

Литература

1. Соколов Е. Я. Теплофикация и тепловые сети. М.: Издательский дом МЭИ, 2006. 472 с.
2. Кондратьев А. Е., Загретдинов А. Р., Гапоненко С. О. Способ определения расположения трубопроводов: пат. Рос. Федерация, заявитель и патентообладатель КГЭУ. № 2482515; заявл. 15.12.2011; опубл. 20.05.2013.
3. Кондратьев А. Е., Загретдинов А. Р., Гапоненко С. О., Мутигуллин Р. З. Измерительно-диагностический комплекс для определения расположения скрытых трубопроводов: пат. Рос. Федерация: заявитель и патентообладатель КГЭУ. № 127203; заявл. 06.12.2012; опубл. 20.04.13.
4. Пейч Л. И., Точилин Д. А., Поллак Б. П. LabVIEW для новичков и специалистов. М.: Горячая линия-Телеком, 2004. 268 с.
5. Виноградова Н. А., Листратов Я. И., Свиридов Е. В. Разработка прикладного программного обеспечения в среде LabVIEW: учеб. пособие. М.: Изд-во МЭИ, 2005. 49 с.
6. Кондратьев А. Е., Загретдинов А. Р., Гапоненко С. О. Свидетельство о государственной регистрации программы для ЭВМ № 2012661393: Программный комплекс для определения расположения полых объектов по их резонансной частоте / Заявка № 2012619257, 2012.
7. Кондратьев А. Е., Загретдинов А. Р., Гапоненко С. О. Свидетельство о государственной регистрации программы для ЭВМ № 2013610546: Программный комплекс для обнаружения полых объектов по их резонансной частоте / Заявка № 2012660385, 2012.
8. Кондратьев А. Е., Загретдинов А. Р., Гапоненко С. О., Сафина С. Д. Свидетельство о государственной регистрации программы для ЭВМ № 2013661788: RESONANCE 2013 / Заявка № 2013619421, 2013.

УДК 004.032.26

Лагунов Никита Алексеевич, Мезенцева Оксана Станиславовна

АНАЛИЗ И ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ ЗАВИСИМОСТИ КАЧЕСТВА ОБУЧЕНИЯ НЕЙРОННЫХ СЕТЕЙ ОТ ПАРАМЕТРОВ ОБУЧАЮЩИХ ВЫБОРОК

В статье анализируются результаты экспериментальных исследований влияния основных параметров обучающих выборок на обобщающую способность и качество распознавания нейронной сети, даются рекомендации по эффективному составлению больших обучающих выборок, содержащих графические образы категорий объектов.

Ключевые слова: нейронные сети, обучающие выборки, распознавание, обработка изображений, обучение.

Lagunov Nikita Alekseyevich, Mezentseva Oksana Stanislavovna

ANALYSIS AND EXPERIMENTAL RESEARCH OF DEPENDENCE BETWEEN NEURAL NETWORKS TRAINING AND TRAINING PARAMETERS SELECTION

The article offers an analysis of the results obtained from experimental research into the impact that the major parameters in training selection have on the general training capacity and recognition capacity in neural networks; there are also some recommendations offered regarding efficient development of large training selections containing graphic images of object categories.

Key words: neural networks, training selections, recognition, image processing, training.

Описание задачи и анализ подходов к ее решению. Распознавание визуальных образов является задачей, имеющей невероятную вычислительную сложность, поскольку каждый объект, находящийся в реальном мире, может отражаться на сетчатке глаза и формировать бесконечное число двумерных изображений в зависимости от своего расположения в пространстве, позиции относительно наблюдателя, освещения, заднего фона и т. д.

Чтобы научить искусственную систему с большой вероятностью соотносить представленное изображение с ограниченным набором объектов, необходимо составить большую обучающую выборку, включающую в себя тысячи различных изображений, обеспечивающих необходимое разнообразие состояний каждого из объектов. При решении данной задачи существует два основных подхода [3].

Первый из возможных подходов – это создание большого набора «естественных» изображений, непосредственно снимков реального мира. Сбор и обработка таких данных должна проводиться максимально объективно и беспристрастно, передавать необходимое разнообразие объекта реального мира, но не смещать акцент к каким-то конкретным ракурсам и расположению в пространстве, не внося искажений в объективное восприятие предмета. При правильном выполнении такой подход способен дать мощную обучающую выборку, с помощью которой возможно добиться хорошего уровня распознавания нейронной сетью, но создание выборки потребует огромных трудозатрат и большого количества времени [1].

Второй подход заключается в том, чтобы синтезировать изображения, используя как данные, непосредственно связанные с целевым объектом, так и не имеющие к нему прямого отношения. Парадоксальность ситуации заключается в том, что опыт применения таких обучающих выборок, как NORB (NYU Object Recognition Benchmark) и Caltech, показал, что такие выборки могут более полно отражать данные об окружающем мире и служить лучшим ресурсом для обучения нейронных сетей, чем наборы «естественных» фотографий, потому как лучше охватывают диапазон возможных вариаций изображения, наблюдаемых в реальном мире.

Для решения наиболее общих задач распознавания, а также научных исследований существуют готовые решения, большие обучающие выборки, например NORB [4], содержащие большое количество изображений определенных типов. Но для решения конкретных прикладных задач, в ситуациях, когда требуется ограничить или, наоборот, расширить выборку конкретным набором объектов, может потребоваться составление нового обучающего множества. При проведении исследований за основу формирования выборки был принят метод наложения объектов, сфотографированных с нескольких ракурсов, на многочисленные, подготовленные заранее фоны. Таким образом, был обеспечен полуавтоматический процесс формирования большого количества визуальных паттернов, необходимый для полноценного обучения.

Описание программы. Для проведения исследований была разработана программа, позволяющая выделять и сохранять объекты из кадров видео потока данных, автоматизировать процесс наложения с применением различных параметров этих объектов на заранее подготовленные фоны, а также кодирование полученных изображений в формат обучающей выборки (рис. 1).



Рис. 1. Логическая структура программы-генератора обучающих выборок для нейронных сетей

Существуют различные типы представления обучающей выборки. При проведении исследований были использованы два распространенных типа [5]. Первый, характерный для базы данных NORB, – это бинарный файл, в котором первые два числа кодируют общее количество примеров и размер единичного паттерна. За ними следует набор из N матриц, кодирующих изображения, представленные в оттенках серого, где каждому пикселю соответствует одно число в диапазоне от 0 до 255. Для определения типа объекта, закодированного в очередной матрице, к файлу выборки добавляются еще два файла, один из которых содержит вектор чисел с последовательностью номеров объектов, а другой – информацию о выборке в целом, а также соответствия номеров объектов их реальным наименованиям. При использовании второго типа представления данных, характерного для библиотеки FANN (Fast Artificial Neural Network Library), выборка представляет собой текстовый файл, в первой строке которого записаны три числа – размер выборки, количество входов и количество выходов – а далее строки поочередно кодируют очередной входной пример и требуемое выходное значение.




Рис. 2. Примеры полученных во время формирования обучающей выборки изображений

При составлении любой обучающей выборки для нейронной сети (НС), очень важно осуществить нормализацию входящих в нее примеров, таким образом обеспечив их единообразие. В случае работы с визуальными образами в качестве такой предобработки могут служить: перевод изображений в оттенки серого, для того чтобы устранить цветное разнообразие паттернов и существенно снизить сложность задачи распознавания образов; сжатие изображений с помощью бикубической интерполяции с целью приведения входных паттернов к фиксированному размеру; локальная нормализация; обработка изображений с помощью фильтров Габора; применение пороговой функции, для того чтобы исключить присутствие среди выходов фильтра отрицательных и чрезмерно больших значений.

Описание экспериментов. Для объективного и эффективного анализа необходимо выбрать критерии обучающей выборки, те признаки, варьируя которые, можно будет оценивать их влияние на качество распознавания и обобщающую способность сети. Все выбранные критерии являются базовыми и могут послужить хорошим фундаментом для создания больших обучающих выборок. Во всех случаях для тестирования НС использовался единственный универсальный набор примеров, включающий пять различных объектов, снятых с пяти ракурсов (в некоторых экспериментах это число изменялось), а также несколько заранее подготовленных наборов фонов, сгруппированных по признаку сложности. В результате наложения объектов на фоны получалась обучающая выборка размером в 500 паттернов, недостаточная для достижения сверхточных результатов обучения, но вполне применимая для отслеживания и изучения тенденций изменения качества обучения при варьировании тех или иных параметров. Таким образом, обеспечивались единообразие условий проверки и объективность тестирования.

Размер объектов. Во всех выборках размер паттерна был фиксированным (96 на 96 пикселей), но размер объектов, накладываемых на фоны, изменялся (минимальное значение – 40, максимальное – 90 пикселей). Эксперимент показал, что процент распознанных изображений в тестовой выборке при увеличении размера объекта плавно возрастает до определенного рубежа, примерно равного 80–85 % от размера фона, затем резко снижается (рис. 3, табл.).

Сложность фонов. Все собранные фоновые изображения были условно разбиты по степени сложности – от практически однотонных изображений, до комплексных, включающих множество деталей и насыщенных участков. По результатам экспериментов можно сделать вывод, что НС показывает наилучшую способность к распознаванию при обучении на несложных фоновых изображениях, даже при наличии фонов с большой степенью насыщенности и разнообразия элементов в тестовой выборке. В этом случае гораздо большее влияние на подстраивание весовых коэффициентов оказывает значимая область, в которой сконцентрировано наибольшее количество информации об объекте. Несмотря на это, включение небольшого процента (5–15%) сложных фонов в обучающую выборку, положительно влияет на распознавание объектов в естественных сценах, а также трудных, зашумленных условиях (рис. 3, табл. 1).

Сдвиг объектов относительно центра. На данном этапе исследования в обучающую выборку последовательно добавлялось некоторое количество паттернов со смещенным положением целевого объекта. В итоге концентрация таких изображений в выборке менялась от 0 до 80 процентов. Несмотря на ожидание, что такие действия могут привести к улучшению обобщающей способности сети, результат оказался прямо противоположным – число правильно распознанных примеров неумолимо сокращалось. В среднем увеличение части изображений со смещением на 10 % в обучающей выборке уменьшает долю правильно распознанных примеров на 1–2 %.

Зашумление. При исследовании данного параметра на небольшой процент паттернов обучающей выборки помещался посторонний объект, находящийся близко к границе изображения и не перекрывающий целевого объекта. В случае небольшого числа зашумления такой подход положительно влияет на обобщающую способность сравнительно с «чистой» обучающей выборкой, особенно при наличии сложных фонов в тестовой выборке, но с увеличением процента зашумленных изображений дает обратный эффект.

Количество ракурсов объекта – увеличение точек, с которых сделаны снимки объектов для обучающей выборки при неизменном общем количестве кадров. При единственном ракурсе качество распознавания было существенно ниже, чем при трех или пяти ракурсах. В то же время, чрезмерное увеличение вариативности точки наблюдения за объектом приводит к ухудшению обучения. При выборе точного количества ракурсов стоит учитывать также размер самой обучающей выборки.

Таблица

Результаты экспериментов

№	Параметр	1	2	3	4	5	6
1	Размер объекта в пикселях	67,5	68	70	70,5	72,5	62,5
2	Насыщенность фона	72,5	71	67,5	67,5	66,5	65
3	Процент паттернов со сдвигом объекта	72,5	65	64	62,5	62	60
4	Процент паттернов с шумом	72,5	74	70	67	65	64
5	Количество ракурсов	57,5	58	65	67,5	64	62,5
6	Поворот вокруг оси	72,5	67,5	68	70	65	45
7	Яркость	72,5	67,5	68,7	67,5	67,5	68,7
8	Перекрытие объекта	72,5	67,5	52,5	42,5	35	35

Поворот объектов вокруг своей оси может восприниматься как частный случай увеличения количества ракурсов объекта, поэтому данный критерий очень схож с предыдущим случаем. Однако за счет того, что вариативность ракурсов и количество паттернов, приходящееся на каждый ракурс, получается существенно меньше, то и вид кривой будет более пологим (рис. 3, табл.).

Изменение яркости / насыщенности изображений. В данном случае часть выборки обрабатывалась следующим образом: изображение переводилось из формата кодирования RGB в HSB (Hue, Saturation, Brightness), после чего изменялся параметр насыщенности или яркости, а обновленное изображение приводилось к первоначальному виду. В реальном мире освещение, расположение источников света является непостоянным и изменяется со временем, нельзя рассчитывать, что программа распознавания будет использоваться исключительно в идеальных условиях, поэтому обеспечение некоторой вариативности паттернов для обучения может обеспечить улучшение обобщающей способности сети. Однако эксперимент не подтвердил каких-либо существенных улучшений или ухудшений качества распознавания при изменении процента обработанных изображений в пределах 0–20 % и изменении параметра яркости в пределах 20 единиц. Более того, современные сверточные нейронные сети могут содержать специальные слои для устранения влияния фактора освещенности.




Рис. 3. Зависимость качества распознавания от (1) размера объектов (2) сложности фона (3) процента изображений, смещенных относительно центра (4) наличия шума (5) поворота объекта вокруг своей оси (6) количество ракурсов исходного объекта (7) изменения яркости изображений (8) наличия частичного перекрытия объектов

Перекрытие объекта. Еще один случай зашумления, при котором дополнительный объект не просто появляется на изображении, но перекрывает образ целевого объекта. Целью такого изменения является попытка обучить сеть справляться с ситуациями, когда часть предмета перекрыта держащей

его рукой или другой помехой. Обычно это приводит к полной потере способности адекватно распознавать объект. Исследования показали, что «исчезновение» части объекта на изображении сильно мешает правильному обучению сети, однако стоит учитывать, что использованные в эксперименте выборки имели сравнительно небольшой размер, и не исключается возможность, что при действительно больших объемах обучающих примеров нейронная сеть сможет обобщить входные данные и отнести искаженный объект к нужной категории (рис. 3, табл.).

Для финального подтверждения полученных результатов была использована еще одна небольшая тестовая выборка, содержащая необработанные изображения тех же объектов в естественных условиях, без сгенерированных искусственно фонов (рис. 4). За счет повышения сложности задачи, процент правильно распознанных изображений сократился, но выявленные соотношения для каждого случая существенным образом не изменились.



Рис. 4. Усложнение задачи использованием необработанных фотографий объектов

Выводы

1. Размер обучающей выборки должен быть достаточно большим, но при достижении определенного предела качество распознавания при добавлении новых паттернов увеличивается незначительно, а время обучения напрямую зависит от этого параметра.
2. Смещение объектов относительно центра обучающих паттернов не дает существенного улучшения качества распознавания, даже при условии наличия изображений со сдвигом объектов в тестовой выборке.
3. Размер изображения объектов относительно размера паттернов напрямую влияет на качество распознавания и обобщающую способность сети. Оптимальная величина объекта находится в районе 80–85 % от величины фона.
4. Усложнение и повышение насыщенности фона в общем случае снижает эффективность обучения сети, однако наличие небольшого процента изображений с комплексным фоном рекомендуется для решения сложных задач распознавания.
5. Зашумление путем добавления «отвлекающих» объектов на изображение дает положительный эффект при небольшом проценте таких примеров (0–10 % всей обучающей выборки).
6. Количество используемых ракурсов объекта напрямую влияет на качество обучающей выборки и должно быть достаточным, но не чрезмерно большим, чтобы, с одной стороны, обеспечивать необходимый уровень вариативности, но, с другой – не приводить сеть к переобучению.
7. Изменение яркости изображений, входящих в состав обучающей выборки, не приводит к серьезным изменениям качества распознавания нейронной сети.
8. Полное «удаление» части объекта путем перекрытия не приводит к положительным изменениям в распознавательной способности нейронной сети, по крайней мере, на небольших объемах обучающих выборок.

Литература

1. Ullman S., Vidal-Naquet M. Visual features of intermediate complexity and their use in classification // Nature Neuroscience, 2002. 490 с. URL: <https://courses.csail.mit.edu/6.803/pdf/features.pdf>.
2. Yann LeCun, Fu Jie Huang. Learning Methods for Generic Object Recognition with Invariance to Pose and Lighting // IEEE Computer Society Conference on Computer Vision and Pattern Recognition (volume 2), 2004. 104 с. URL: <https://courses.csail.mit.edu/6.803/pdf/features.pdf>.
3. Nicolas Pinto, David Cox, James DiCarlo. Why is Real-World Visual Object Recognition Hard? // {PLOS} Computational Biology, 2008. 27 с. URL: <http://dicarloblab.mit.edu/sites/dicarloblab.mit.edu/files/pubs/Pinto%20et%20al%202008.pdf>.
4. James DiCarlo. How Does the Brain Solve Visual Object Recognition? Neuron. Cell-Press, 2012. 415 с.
5. Weber M., Welling M., Perona P. Unsupervised learning of models for recognition, 2000. URL: <http://www.vision.caltech.edu/CNS179/papers/Perona00.pdf>.

УДК 681.5.01:658.512

Лубенцова Елена Валерьевна

СИНТЕЗ НЕЙРО-НЕЧЕТКОЙ СИСТЕМЫ СТАБИЛИЗАЦИИ ТЕМПЕРАТУРЫ ПРОЦЕССА НЕПРЕРЫВНОЙ СТЕРИЛИЗАЦИИ

Для синтеза нейро-нечеткой системы стабилизации температуры рассмотрено формирование базы правил нечеткого контроллера с учетом оптимального управления объектом и обучение гибридной нейронной сети. В качестве оптимальной траектории принято найденное по принципу максимума оптимальное по быстродействию управление для замкнутой системы автоматического управления. Осуществлен переход из временной области, в которой найдено оптимальное управление, к фазовой плоскости системы, что позволило непосредственно применить полученное решение для формирования базы правил нечеткого контроллера. Для разработки системы стабилизации температуры стерилизации среды с двумя управляющими воздействиями использована нейро-нечеткая сеть Adaptive-Network-Based Fuzzy Inference System – ANFIS.

Ключевые слова: нейро-нечеткая система, стабилизация температуры, оптимальная траектория, база правил, обучение нейронной сети, моделирование

Lubentsova Elena Valerievna

SYNTHESIS OF NEURO-FUZZY NETWORK FOR STABILIZING TEMPERATURE IN PROCESS OF CONTINUOUS STERILIZATION

To synthesize a neuro-fuzzy network of stabilizing temperature there is a view on the development of a base of rules for a fuzzy controller taking into account the optimal object management and training of a hybrid neural network. The optimal trajectory was accepted as the performance-optimal (detected by the maximum principle) management for a closed loop system for automatic management. There has been a transition made from the temporary area where the optimal management has been found, to the phase plane of the system, which allowed a direct use of the solution to develop a rule base for a fuzzy controller. There has been a neuro-fuzzy network (Adaptive-Network-Based Fuzzy Inference System – ANFIS) employed to develop a temperature stabilization system for sterilization with two management influences.

Key words: neuro-fuzzy network, temperature stabilization, optimal trajectory, rule base, neural network training, simulation.

Процессы тепловой стерилизации жидких питательных сред составляют основу стадии ферментации и широко используются в микробиологической, химико-фармацевтической и медицинской промышленности. К таким процессам предъявляются очень высокие требования, поскольку в случае нестерильности питательной среды происходит инфицирование культуральной жидкости в фермен-