных являются нейронные сети [1].

Основное преимущество нейронных сетей заключается в их способности аппроксимировать любую непрерывную функцию, что дает возможность аналитику не делать заранее какие-либо предположения о модели. С другой стороны, не существует каких-либо устоявшихся методик выбора параметров обучения и архитектуры нейронной сети.

В статье обсуждается решение задачи распознавания образов с использованием нейронной сети Хопфилда.

Образ – это определенная группа в системе классификации, выделенная по некоторому признаку.

Распознавание образов – это процесс идентификации предъявляемого объекта или его свойств с целью определения принадлежности этого объекта к одному из predetermined классов объектов [2].

Предлагается один из вариантов решения автоматического контроля доступа на охраняемую территорию автотранспортных средств. Решение основано на применении сети Хопфилда, реализующей распознавание регистрационных номеров.

II. НЕЙРОННАЯ СЕТЬ ХОПФИЛДА

A. Архитектура нейронной сети Хопфилда

Сети Хопфилда представляют собой класс рекуррентных нейронных сетей. Благодаря обратной связи изменение состояния одного нейрона приводит к изменению состояния всей сети – таким образом появляется переходный процесс, который формирует некое устойчивое состояние сети, отличающееся от предыдущего [3].

На рис. 1 приведена структура сети Хопфилда, в которой $S(t)$ – состояние нейрона в момент времени t , w_{ij} – элементы матрицы \mathbf{W} весовых коэффициентов.

Каждый нейрон может находиться в одном из двух состояний: $S(t) \in \{-1; 1\}$.

Активации нейрона соответствует +1, а остановке -1. Дискретность состояний нейрона отражает нелинейный, пороговый характер его функционирования.

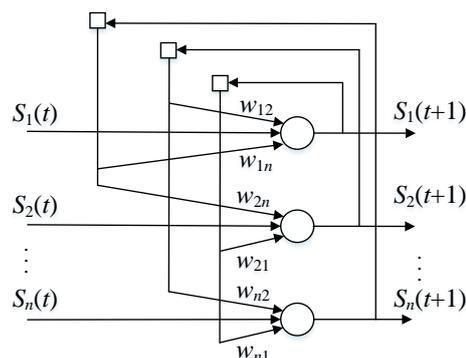


Рис. 1. Структура сети Хопфилда

Переходный процесс i -го нейрона в сети Хопфилда из N нейронов описывается дискретной динамической системой:

$$S_i(t+1) = F\left(\sum_{j=1}^N w_{ij} S_j(t)\right), \quad i, j = \overline{1, N}, \quad (1)$$

Случай $\sum_{j=1}^N w_{ij} S_j(t) = 0$ не имеет места.

В. Обучение нейронной сети Хопфилда

Обучение для одного входного образа \mathbf{X} есть процесс сохранения образа, который сводится к вычислению значений элементов матрицы \mathbf{W} и формально звучит как «обучить распознавать M образов $x_k, k = \overline{1, M}$ ». Входной образ x_k представляет собой:

$$\bar{x}_k = x_k + \xi, \quad (2)$$

где ξ – шум, наложенный на исходный образ x_k .

На практике обучение нейронной сети – это определение допустимого отклонения δ исходного образа \bar{x}_k от эталонного x_k в пространстве образов

$$|x_k - \bar{x}_k| < \delta. \quad (3)$$

Тогда, очистка входного образа от шума есть минимизация δ .

Важной характеристикой нейронной сети является отношение числа образов M к числу нейронов сети N : $\alpha = M/N$. Для сети Хопфилда значение α должно быть не больше 0,14.

Вычисление элементов матрицы \mathbf{W} производится по правилу Хебба:

$$w_{ij} = \frac{1}{N} \sum_{k=1}^M (x_{ik} \cdot x_{jk}), \quad (3)$$

где x_{jk} – j -й элемент образа k .

В силу коммутативности операции умножения $w_{ij} = w_{ji}$

Входной образ, который предъявляется для распознавания, соответствует начальным условиям динамической системы:

$$S_i = \bar{x}_k. \quad (4)$$

Уравнения (1) – (4) полностью описывают процесс обучения нейронной сети Хопфилда [4].

С. Алгоритм решения задачи распознавания образов на основе сети Хопфилда

Пусть вектор \mathbf{X} представляет собой черно-белые изображения образов размера 7×7 пикселей. Изображения образов представляются как одномерные вектора со значениями 1 и -1, где 1 – это черный пиксель, -1 – белый пиксель.

Решение поставленной задачи включает следующие шаги:

1. Создание базы эталонных образов.

2. Построение весовой матрицы \mathbf{W} .

3. Распознавание образов: классификация нового образа путем поиска максимально похожего на него из набора эталонных образов.

4. Вывод результата: изображение образа, который максимально похож на распознаваемый, либо сообщение о том, что искомым образ в наборе эталонных образов отсутствует.

Приложение работает сначала в режиме обучения – пользователь записывает и сохраняет ряд эталонных образов, а потом в режиме распознавания – пользователь подает изображение образа, в том числе искаженного с целью классификации этого образа [5].

Режим обучения сети включает:

- преобразование каждого эталонного изображения образа в одномерный вектор \mathbf{X} , таким образом сохраняется набор эталонов;
- вычисление весовой матрицы \mathbf{W} по полученным одномерным векторам;
- обнуление главной диагонали матрицы \mathbf{W} .

Режим распознавания включает:

- преобразование распознаваемого изображения в одномерный вектор $\bar{\mathbf{X}}^*$;
- определение комбинированного ввода каждого нейрона: умножение транспонированного вектора $\bar{\mathbf{X}}^*$ на матрицу \mathbf{W} : $S_i = \bar{\mathbf{X}}^T \times \mathbf{W}, i = \overline{1, 49}$;
- определение функции активации для нейрона и оценка состояния нейрона $S_i \in \{-1; 1\}$;
- получение результирующего вектора изображения $\bar{\mathbf{X}}$.

Сравнение $\bar{\mathbf{X}}$ и \mathbf{X} , в результате сравнения возможен один из вариантов:

1. $|\mathbf{X} - \bar{\mathbf{X}}| < \delta$, то получим ответ в виде искомого эталонного образа;

2. $|\mathbf{X} - \bar{\mathbf{X}}| \geq \delta$, то результат пока не найден и проводится серия итераций до получения устойчивого состояния сети. Когда сеть достигнет устойчивого состояния, то снова проверяется $|\mathbf{X} - \bar{\mathbf{X}}| < \delta$: если результат совпал с одним из имеющихся эталонных образов, то получим ответ в виде искомого эталонного изображения, в противном случае выведем сообщение об невозможности распознать образ.

Для проверки устойчивости обученной сети Хопфилда проведен ряд экспериментов, позволивших оценить значение δ , при котором образы перестанут распознаваться.

На рис. 2 представлен графический интерфейс приложения. Кнопка «Добавить образ» реализует функцию преобразования изображения образа в двумерный массив и добавление его в базу данных эталонных образов. Кнопка «Посмотреть все образы» реализует функцию последовательного показа в интерфейсном окне всех добавленных изображений (рис. 3). Кнопка «Удалить все образы» реализует функцию удаления из списка всех образов. Кнопка «Очистить поле» реализует функцию очистки интерфейсного окна от изображения. Кнопка «Распознать образ» реализует функцию распознавания текущего изображения по заданному пользователем списку эталонных изображений и определения уровня искажения в процентах: $\delta = \frac{100c}{49}$, где c – количество отличающихся позиций, 49 – длина вектора X .

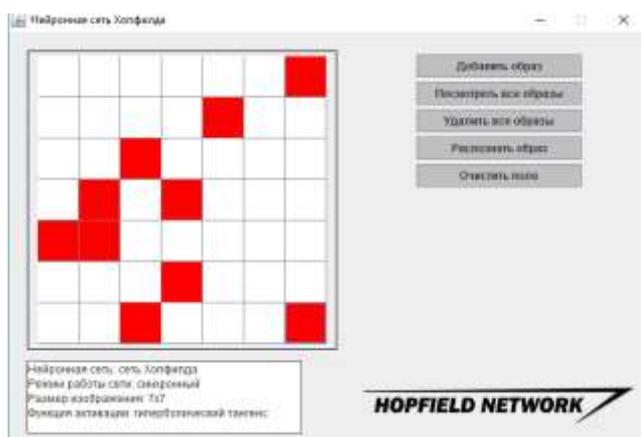


Рис. 2. Интерфейс приложения

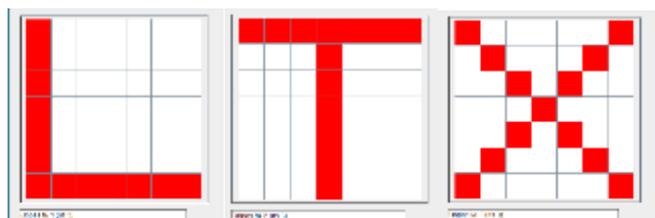


Рис. 3. Демонстрация коллекции эталонных образов

Для демонстрации работы сети Хопфилда рассмотрим три латинские буквы «L» – образ 1, «Т» – образ 2, «X» – образ 3, сохраненные в базу эталонных образов.

В качестве искаженного образа \bar{X} использован зашумленный образ буквы «L», как показано на рис. 4, который был успешно распознан.

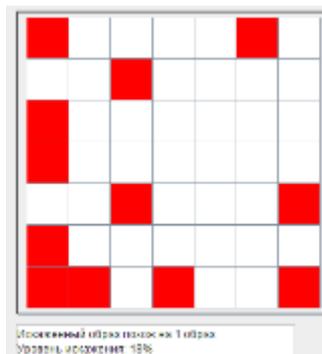


Рис. 4. Искаженный вариант буквы «L»

В эксперименте кроме эталонных образов участвовали искаженные образы в различных вариациях. Уровень распознавания образа оказался достаточно высоким – максимальное значение отклонения от эталонного образа составило 41 %.

Стоит заметить, что чем сильнее искажен необходимый объект, а не прочие искажения за объектом, тем слабее происходит распознавание.

Аналогичные результаты получены и для других экспериментов при добавлении эталонных образов.

Наиболее известные задачи распознавания образов, которые решаются с применением сети Хопфилда [6],[7]: распознавание текста или отдельных букв (символов); распознавание лиц, отпечатков пальцев и других биометрических характеристик; распознавание отдельных объектов на изображении; распознавание автомобильных номеров.

Основной недостаток сети Хопфилда заключается в том, что смещение или поворот объекта на изображении относительно его эталонного образа может привести к тому, что объект может быть не распознан. Казалось бы, выходом из такой ситуации может быть пополнение базы эталонных образов одного и того же объекта с разным смещением и поворотами. Но такое решение не подходит. Это связано с относительно небольшим объемом памяти сети Хопфилда, в результате чего эталонные изображения образов начинают «перекрывать» друг друга.

Тем не менее, есть задачи, для решения которых сеть Хопфилда является одним из лучших техник применения. Приведем пример внедрения разработанного приложения на конкретном объекте.

III. ЭКСПЕРИМЕНТАЛЬНАЯ ЧАСТЬ

Приложение, реализующее сеть Хопфилда по распознаванию образов стало частью системы автоматического контроля доступа на охраняемую территорию. Система предназначена для круглосуточной регистрации автотранспортных средств, имеющих индивидуальные регистрационные знаки.

Средствами автоматического контроля доступа возможно фиксировать время заезда в конкретной зоне, организовывать автоматический въезд и выезд автомобилей, контролировать наличие автомобилей в зоне обслуживания. Система также может использоваться на больших территориях парковок и контроля закрытых зон, запрещенных к въезду автотранспорта.

Разработанная система установлена на территории музея с охраняемой территорией «Дом Демидова» по адресу: г. Санкт-Петербург ул. Большая Морская 43. Музей включает в себя 3-х этажное здание, внутреннюю парковку, соединенную с проезжей частью улицы Большой Морской аркой первого этажа здания. Арка обустроена стальными воротами для охраны внутренней территории. Ширина арки достигает 2,5 метра, а высота проезда составляет 4 метра, что позволяет проезжать легковым автомобилям и небольшим малотоннажным грузовым транспортным средствам. Во внутреннем дворе имеется парковочная площадка на 10 стояночных мест.

Система состоит из следующих модулей:

- IP камера с инфракрасным прожектором для работы в ночное время.
- Персональный компьютер – автоматизированное рабочее место (АРМ) диспетчера пункта контроля.
- Локальная вычислительная сеть, устроенная на базе кабеля «витая пара».

На территории музея была выбрана область пространства, в которой происходит распознавание автомобильного номера, туда устанавливалась видеокамера, которая присоединялась к АРМ, в АРМ устанавливалось программное обеспечение обнаружения и распознавания регистрационного номера.

Рабочий процесс системы доступа происходит следующим образом. Автомобиль останавливается напротив закрытых ворот, оборудованных видеокамерой. Объектив камеры направлен на переднюю часть машины, так чтобы был виден индивидуальный регистрационный знак. Видеокамера в режиме реального времени передает видеопоток на АРМ, где происходит распознавание номера автомобиля (рис. 5). Если распознанный номер присутствует в базе данных, то на пульт оператора передается сигнал о разрешении въезда транспортному средству и фиксируется время въезда. Оператором пульта является дежурный пропускного пункта. Оператор на основании информации полученной от системы принимает решение об открытии ворот для пропуска автотранспорта на охраняемую территорию музея.

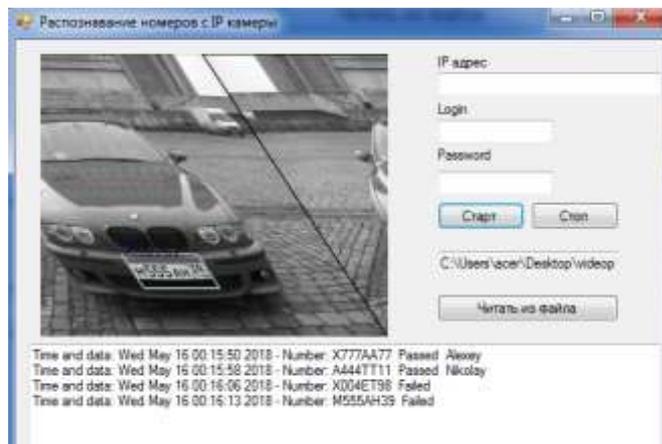


Рис. 5. Визуализация регистрационного номера на экране АРМ

Основная работа по проверке качества работы системы, и в частности распознавания регистрационных номеров автотранспорта проводилась с 26 по 31 мая 2020 г.

На рис. 6 приведена гистограмма сравнения количества автотранспорта, заехавшего на охраняемую территорию и количества правильно распознанных регистрационных номеров.

Как можно видеть (рис. 6) система успешно распознавала все въезжающие автомобили. Так как 26.05.2020 проводились пуско-наладочные работы, а также запись номеров в базу данных, система была запущена во второй половине дня. 31.05.2020 был выходной день, поэтому общее количество автотранспорта небольшое.



Рис. 6. Сравнение количества автотранспорта, заехавшего на охраняемую территорию и количества правильно распознанных регистрационных номеров

IV. ЗАКЛЮЧЕНИЕ

Одним из известных преимуществ искусственных нейронных сетей заключается в их способности самообучаться. Поэтому это преимущество становится основным, в таких случаях, когда, например, не весь регистрационный номер попал в объектив камеры, нечитаемый регистрационный номер (грязный, стерт и т. п.).

Предложенная система, как один из вариантов решения автоматического контроля доступа автотранспортных средств на охраняемую территорию показала 100% результат верного распознавания регистрационных номеров.

Апробация системы автоматического контроля автотранспортных средств показала, что система может быть введена в эксплуатацию.

СПИСОК ЛИТЕРАТУРЫ

- [1] Каллан Р. Нейронные сети: Краткий справочник. М.: Вильямс, 2017. 288 с.
- [2] Тархов Д.А. Нейросетевые модели и алгоритмы. Справочник. М.: Радиотехника, 2014. 352 с.
- [3] Гелиг А.Х. Введение в математическую теорию обучаемых распознающих систем и нейронных сетей. М.: Издательство СПбГУ, 2017. 224 с.
- [4] E. Fatihand G. Aydin Data Classification with Deep Learning Using Tensorflow // International Conference on Computer Science and Engineering, 2017. P. 755–758.
- [5] B.Y. Sovetov, T.M. Tatarnikova and V.V. Cehanovsky. Detection System for Threats of the Presence of Hazardous Substance in the Environment // 2019 XXII International Conference on Soft Computing and Measurements (SCM), St. Petersburg, Russia, 2019. P. 121-124. doi: 10.1109/SCM.2019.8903771.
- [1] Татарникова Т.М. Ограничения утечки информации посредством неочевидных функций смартфона Android 5 // Информационно-управляющие системы. 2019. Vol. 5. P. 25-29.
- [6] Zhao B., Lu H., Chen S., Liu J.,and Wu D. Convolutional Neural Networks for Time Series Classification// Journal of Systems Engineering and Electronics. 2017. Vol. 28. P. 162–169.