

при помощи формулы: $\text{double deg} = 30; // \text{угол в градусах}$ $\text{double rad} = \text{deg} * \text{Math.PI}/180; // \text{угол в радианах}$; $\text{Sin}(\text{угол})$ – вычисление синуса угла; $\text{Cos}(\text{угол})$ – вычисление косинуса угла; $\text{Tan}(\text{угол})$ – вычисление тангенса угла; $\text{Asin}(\text{значение})$ – вычисление арксинуса значения из диапазона $[-1; 1]$, возвращаемое значение лежит в диапазоне $[-\pi/2; \pi/2]$; $\text{Acos}(\text{значение})$ – вычисление арккосинуса значения из диапазона $[-1; 1]$, возвращаемое значение лежит в диапазоне $[0; \pi]$ и др.

Логарифмические функции

Класс `Math` предусматривает ряд методов для работы с экспонентой и логарифмами:

$\text{Exp}(\text{double степень})$ – возвращает значение числа e (`Math.E`) в указанной степени.

$\text{Log}(\text{double число})$ – возвращает натуральный логарифм указанного числа.

$\text{Log10}(\text{double число})$ – возвращает десятичный логарифм указанного числа.

$\text{Log}(\text{double число}, \text{double основание})$ – возвращает логарифм указанного числа по указанному основанию.

Возведение в степень и извлечение квадратного корня

Для возведения числа в степень предусмотрен метод `Pow(double, double)`, в качестве первого аргумента которого указывается число, возводимое в степень, а в качестве второго аргумента – показатель степени. Для извлечения квадратного корня из числа типа `double` можно также использовать метод `Sqrt(double)`.

УДК 621.762.4

Руйчева А.П.

РАЗВИТИЕ МАШИННОГО ОБУЧЕНИЯ

БНТУ, Минск

Научный руководитель Липень С.Г.

Публицисты всего мира обещают нам неизбежное пришествие искусственного интеллекта. Его можно сравнить с малышом, который постепенно растет и развивается. Удивительно, сколько ресурсов было вложено в развитие этой отрасли за последние

50 лет! Но только сейчас она начала давать действительно человекоподобные результаты. Невозможно не заметить, какой резкий скачок в развитии методов искусственного интеллекта совершили глубокие нейронные сети.

На сегодняшний день нейросеть может так раскрыть содержимое картинки, что спокойно может конкурировать с описанием от пятилетнего ребенка. Она способна генерировать музыку, подражая разным стилям. Нейронные сети также генерируют рукописные текст. На практике же нейросеть пытается симитировать написание букв пером и даже сама соединяет эти буквы. Можно обучить ее генерировать научные статьи. Существуют даже примеры публикации автоматически сгенерированных статей в научной периодике. Они являются полной бессмыслицей, но глядя насколько красиво оформлено, понять, что на самом деле в статье нет смысла, может только очень узкий круг ученых из близкой области.

Не так давно получил широкое распространение термин «большие данные», обозначивший новую прикладную область – поиск способов автоматического быстрого анализа огромных объёмов разнородной информации. Несмотря на то, что наука о больших данных ещё только обособляется, уже сейчас она очень востребована. А в будущем будет востребована ещё больше.

С её помощью можно решать невероятные задачи: оценивать состояние органов по кардиограмме, предсказывать зарплату по описанию вакансии, предлагать пользователю музыку на основании его анкеты в интернете. Большими данными может оказаться что угодно: результаты научных экспериментов, информация о скачках курсов валют и стоимости акций, метеорологические наблюдения, наши профили в социальных сетях – словом, всё, что может быть проанализировано и использовано в дальнейшем.

Самым перспективным подходом к анализу больших данных принято считать применение машинного обучения. Теория обучения машин находится на стыке статистики, численных методов оптимизации, дискретного анализа, а также других классических математических дисциплин, и несмотря на это имеет также и собственную специфику, связанную с проблемами эффективности и переобучения. Машинное обучение – обширный подраздел искусственного интеллекта, изучающий методы построения

алгоритмов, способных обучаться. Различают два типа обучения. Обучение по прецедентам, или индуктивное обучение, основано на выявлении общих закономерностей по конкретно имеющимся данным. Дедуктивное обучение предполагает формализацию знаний экспертов и их оцифровку в виде базы знаний.

Многие методы обучения разрабатывались как альтернатива классическим подходам и тесно связаны с извлечением информации и интеллектуальным анализом данных. И все же, в чем различие между классическим моделированием и машинным обучением? В классическом моделировании учеными, на основании собственного научного понимания восприятия мира, создается модель. Затем проверяется, правильно ли она предсказывает поведение соответствующей системы или нет. Если предсказывает правильно, то модель хорошая, с ней работают дальше. При этом никакая модель не может предсказывать всё абсолютно точно, поэтому ученые определяют границы её применимости. При этом они пытаются понять, почему в каких-то случаях она может не работать, улучшают её, и дальше всё повторяется. При этом весь прогресс обусловлен пониманием учеными нашего мира, а это понимание реализуется в виде некой модели. Следовательно, если мы не понимаем, как наша модель устроена, то, соответственно, мы не можем двигать научный прогресс.

С машинным же обучением ситуация обстоит по-другому. Оно позволяет нам решать даже такие задачи, метод решения которых мы сами понимаем не до конца, поэтому не можем сами полностью построить модель. Одна из задач, которую решает машинное обучение, но которая ранее являлась нерешаемой, – распознавание или классификация изображений. Например, на картинке изображено окно, и компьютер должен по картинке понять, что это именно окно. Мы практически не понимаем, как на практике работает человеческое сознание и как происходит распознавание предметов по картинке, и поэтому мы не можем составить точную модель этого процесса. Но, при этом, у нас есть много картинок с окнами, про которые точно известно, что это именно оно. И если бы на этом дело заканчивалось, то задачу мы бы решить не могли. Но частично мы понимаем, как работает распознавание образов. Мы понимаем, что окно остается окном, если поменяется его

расположение на картинке или если будет другое время суток или другое освещение. И неполное понимание того, как работает распознавание, мы вкладываем в модель машинного обучения, и тот зазор между пониманием и полной моделью мы восполняем за счет огромного числа данных, по которым фактически и строится модель машинного обучения. И это эффективно работает и фактически позволяет решить задачу, с которой не получалось разобраться ранее.

Интересны области исследований, где совместное применение классического моделирования и машинного обучения дает более успешные модели, чем их применение по отдельности. Пример такой области – это, например, обработка изображений. Например, мы гуляем ночью по парку и выходим к озеру, которое освещено красивым лунным светом. И мы хотим снять это на наш телефон, фотографируем его, а у нас получается очень темное изображение. Но на этом мы не останавливаемся, открываем графический редактор и увеличиваем яркость изображения. Тогда видно некое изображение этого озера, и появляется некий визуальный шум. Некоторые пиксели этого изображения будут принимать какие-то случайные цвета, изображение будет зашумленным. Алгоритмы обработки изображений позволяют убрать этот шум.

Классическим способом составлялась модель идеального изображения, которое, с одной стороны, должно быть близко к той зашумленной картинке, которую мы сфотографировали на телефон, а с другой стороны, оно должно иметь хорошее качество или быть регулярным. Регуляризация означает, что если, например, мы посмотрим на качественную картинку, снятую с хорошим освещением, увеличим ее и увидим пиксель белого цвета, то, скорее всего, рядом будет пиксель белого цвета. Дальше находится в этой модели некий баланс между близостью к исходному изображению и регулярностью и получаем картинку с отфильтрованным шумом. Классической парадигме вполне удавалось продвигаться в данном направлении. Но при такой обработке, скорее всего, на нашей картинке уйдут плавные изменения цветов, появятся контуры одного цвета, между которыми будут границы. Тогда мы делаем новую модель, основанную не на научных представлениях, а на обычных, примитивных понятиях о том, какими должны быть

картинки: должны быть плавные переходы между цветами, должны быть границы между объектами. Мы это заново вносим в нашу модель и смотрим, как она работает. Она будет работать лучше. Например, клетчатый принт на футболке она сгладит, решив, что это шум (хотя это не шум). И мы будем строить все новые и новые модели, дополняя необходимыми ограничениями.

Сейчас же вместо этого мы можем на примере огромного количества изображений обучить некую нейросеть, и она будет нам предсказывать, какая картинка хорошая, а какая картинка плохая. И вероятнее всего, мы сможем решать эту задачу более качественно.

В случае с картинкой, на которой изображено озеро, это, конечно, не представляет собой большую общественную пользу. Но, например, в задачах магнитно-резонансной томографии внутренних органов организма алгоритмы отфильтровывания шума очень важны.

Не так давно появилась идея применять машинное обучение и анализ данных в прогнозировании спортивных матчей. Параметры игроков и матча вместе с результатом матча могут составить обучающую выборку. Алгоритм машинного обучения со специалистом может использовать эту выборку для построения функции предсказания результатов новых матчей. В ходе анализа данных бейсбольных матчей было обнаружено, что многие общепринятые идеи о том, что важно, а что нет, не находят статистического подтверждения. Например, одним из важнейших качеств бейсболиста считалась его скорость и частота контакта. Расчёты же показывали, что связь между этими качествами и исходом матча не так уж сильна. Зато на результаты команды заметно влияют совсем не очевидные факторы – такие, например, как размер поля, на котором проходят тренировки. Кроме того, статистика свидетельствовала, что разница в уровне между игроками Главной и Низшей лиг куда меньше, чем принято считать.

На сегодняшний день компанией SPORTS разработана система отслеживания перемещений игроков. С помощью шести видеокамер, установленных на стадионе, она «на лету» определяет координаты каждого игрока, судьи и мяча, а затем пересчитывает их в десятки показателей. Например, во время баскетбольных матчей она, среди прочего, вычисляет скорость передвижения

каждого игрока, расстояние, которое он преодолел с мячом, дальность бросков, излюбленные места на поле, долю результативных передач и общей темп игры команды.

Успех данного анализа данных в спорте, в сущности, тот же, что и в любом другом бизнесе. Далеко не всё можно заметить невооружённым взглядом. Далеко не всегда опыт, «наметанный глаз» и здравый смысл правы. Закономерности, которые возможно различить только при помощи анализа данных, позволяют не только «срезать» углы, но немного увеличить эффективность. В спорте это «немного» может означать разницу между победой и поражением, а такую разницу трудно игнорировать.

Таким образом, можно прийти к заключению, что машинное обучение – не только математическая, но и практическая, инженерная дисциплина. Чистая теория, как правило, не приводит сразу к методам и алгоритмам, применимым на практике. Чтобы заставить их хорошо работать, приходится изобретать дополнительные эвристики, компенсирующие несоответствие сделанных в теории предположений условиям реальных задач. Практически ни одно исследование в машинном обучении не обходится без эксперимента на модельных или реальных данных, подтверждающего практическую работоспособность метода.

УДК 621.762.4

Руйчева А.П.

СРАВНИТЕЛЬНЫЙ АНАЛИЗ УРОВНЯ САМООТНОШЕНИЯ И САМОПРИНЯТИЯ ЮНОШЕЙ И ДЕВУШЕК

БНТУ, Минск

Научный руководитель Шеринёва Т.В.

Самооценка – эмоционально окрашенное отношение к себе в разных конкретных ситуациях и разных видах деятельности. Самоотношение – это целостное, относительно постоянное эмоциональное отношение к себе, мера принятия или непринятия индивидом самого себя. К. Роджерс разделил общее отношение к себе на самооценку (отношение к себе как носителю определенных