

# ИСПОЛЬЗОВАНИЕ БАЙЕСОВСКОГО ПОДХОДА В МАТЕМАТИЧЕСКОМ МОДЕЛИРОВАНИИ АЛГОРИТМОВ ПРОЦЕССА МЫШЛЕНИЯ

Пен О.В., Левченко С.И.

научный руководитель канд. техн. наук Сергиенко Р.Б.

*Сибирский Федеральный Университет*

В настоящий момент существует потребность в разработке искусственного интеллекта (ИИ), обладающего чертами, присущими человеческому разуму для решения плохо формализуемых прикладных задач. Однако прежде чем приступить к разработке программного обеспечения, имитирующего работу мозга, необходимо понять алгоритмы его работы, создать математическую модель процесса мышления.

При создании алгоритмов имитации процесса мышления необходимо учитывать разобщенность и искажения в поступающей информации, равно как и искажения, добавляемые самим объектом. К счастью, теория вероятности позволяет рассчитать возможный выход даже при неполной и неточной информации, а именно на теории вероятности основан байесовский подход. О его основных принципах будет рассказано ниже.

Байесово правило позволяет нам высчитать вероятность того или иного события в зависимости от неких факторов, а также их возможных комбинаций и взаимозависимости. Одним из главных преимуществ байесовской модели является возможность оптимизации данной комбинации. Оптимальная байесовская модель выдает субъективно наилучшее решение проблемы из возможных – а значит, наиболее рациональное. Все возможные варианты отклонения от наиболее рационального решения легко моделируются путем рекомбинации факторов (см. далее). Это также является существенным плюсом, так как позволяет четко проследить, какое влияние оказывает тот или иной фактор на принимаемое решение, когда погрешность становится слишком велика. Данный факт может использоваться для устранения так называемых «пробок» (bottle neck). Так, предположим, человек и наша условная «модель» решают одну и ту же задачу с одинаковым набором начальных данных, т.н. «предположений». В случае, если эффективность модели превышает эффективность человека, очевидно, что мозг не использует всю доступную информацию или же комбинирует ее недостаточно оптимальным образом. Дальнейшие эксперименты позволяют выявить, какой фактор является наиболее частой причиной ошибок – той самой «пробкой». В таком случае можно разработать новую модель, включающую в себя влияние «пробки». Таким образом мы можем анализировать эффективность работы модели под влиянием изначальных «предположений», а также способа их комбинации. Данная концепция крайне важна в дальнейшем построении байесовских сетей, а также работе непараметрического байесовского классификатора.

Байесовские сети позволяют получить графическое представление о факторизации объединенного распределения. Каждый узел представляет собой переменную, каждая грань – взаимозависимость между переменными, а также демонстрируют принцип наследственности. Так, по ним можно проследить, как изменения в «родительской» переменной меняют значения всех «дочерних» переменных. Рассмотрим один из примеров данного распределения со следующими начальными «предположениями» (формула 1).

$$p(A, B, C, D, E, F, G) = p(A)p(B)p(C|A)p(D|A, B) \\ p(E|B)p(F|C)p(G|D, E) \quad (1)$$

Что отвечает данной схеме Байесовской сети (рис. 1).




Рис. 1 Байесовская сеть, представляющая объединенное распределение переменных A, B, C, D, E, F, G

Здесь в узлах сети указаны значения переменных, стрелка показывает, на какие еще переменные будет влиять значение этого узла. Параметры байесовской сети являются параметрами вероятностного распределения значения. Исходя из закона распределения, можно найти весовые коэффициенты узла. Основное преимущество байесовского подхода заключается в том, что для адекватного расчета весовых коэффициентов нам не нужно заранее знать распределение – мы можем вывести его, используя классический алгоритм работы непараметрического байесовского классификатора.

По данной несортированной выборке человек способен самообучаться, заменять прошлые «предположения» на более точные и совершенные, и этот процесс легко моделируется математически. Предположим, мы наблюдаем некое явление (пусть оно будет обозначено через переменные F и G) и хотим на основании полученных сведений улучшить исходные «предположения» (переменные A, B, C, D, E). Согласно байесовскому правилу, их зависимость будет представлена следующим образом (формула 2)

$$p(A, B, C, D, E|F, G) = \frac{p(F, G|A, B, C, D, E)p(A, B, C, D, E)}{p(F, G)} \quad (2)$$

Где  $p(A, B, C, D, E)$  – априорная вероятность,  $p(A, B, C, D, E|F, G)$  – апостериорная,  $p(F, G|A, B, C, D, E)$  – правдоподобность вывода на основе совокупности наблюдаемых явлений и известных данных,  $p(F, G)$  – наблюдаемое явление. В случае, если мы хотим рассмотреть влияние переменных F и G, лишь на некоторые признаки, к примеру, на A и B, можно воспользоваться дополнительной формулой (формула 3)

$$p(A, B|F, G) = \iiint p(A, B, C, D, E|F, G) dC dD dE \quad (3)$$

Комбинируя таким образом факторы и рассматривая их влияние друг на друга, мы можем более точно установить причинно-следственные связи, что является важной составляющей человеческого мышления. Определив же вероятность того или иного события и зная, хотя бы примерно, его распределение, нетрудно произвести классификацию объекта и его распределение по установленным классам, что человеческий мозг делает постоянно. Нахождение логических взаимосвязей и соотношение поступающей информации с прежним опытом является неотъемлемой частью процесса мышления. Байесовский подход помогает существенно облегчить структуризацию данного процесса при разработке алгоритма, имитирующего данный аспект работы человеческого мозга.