

Для создания презентаций и тестовых вопросов потребовалось освоить графические возможности Word-2007, а также встроенные редакторы формул. Для того чтобы разместить тесты в системе дистанционного обучения было необходимо было изучить редактор формул Latex.

Пример тестового вопроса типа «числовой».

Вопрос 1
Пока нет ответа
Балл: 1,00

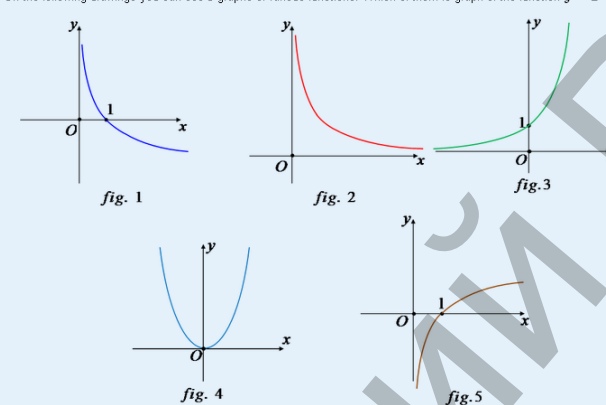
Find solution of equation $3^x = \frac{1}{27}$.

Ответ:

Пример вопроса типа «множественный выбор»

Вопрос 1
Пока нет ответа
Балл: 1,00

On the following drawings you can see 5 graphs of various functions. Which of them is graph of the function $y = 2^x$?



Выберите один ответ:

- fig. 3
- fig. 4
- fig. 5
- fig. 2
- fig. 1

[Начать сначала](#) [Сохранить](#) [Отобразить правильные ответы](#) [Отправить и завершить](#) [Закреть предварительный просмотр](#)

Заключение. В процессе работы созданы презентации и тесты, которые могут быть использованы для довузовской подготовки иностранных студентов, а также в процессе преподавания дисциплины «Методы решения математических задач». Данная работа потребовала освоения графических возможностей и редакторов формул программы Word-2007 и редактора формул Latex. Все эти навыки, безусловно, будут полезны в работе, после окончания обучения в университете.

Литература:

1. Lohwater's A.J. Russian-English Dictionary of Mathematical Sciences / Edited by R.P. Boas // American Mathematical Society, Providence, Rhode Island, 1990.
2. Бубен, С.В. Математика. Полный сборник задач / С.В. Бубен, В.В. Казачёнок. – Минск: Аверэв, 2011.
3. Сборник задач по математике для поступающих в вузы / под ред. М.И. Сканави. – Изд-во Оникс, 2006.

ЭФФЕКТИВНОСТЬ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ В ЗАДАЧАХ РАСПОЗНАВАНИЯ РУКОПИСНЫХ ЦИФР

Махлаев Ю.Н.,

студент 4 курса ВГУ имени П.М. Машерова, г. Витебск, Республика Беларусь

Научный руководитель – Кухарев А.В., канд. физ.-мат. наук

Область применения нейросетевых технологий постоянно расширяется, что связано в первую очередь с появлением новых архитектур глубоких нейронных сетей, одним из примеров которых являются сверточные нейронные сети. Сверточная нейронная сеть, или сеть свертки – это специальная архитектура многослойных искусственных нейронных сетей, предложенная Яном Лекуном в 1998-м году и нацеленная на эффективное распознавание изображений [1].

Цель настоящей работы – оценить преимущества сверточных нейронных сетей в задачах распознавания рукописных символов на примере десятичных цифр по сравнению с классическими полносвязными сетями. В работе проводится сравнение времени обучения и точности распознавания классических полносвязных сетей и сетей свертки, не содержащих полносвязных слоев.

Материал и методы. Обе рассматриваемые архитектуры нейронных сетей обучаются по алгоритму обратного распространения ошибки. Классическая многослойная нейронная сеть состоит из одного входного слоя, нескольких скрытых полносвязных слоев и выходного слоя. Архитектура же сверточных нейронных сетей подразумевает наличие чередующихся слоев свертки и подвыборки [2, с. 330].

Программная реализация изучаемых нейронных сетей выполнена на основе библиотеки Theano языка Python. Важным преимуществом этой библиотеки является то, что она позволяет задействовать при вычислениях графический сопроцессор, что позволяет увеличить скорость обучения сети в 5 – 10 раз. В ходе данной работы вычисления проводились на видеокарте GeForce GT 610.

Анализ эффективности распознавания образов сверточными и полносвязными нейронными сетями проводился на примере задачи распознавания рукописных десятичных цифр из базы MNIST. Пример изображений цифр этой базы показан на рисунке 1.




Рисунок 1 – Пример данных из базы MNIST

Результаты и их обсуждение. В качестве тестируемых полносвязных нейронных сетей использовались следующие три сети: 1) FNN1 – сеть, состоящая из трех полносвязных слоев, в каждом из которых по 100 нейронов, и одного выходного softmax-слоя; 2) FNN2 – отличается от FNN1 только тем, что содержит по 200 нейронов в каждом полносвязном слое; 3) FNN3 – сеть с 4-мя полносвязными слоями по 200 нейронов и одним выходным. Обучение каждой сети осуществлялось в 40 эпох (одна эпоха соответствует прогону всех образов базы MNIST). Коэффициент скорости обучения η сети за время обучения уменьшался от 0,5 до 0,009.

Графики зависимости точности распознавания полносвязных сетей от количества эпох обучения показаны на рисунке 2.

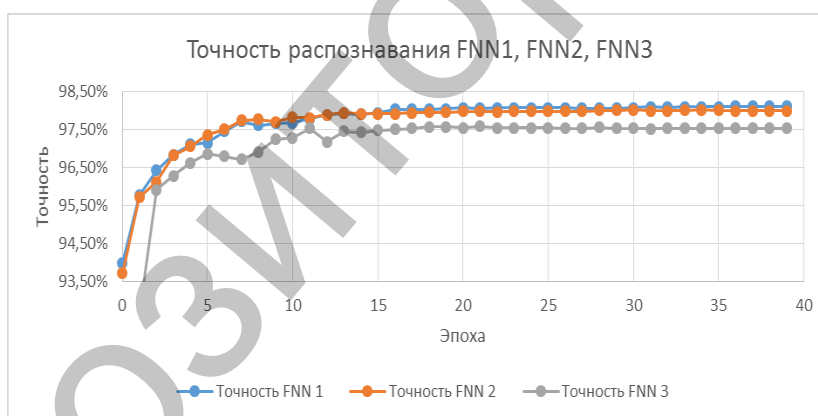


Рисунок 2 – Точность распознавания цифр с помощью полносвязных нейронных сетей FNN1, FNN2 и FNN3

Из рисунка 2 видно, что точность распознавания полносвязных нейронных сетей не улучшается при увеличении количества нейронов в слоях выше 100. Кроме того, добавление еще одного скрытого слоя также не приводит к повышению точности распознавания (см. таблицу 1).

Таблица 1 – Время обучения и ошибка распознавания полносвязных сетей

Сеть	Время обучения, мин	Ошибка
FNN1	13,79	1,90%
FNN2	13,78	1,99%
FNN3	16,03	2,42%

Проведено также тестирование трех сверточных сетей. Каждая сеть включают по три слоя свертки и три слоя подвыборки, чередующихся между собой, и один выходной слой. Обозначим эти сети как CNN8, CNN20 и CNN50, где число обозначает количество карт признаков в первом сверточном слое. Результат обучения показан на рисунке 3.




Рисунок 3 – Точность распознавания цифр с помощью сверточных нейронных сетей CNN8, CNN20 и CNN50

Как видно из рисунка 3, у всех трех сверточных сетей точность распознавания выше, чем у полносвязных сетей. При этом у сверточной сети с 20 картами признаков точность выше, чем у сети с 8 картами. Однако дальнейшее увеличение количества карт признаков до 50 не дает повышения точности, но увеличивает время обучения (таблица 2). Таким образом, сеть CNN20 показала лучшие результаты из рассмотренных здесь сетей.

Таблица 2 – Время обучения и ошибка распознавания сверточных сетей

Сеть	Время обучения, мин	Ошибка
CNN8	24,72	1,06%
CNN20	58,49	0,83%
CNN50	184,95	0,86%

Заключение. У сверточных нейронных сетей, не содержащих полносвязных слоев, ошибка распознавания рукописных цифр в среднем в 2 раза меньше, чем у полносвязных нейронных сетей. Это делает сверточные сети перспективными для практического применения в задачах распознавания, где присутствуют большие искажения во входных данных, и другие алгоритмы машинного обучения перестают работать эффективно.

Литература:

1. LeCun, Y. Gradient-based learning applied to document recognition / Y. LeCun [et al.] // Proc. of the IEEE. – 1998. – Vol. 86. – P. 1–46.
2. Хайкин, С. Нейронные сети: полный курс / С.Хайкин. – М.: ООО “И.Д.Вильямс”, 2006. – 1104 с.

РАСШИРЕНИЕ БАЗЫ ЗАДАЧ ПО ТФКП КАК ЭЛЕМЕНТ ЭЛЕКТРОННОГО УЧЕБНИКА

Медведева В.Ю.,

студентка 3 курса ГрГУ имени Я. Купалы, г. Гродно, Республика Беларусь

Научный руководитель – Сетько Е.А., канд. физ.-мат. наук, доцент

Сегодня становится актуальным создание электронных учебников, проектируемых на основе гиперссылок. В них происходит структурирование материала, что способствует дифференциации обучения за счёт изложения теории и подбора задач по уровням сложности.

Материал и методы. В статье рассматривается механизм подготовки банка задач по теме «Конформные отображения» с использованием автоматизированной компьютерной системы как элемента электронного учебника, создаваемого на кафедре ФиПМ ГрГУ [3]. Преподавателями кафедры была разработана компьютерная система, позволяющая автоматизировать процесс разработки банка задач [1]. Она включает:

- саму базу, содержащую задачи и ответы в параметризованном виде;
- программу на языке C++, подставляющую значения параметров в общий вид задачи из базы и генерирующую заданное пользователем количество вариантов;
- макроопределения в системе LaTeX, которые осуществляют верстку сгенерированного основной программой материала в различных форматах.