

АЛГОРИТМЫ РАСПОЗНАВАНИЯ И КЛАССИФИКАЦИИ ОСНОВАННЫЕ НА ВЫЧИСЛЕНИИ ОЦЕНОК.

АБДУКАРИМОВ АБДУМАНАП

*Джиззакский филиал Национального
университета Узбекистана имени Мирзо Улугбека
доцент кафедры Информационных систем и технологий
abdumanaparabdukarimov @jbnuu.uz*

Abstract: To “invent” new methods for solving artificial intelligence problems, the article proposes a method based on an algorithm for calculating estimates. Since among the methods under consideration, the potential of algorithms for calculating estimates is enormous, since it contains the theoretical foundations for reducing the complexity of data processing on large datasets.

Keywords: pattern recognition, estimation calculations, proximity function, support set;

1. ВВЕДЕНИЕ

Искусственный интеллект (ИИ) и машинное обучение (МО) в последнее время очень успешно применяются во многих практических приложениях (например, в распознавании речи, распознавании лиц, автономном вождении, рекомендательных системах, классификации изображений, обработке естественного языка, автоматизированной диагностике...), особенно когда компоненты этих практических проблем могут быть сформулированы как проблемы классификации данных.

Подходы к глубокому обучению, в том числе более сложные архитектуры обучения с подкреплением, превосходят возможности человека во многих областях [1-4]. Однако остаётся нерешенной одна из исторических проблем искусственного интеллекта: каковы подходящие представления знания, которые демонстрируют достоверность и какие механизмы рассуждений предлагают основу для передачи вычисляемого вывода в терминах этой модели распознавания? Реальность практического применения ИИ и МО в таких областях как медицина показывает неспособность систем глубокого обучения эффективно взаимодействовать со своими пользователями. Острая необходимость сделать результаты и машинные решения прозрачными, понятными и объяснимыми [5], [6], [7] остается до сих пор проблемой. Большим преимуществом таких систем будет не только объяснимость, но и более глубокое понимание и воспроизводимость [8]. Прежде всего, это увеличило бы доверие,

которое является обязательными в критических случаях (медицина, чрезвычайные ситуации любой причины) с точки зрения безопасности.

В этой связи следует напомнить одно из фундаментальных направлений предтечи ИИ,- классических постановок и решений задач распознавания и классификации, которое было основано, развито и продолжает развиваться в Узбекистане [9,10]. Речь идет об алгоритмах вычисления оценок.

2. Мотивация

Задача распознавания (классификации) образов заключается в отнесении объекта к тому или иному классу объектов на основе информации, заданной совокупностью объектов с известной классификацией. Объекты представлены своими признаковыми описаниями - как правило, векторами или матрицами чисел; природа объектов может быть самой разной (предмет, состояние, ситуация, процесс и т.д.). Характерной чертой задачи распознавания образов является то, что решение о классификации объекта необходимо принять на основе неформализованной, неполной, косвенной, разнородной, иногда противоречивой информации.

Сегодня, в эпоху информационных технологий, задачи распознавания образов успешно решаются в самых различных областях человеческой деятельности - в медицине, экологии, социологии, геологии, в технике, в военных разработках, криминалистике, управлении, и т.д. К настоящему времени создано и исследовано большое количество разнообразных методов и подходов к решению задач распознавания и классификации..

Можно выделить пять основных типов алгоритмов распознавания:

- 1) алгоритмы, основанные на принципе разделения;
- 2) статистические алгоритмы;
- 3) алгоритмы, основанные на принципе потенциалов;
- 4) алгоритмы, основанные на исчислении высказываний;
- 5) алгоритмы, основанные на вычислении оценок;

Алгоритмы первого типа основаны на построении в признаковом пространстве, соответствующем числовым описаниям объектов, гиперплоскости (или более сложные поверхности), разделяющей объекты разных классов. Эти алгоритмы различаются типами разделяющих поверхностей и методами их построения.

Статистические алгоритмы принимают решение о классификации объекта на основе тех или иных принципов математической статистики.

Как правило, используется информация о вероятностных характеристиках классов, например, соответствующие функции распределения.

В алгоритмах третьего типа для определения меры сходства объектов используется функция близости, значение которой пропорционально

произведению "масс" объектов (определяемых, например, соответственно степени их представительности), и обратно пропорционально расстоянию между их описаниями в признаковом пространстве.

В алгоритмах, основанных на исчислении высказываний, объекты описываются логическими переменными, а классы объектов - булевыми соотношениями между этими переменными. Классификация объекта сводится к проверке для его описания булевых условий, описывающих классы.

Для решения большого количества задач распознавания образов успешно использовалась предложенная Ю.И. Журавлёвым модель алгоритмов распознавания,

основанных на вычислении оценок (модель АВО). Модель описывает вычислительную структуру алгоритма распознавания, работающего с одномерными признаковыми описаниями объектов (числовыми векторами), и параметрами, которые необходимо задать для определения конкретного алгоритма в модели.

Алгоритм АВО классифицирует объект в два этапа. На первом этапе строится вектор оценок объекта по заданным классам; на втором этапе на основе этого вектора принимается решение о принадлежности объекта к тому или иному классу. Обычно объект вносится в класс, по которому получена максимальная оценка. Оценка объекта по классу вычисляется на основе последовательного сравнения и вычисления меры сходства признакового описания объекта с признаковыми описаниями объектов обучающей выборки, принадлежащих этому классу. Метод вычисления меры сходства между классифицируемым объектом и прецедентом (эталоном) класса основан на сравнении значений различных комбинаций признаков двух объектов или, другими словами, на сравнении различных фрагментов их признаковых описаний. Целью настоящей статьи является изложение теории АВО для целей его использования в современной методологии искусственного интеллекта.

3.Метод

Модель АВО оказалась полезной не только для решения прикладных задач, но также и для теории распознавания образов, где на её примере было предпринято первое глубокое исследование возможностей некорректных (эвристических) алгоритмов обработки данных.

Одной из важных задач, связанных с практическим использованием модели АВО, является задача уменьшения вычислительной сложности алгоритмов для различных типов параметров модели. Алгоритмы с практически приемлемой вычислительной сложностью строятся на основе эффективных

формул вычисления оценок, моделирующих работу алгоритма - формул вычисления оценок близости распознаваемых объектов и прецедентов. Параметрами АВО, существенно влияющими на сложность формул вычисления оценок, являются система опорных множеств и вид функции близости. Система опорных множеств представляет собой набор подмножеств признаков, по которым распознающий алгоритм производит сравнение описаний объектов; функция близости определяет, будут ли сравниваемые объекты считаться "близкими" или нет. К настоящему времени довольно полно исследованы задачи, связанные с получением эффективных формул вычисления оценок для случая, когда объекты в задаче описываются векторами признаков, а опорные множества представляют части этих описаний. После построения эффективных формул вычисления оценок может быть решена задача выбора в модели алгоритма, экстремального по функционалу качества классификации..

Класс алгоритмов вычисления оценок (АВО), предложенный Ю.И.Журавлевым [9], доводит идею использования совокупностей сочетания признаков до логического конца: поскольку не всегда известно, какие именно сочетания признаков информативны в наибольшей степени, то в АВО степень похожести объектов вычисляется в процессе сопоставления всех возможных сочетаний признаков, входящих в их описание.

Приводимое ниже упрощенное описание метода включает в себя только элементы, предназначенные для решения новых задач.

Пусть задана обучающая последовательность объектов s_1, s_2, \dots, s_m принадлежащих l непересекающимся классам $k_q (q=1, 2, \dots, l)$, причем первые i объектов – из класса k_1 , следующие t - объектов ($t < m$)- из класса k_2 , и т.д. Пусть пространство объектов S является n -мерным. Это означает что любой объект S есть набор n характеристик, признаков, описывающих объект.

Обозначим признаки, характеризующие объекты S , в виде :

$$S = (p_1, p_2, \dots, p_n)$$

Тогда обучающая последовательность объектов s образует таблицу обучения $T_{n \times m}$. Каждая строка этой таблицы представляет собой один из объектов обучающей последовательности.

Поскольку все объекты из обучающей последовательности относятся к тому или иному классу, можно сказать, что таблица обучения $T_{n \times m}$ разбита на l групп непересекающихся строк.

Перейдем к описанию класса алгоритмов, решающих эту задачу.

Класс алгоритмов, основанных на вычисления оценок, задается посредством описания шести элементов, его определяющих:

1. Система опорных множеств.
2. Функция близости.

3. Вычисления оценок по строкам фиксированного опорного множества.
4. Вычисления оценки для класса по опорному множеству.
5. Оценка для класса по опорному множеству.
6. Решающее правило.

Рассмотрим описание каждого элемента алгоритма в отдельности.

1. Под опорным множествам будем подразумевать некоторый набор номеров столбцов таблицы T_{nml} ; обозначим совокупность всех таких наборов(подмножеств) через Ω . Примерами таких систем могут быть: совокупность всех элементов одинаковой мощности[1], само множество Ω ; совокупность таблиц T_{nml} ; совокупность всех тупиковых тестов таблицы T_{nml} .

2. Ключевым элементом метода вычисления оценок является функция сходства (близости) частей объектов. Из множества P исходных признаков выделим некоторое подмножество $\omega(\omega < p)$. Совокупность значений координат объекта S , соответствующих подмножеству ω , называется ω - частью этого объекта. На множестве – ω частей рассматриваемых объектов определяется бинарное

отношение $r\omega(s,s')$ неразличимости. Искомая функция сходства между частями объектов s и s' задается в виде:

$r\omega(s,s') = \{1, \text{если между } \omega\text{-частями } s \text{ и } s' \text{ имеет место отношение } R(s,s'), 0, \text{в противном случае (1)}$

Таким образом, функция сходства – это характеристическая функция отношения неразличимости.

3. Опорное множество имеет смысл учета степени важности представительности объектов, входящих в обучающую последовательность. Другими словами, пусть априорно задаются числовые коэффициенты $\gamma_1, \gamma_2, \dots, \gamma_m$ характеризующие важность объектов. Тогда по строкам фиксированного опорного множества определяем $\omega\Gamma$ как некоторую заданную функцию от функции близости коэффициентов:

$\omega\Gamma(s,sq) = \gamma_1(sq)r(\omega s, \omega sq)$ если функция близости вычисляется между объектами s, sq по некоторому опорному множеству ω . Таким образом, Γ – это близость по опорному множеству с учетом важности объектов.

4. Вычисление оценки для класса по фиксированному опорному множеству.

Для простоты обозначений рассмотрим оценку для класса K , в которую входят объекты s_1, s_2, \dots, s_n , таблицы T_{nml} . Пусть вычислены величины $\omega\Gamma(s,s_1), \dots, \omega\Gamma(s,s_m)$. Оценкой для класса будем считать

$$\Gamma_q(W) = \sum_{q=1}^m \omega\Gamma(s,s_q) m_q = 1 \quad (2)$$

5. Оценка для класса K_q по всем опорным множеств.

Оценка Γ для класса K по системе опорных множеств означает близость произвольного объекта s к объектам из класса K по всем опорным множествам из системы опорных множеств. Например, в качестве оценки Γ можно взять сумму всех оценок $\Gamma_q(W)$ для каждого опорного множества.

6. Решающее правило.

Пусть по системе опорных множеств и объекта s вычислены оценки $\Gamma_1, \Gamma_2, \dots, \Gamma_l$. Под решающим правилом будем подразумевать правило, которое по оценкам $\Gamma_1, \Gamma_2, \dots, \Gamma_l$ выносит суждение о принадлежности s классам k_1, k_2, \dots, k_l . Например, s относится к классу k , если Γ - наибольшая оценка из $\Gamma_1, \Gamma_2, \dots, \Gamma_l$.

Завершая описание основы алгоритмов распознавания, основанных на вычислении оценок, отметим, что, выбирая конкретную систему опорных множеств, определяя функцию близости, задавая правила вычисления оценок, а так же назначая решающее правило можем получить конкретный алгоритм вычисления оценок. Класс же алгоритмов распознавания, основанных на вычислении оценок, включает в себя всевозможные алгоритмы, которые могут быть построены из рассмотренных шести элементов.

Качество работы алгоритма распознавания будет оцениваться на контрольной или тестовой последовательности, заданной априори помимо обучающей последовательности объектов. Для каждого из объектов контрольной последовательности известен класс, к которому он принадлежит. В частности, контрольная последовательность может совпадать с обучающей последовательностью. В таком случае говорят о скользящем контроле.

Поиск экстремального алгоритма числа объектов обучения возможен на современных суперкомпьютерах. При этом по заданной таблице обучения и контрольной последовательности находится экстремальный по качеству алгоритм, т.е. происходит подстройка подмножества алгоритмов распознавания, основанных на вычислении оценок под материал обучения и контроля. Очевидно, что отыскание экстремума в многомерной области практически невозможно осуществить прямым перебором, поэтому экстремальное значение функционала получают под контролем оценки качество решающего правило распознавания.

4. Выводы

Сегодня работа по изобретению новых методов решения задач ИИ,- по сути решение проблем оценки близости и объяснимости моделей до сих пор остается актуальной, хотя алгоритмической, программной, и технической базой стали нейронные сети, новые языки программирования и новые подходы. Достаточно посмотреть на крупномасштабные наборы данных, доступных для обучения моделей машинного обучения, на развитие глубокого обучения

(DeepLearning, - CNN, RNN, LSTM, BERT, Transfer Learning и т.д.), других подходов к искусственному интеллекту, которые позволяют комплексно использовать разнородные данные и получать хорошие результаты в различных областях (анализ изображений, машинный перевод, распознавание текстов и речи и т.п.). Однако работа по «изобретению» новых методов остается актуальной. И в этом потенциал алгоритмов вычисления оценок огромен, поскольку в нем заложены теоретические основы снижения сложности дата процессинга на больших датасетах..

Литература:

1. Matej Moravck, Martin Schmid, Neil Burch, Viliam Lisy, Dustin Morrill, Nolan Bard, Trevor Davis, Kevin Waugh, Michael Johanson, and Michael Bowling. Deepstack: Expert-level artificial intelligence in heads-up no-limit poker. Science, 2017.
2. Yaniv Taigman, Ming Yang, Marc' Aurelio Ranzato, and Lior Wolf. Deepface: Closing the gap to human-level performance in face verification. pages 1701 { 1708, 2014.
3. Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Andrei A. Rusu, Joel Veness, Marc G. Bellemare, Alex Graves, Martin Riedmiller, Andreas K. Fidjeland, Georg Ostrovski, Stig Petersen, Charles Beattie, Amir Sadik, Ioannis Antonoglou, Helen King, Dhharshan Kumaran, Daan Wierstra, Shane Legg, and Demis Hassabis. Human-level control through deep reinforcement learning. Nature, 518(7540):529{533, 2015.
4. Andre Esteva, Brett Kuprel, Roberto A. Novoa, Justin Ko, Susan M. Swetter, Helen M. Blau, and Sebastian Thrun. Dermatologist-level classification of skin cancer with deep neural networks. Nature, 542(7639):115{118, 2017.
5. Andreas Holzinger, Markus Plass, Katharina Holzinger, Gloria Cerasela Crisan, Camelia-M. Pintea, and Vasile Palade. Towards interactive machine learning (iml): Applying ant colony algorithms to solve the traveling salesman problem with the human-in-the-loop approach. In Springer Lecture Notes in Computer Science LNCS 9817, pages 81{95. Springer, Heidelberg, Berlin, New York, 2016.
6. Andreas Holzinger, Bernd Malle, Peter Kieseberg, Peter M. Roth, Heimo Mller, Robert Reihs, and Kurt Zatloukal. Towards the augmented pathologist: Challenges of explainable-ai in digital pathology. arXiv:1712.06657, 2017.
7. Andreas Holzinger, Markus Plass, Katharina Holzinger, Gloria Cerasela Crisan, Camelia-M. Pintea, and Vasile Palade. A glass-box interactive machine learning approach for solving np-hard problems with the human-in-the-loop. arXiv:1708.01104, 2017.

8. 17. Andreas Holzinger, Chris Biemann, Constantinos S. Pattichis, and Douglas B. Kell. What do we need to build explainable ai systems for the medical domain? arXiv:1712.09923, 2017
9. Juravlev Y.I. , Kamilov M.M., Tulaganov Sh. E. IMAGE RECOGNITION AND CLASSIFICATION ALGORITHMS . Tashkent,1974.
10. Абдукаримов А. Алгоритм построения решающего правила с малым числом опорных подмножеств.- Известия АН УзССР, №2, 1989, с. 16-19

