

3. G. Zhang, Y. Li, and T. Lin, “Caching in information centric networking: A survey,” *Computer Networks*, vol. 57, no. 16, pp. 3128 – 3141, 2013.
4. G. Rossini and D. Rossi, “A dive into the caching performance of content centric networking.” in *CAMAD*. IEEE, 2012, pp. 105–109.
5. I. Abdullahi, S. Arif, and S. Hassan, “Survey on caching approaches in information centric networking,” *Journal of Network and Computer Applications*, vol. 56, pp. 48 – 59, 2015.

УДК 004.588

Студ. М.Н. Карпович  
Науч. рук. доц. Н.В. Пацей  
(кафедра программной инженерии, БГТУ)

## АНАЛИЗ БИБЛИОТЕК АЛГОРИТМОВ MACHINE LEARNING

Машинное обучение (Machine Learning) - обширный подраздел искусственного интеллекта, изучающий методы построения алгоритмов, способных обучаться. Существует два типа обучения. Обучение по прецедентам, или индуктивное обучение, основано на выявлении общих закономерностей по частным эмпирическим данным. Дедуктивное обучение предполагает формализацию знаний экспертов и их перенос в компьютер в виде базы знаний. Его принято относить к области экспертных систем.

Существующие инструменты глубокого обучения имеют различный функционал и требуют от пользователя разного уровня знаний и навыков. Правильный выбор инструмента — важная задача, позволяющая добиться необходимого результата за наименьшее время и с меньшей затратой сил.

***Краткий обзор инструментов проектирования и обучения нейросетевых моделей.*** Основное внимание уделено четырем библиотекам: Caffe, Pylearn2, Torch и Theano. Рассмотрим базовые возможности указанных библиотек, примеры их использования. Сравним качество и скорость работы библиотек при конструировании одинаковых топологий нейросетей для решения задачи классификации рукописных цифр (в качестве обучающей и тестовой выборки используется датасет MNIST).

Далее в качестве исследуемого набора данных будет использоваться база изображений рукописных цифр MNIST. Изображения в данной базе имеют разрешение 28x28 и хранятся в формате оттенков серого. Цифры отцентрированы на изображении. Вся база разбита на

две части: тренировочную, состоящую из 50000 изображений, и тестовую — 10000 изображений.

Существует множество программных средств для решения задач глубокого обучения. В [1] можно найти общее сравнение функциональных возможностей наиболее известных. Первые шесть программных библиотек реализуют наиболее широкий спектр методов глубокого обучения. Разработчики предоставляют возможности для создания полностью связанных нейросетей (fully connected neural network, FC NN), сверточных нейронных сетей (convolutional neural network, CNN), автокодировщиков (autoencoder, AE) и ограниченных машин Больцмана (restricted Boltzmann machine, RBM). Необходимо обратить внимание на оставшиеся библиотеки. Несмотря на то, что они обладают меньшей функциональностью, в некоторых случаях их простота помогает достичь большей производительности.

После проведения эксперимента, легко заметить, что Pylearn2 показывает худшую производительность (как на CPU, так и на GPU) по сравнению с другими библиотеками. Что же касается остальных, время обучения сильно зависит от структуры сети. Лучший результат среди реализаций сетей, запущенных на CPU, показала библиотека Torch (причем на CNN она обошла саму себя же, запущенную на GPU). Среди GPU-реализаций наилучший результат (на обеих сетях) показала библиотека Caffe. В целом от использования Caffe остались только положительные впечатления.

Что же касается времени классификации одного изображения на CPU с помощью обученных моделей, то несложно видеть, что библиотека Torch оказалась вне конкуренции на обеих тестовых нейросетях. Немного от нее отстала Caffe на CNN, которая при этом показала худшее время классификации на MLP.

Если обратиться к точности классификации, то на сети MLP оно выше 97.4%, а CNN — ~99% для всех библиотек. Полученные значения точности несколько ниже приведенных на сайте MNIST на тех же структурах нейросетей. Небольшие отличия обусловлены различиями в настройках начальных весов сетей и параметрах методов оптимизации, применяемых в процессе обучения. Собственно, цели достижения максимальных значений точности и не было, скорее необходимо было построить идентичные структуры сетей и задать максимально схожие параметры обучения

На основании проведенного исследования функционала библиотек, а также анализа производительности на примере задачи классификации рукописных цифр дана оценка каждой из них по шкале от 1 до 3 по следующим критериям:

- Скорость обучения отражает время обучения нейросетевых моделей, рассмотренных на этапе проведения экспериментов.
- Скорость классификации отражает время классификации одного изображения.
- Удобство использования — критерий, который позволяет оценить время, затраченное на изучение библиотеки.
- Гибкость настройки связей между слоями, установки параметров методов, а также наличие различных способов обработки данных.
- Объем функционала — наличие реализации типовых методов глубокого обучения (полностью связанных сетей, сверточных нейросетей, автокодировщиков, ограниченных машин Больцмана, различных методов оптимизации и функций ошибки).
- Наличие и удобство использования документации и обучающих материалов

**Таблица 1**

Параметры	Caffe	Pylearn2	Torch	Theano
Скорость обучения	1	3	2	2
Скорость классификации	2	3	1	2
Удобство	1	2	2	3
Гибкость	3	3	2	1
Функционал	3	1	2	2
Документация	2	3	1	2
Сумма	12	15	10	12

Подводя итог, можно сказать, что наиболее зрелой является библиотека Torch. При этом библиотеки Caffe и Theano не уступают ей по многим критериям, поэтому нельзя исключать возможность их последующего использования. В дальнейшем для исследования применимости методов глубокого обучения к задачам детектирования лиц, пешеходов и автомобилей планируется применять библиотеки Caffe и Torch.

#### ЛИТЕРАТУРА

1. Дж. Вандер Плас(2018) Python для сложных задач. Наука о данных и машинное обучение Питер, ISBN978-5-496-03068-7
2. Сравнение библиотек глубокого обучения на примере задачи классификации рукописных цифр. [Электронные ресурс] – Режим доступа: <https://habrahabr.ru/company/intel/blog/254747/> (дата обращения 20.03.2018).