




Bayesian Additive Regression Trees


Максим Николаев
СПбГУ, 19 ноября 2025

Деревья решений




Ансамбль деревьев

1 дерево глубины 3



100 деревьев глубины 3



Bayesian Additive Regression Trees

BART, Bayesian Additive Regression Trees – является непараметрическим методом, который объединяет в себе лучшие черты древесных ансамблей и байесовского подхода: выразительность и оценку неопределенности.

Если кратко, то идея очень простая:

1. Задаем априорное распределение на случайному лесу, то есть распределение, из которого можно генерировать леса, совместимые с форматом наших данных
2. По имеющейся обучающей выборке считаем апостериорное распределение, из которого можно генерировать леса, описывающие наши данные
3. Прогоняем интересующие нас данные через апостериорные леса, получая апостериорное распределение предсказаний

Более формально

$$Y_i = f(X_i, Z) + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma^2),$$

$$f(x, z) = g(x, z, T_1, M_1) + g(x, z, T_2, M_2) + \dots + g(x, z, T_m, M_m).$$

Здесь g это функция, которая выдает значение дерева на данных, T_h описывает структуру дерева h , а $M_h = (\mu_{h1}, \dots, \mu_{hb_h})$ описывает оценки средних в листьях дерева.

Если мы считаем t фиксированным, то для проведения байесовского вывода нам нужно задать:

- априорное распределение на T
- априорное распределение на M
- априорное распределение на σ^2

Априорное распределение на T

Априорное распределение на одном дереве состоит из трех частей:

- Вероятность того, что вершина на глубине d не является **листом**. Обычно берут в виде
$$\frac{\alpha}{(1+d)^\beta} \cdot [\text{мы можем разделиться на две вершины}], \alpha \in (0, 1), \beta > 0$$
- **Распределение на множестве переменных**, по которому будет проводиться разделение в данной вершине. Обычно берут равномерное.
- **Распределение значения переменной**, в котором будет проводиться разделение. Обычно берут равномерное на значениях из данных

Априорное распределение на M

Для того, чтобы задать априорное распределение на M , делают следующее:

1. Стандартизируют переменную Y , чтобы ее значения были между -0.5 и 0.5
2. Задают априорное распределение на $\mu_i \sim \mathcal{N}\left(0, \left(\frac{0.5}{k\sqrt{m}}\right)^2\right)$. В этом случае сумма t

независимых деревьев будет иметь распределение $\mathcal{N}\left(0, \left(\frac{0.5}{k}\right)^2\right)$, которое накрывает интервал $(-0.5, 0.5)$ с большой вероятностью, которую можно выбирать за счет k

Априорное распределение на σ

Для того, чтобы задать априорное распределение на σ , делают следующее:

1. Считают $RSE = \sqrt{\frac{1}{n} \sum_i e_i^2}$ линейной регрессии (e_i это остатки)
2. Задают на σ распределение Inv-Gamma так, чтобы оно было меньше RSE с большой вероятностью, например, 90%.

Аппроксимация апостериорного распределения

Как это часто бывает со сложными моделями, получить апостериорное распределение аналитически невозможно.

Вместо этого используют метод **Монте-Карло на марковских цепях** (МСМС), чтобы сгенерировать достаточно большую выборку из апостериорного распределения. Все необходимые оценки делаются по этой выборке.

Markov Chain Monte Carlo

МСМС

Мы не будем особо погружаться в теорию марковских цепей, и просто рассмотрим следующую структуру:

- Есть некоторое множество состояний \mathbb{X} ,
- Для каждого состояния $x \in \mathbb{X}$ есть **распределение перехода** $T(x'|x)$ на \mathbb{X} .

Имея такую структуру мы можем начать **блуждать** по \mathbb{X} : стартуем в точке x_0 , потом генерируем x_1 из $T(\cdot | x_0)$, потом генерируем x_2 из $T(\cdot | x_1)$ и так далее: x_{i+1} генерируется из $T(\cdot | x_i)$.

MCMC

Последовательность x_0, x_1, x_2, \dots называется **траекторией**. Если семейство распределений переходов обладают некоторыми специальными свойствами, то

1. Точки траектории, находящиеся далеко друг от друга, будут практически независимы.
2. Эти далекие точки будут иметь некоторое фиксированное распределение $\pi(x)$, называющееся **стационарным**.

МСМС

Последовательность x_0, x_1, x_2, \dots называется **траекторией**. Если семейство распределений переходов обладают некоторыми специальными свойствами, то

1. Точки траектории, находящиеся далеко друг от друга, будут практически независимы.
2. Эти далекие точки будут иметь некоторое фиксированное распределение $\pi(x)$, называющееся **стационарным**.

Цель МСМС — выбрать такие T , чтобы стационарное распределение было равно нужному нам распределению $p(x)$, и чтобы точки траекторий становились достаточно независимыми достаточно быстро.

Если это выполнено, то мы можем сгенерировать выборку из $p(x)$, сгенерировав длинную траекторию и потом выбрав достаточно далеко отстоящие точки.

Алгоритм Метрополиса—Гастингса

Имеются достаточные условия на T для существования единственного стационарного распределения, равного $p(x)$:

1. **Принцип детального равновесия:** $p(x)T(x'|x) = p(x')T(x|x')$
2. $T(x'|x) > 0$ для всех x' и x

Заметим, что из первого условия следует, что

$$\frac{T(x'|x)}{T(x|x')} = \frac{p(x')}{p(x)}.$$

Представим $T(x'|x)$ в виде $T(x'|x) = g(x'|x)A(x'|x)$, где $g(x'|x)$ это распределение, которое предлагает кандидатуру для очередного перехода, а $A(x'|x)$ это вероятность, с которой такой переход одобряется. Если переход не одобряется, то стоим на месте.

Алгоритм Метрополиса—Гастингса

$$\frac{T(x'|x)}{T(x|x')} = \frac{p(x')}{p(x)}.$$

Представим $T(x'|x)$ в виде $T(x'|x) = g(x'|x)A(x'|x)$, где $g(x'|x)$ это распределение, которое предлагает кандидатуру для очередного перехода, а $A(x'|x)$ это вероятность, с которой такой переход одобряется. Если переход не одобряется, то стоим на месте.

Получаем

$$\frac{A(x'|x)}{A(x|x')} = \frac{p(x')}{p(x)} \frac{g(x|x')}{g(x'|x)}.$$

Заметим, что если взять $A(x'|x) = \min\left(1, \frac{p(x')}{p(x)} \frac{g(x|x')}{g(x'|x)}\right)$, то все получится!

Алгоритм Метрополиса—Гастингса

$$\frac{T(x'|x)}{T(x|x')} = \frac{p(x')}{p(x)}.$$

Представим $T(x'|x)$ в виде $T(x'|x) = g(x'|x)A(x'|x)$, где $g(x'|x)$ это распределение, которое предлагает кандидатуру для очередного перехода, а $A(x'|x)$ это вероятность, с которой такой переход одобряется. Если переход не одобряется, то стоим на месте.

Получаем

$$\frac{A(x'|x)}{A(x|x')} = \frac{p(x')}{p(x)} \frac{g(x|x')}{g(x'|x)}.$$

Заметим, что если взять $A(x'|x) = \min\left(1, \frac{p(x')}{p(x)} \frac{g(x|x')}{g(x'|x)}\right)$, то все получится!

Нам достаточно знать $p(x)$ с точностью до множителя!

Алгоритм Метрополиса—Гастингса

Алгоритм:

1. Выбираем x_0
2. Пока не надоест:
 1. Генерируем x' из $g(\cdot | x_i)$
 2. Считаем $A = \min\left(1, \frac{p(x')}{p(x_i)} \frac{g(x_i|x')}{g(x'|x_i)}\right)$
 3. С вероятностью A берем $x_{i+1} = x'$, а с вероятностью $1 - A$ берем $x_{i+1} = x_i$.

Если $g(x|x') = g(x'|x)$, то A считать еще проще: $A = \min\left(1, \frac{p(x')}{p(x)}\right)$

Сэмплирование по Гиббсу

В многомерных пространствах сложно предлагать хорошие новые состояния для всего вектора $x = (x_1, \dots, x_n)$ сразу.

Решение: итеративно обновлять по одной переменной за раз, фиксируя все остальные. Это частный случай Метрополиса—Гастингса, в котором в качестве g выступает распределение $p(\cdot | x_{-i})$, где i может быть случайным, а может последовательно обходить все координаты. Распределение перехода не зависит от текущего значения x_i , и нетрудно показать, что в этом случае A всегда будет равно 1.

Когда применяется: совместное распределение случайных величин неизвестно явно, но условные вероятности известны и из них легко генерировать.

Сэмплирование для BART

Сэмплирование из n деревьев на верхнем уровне является сэмплированием по Гиббсу: мы проходим по деревьям по очереди и сэмплируем дерево из условного распределения. Это сэмплирование можно проводить разными способами, например, с помощью еще одного Метрополиса—Гастингса.

Algorithm 1 Bayesian backfitting MCMC for posterior inference in BART

- 1: Inputs: Training data (\mathbf{X}, Y) , BART hyperparameters $(\nu, q, k, m, \alpha_s, \beta_s)$
- 2: Initialization: For all j , set $\mathcal{T}_j^{(0)} = \{\mathbf{T}_j^{(0)} = \{\epsilon\}, \boldsymbol{\tau}_j^{(0)} = \boldsymbol{\kappa}_j^{(0)} = \emptyset\}$ and sample $\boldsymbol{\mu}_j^{(0)}$
- 3: **for** $i = 1 : \text{max_iter}$ **do**
- 4: Sample $\sigma^{2(i)} | \mathcal{T}_{1:m}^{(i-1)}, \boldsymbol{\mu}_{1:m}^{(i-1)}$ ▷ sample from inverse gamma distribution
- 5: **for** $j = 1 : m$ **do**
- 6: Compute residual $R_j^{(i)}$
- 7: Sample $\mathcal{T}_j^{(i)} | R_j^{(i)}, \sigma^{2(i)}, \mathcal{T}_j^{(i-1)}$ ▷ using CGM, GrowPrune or PG
- 8: Sample $\boldsymbol{\mu}_j^{(i)} | R_j^{(i)}, \sigma^{2(i)}, \mathcal{T}_j^{(i)}$ ▷ sample from Gaussian distribution

$$R_j = Y - \sum_{j'=1, j' \neq j}^m g(\mathbf{X}; \mathcal{T}_{j'}, \boldsymbol{\mu}_{j'}).$$

Направления для исследований

1. Другие структуры деревьев. Например, интересно посмотреть, что будет в случае таблиц решений — полных двоичных деревьев, у которых на каждом уровне стоит один и тот же предикат
2. Асимптотическое поведение. При возрастании числа деревьев BART сходится к гауссовскому процессу.
3. Эффективные алгоритмы для сэмплирования.