Обучение с подкреплением: многорукие бандиты

Сергей Николенко

Казанский Федеральный Университет, 2014

Outline

Постановка задачи

- До сих пор задача ставилась так: есть набор «правильных ответов», и нужно его продолжить на всё пространство (supervised learning), или есть набор тестовых примеров без дополнительной информации, и нужно понять его структуру (unsupervised learning).
- Как работает обучение в реальной жизни? Мы далеко не всегда знаем набор правильных ответов, мы просто делаем то или иное действие и получаем результат.

Постановка задачи

- Отсюда и обучение с подкреплением (reinforcement learning).
- Агент взаимодействует с окружающей средой, предпринимая действия; окружающая среда его поощряет за эти действия, а агент продолжает их предпринимать.

Постановка задачи — формально

- На каждом шаге агент может находиться в состоянии $s \in S$.
- На каждом шаге агент выбирает из имеющегося набора действий некоторое действие $a \in A$.
- Окружающая среда сообщает агенту, какую награду r он за это получил и в каком состоянии s' после этого оказался.

Пример

- Диалог:

Среда: Агент, ты в состоянии 1; есть 5 возможных действий.
Агент: Делаю действие 2.
Среда: Даю тебе 2 единицы за это. Попал в состояние 5, есть 2 возможных действия.
Агент: Делаю действие 1.
Среда: Даю тебе за это -5 единиц. Попал в состояние 1, есть 5 возможных действий.
Агент: Делаю действие 4.
Среда: Даю тебе 14 единиц за это. Попал в состояние 3, есть 3 возможных действия...

- В этом примере агент успел вернуться в состояние 1 и исследовать ранее не пробовавшуюся опцию 4 (получив за это существенную награду).

Exploitation vs. exploration

- Каждый алгоритм должен и изучать окружающую среду, и пользоваться своими знаниями, чтобы максимизировать прибыль.
- Вопрос — как достичь оптимального соотношения? Та или иная стратегия может быть хороша, но вдруг она не оптимальная?
- Этот вопрос всегда присутствует в обучении с подкреплением.

Пример

- Пример: крестики-нолики.
- Как научить машину играть и *выигрывать* в крестики-нолики?
- Вариант: генетический алгоритм, пусть играют с противником, кто выиграл, тот выживает и даёт потомство.
- Но это очень медленно, не учитывается информация о собственно ходе игры, о том, какие ходы привели к победе; как это сделать?

Пример

- Состояния – позиции на доске.
- Для каждого состояния введём функцию $V(s)$ (value function).
- Подкрепление приходит только в самом конце, когда мы выиграли или проиграли; как его распространить на промежуточные позиции?

Пример

- Можно просто пропагировать обратно: если мы попадали из s в s', апдейтим

$$V(s) := V(s) + \alpha \left[V(s') - V(s) \right].$$

- Это называется TD-обучение (temporal difference learning), и оно очень хорошо работает на практике.

Агенты с одним состоянием

- Формально всё то же самое, но $|S| = 1$, т.е. состояние агента не меняется. У него фиксированный набор действий A и возможность выбора из этого набора действий.
- Модель: агент в комнате с несколькими игровыми автоматами. У каждого автомата своё ожидание выигрыша. Нужно за ограниченное количество попыток выбрать лучший автомат.

Жадный алгоритм

- Всегда выбирать стратегию, максимизирующую прибыль; прибыль оцениваем как среднее вознаграждение:

$$Q_t(a) = \frac{r_1 + r_2 + \ldots + r_{k_a}}{k_a}.$$

- Что не так с таким алгоритмом?

Жадный алгоритм

- Оптимум легко проглядеть, если на начальной выборке не повезёт (что вполне возможно).
- Поэтому полезная эвристика — *оптимизм при неопределённости*. То есть выбирать жадно, но при этом прибыль ожидается весьма оптимистично, и нужны серьёзные отрицательные свидетельства, чтобы отклонить стратегию.

Случайные стратегии

- Стратегия: выбрать действие с наилучшей ожидаемой прибылью с вероятностью $1 - \epsilon$, а с вероятностью ϵ выбрать случайное действие.
- Обычно начинают с маленьких p, затем увеличивают.
- Но алгоритм не различает хорошую альтернативу от бесполезной.

Случайные стратегии

- Исследование по Больцману (Boltzmann exploration):

$$\pi_t(a) = \frac{e^{Q_t(a)/T}}{\sum_{a'} e^{Q_t(a')/T}},$$

  где ER — ожидаемая прибыль, T — *температура*.
- Тоже обычно температура понижается со временем.

Алгоритм линейного вознаграждения–бездействия

- *Алгоритм линейного вознаграждения–бездействия* (linear reward-inaction) добавляет линейно к вероятности действия a_i, если оно успешно (в бинарном случае):

$$p_i := p_i + \alpha(1 - p_i),$$

$$p_j := p_j - \alpha p_j, \quad j \neq i,$$

а если оно безуспешно, то вероятности сохраняются.

Алгоритм линейного вознаграждения–бездействия

- Алгоритм сходится с вероятностью 1 к вектору из одной единички и остальных нулей.
- Не всегда сходится к оптимальной стратегии; но вероятность ошибиться можно сделать сколь угодно малой, уменьшая α.
- Есть, соответственно, алгоритм линейного вознаграждения–наказания (linear reward-penalty): тот же самый апдейт, но всегда, даже при безуспешных действиях (тогда вознаграждаем другую ручку).

Интервальные оценки

- Один из способов применить оптимистично–жадный метод.
- Для каждого действия мы храним статистику n и w, а потом вычисляем доверительный интервал для вероятности успеха (с границей $1 - \alpha$) и для выбора стратегии используем верхнюю границу этого интервала.

Интервальные оценки

- Пример: испытания Бернулли (монетка, например). Тогда с вероятностью .95 среднее лежит в интервале

$$\left(\bar{x} - 1.96\frac{s}{\sqrt{n}}, \bar{x} + 1.96\frac{s}{\sqrt{n}}\right),$$

  где 1.96 берётся из распределения Стьюдента, n — количество испытаний, $s = \sqrt{\frac{\sum(x-\bar{x})^2}{n-1}}$.
- Отличный метод, если вероятностные предположения соответствуют действительности (часто непонятно).

Правило инкрементального обновления

- Как пересчитывать $Q_t(a) = \frac{r_1+\ldots+r_{k_a}}{k_a}$ при поступлении новой информации?
- Довольно просто:

$$Q_{k+1} = \frac{1}{k+1}\sum_{i=1}^{k+1} r_i = \frac{1}{k+1}\left[r_{k+1} + \sum_{i=1}^{k} r_i\right] =$$
$$= \frac{1}{k+1}\left(r_{k+1} + kQ_k\right) = Q_k + \frac{1}{k+1}\left(r_{k+1} - Q_k\right).$$

Правило инкрементального обновления

- Это частный случай общего правила – сдвигаем оценку так, чтобы уменьшалась ошибка:

  НоваяОценка := СтараяОценка+Шаг [Цель − СтараяОценка] .

- Заметим, что шаг у нас тут непостоянный: $\alpha_k(a) = \frac{1}{k_a}$.
- Изменяя последовательность шагов, можно добиться других эффектов.

Нестационарная задача

- Часто бывает, что выплаты из разных бандитов на самом деле нестационарны, т.е. меняются со временем.
- В такой ситуации имеет смысл давать большие веса недавней информации и маленькие веса – давней.
- Пример: у правила апдейта

$$Q_{k+1} = Q_k + \alpha\left[r_{k+1} - Q_k\right]$$

с постоянным α фактически веса затухают экспоненциально:

$$Q_k = Q_{k-1} + \alpha\left[r_k - Q_{k-1}\right] = \alpha r_k + (1-\alpha)Q_{k-1} =$$

$$= \alpha r_k + (1-\alpha)\alpha r_{k-1} + (1-\alpha)^2 Q_{k-2} = (1-\alpha)^k Q_0 + \sum_{i=1}^{k} \alpha(1-\alpha)^{k-i} r_i.$$

Нестационарная задача

- Такое правило апдейта не обязательно сходится, но это и хорошо – мы хотим следовать за целью.
- Общий результат – правило апдейта сходится, если последовательность весов удовлетворяет

$$\sum_{k=1}^{\infty} \alpha_k(a) = \infty \quad \text{и} \quad \sum_{k=1}^{\infty} \alpha_k^2(a) < \infty.$$

- Например, для $\alpha_k(a) = \frac{1}{k_a}$ явно сходится.

Оптимизм

- Можно ускорить и упростить поиск, если начать с оптимистичных значений средних.
- Давайте выставим $Q_0(a)$ такими большими, что любое реальное вознаграждение будет «разочаровывать», но не слишком большими – нам нужно, чтобы достаточно быстро Q_0 усреднилось с реальными r_i.
- Тогда даже тривиальная жадная стратегия достаточно быстро обучится.

Сравнение подкреплений

- Однако интуиция тут в том, что мы ищем «большие» вознаграждения. А что такое «большие»?
- Можно сравнивать со средним вознаграждением по всем ручкам; это называется *метод сравнения подкреплений* (reinforcement comparison).
- В таких методах обычно нет action values Q_k, есть предпочтения $p_t(a)$; вероятности можно получить, например, по Больцману:

$$\pi_t(a) = \frac{e^{p_t(a)}}{\sum_{a'} e^{p_t(a')}}.$$

Сравнение подкреплений

- И на каждом шаге мы обновляем среднее вознаграждение и предпочтения:

$$\begin{aligned}\bar{r}_{t+1} &= \bar{r}_t + \alpha\left(r_t - \bar{r}_t\right), \\ p_{t+1}(a) &= p_t(a_t) + \beta\left(r_t - \bar{r}_t\right).\end{aligned}$$

Методы погони

- Методы погони (pursuit methods) хранят и оценки ожидаемой выплаты, и предпочтения действий, и предпочтения «гонятся» за оценками.
- Например, $\pi_t(a)$ – вероятность выбрать a во время t; после шага t мы ищем жадную стратегию

$$a^*_{t+1} = \arg\max_a Q_{t+1}(a)$$

и подправляем π в сторону жадной стратегии:

$$\pi_{t+1}(a^*_{t+1}) = \pi_t(a^*_{t+1}) + \beta \left[1 - \pi_t(a^*_{t+1})\right],$$
$$\pi_{t+1}(a) = \pi_t(a) + \beta \left[0 - \pi_t(a)\right].$$

Outline

Динамическое программирование

- Предположим, что агент действует на протяжении h шагов.
- Используем байесовский подход для определения оптимальной стратегии.
- Начинаем со случайных параметров $\{p_i\}$, например, равномерно распределённых, и вычисляем отображение из *belief states* (состояния после нескольких раундов обучения) в действия.
- Состояние выражается как $\mathcal{S} = \{n_1, w_1, \ldots, n_k, w_k\}$, где каждого бандита i запустили n_i раз и получили w_i единичек (считаем, что результат бинарный).

Динамическое программирование

- $V^*(\mathcal{S})$ — ожидаемый оставшийся выигрыш.
- Рекурсивно: если $\sum_{i=1}^{k} n_i = h$, то больше нечего делать, и $V^*(\mathcal{S}) = 0$.
- Если знаем V^* для всех состояний, когда осталось t запусков, сможем пересчитать и для $t+1$:

$$V^*(n_1, w_1, \ldots, n_k, w_k) =$$
$$= \max_i \left(\rho_i(1 + V^*(\ldots, n_i + 1, w_i + 1, \ldots)) + \right.$$
$$\left. (1 - \rho_i) V^*(\ldots, n_i + 1, w_i, \ldots)\right),$$

где ρ_i — апостериорные вероятности того, что действие i оправдается (если изначально p_i равномерно распределены, то $\rho_i = \frac{w_i+1}{n_i+2}$).

Байесовский подход к многоруким бандитам

- А теперь давайте посмотрим на многоруких бандитов в общем вероятностном виде.
- Для простоты – бинарный случай, выплата либо 1, либо 0.

Байесовский подход к многоруким бандитам

- Пусть во время t у нас состояние $\boldsymbol{s}_t = (s_{1t}, \ldots, s_{Kt})$ для K ручек, и мы хотим дёрнуть такую ручку, чтобы максимизировать общее ожидаемое число успехов.
- Есть функция вознаграждения $R_i(\boldsymbol{s}_t, \boldsymbol{s}_{t+1})$ – награда за дёргание ручки i (a_i), которое переводит состояние $\boldsymbol{s}_t$ в $\boldsymbol{s}_{t+1}$.
- Есть вероятность перехода $p\left(\boldsymbol{s}_{t+1} \mid \boldsymbol{s}_t, a_i\right)$.
- И мы хотим обучить стратегию $\pi(\boldsymbol{s}_t)$, которая возвращает, какую ручку дёргать.

Байесовский подход к многоруким бандитам

- Тогда value function в самом общем виде до горизонта T:

$$V_T(\pi, s_0) = \mathbb{E}\left[R_{\pi(s_0)}(s_0, s_1) + V_{T-1}(\pi, s_1)\right] =$$
$$= \int p(s_1 \mid s_0, \pi(s_0))\left[R_{\pi(s_0)}(s_0, s_1) + V_{T-1}(\pi, s_1)\right] ds_1.$$

- Если всё известно, и T невелико, то можно, опять же, динамическим программированием.
- Но даже подсчитать отдачу от фиксированной стратегии может быть очень дорого, не говоря уж об оптимизации.

Байесовский подход к многоруким бандитам

- Если T большой/неограниченный, логично рассмотреть

$$R = R(0) + \gamma R(1) + \gamma^2 R(2) + \ldots, \quad 0 < \gamma < 1.$$

- Теорема Гиттинса (1979): задачу поиска оптимальной стратегии

$$\pi(\boldsymbol{s}_t) = \arg\max_\pi V(\pi, \boldsymbol{s}_t = (s_{1t}, \ldots, s_{Kt}))$$

можно факторизовать и свести к

$$\pi(\boldsymbol{s}_t) = \arg\max_i \gamma(s_{it}).$$

- $\gamma(s_{it})$ – *индекс Гиттинса*; но его подсчитать тоже обычно трудно; есть приближения.

Оценки на regret

- Другой вариант – давайте рассчитаем приоритет каждой ручке i так, чтобы непосредственно regret ограничить.
- [Auer et al., 2002]: стратегия $\mathrm{UCB1}$. Учитывает неопределённость, «оставшуюся» в той или иной ручке, старается ограничить regret. Если мы из n экспериментов n_i раз дёрнули за i-ю ручку и получили среднюю награду $\hat{\mu}_i$, алгоритм $\mathrm{UCB1}$ присваивает ей приоритет

$$\mathrm{Priority}_i = \hat{\mu}_i + \sqrt{\frac{2 \log n}{n_i}}.$$

Дёргать дальше надо за ручку с наивысшим приоритетом.

Оценки на regret

- При таком подходе субоптимальные ручки будут дёргать $O(\log n)$ раз, и regret будет $O(\log n)$, а меньше и нельзя (но тут константы тоже важны :)).
- $\mathrm{UCB1}$ – хорошая стратегия, но рассчитывает на оценку в худшем случае, может быть неоптимально.

Thank you!

Спасибо за внимание!