

Постановка задач и выбор моделей в машинном обучении

Вадим Викторович Стрижов

Московский физико-технический институт

Осенний семестр 2019

Модели как суперпозиции

Экспертно задано множество G порождающих функций $g(\mathbf{w}, \mathbf{x})$. Для g_i определены области аргументов $\mathbf{w} \in \mathbb{R}^m, \mathbf{x} \in \mathbb{R}^n$ и значений $g_i(\mathbf{x}) \in \mathbb{R}^1$.

Множество G пополняется функциями $\text{id}(\mathbf{x})$ и const .

Искомая модель f будет искааться среди множества $\tilde{\mathcal{G}}$ суперпозиций функций $g \in G$.

Список порождающих функций

Description	In	N in	Out	N out	Comm	Param
Nominal to binary	nom	1	bin	1–4	-	Yes
Ordinal to binary	ord	1	bin	1–4	-	Yes
Linear to linear segments	lin	1	lin	1–4	-	Yes
Linear segments to binary	lin	1	bin	1–4	-	Yes
Get one column of n-matrix	bin	1–4	bin	1	-	Yes
Conjunction	bin	2–6	bin	1	Yes	-
Dijunction	bin	2–6	bin	1	Yes	-
Negate binary	bin	1	bin	1	-	-
Logarithm	lin	1	lin	1	-	-
Hyperbolic tangent sigmoid	lin	1	lin	1	-	-
Logistic sigmoid	lin	1	lin	1	-	-
Sum	lin	2–3	lin	1	Yes	-
Difference	lin	2	lin	1	No	-
Multiplication	lin,bin	2–3	lin	1	Yes	-
Division	lin	2	lin	1	No	-
Inverse	lin	1	lin	1	-	-
Polynomial transformation	lin	1	lin	1	-	Yes
Radial basis function	lin	1	lin	1	-	Yes
Monomials: $x\sqrt{x}$, etc.	lin	1	lin	1	-	-

Задача порождения признаков

Даны

- измеряемые признаки $\Xi = \{\xi\}$,
- заданные экспертами порождающие функции $G = \{g(\mathbf{b}, \xi)\}$,

$$g : \xi \mapsto x;$$

- правила порождения: $\mathcal{G} \supset G$, где суперпозиция $g_k \circ g_l \in \mathcal{G}$ построена с учетом ограничений на число типы входных и выходных переменных ;
- правила упрощения суперпозиций: g_u не принадлежит \mathcal{G} , если существует правило

$$r : g_u \mapsto g_v \in \mathcal{G}.$$

Результат

набор «композитных» признаков $X = \{\mathbf{x}_1, \dots, \mathbf{x}_j, \dots, \mathbf{x}_n\}$.

*Внимание! Число порожденных признаков может превосходить
число клиентов!*

Примеры композитных признаков

- **Frac(Period of residence, Undeclared income)**
- **Frac(Seg(Period of employment), Term of contract)**
- **And(Income confirmation, Bank account)**
- **Times(Seg(Score hour), Frac(Seg(Period of employment), Salary))**

$$f = (g_1 \circ \dots \circ g_V)(x)$$

Определение

Допустимыми называют суперпозиции, удовлетворяющие следующим требованиям

- Элементами s_i суперпозици f могут являться только порождающие функции g_j и свободные переменные x_i .
- Количество аргументов элемента суперпозиции s_i равно арности соответствующей ему функции g_j .
- Порядок аргументов элемента s_i суперпозиции f соответствует порядку аргументов соответствующей функции g_j .
- Для элемента s_i , аргументом которого является элемент s_j , для соответствующих порождающих функций $\text{dom}(g_i) \supset \text{cod}(g_j)$;




Каждой суперпозиции f однозначно соответствует дерево Γ_f :

- В вершинах v_i дерева Γ_f находятся соответствующие функции g_j .
- Число дочерних вершин у v_i равно арности соответствующей функции g_j .
- Порядок дочерних вершин v_i соответствует порядку аргументов функции g_j .
- Листьями дерева Γ_f являются x_i или const.


Система координат на деревьях

Естественным образом каждой вершине может быть сопоставлена координатная строка.



Прямоугольная система координат

Наиболее удобным способом задания координат является прямоугольная система, в которой ограничена арность вершин a_{\max} .



Определение

Дерево $\Gamma'(V')$ называется поддеревом дерева $\Gamma(V)$, если его множество вершин V' является подмножеством множества V .

Определение

Два дерева Γ_1 и Γ_2 называются изоморфными, если между их множествами вершин существует взаимно однозначное отображение, сохраняющее метки вершин.

Определение

Дерево Γ_0 называется общим поддеревом деревьев Γ_1 и Γ_2 , если в них существуют поддеревья Γ'_1 и Γ'_2 , изоморфные дереву Γ_0 .

Определение

Общее поддерево двух деревьев называется наибольшим, если в нем содержится наибольшее число вершин среди других общих поддеревьев. Наибольшее поддерево деревьев $\Gamma_i(V_i)$ и $\Gamma_j(V_j)$ обозначается как $\Gamma_{ij}(V_{ij})$. Символом p будет обозначаться количество элементов в множестве V : $|V_i| = p_i$, $|V_j| = p_j$, $|V_{ij}| = p_{ij}$.

Рассмотрим абсолютную функцию расстояния r между Γ_i и Γ_j , зависящую от их размеров и наибольшего общего подграфа,

$$r_{ij} = p_i + p_j - p_{ij},$$

Рассмотрим неравенство треугольника. Пусть даны графы Γ_1 , Γ_2 и Γ_3 . Необходимо доказать неравенство:

$$r_{12} + r_{23} \geq r_{13},$$



$$p_1 + p_2 - 2p_{12} + p_2 + p_3 - 2p_{23} \geq p_1 + p_3 - 2p_{13},$$

$$p_2 - p_{12} - p_{23} + p_{13} \geq 0.$$

Сложность суперпозиции

Описание суперпозиции f , представленной в виде дерева Γ , определяется следующими параметрами.

- 1 Число вершин v_i в дереве Γ .
- 2 Количество порождающих функций g_i , не являющихся терминальными вершинами x_i .



Сложность суперпозиции

Сложность суперпозиции равна f сложности корня v_0 и определяется индуктивно с помощью следующей процедуры:

- 1 Сложность C суперпозиции, дерево которой представляет собой одну вершину, соответствующую константной порождающей функции, равна 0:

$$C(\text{const}) = 0.$$

- 2 Сложность C суперпозиции f , дерево Γ которой представляет собой одну свободную переменную x_i ; равна 1:

$$C(x_i) = 1.$$

- 3 Сложность суперпозиции $g_i(f)$, где $C(f) = K$, а g_i - порождающая функция, равна сумме количества элементов в $g_i(f)$ и сложности f :

$$C(g_i(f)) = C(f) + |g_i(f)|$$

Построение всех допустимых суперпозиций

Перед первым шагом построим начальное значение множества моделей \mathcal{F}_0 :

$$\mathcal{F}_0 = \{X, C\},$$

На каждом шаге для \mathcal{F}_i построим множество U_i из суперпозиций, полученных при применении функций $g_i \in G$ к элементам $f_j \in \mathcal{F}_{i-1}$:

$$U_i = \{g_i(f_{j_1}, \dots, f_{j_k}), \mid g_i \in G_u, f \in \mathcal{F}_{i-1}\}.$$

Тогда множество \mathcal{F}_i

$$\mathcal{F}_i = \mathcal{F}_{i-1} \cup U_i.$$

Количество возможных суперпозиций

Пусть в множестве порождающих функций G содержится I_p функций максимальной арности $p > 1$, и имеется $n > 1$ независимых переменных.


Справедлива следующая оценка количества суперпозиций, порожденных алгоритмом \mathcal{U} после k -ой итерации:

$$|\mathcal{F}_k| = \mathcal{O}(I_p^{(p^k - 1)/(p - 1)} n^{p^k}).$$

0. Экспертно задается множество исходных моделей.
- 1 Выполняется обмен поддеревьями.
- 2 Выполняется модификация суперпозиции
- 3 В соответствии с критерием качества отбираются лучшие модели и далее происходит следующая итерация процесса.


1. Выполняется обмен поддеревьями:

- ① случайно выбирается пара суперпозиций f_i и f_j .
- ② в деревьях Γ_i и Γ_j выбираются вершины v_i и v_j
- ③ порождаются новые модели f'_i и f'_j путем обмена поддеревьями с корнями в выбранных вершинах.




1. Выполняется обмен поддеревьями:

- ① случайно выбирается пара суперпозиций f_i и f_j .
- ② в деревьях Γ_i и Γ_j выбираются вершины v_i и v_j
- ③ порождаются новые модели f'_i и f'_j путем обмена поддеревьями с корнями в выбранных вершинах.




2. Выполняется модификация полученных моделей.

- ① В дереве Γ_j выбирается вершина v_k ;
- ② Из элементов G , имеющих число аргументов, как у g_k , выбирается g_s .
- ③ Порождающая функция g_k заменяется функцией g_s .




Think of a model

Let it be $y = f(\mathbf{w}, \mathbf{x}) = \sin(x_1) * \sin(w_1x_2 + w_2)$.



Given data

The corresponded sample set is shown; it has 380 samples.



Given primitive functions

Function	Description	Parameters
$g(\mathbf{b}, x_1, x_2)$		
plus	$y = x_1 + x_2$	–
times	$y = x_1 x_2$	–
$g(\mathbf{b}, x_1)$		
divide	$y = 1/x$	–
multiply	$y = ax$	a
add	$y = x + a$	a
normal	$y = \frac{\lambda}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\xi)^2}{2\sigma^2}\right) + a$	λ, σ, ξ, a
linear	$y = ax + b$	a, b
parabolic	$y = ax^2 + bx + c$	a, b, c
sin	$y = \sin(x)$	–
logsig	$y = \frac{\lambda}{1+\exp(-\sigma(x-\xi))} + a$	λ, σ, ξ, a

Set of the generated models

Let the generated models $\mathcal{F} = \{f_i\}$ be a set
of admissible superpositions
of the primitive functions $G = \{g\}$.

Expert information

Experts assign the initial models


$$\begin{aligned}f_1 : \quad & y = \text{linear}(x_1), \\f_2 : \quad & y = \text{normal}(x_2).\end{aligned}$$

And the initial conditions

- ① the model complexity:
 { number of primitives in a superposition g no more than 8,
 { number of parameters w no more than 10;
- ② the target function is sum of squared errors, SSE.

Competitive models

Given data




Competitive models

$\text{normal}(w_{1:3}, x_2)$



normal

x_2





Competitive models

`plus2(∅,times2(∅,plus2(∅,x2,x1),linear(w1:2,x1)),linear(w3:4,x2))`





Competitive models

`times2((),times2((),plus2((),x2,linear(w1:2,x1)),linear(w3:4,x1)),x2)`





Competitive models

`times2((),times2((),plus2((),parabola(w1:3,x2),x2),sin((),x1)),sin((),x1))`





Competitive models

times2(\emptyset ,plus2(\emptyset ,linear($w_{1:2}, x_1$),sin(\emptyset, x_2)),sin(\emptyset, x_1))



Competitive models


`times2((),plus2((),parabola(w1:3,parabola(w4:6,x2)),sin((),x1)),sin((),x1))`



Competitive models

`times2((),plus2((),plus(w1,linear(w2:3,x1))),linear(w4:5,x2)),sin((),sin((),x1)))`


times2
 plus2
 plus linear sin
 linear x2 sin
 x1



Competitive models



times2(\emptyset ,parabola($w_{1:3}$,linear($w_{4:5},x_2$)),linear($w_{6:7},\sin(\emptyset,x_1)$))

times2
parabola linear
linear sin
 x_2 x_1



Competitive models


times2(\emptyset ,plus2(\emptyset ,parabola($w_{1:3}, x_2$),sin(\emptyset, x_2)),sin(\emptyset, x_1))



Competitive models

`times2(∅,sin(∅,linear(w1:2,x2)),sin(∅,x1))`

times2
sin sin
linear x₁
x₂



Процедура построения модели

