


Высокопроизводительные вычисления, нейронные сети и линейное программирование: на пути к гибридному искусственному интеллекту

Соколинский Леонид Борисович
доктор физ.-мат. наук


Южно-Уральский государственный университет
(национальный исследовательский университет)

Гибридный искусственный интеллект


- Гибридный ИИ (Hybrid AI): разработка методов объединения сильных сторон машинного обучения, точных математических моделей и высокопроизводительных вычислений



Высокопроизводительные вычисления




Искусственный интеллект





Глубокая нейронная сеть прямого распространения

- + Универсальный инструмент для аппроксимации сложных функций
- + Реальный режим времени
- Необходимы наборы обучающих данных
- Трудности с верификацией



Принцип работы искусственного нейрона




Линейное программирование

- Одна из самых востребованных математических оптимизационных моделей
- Области применения:
 - Экономика
 - Производство
 - Логистика
 - Квантовая физика (теорема Белла)
 - Высокопроизводительные вычисления

$$f(x_1, x_2) = x_1 + x_2 \rightarrow \max$$

$$\begin{cases} x_1 + 2x_2 \leq 2 \\ 2x_1 + x_2 \leq 2 \\ x_1 + x_2 \geq 1 \\ x_1 \geq 0 \\ x_2 \geq 0 \end{cases}$$



$c = (1; 1)$ – градиент целевой функции


Система линейных ограничений и целевая функция

$$\begin{cases} a_{1,1}x_1 + \dots + a_{1,n}x_n \leq b_1 \\ \dots \dots \dots \dots \dots \\ a_{m,1}x_m + \dots + a_{m,n}x_m \leq b_m \\ \\ a_{m+1,1}x_1 + \dots + a_{m+1,n}x_{m+1} = b_{m+1} \\ \dots \dots \dots \dots \dots \\ a_{m+k,1}x_{m+k} + \dots + a_{m+k,n}x_{m+k} = b_{m+k} \end{cases} \quad \Rightarrow \quad \begin{cases} \langle \mathbf{a}_1, \mathbf{x} \rangle \leq b_1 \\ \dots \\ \langle \mathbf{a}_m, \mathbf{x} \rangle \leq b_m \\ \\ \langle \mathbf{a}_{m+1}, \mathbf{x} \rangle = b_{m+1} \\ \dots \\ \langle \mathbf{a}_{m+k}, \mathbf{x} \rangle = b_{m+k} \end{cases} \quad \Rightarrow \quad \begin{cases} \hat{A}\mathbf{x} \leq \hat{\mathbf{b}} \\ \bar{A}\mathbf{x} = \bar{\mathbf{b}} \end{cases}$$

$$f(x_1, \dots, x_n) = c_1x_1 + \dots + c_nx_n \qquad f(\mathbf{x}) = \langle \mathbf{c}, \mathbf{x} \rangle \qquad f(\mathbf{x}) = \langle \mathbf{c}, \mathbf{x} \rangle$$

Симплекс-метод

- Основной метод решения задач ЛП на практике
 - Экспоненциальная сложность
 - Потеря точности
 - Ограниченная масштабируемость (16-32 процессорных узла)



Геометрический подход с использованием НРС и искусственной нейронной сети

Неравенства порождают полупространства


Полупространство:

$$P_i = \{\mathbf{x} \in \mathbb{R}^n \mid \langle \mathbf{a}_i, \mathbf{x} \rangle \leq b_i\}$$

Граничная гиперплоскость:

$$\hat{H}_i = \{\mathbf{x} \in \mathbb{R}^n \mid \langle \mathbf{a}_i, \mathbf{x} \rangle = b_i\}$$

$$i = 1, \dots, m$$




Уравнения порождают опорные гиперплоскости

Опорная гиперплоскость:

$$\bar{H}_i = \{\mathbf{x} \in \mathbb{R}^n \mid \langle \mathbf{a}_i, \mathbf{x} \rangle = b_i\}$$

$$i = m + 1, \dots, m + k$$



Допустимый многогранник

Граничный многогранник:


$$\hat{M} = \bigcap_{i=1}^m P_i$$

Опорное полупространство:

$$\bar{S} = \bigcap_{i=m+1}^{m+k} \bar{H}_i$$


Допустимый многогранник:

$$M = \hat{M} \cap \bar{S}$$




Идея метода ALEM (Along Edges Movement)

1. Находясь в вершине v , выбираем ребро, ведущее к увеличению целевой функции
2. Выполняем переход к следующей вершине
3. Останавливаемся в вершине, у которой нет ребер, ведущих к увеличению целевой функции




Идея метода ALEM (Along Edges Movement)

1. Находясь в вершине, выбираем ребро, ведущее к увеличению целевой функции
 2. Выполняем переход к следующей вершине
 3. Останавливаемся в вершине, у которой нет ребер, ведущих к увеличению целевой функции
- Стратегии выбора ребра
 - **Максимальная конечная вершина**




Идея метода ALEM (Along Edges Movement)

1. Находясь в вершине, выбираем ребро, ведущее к увеличению целевой функции
 2. Выполняем переход к следующей вершине
 3. Останавливаемся в вершине, у которой нет ребер, ведущих к увеличению целевой функции
- Стратегии выбора ребра
 - Максимальная конечная вершина
 - **Максимальный градиент**



Идея метода ALEM (Along Edges Movement)

1. Находясь в вершине, выбираем ребро, ведущее к увеличению целевой функции
 2. Выполняем переход к следующей вершине
 3. Останавливаемся в вершине, у которой нет ребер, ведущих к увеличению целевой функции
- Стратегии выбора ребра
 - Максимальная конечная вершина
 - Максимальный градиент
 - **Случайный / первое попавшееся ребро**



Как получить ребра, исходящие из вершины v

Множество номеров граничных гиперплоскостей, проходящих через v :


$$I_v = \{i \in \{1, \dots, m\} | \langle a_i, v \rangle = b_i\}$$

Подмножество из $n - k - 1$ элементов:

$$\tilde{I}_v \subseteq I_v, \quad |\tilde{I}_v| = n - k - 1$$

Прямая, образующая ребро с началом в точке v :

$$L_v = \bar{S} \cap \bigcap_{i \in \tilde{I}_v} \hat{H}_i$$



Перебор всех вариантов можно сделать с помощью алгоритма TWIDDLE*

*Phillip J. Chase. 1970. Algorithm 382: combinations of M out of N objects [G6]. Commun. ACM 13, 6 (June 1970), 368. <https://doi.org/10.1145/362384.362502>

Необходимость НРС

- Если через точку v проходит k гиперплоскостей, то количество исходящих ребер равно

$$C_k^{n-1} = \frac{k!}{(n-1)!(k-n+1)!}$$


- Эксперименты на вычислительном кластере показали, что алгоритмы выбора оптимального ребра обладают практически неограниченной масштабируемостью
- Чем больше вариантов, тем выше масштабируемость

Для определения конечной точки ребра
необходим направляющий вектор $\mathbf{d}$


$$L_v = \bar{S} \cap \bigcap_{i \in \tilde{I}_v} \hat{H}_i = \left(\bigcap_{i=m+1}^{m+k} \bar{H}_i \right) \cap \left(\bigcap_{i \in \tilde{I}_v} \hat{H}_i \right)$$

$$L_v = \{x \in \mathbb{R}^n \mid x = v + \lambda \mathbf{d}, \lambda \in \mathbb{R}\}$$

$\mathbf{d} = ?$



Нейросетевой метод вычисления направляющего вектора d




Рецептивное поле Q

- В целевой гиперплоскости H_c формируем рецептивное Q поле в виде гиперкубической решетки точек
- Каждой точке x рецептивного поля Q сопоставляем смещение относительно M

$$\beta(x) = \min_i \beta_i(x)$$


$$\beta_i(x) = -\frac{\langle a_i, x \rangle - b_i}{\langle a_i, c \rangle} \|c\|$$

- Получаем образ G в виде матрицы размерности $n - 1$




$$H_c = \{x \in \mathbb{R}^n | \langle c, x - v \rangle = 0\}$$

Переход к крестообразному рецептивному полю




$$|Q_{cube}| = \eta^{n-1}$$



$$|Q_{cross}| = (\eta - 1)n + 1$$

Нейронная сеть для $\mathbb{R}^5$



Метрики и результаты

- Функция потерь (Bidirectional Mean Absolute Percentage Error):

$$BiMAPE = 100 \frac{1}{K} \sum_{i=1}^K \min(\|\hat{y}_i - y_i\|, \|\hat{y}_i + y_i\|)$$

- Косинусное подобие (Bidirectional Mean Percentage Cosine Similarity):

$$BiMPCS = 100 \frac{1}{K} \sum_{i=1}^K \text{abs} \left(\frac{\langle \hat{y}_i, y_i \rangle}{\|\hat{y}_i\| \cdot \|y_i\|} \right)$$

y_i – точное значение

$\hat{y}_i$ – выход нейронной сети

K – количество прецедентов

Dataset elements count	171000
Train/validate ratio	80:20
Optimizer	AdamW
Learning rate	0.001
Batch size	256

Точность ($100 - BiMAPE$)	95%
Косинусное подобие ($BiMPCS$)	99.8%

Спасибо за внимание!