

SMART Закупка

2 минуты назад

Оптимизация AI



Большинство проблем бизнеса, с которыми сталкивается современное предприятие, можно представить с точки зрения оптимизации. Компании обычно стремятся максимизировать желаемые характеристики, такие как прибыль и удовлетворенность клиентов, или минимизировать нежелательные признаки, такие как потери материала и отток. Достижение этих целей нетривиально, особенно когда сталкиваются с реальными жизненными ограничениями, налагаемыми на их работу. Способность создавать сложные, основанные на

оптимизации решения для решения критических бизнес-задач крайне важна для конкуренции в современную эпоху, основанную на данных.

Цель решения задач оптимизации

Цель решения задачи оптимизации - найти оптимальное решение из всех возможных решений. Эти проблемы могут рассматриваться как минимизация или максимизация целевой функции. Целевая функция - это математическое выражение, которое представляет качество возможного решения в контексте конкретной проблемы, принимая во внимание ограничения и переменные проблемы

Например, логистическая компания может захотеть минимизировать расстояние, пройденное транспортными средствами, и максимизировать своевременную доставку, поэтому целевой функцией будет общее время в пути. Ограничения могут включать: количество доступных транспортных средств, график доставки, вместимость транспортного средства и т. Д. Может быть несколько возможных маршрутов, которые могут быть сгенерированы, и каждый будет иметь различную степень оптимальности по отношению к целевой функции. Каждый возможный маршрут представляет собой решение, а набор маршрутов является пространством решения. Алгоритмы оптимизации работают в направлении навигации по возможным областям решений в итерационном процессе, чтобы найти наилучшее возможное решение.

Традиционные методы оптимизации

Традиционные методы оптимизации используют дифференциальное исчисление или поиск методом грубой силы, чтобы направлять исследование пространства решений - пространства, состоящего из всех возможных решений. Они детерминистически основаны на изменениях

оценки целевой функции в течение итераций. Эти типы методов имеют тенденцию быть менее обобщенными в своей конструкции и часто страдают от застревания в локально-оптимальном пространстве.

Чтобы понять концепцию локального оптимума, представьте, что вы взбираетесь на гору. Цель оптимизации - достичь вершины горы. Поскольку масштабирование гор редко является непрерывным подъемом под уклоном, вам, вероятно, придется подниматься и опускаться по небольшим пикам, пытаясь достичь вершины.

Решение задач оптимизации очень похоже на вышеупомянутый пример; однако традиционные алгоритмы затрудняют различие между плато на полпути вверх по горе (местный оптимум) и вершиной (глобальный оптимум). Это легко визуализировать, если учесть приведенную выше картинку. Если альпинист достигает первого плато горы (локальный максимум), находясь в облаках, он может ошибочно полагать, что он масштабировал всю гору (глобальный максимум). Поскольку они в облаках, они не могут видеть, что фактическая вершина намного выше. Точно так же, если альпинист представляет традиционный алгоритм оптимизации, он может застрять в этой точке и остановиться.

Основная проблема традиционных методов оптимизации заключается в том, что они могут ввести вас в заблуждение, полагая, что вы оптимизировали проблему, когда в действительности вы достигли только локального максимума. Это потому, что они часто только максимизируют локальную проблему и не имеют возможности анализировать глобальную проблему. Например, представьте, что вы управляете национальным ритейлером в Миннесоте. Если вы оптимизируете инвентарь исключительно на основе местных продаж (локальный максимум), то все, что вы будете носить, - это тяжелая фланелевая одежда. Но это пренебрегает ростом вашего бизнеса за пределами Миннесоты (глобальный максимум).

Расширенные методы оптимизации

Продвинутые методы, такие как генетические алгоритмы и имитация отжига, используют несколько интересных «уловок», которые позволяют им обрабатывать сложные целевые функции, которые трудно решить с помощью традиционных методов. Эти методы являются стохастическими (по своей природе случайными) по своей природе и используют эвристику для аппроксимации глобального оптимума для больших пространств решений. Для дальнейшего объяснения мы рассмотрим моделируемый отжиг в качестве типичного примера.

Оптимизация имитации отжига основана на процессе охлаждения расплавленных металлов, который называется «отжиг». В металлургии процесс отжига нагревает металл до высокой температуры и медленно охлаждает его. Это повышает качество металлов с точки зрения твердости и пластичности. В имитированном отжиге постоянно присутствует температурная переменная 'T', которая определяет, как алгоритм продвигается на протяжении всех итераций оптимизации. Это значение 'T' начинается с высокого значения в начале, а затем уменьшается с каждой итерацией. Аналогично, имитация отжига начинается со случайного начального решения и возмущает предыдущее решение на каждой последующей итерации, чтобы прийти к новому решению.

Это можно представить с точки зрения восхождения на гору. Обратите внимание, что в итеративном процессе имитации отжига новое решение может быть лучше или хуже предыдущего. Интересной особенностью имитации отжига является то, что он принимает менее оптимальное вероятностное решение с вероятностью, пропорциональной

температурной переменной 'T'. Следует спросить: «Зачем нам вообще принимать худшее решение?». Это эффективно предотвращает застревание в локальном оптимуме. Опять же, здесь помогает аналогия альпинизма. Если вы достигнете плато во время восхождения, вам придется немного спуститься, прежде чем снова подняться. Это похоже на разницу между зеленым и синим путем на изображении выше. Чтобы зеленый путь достиг максимально возможной точки, он должен идти к красной вершине, а затем двигаться вниз. Перемещение назад является примером принятия менее оптимального решения, поскольку оно является меньшим значением, поскольку цель алгоритма - найти наиболее оптимальное решение. Аналогично, имитация отжига позволяет избежать локального оптимума, позволяя решениям ухудшаться до того, как они станут лучше, тем самым избегая ловушек локальных оптимумов. Оптимизация по моделированию отжига сходится и приближается к окончательному решению, когда значение 'T' является достаточно низким, и когда дальнейшие возмущения перестают приводить к лучшим решениям.

Имитация отжига оказалась чрезвычайно полезной для быстрой оптимизации. Это особенно верно в тех случаях, когда число возможных решений огромно, а традиционные методы либо слишком долго оптимизируются, либо застревают в локальном оптимуме. В последнее время наблюдается устойчивый рост применения таких вероятностных методов оптимизации для решения реальных бизнес-задач.

Оптимизируйте свой бизнес

Компании, которые хотят получить конкурентное преимущество за счет использования этих передовых методов, должны обратиться к Soothsayer Analytics. Наша команда включает в себя несколько человек с глубокими знаниями в области оптимизации, таких как физики и материаловеды. Мы обладаем разнообразным опытом - от оптимизации инвентаря до оптимизации маршрутов транспортных средств и от оптимизации цепочек поставок до оптимизации межконтинентальных баллистических ракет. Мы обобщаем наши навыки в области искусственного интеллекта, углубленной математики и науки о данных для решения различных бизнес-задач, которые, вероятно, имеют отношение к вам.

Ссылка на статью: [Оптимизация AI](#)