

ВСИ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

курс: Архитектура суперкомпьютерных систем

ЛЕКЦИЯ 2: ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА
ДИСПЕТЧЕРСКОГО УПРАВЛЕНИЯ ГИБРИДНЫМИ
ВЫСОКОПРОИЗВОДИТЕЛЬНЫМИ КЛАСТЕРАМИ
ВЫЧИСЛИТЕЛЬНЫМИ КЛАСТЕРАМИ.

12.09.2023



- **Введение.** Что мы хотим от «Машинного обучения» высокопроизводительных вычислительных кластеров
- **Возможности** повышения «реальной производительности» гибридных СК кластеров:
 - интеллектуальное диспетчерское управление
- **Оценка** параметров, используемых диспетчером slurm, на основе машинного обучения модели «выживаемости» прикладных задач
- **Результаты** моделирования
- **Выводы**



ВВЕДЕНИЕ. ЧТО МЫ ХОТИМ ОТ «МАШИННОГО ОБУЧЕНИЯ» СК

- **Имеем:** в настоящее время «машинное обучение» – стало синонимом «больших данных». Без гигантских объемов заранее размеченных данных алгоритмы машинного обучения не способны извлечь абстрактные знания, которые затем можно перенести на новые ситуации
- **Вопрос:** как получить максимум информации из минимума данных, то есть выявить суть явления или процесса из наблюдений ?
- **Ответ:** нужно **встроить в СК искусственный механизм внимания**, чтобы ... эффективно
 - фильтровать поступающую информацию,
 - выявлять релевантные связи,
 - строить гипотезы и обобщать полученные данные, чтобы развивать возможности **оценивать вероятности** соответствия выбранных моделей и гипотез результатам наблюдений, извлекая из «сырых» данных **объяснительные абстракции (функция выживания)**, которые можно переносить на другие ситуации
- **Как это сделать.** Для большинства алгоритмов машинного обучения настраиваемые параметры – это веса нейронов или ветвей «случайных деревьев»..., поэтому задача «обучения» состоит в поиске такого сочетания всех **параметров модели процесса**, которые вместе определяют **модель «наилучшего из возможных решений»**.



ВОЗМОЖНОСТИ «УМНЫХ» ВЫЧИСЛЕНИЙ


Общая характеристика эффективности для всех видов запусков заданий



Класс эквивалентности 1: запуск заданий на СК в «ИИ режиме»



Класс эквивалентности 2: запуск неизвестных задания «в ручном» режиме



Вывод:

Если параметры заданий пользователей, хорошо (точно) известны, то **настройки процессов вычислений можно автоматизировать** и более эффективно использовать имеющиеся компьютерные ресурсы

Есть два основных направления:

1) Разрабатывать новые компьютерные архитектуры, ППО и электронную компонентную базу

2) Построить модель задачи, которая на основе :

- используется для проведения **прямого вычисления** правильного ответа на основе заданных начальных данных и «формулы» описания процесса, реализуемого на имеющейся аппаратно-программной базе СК
- «опыта» научиться предсказывает правильный ответ для решаемой задачи с вероятностью $0.9X$
- использования методов «машинного обучения» объяснит как надо распределить имеющиеся ресурсы кластера между всеми прикладными задачами, чтобы с вероятностью $0.9X$ они завершилась успешно, объяснив при этом, почему выбран именно такой вариант действий

Цель обучения – повышение реальной производительности

Реальную производительность работы гибридного СКЦ, работающего в режиме центра коллективного пользования (ЦКП), можно повысить на основе такого **планирования процесса** распределения ресурсов гибридного кластера, которое обеспечивает успешное завершение задачи пользователя за интервал времени, выделенный для нее диспетчером slurm

Реальная производительность работы СКЦ оценивается через:

- Вероятность **успешного** (или не успешного) выполнения прикладной задачи за выделенное slurm время выполнения,
- Количество успешно выполненных задач пользователей за заданный интервал времени

Для этого требуются оценки параметров прикладных заданий и самого СК, которые используются для системой планирования slurm и влияют на реальную производительность работы СКЦ, **однако могут быть неизвестны пользователю на момент запуска задачи.**

Для **системы машинного обучения СКЦ** используется цензурированная выборка данных, включая

- $x_i \in \mathcal{X}$ – входной вектор параметров задания, задаваемых непосредственно самим пользователем
- $t_i \in [0, +\infty)$ – время до события (завершения задачи)
- $\delta_i \in \{0, 1\}$ – индикатор цензурирования (1, если задача завершена до истечения времени, 0 иначе)
- $y_i \in \mathcal{Y}$ – вектор параметров задачи, не известный на момент запуска (например, факторы изменения состояния системы slurm), в который могут входить индикаторы ошибки выполнения задачи (0 – успешное завершение, 1 – завершение с ошибкой)



Формулировка задачи обучения диспетчера СК:

Построить модель оценки параметров прикладного задания (оценку ожидаемого времени решения) с использованием **механизмов внимания** в условиях цензурирования данных, а именно:


- Ожидаемое время решения $\mathbb{E}[T|X = x]$
- Функции выживаемости прикладной задачи в среде СК, а именно $S(t, X)$
- вектора параметров \hat{y} выполнения задачи, компонентами которого являются вероятность успешного выполнения задания $P(X=x)$

С целью использования этих параметров в системе планирования ресурсов СКЦ, построенной на базе **диспетчера slurm**

Post-hoc и model-based интерпретация результатов обучения

Post-hoc интерпретация - объяснение после обучения основной модели, пример - метод LIME (Local Interpretable Model-Agnostic Explanations)

Model-based интерпретация результата, которая позволяет "вмешиваться" в процесс обучения и повысить «вероятность» получения правильного ответа



- 1 Локальная - методы интерпретации относятся к отдельному примеру и результатам его классификации, а именно:
 - Почему модель принимает конкретное решение для данной задачи?
 - Почему модель принимает конкретные решения для группы задач одного класса?
- 1 Глобальная - методы интерпретации сфокусированы на значимых признаках всего множества анализируемых задач

Модель задачи интерпретация полученных решений

Любая интерпретация – это «решение обратной задач», которая имеет множество решений, **поэтому нуждается в регуляризации.**

Формально модель задачи это функция $f : \mathbb{R}^m \rightarrow \mathbb{R}^D$, например, в задаче классификации $f(\mathbf{x})$ - это вероятность того, что \mathbf{x} принадлежит определенному классу

Интерпретация - это также модель $g(x) \in G$, где G - класс эффективно интерпретируемых моделей, например:

линейная регрессия, деревья решений, ..., случайные леса

Задача оптимизации модели интерпретации:

$$\min_{g \in G} \{L(f, g, \theta) + \Omega(g)\}$$

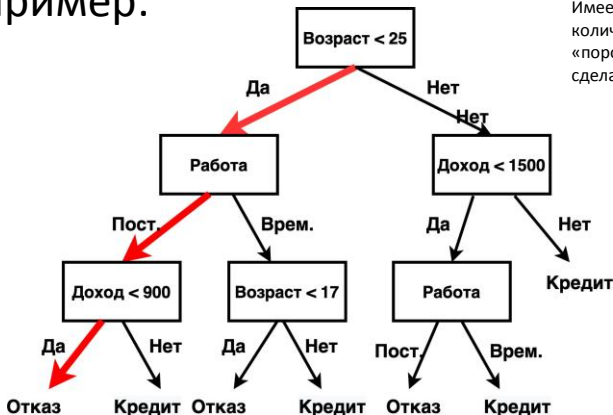
$L(f, g, \theta)$ - мера того, как неточна g в аппроксимации f

θ - вектор параметров; $\Omega(g)$ - **регуляризатор**

- Линейная регрессия
- Логистическая регрессия
- Деревья решений
- GLM (Лассо, гребневая регрессия, эластичная сеть)
- К ближайших соседей

Выбор объяснения на основе дерева решений, почему ?

пример:




Имеется количественный «порог» обоснования сделанного выбора

Выбор объяснения на основе регрессии, почему?

Линейная регрессия: $g(\mathbf{x}) = a_1x_1 + a_2x_2 + \dots + a_mx_m$

GAM: $g(\mathbf{x}) = g_1(x_1) + g_2(x_2) + \dots + g_m(x_m)$



Имеется линейная зависимость от локально измеряемых параметров или линейная зависимость от функций от этих

Модели "выживаемости" прикладной задачи в СКЦ

Дано: Рассматривается «событие» - вероятность «успешного решения» задач пользователя до истечения заданного диспетчером времени T_i , которая связано с вектором \mathbf{x} .
Имеется обучающая выборка $(\mathbf{x}_i, \delta_i, T_i)$, где вектор $\mathbf{x}_i = (x_{i1}, \dots, x_{id})$, $i = 1, \dots, n$ - цензурированные данные о функционировании СК во время выполнения задания, включая параметры прикладной задачи, которые задаются самим пользователем

Заданы функции

- риска $h(t|\mathbf{x})$, что задача завершится в момент времени t
- кумулятивная функция риска $H(t|\mathbf{x})$,
- функция выживаемости $S(t|\mathbf{x}) = \Pr\{T > t|\mathbf{x}\}$

(пример: модель пропорционального риска Кокса: $H(t|\mathbf{x}, \mathbf{b}) = H_0(t) \exp(\mathbf{x}\mathbf{b}^T)$)

Рассматривается модель выживаемости на основе случайного леса и обучающая выборка $(\mathbf{x}_i, \delta_i, T_i)$,
 $i = 1, \dots, n$.

Выход модели либо функция

- риска
- выживаемости (имеет не одно значение)

Требуется определить какие компоненты вектора \mathbf{x} определяют функцию риска $H(t|\mathbf{x})$?

Например, функция риска на основе модели Кокса имеет вид:

$$H_{\text{Cox}}(t|\mathbf{x}, \mathbf{b}) = H_0(t) \exp(\mathbf{x}\mathbf{b}^T)$$

Роль выхода модели прогноза $y = f(\mathbf{x})$ (класса) играет кумулятивная функция риска $H(t|\mathbf{x})$,

Функцию риска $H(t|\mathbf{x})$ будем аппроксимировать моделью Кокса

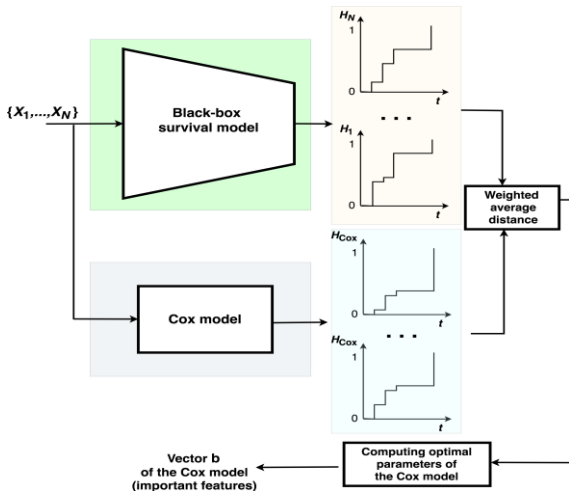
$H_{\text{Cox}}(t|\mathbf{x}, \mathbf{b}) = H_0(t) \exp(\mathbf{x}\mathbf{b})^T$, чтобы получить зависимость

$H_{\text{Cox}}(t|\mathbf{x}, \mathbf{b})$ от \mathbf{x} с коэффициентами \mathbf{b}

Для этого сгенерируем «облако» точек \mathbf{x}_k вблизи \mathbf{x} с весами $w_k = K(\mathbf{x}_k, \mathbf{x})$

Оптимальные значения \mathbf{b} определяются минимизируя среднее "весовое" расстояние между $H(t|\mathbf{x})$ и $H_{\text{Cox}}(t|\mathbf{x}, \mathbf{b})$

Иллюстрация SurvLIME



Задача оптимизации для вычисления коэффициентов

$$\min_{\mathbf{b}} \sum_{k=1}^N w_k \sum_{j=0}^m v_{kj}^2 (\ln H_j(\mathbf{x}_k) - \ln H_{0j} - \mathbf{b}^T \mathbf{x}_k)^2 (t_{j+1} - t_j),$$

где

$$w_k = 1 - \sqrt{\frac{\|\mathbf{x} - \mathbf{x}_k\|_2}{r}}, \quad v_{kj} = H_j(\mathbf{x}_k) / \ln(H_j(\mathbf{x}_k)).$$

\mathbf{x}_k - сгенерированные точки, \mathbf{b} - вектор искомых коэффициентов
 $H_0(\mathbf{x}_k)$, $H(\mathbf{x}_k)$ - базовая и обычная кумулятивные функции риска
 N - количество сгенерированных точек

Числовые эксперименты с синтетическими данными

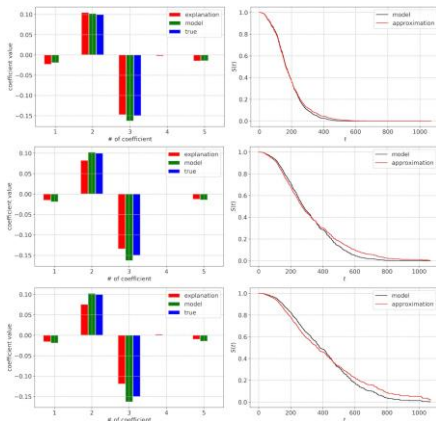


Рис.: Наилучшая, средняя и наихудшая аппроксимации для модели Кокса как черного ящика

Числовые эксперименты с реальными данными




Рис.: Аппроксимации для модели Кокса как черного ящика (первый и второй графики) и случайного леса выживаемости (третий график), обученных на датасете Primary Biliary Cirrhosis

Числовые эксперименты с реальными данными




Рис.: Аппроксимации для модели Кокса как черного ящика (первый и второй графики) и случайного леса выживаемости (третий график), обученных на датасете Veterans' Administration Lung Cancer Study

Модели выживаемости, учитывающие совместное влияние признаков

Имеется основная обученная модель выживаемости (случайный лес выживаемости, нейронная сеть) и датасет $(\mathbf{x}_i, \delta_i, T_i)$, $i = 1, \dots, n$.

Вопрос: какие пары признаков некоторого вектора \mathbf{x} совместно определяют его функцию риска $H(t|\mathbf{x})$?

Идея: использовать метод Лассо и произведение признаков в расширенной модели Кокса:

$$H_{\text{Cox}}(t|\mathbf{x}, \mathbf{z}, \mathbf{b}, \mathbf{c}) = H_0(t) \exp(\mathbf{x}\mathbf{b}^T + \mathbf{z}\mathbf{c}^T)$$

где \mathbf{z} - вектор произведений пар признаков

$\mathbf{z} = (x_1x_2, x_1x_3, \dots, x_{d-1}x_d)$;

\mathbf{c} - искомый вектор коэффициентов длины $d(d-1)/2$:

$\mathbf{c} = (c_{1,1}, c_{1,2}, \dots, c_{d-1,d})$

- 1 Анализ аналогичен SurvLIME, где функция риска $H(t|\mathbf{x})$ - выход основной модели "черного ящика".
- 2 Аппроксимируем $H(t|\mathbf{x})$ функцией риска расширенной модели Кокса $H_{\text{Cox}}(t|\mathbf{x}, \mathbf{z}, \mathbf{b}, \mathbf{c}) = H_0(t) \exp(\mathbf{x}\mathbf{b}^T + \mathbf{z}\mathbf{c}^T)$
- 3 Для построения модели Кокса генерируем много точек \mathbf{x}_k вблизи \mathbf{x} с весами $w_k = K(\mathbf{x}_k, \mathbf{x})$
- 4 Оптимальные значения \mathbf{b} определяются минимизируя среднее весовое расстояние между $H(t|\mathbf{x})$ и $H_{\text{Cox}}(t|\mathbf{x}, \mathbf{z}, \mathbf{b}, \mathbf{c})$ с учетом **регуляризации**

Задача оптимизации для вычисления коэффициентов

$$\min_{\mathbf{b}, \mathbf{c}} \sum_{k=1}^N w_k \sum_{j=0}^m v_{kj}^2 \left(\ln H_j(\mathbf{x}_k) - \ln H_{0j} - \mathbf{b}^T \mathbf{x}_k - \mathbf{c}^T \mathbf{z}_k \right)^2 (t_{j+1} - t_j) \\ + \lambda \sum_{i=1}^d \sum_{j=1, j \neq i}^d |c_{i,j}| + \mu \sum_{i=1}^d b_i^2.$$

Слагаемое $\lambda \sum_{i=1}^d \sum_{j=1, j \neq i}^d |c_{i,j}|$ - **регуляризационное слагаемое** в соответствии с методом Лассо, используется для ограничения множества ненулевых коэффициентов в векторе \mathbf{c} .

Регуляризация вектора \mathbf{b} ($\mu \sum_{i=1}^d b_i^2$) осуществляется с использованием квадратичной нормы.

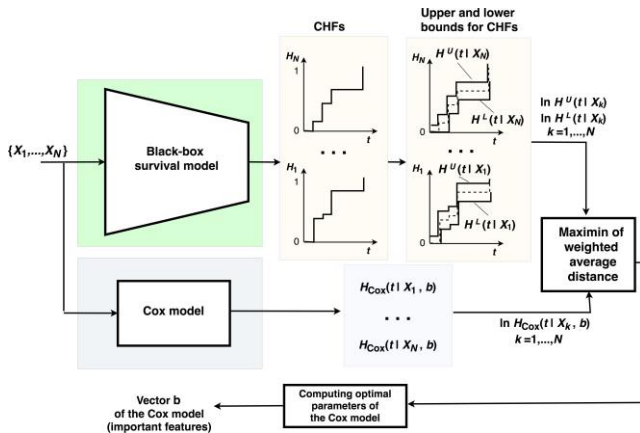
$$F_n^L(\mathbf{x}) \leq F(\mathbf{x}) \leq F_n^U(\mathbf{x}),$$

$$F_n^L(\mathbf{x}) = \max(F_n(\mathbf{x}) - d_{n,1-\gamma}, 0),$$

$$F_n^U(\mathbf{x}) = \min(F_n(\mathbf{x}) + d_{n,1-\gamma}, 1).$$

Для $n > 10$: $d_{n,1-\gamma} \approx k_{1-\gamma} / \sqrt[3]{n^-}$

Для $n \leq 10$: $d_{n,1-\gamma} \approx k_{1-\gamma} (\sqrt[3]{n^+ 0.12 + 0.11} / \sqrt[3]{n})^{-1}$



$$\max_k \min_{\mathbf{b}, z_k} L(\mathbf{b}) = \max_k \min_{\mathbf{b}, z_k} \sum_{k=1}^N w_k z_k,$$

при ограничениях $\theta_k \in F_k, k = 1, \dots, N,$

$$z_k \geq \max_{j=0, \dots, m} \theta_{kj} - \mathbf{x}_k \mathbf{b}^T, \quad k = 1, \dots, N,$$

$$z_k \geq \mathbf{x}_k \mathbf{b}^T - \min_{j=0, \dots, m} \theta_{kj}, \quad k = 1, \dots, N$$

F_k - множество θ_k , определяемое из

$$\theta_{k,j}^L \leq \theta_{k,j} \leq \theta_{k,j}^U, \quad k = 1, \dots, N, \quad j = 0, \dots, m,$$

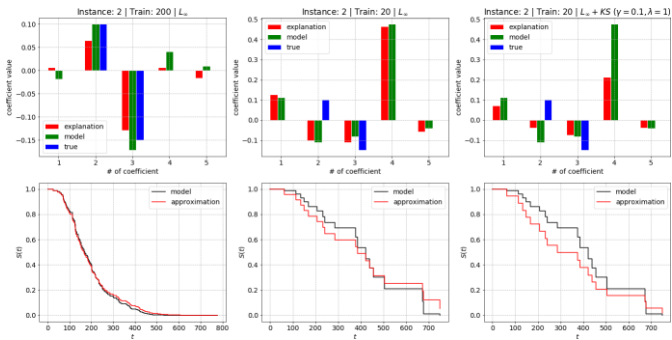
$$\theta_{k,j} \leq \theta_{k,j+1} + \ln(H_{0j+1}/H_{0j}), \quad j = 0, \dots, m-1$$

$$\min_{\mathbf{b}} \sum_{k=1}^N w_k z_k + \lambda \|\mathbf{b}\|^2,$$

$$z_k + \mathbf{x}_k \mathbf{b}^T \geq \max_{j=0, \dots, m} \theta_{k,j}^U, \quad k = 1, \dots, N,$$

$$z_k - \mathbf{x}_k \mathbf{b}^T \geq - \min_{j=0, \dots, m} \theta_{k,j}^L, \quad k = 1, \dots, N.$$

Числовые эксперименты с синтетическими данными



Числовые эксперименты с реальными данными

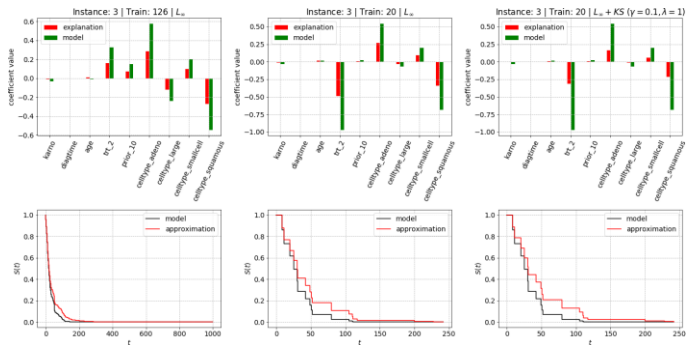




Рис.: An illustration of the approximation results under three conditions of experiments for the lack-ox Cox model trained on the Veteran dataset

Counterfactual объяснения (гипотетические, противопоставления)

- Counterfactual - наименьшие изменения значений признаков, которые изменяют класс примера
- "Ваш запрос на кредит отклонен, так как ваш доход \$30,000 и ваш баланс \$200. Если бы ваш доход был \$35,000 и ваш текущий баланс был \$400, то ваш запрос был бы одобрен"



Step 1: Generation



Step 2: Feature Selection

Конфликтные примеры (counterfactual)

f - функция «черного ящика». Counterfactual пример $\mathbf{z} = (z_1, \dots, z_d) \in \mathbb{R}^d$ для объясняемого примера $\mathbf{x} = (x_1, \dots, x_d) \in \mathbb{R}^d$ определяется из решения задачи оптимизации:

$$\min_{\mathbf{z} \in \mathbb{R}^m} L(f(\mathbf{z}), f(\mathbf{x})) + C\theta(\mathbf{z}, \mathbf{x}),$$

где $L(\cdot, \cdot)$ - функция потерь, устанавливающая отношение между предсказаниями модели f ;

$\theta(\cdot, \cdot)$ - штрафное слагаемое для отклонения \mathbf{z} от \mathbf{x} , например евклидово расстояние;

$C > 0$ - параметр

Конфликтные примеры (counterfactual)

Постановка задачи для модели выживаемости

$$m_{\mathbf{z}} = E(\mathbf{z}) = \int_0^{\infty} S(t|\mathbf{z})dt, \quad m_{\mathbf{x}} = E(\mathbf{x}) = \int_0^{\infty} S(t|\mathbf{x})dt.$$

Задача оптимизации:

$$\min_{\mathbf{z} \in \mathbb{R}^d} L(m_{\mathbf{z}}, m_{\mathbf{x}}) + C\theta(\mathbf{z}, \mathbf{x}).$$

Ограничение на классы:

$$m_{\mathbf{z}} - m_{\mathbf{x}} \geq r.$$

Итоговая задача оптимизации


$$\min_{\mathbf{z} \in \mathbb{R}^m} L(\mathbf{z}) = \min_{\mathbf{z} \in \mathbb{R}^m} \{\max\{0, C\psi(\mathbf{z})\} + \|\mathbf{z} - \mathbf{x}\|_2\},$$

где

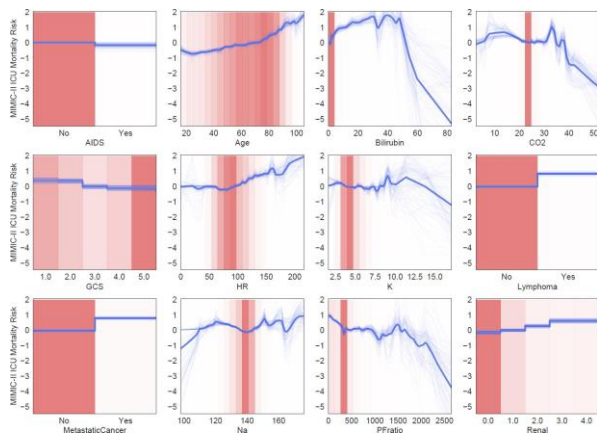
$$\psi(\mathbf{z}) = r - (m(\mathbf{z}) - m(\mathbf{x})) \leq 0.$$

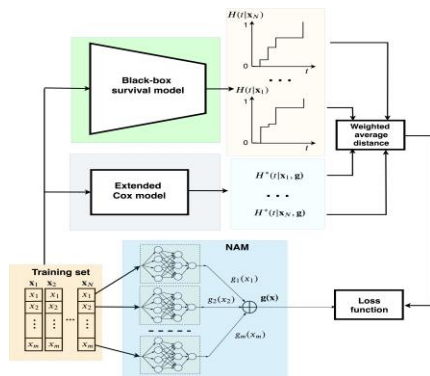
NAM (neural additive model)

$$\text{GAM: } g(\mathbf{x}) = g_1(x_1) + g_2(x_2) + \dots + g_m(x_m)$$




NAM: результаты (графики частичной зависимости)





$$L(\mathbf{W}, D) = \sum_{i=1}^N K(\mathbf{x}, \mathbf{x}_i) \sum_{j=0}^S \tau_j \ln H_j(\mathbf{x}_i) - \ln H_{0j} - \sum_{k=1}^m g_k(x_k^{(i)}) \quad 2$$

Неопределенность предсказаний



Неопределенность предсказаний - объяснение

