

(19)



Евразийское
патентное
ведомство

(11) 048036

(13) B1

(12) ОПИСАНИЕ ИЗОБРЕТЕНИЯ К ЕВРАЗИЙСКОМУ ПАТЕНТУ

(45) Дата публикации и выдачи патента
2024.10.22

(51) Int. Cl. G06N 3/02 (2006.01)
G06N 3/08 (2023.01)

(21) Номер заявки
202490592

(22) Дата подачи заявки
2024.03.14

(54) МОДЕЛЬ ПРЕДСКАЗАНИЯ ВРЕМЕННЫХ РЯДОВ, ОСНОВАННАЯ НА
МОДИФИЦИРОВАННОЙ АРХИТЕКТУРЕ TRANSFORMER

(43) 2024.10.10

(56) RU-C1-2744041
RU-C2-2755606
RU-C1-2702978
RU-C1-2600099
US-A1-20110066579
EA-A1-201990407

(96) 2024000054 (RU) 2024.03.14

(71)(73) Заявитель и патентовладелец:
ОБЩЕСТВО С ОГРАНИЧЕННОЙ
ОТВЕТСТВЕННОСТЬЮ
"АстонЛаб" (RU)

(72) Изобретатель:
Пономарев Андрей Александрович
(RU)

(74) Представитель:
Котлов Д.В. (RU)

(57) Изобретение относится к области прогнозирования значений временных рядов. Предложен способ перевода признаков, репрезентирующих временные ряды, в обновленный вид перед подачей в Encoder и Decoder слои. Данный способ позволяет обогащать временные ряды для нейронной сети как табличными данными, характеризующими весь временной ряд, так и данными, характеризующими отдельный момент во времени.

048036

B1

048036

B1

Область техники

Настоящее техническое решение относится к области вычислительной техники, в частности к способам прогнозирования значений временных рядов.

Уровень техники

Одним из способов получить выгоду из данных является прогнозирование временных рядов. Потребность в предсказании значений временных рядов наблюдается, например, в производстве. Модель применяется в целях прогнозирования температурных показателей устройств в производственном цехе. Её функционирование основано на анализе данных, полученных от других устройств в течение времени, а также учете разнообразных параметров производственного процесса.

Из уровня техники известно решение, выбранное в качестве наиболее близкого аналога, RU 2744041C1, опублик. 02.03.2021. В аналоге раскрыт способ прогнозирования значений временного ряда интересующей характеристики, основанный на использовании предварительно обучаемой искусственной нейронной сети (ИНС) прямого распространения, содержащей входной слой нейронов, как минимум один скрытый слой нейронов и выходной слой нейронов, для обучения которой записывают временной ряд исходных данных, выделяя отдельно ряд значений исследуемой характеристики и ряд моментов времени, строят искусственную нейронную сеть с начальным набором весовых синаптических коэффициентов, при этом для подготовки обучающей выборки искусственной нейронной сети (ИНС) создаются разбиения исходной временной шкалы ряда на временные интервальные отрезки различной длины, при этом для обучения ИНС используют три ряда: ряд значений момента времени конца отрезка, ряд приращений времени как разницы между значениями времени конца и начала интервального отрезка и ряд приращений самих известных значений временного ряда прогнозируемой характеристики на этом интервальном отрезке как разницы между ее значениями в моменты времени, соответствующие концу и началу интервального отрезка, причем в настоящей реализации изобретения два первых ряда используются как ряды обучающей выборки, а третий ряд - как ряд значений контрольной выборки, при этом после прохождения процедуры шифрования и преобразования в ряды метаданных, в соответствии с параметрами формирования входного сигнала ряды обучающей выборки или их части подаются в качестве входного сигнала прямого распространения при процедуре обучения ИНС, причем на первый нейрон входного слоя ИНС подается зашифрованное значение временной шкалы - моментов времени исходного временного ряда, соответствующее концу интервального отрезка определенного шага, а на второй нейрон входного слоя ИНС подается зашифрованное значение, соответствующее длине интервального отрезка, данного шага временного ряда, характеризующее приращение параметра времени, при этом контрольным сигналом является зашифрованное значение приращения прогнозируемой характеристики на временном интервале, с начальным и конечным моментами времени, соответствующих интервальному отрезку данного шага временного ряда, затем, после прохождения входного сигнала через ИНС прямого распространения, с ее выходного нейрона снимается выходной сигнал, вычисляется разность между выходным сигналом и контрольным сигналом, далее методом обратного распространения ошибки с использованием стандартного метода оптимизации, известного на данном уровне техники как метод градиентного спуска, производится корректировка весовых синаптических коэффициентов - обучение ИНС; далее с использованием трех основных параметров обучения, таких как скорость обучения, число циклов обучения с одинаковыми входным и контрольным сигналами и число эпох, представляющее из себя число повторяющихся «проходов» по всей длине подготовленной для обучения ИНС выборки комбинаций входных и контрольных сигналов, на ИНС вводятся все новые и новые данные путем сдвига двух первых рядов обучающей выборки и ряда контрольной выборки каждый раз на один шаг временного ряда, с каждым разом выполняя корректировку синаптических коэффициентов, что позволяет в результате получить корректировку набора синаптических весовых коэффициентов ИНС, обеспечивающих наиболее точный прогноз исследуемой характеристики; при этом для построения наиболее точного прогноза от обученной ИНС производят деление общего временного интервала, на котором требуются построение прогноза, на отрезки случайной длины, затем подаются зашифрованные значения моментов времени, соответствующие концам построенных интервальных отрезков случайной длины и зашифрованные значения длин самих интервальных отрезков в качестве приращения параметра времени - как сигналы входа ИНС, т.е. значениями, подающимися на первый и второй нейроны входного слоя обученной ИНС для построения прогноза, далее выходной сигнал ИНС с ее единственного выходного нейрона проходит расшифровку и перевод из метаданных в прогнозные значения характеристики на основе полученных прогнозных данных приращения этой характеристики.

Предлагаемое техническое решение направлено на устранение недостатков современного уровня техники и отличается от известных решений тем, что предложенный способ обеспечивает значительное улучшение качества прогнозирования непрерывных величин с помощью оптимизации структуры векторного пространства, которое строит модель.

Сущность изобретения

Технической проблемой, на решение которой направлено заявленное решение, является создание способа прогнозирования значений временных рядов. Дополнительные варианты реализации настоящего изобретения представлены в зависимых пунктах изобретения.

Технический результат заключается в повышении эффективности предоставления набора признаков временных рядов, что в дальнейшем обеспечивает эффективное обучение нейронной сети для прогнозирования значений рядов, например, предсказания температурных показателей устройств.

Заявленный результат достигается за счет осуществления способа прогнозирования значений временных рядов, включающего этапы, на которых на вход адаптированной модели Transformer подаются дополнительный набор признаков и набор значений прогнозируемого временного ряда t_{n-k}, \dots, t_{n-1} , причем модель осуществляет прогноз для значения t_n ; при этом для представления категориальных признаков целого временного ряда строят таблицы векторных представлений, где каждое отдельное векторное представление отражает значение категориального признака; для представления непрерывных признаков целого временного ряда конкатенируют все признаки и пропускают их через Feed-Forward Layer слой; для представления категориальных признаков отдельного события временного ряда строятся таблицы векторных представлений; для представления непрерывных признаков отдельного события временного ряда конкатенируют их и подают через отдельный Feed-Forward Layer слой.

В частном варианте реализации описываемого способа подаваемый в модель дополнительный набор признаков - это временные ряды или скалярные признаки.

Описание чертежей

Реализация изобретения будет описана в дальнейшем в соответствии с прилагаемыми чертежами, которые представлены для пояснения сути изобретения и никоим образом не ограничивают область изобретения. К описанию прилагаются следующие чертежи.

Фиг. 1 иллюстрирует поясняющий вид, на котором схематически изображена архитектура нейронной сети, используемая автором изобретения для обучения на задаче предсказания, с входными данными в Encoder и Decoder слои - набором временных рядов.

Фиг. 2 иллюстрирует поясняющий вид, на котором изображен слой построения эмбедингов, предложенный автором изобретения. На вход подаются временные ряды, их общие характеристики, а также характеристики отдельных моментов во времени.

Детальное описание изобретения

В приведенном ниже подробном описании реализации изобретения приведены многочисленные детали реализации, призванные обеспечить отчетливое понимание настоящего изобретения. Однако квалифицированному в предметной области специалисту, будет очевидно, каким образом можно использовать настоящее изобретение, как с данными деталями реализации, так и без них. В других случаях хорошо известные методы, процедуры и компоненты не были описаны подробно, чтобы не затруднять излишне понимание особенностей настоящего изобретения.

Кроме того, из приведенного изложения будет ясно, что изобретение не ограничивается приведенной реализацией. Многочисленные возможные модификации, изменения, вариации и замены, сохраняющие суть и форму настоящего изобретения, будут очевидными для квалифицированных в предметной области специалистов.

Изобретение относится к области прогнозирования значений временных рядов. Решение позволяет повысить эффективность прогнозирования рядов путем обучения модифицированной версии нейронной сети Transformer. Предложен способ перевода признаков, репрезентирующих временные ряды, в обновленный вид перед подачей в Encoder и Decoder слои. Данный способ позволяет обогащать временные ряды для нейронной сети как табличными данными, характеризующими весь временной ряд, так и данными, характеризующими отдельный момент во времени.

Таким образом, целью настоящего изобретения является повышение эффективности предоставления набора признаков временных рядов, что в дальнейшем обеспечивает эффективное обучение нейронной сети для прогнозирования значений рядов, например предсказания температурных показателей устройств.

В данном решении осуществляется обучение модели вида Transformer для предсказания будущих значений временных рядов, основываясь на наборе предыдущих значений (фиксированной длины). В изобретении предложена измененная версия модели, представленная в статье [1], которая может использоваться для обучения векторных представлений временных рядов путем обучения Encoder слоя (так называемой шифровкой временных рядов и отображения в многомерном векторном представлении) и Decoder слоя (так называемой дешифровкой многомерного векторного представления) для восстановления будущего значения временного ряда.

Первоначальная нейронная сеть обучается путем воспроизведения замаскированных токенов, определяя, являются ли временные ряды логической последовательностью, и используя функцию потерь, основанную на этих двух задачах. В данном изобретении, в свою очередь, осуществляется обучение нейронной сети на функции потерь MAE, где токены не маскируются. Также модифицируем способ отображения фичей временных рядов, предложенный в статье [2].

Первоначальная архитектура базируется на нейронной сети Transformer. Авторы Transformer сразу опубликовали модели, обученные на огромном количестве данных. Дальше эти модели можно дообучить для различных задач, например задача детекции сообщений на предмет наличия жалобы на сотрудника.

Позже эту модель начали использовать и для задач, связанных с временными рядами. Авторы архи-

тектуры, представленной в статье [1], которую автор изобретения модифицировал, адаптировали модель Transformer под унивариативные временные ряды.

Адаптированная версия принимает на вход не предложения из слов, а целые ряды, где каждый элемент - это значение в определенный момент во времени. Дальше входные ряды переводятся в векторные представления и проходят через несколько слоев кодировщиков, которые идут подряд. Кодировщик-слой состоит из механизма Self-attention [3], а также из слоя Position-wise Feed Forward [3]. Также используется residual connections [3] вокруг Self-attention и Position-wise Feed Forward, чтобы позволить проходить информации через несколько слоев подряд без потери данных и ускорения распространения градиента. Благодаря этому модель способна улавливать сложные зависимости между различными значениями и создавать более точные представления каждого значения во временном ряду. Данные нормализуются после каждого из двух residual connections с помощью Layer Normalization [4]. После слоево-кодировщиков полученное векторное представление вместе с набором последних значений временных рядов подается в слой-декодировщики. Декодировщик-слой также состоит из механизма Self-attention, Position-wise Feed Forward вместе с residual connections и Layer Normalization.

Помимо архитектуры, автор Transformer представляет способ обучения нейронной сети, основанный на двух задачах - определение взаимосвязи двух предложений по смыслу и воспроизведение замаскированных токенов. Авторы архитектуры для временных рядов отказываются от обеих задачи в пользу обучения воспроизведения будущих значений временных рядов и используют Huber Loss. Архитектура представлена на фиг. 1.

Входные данные в модель. Данные подаются в модель с одинаковыми размерами рядов. Каждый временной ряд состоит из:

- 1) категориальных параметров, представляющих целый временной ряд, к примеру тип производимой продукции;
- 2) непрерывных параметров, представляющих целый временной ряд, к примеру массу продукции;
- 3) категориальных параметров, представляющих отдельные моменты времени, к примеру булева переменная, отражающая факт начала процесса обработки в условный момент времени;
- 4) непрерывных параметров, представляющих отдельные моменты времени, к примеру температура в условный момент времени.

Формально,

$$U = [TCat_1, TCat_2, \dots, TCat_p, TNum_1, TNum_2, \dots, TNum_v, X_1, X_2, \dots, X_i, \dots, X_n]$$

$$X_i = [S(i); FCat_1(i); FCat_2(i); \dots; FCat_q(i); FNum_1(i); FNum_2(i); \dots; FNum_k(i)],$$

где каждый временной ряд U можно представить в виде набора из p категориальных параметров, представляющих целый временной ряд $[T_1, T_2, \dots, T_p]$, v непрерывных параметров, представляющих целый временной ряд $[TNum_1, TNum_2, \dots, TNum_v]$, и последовательности n событий $[X_1, X_2, \dots, X_i, \dots, X_n]$.

Каждое событие X_i , в свою очередь, характеризуется значением события $S(i)$, q категориальными параметрами $[FCat_1(i), FCat_2(i); \dots, FCat_q(i)]$ и k непрерывными параметрами $[FNum_1(i); FNum_2(i); \dots; FNum_k(i)]$.

Строим отдельный слой построения эмбеддингов, модифицируя предложенный в статье [2] вариант построения эмбеддингов.

Для представления категориальных параметров целого временного ряда строим таблицы векторных представлений, где каждый отдельный эмбеддинг (так называемое векторное представление) отражает значение категориальной фичи.

Для представления непрерывных параметров целого временного ряда конкатенируем все параметры и пропускаем их через Feed-Forward Layer [5].

Для представления категориальных параметров отдельного события временного ряда также строим таблицы векторных представлений.

Для представления непрерывных параметров отдельного события временного ряда также конкатенируем их и подаем через отдельный Feed-Forward Layer.

Также пропускаем все значения событий S через отдельный Feed-Forward Layer.

После произведенных операций все складываем, а также добавляем к входным данным Positional Encoding. Данный способ проиллюстрирован на фиг. 2.

Предложенное изобретение принадлежит к классу авторегрессионных моделей с дополнительными признаками. Таким образом, на вход модели отдается дополнительный набор признаков (таких как временные ряды или обычные скалярные признаки) и набор значений прогнозируемого временного ряда $tn-k, \dots, tn-1$. Модели необходимо построить прогноз для значения tn . Дополнительные признаки могут представлять собой временные ряды или быть обычными скалярными признаками. Они также могут быть дискретными или непрерывными.

Encoder-слои. Encoder-слои в архитектуре нейронной сети Transformer играют ключевую роль в обработке входных данных. В архитектуре Transformer используются повторяющиеся блоки, называемые "Encoder layers" или "Encoder blocks", которые обрабатывают входную последовательность. Каждый

Encoder-слой состоит из следующих основных компонентов:

- Self-Attention;
- Position-wise Feedforward Layer;
- Layer Normalization;
- Residual Connection.

К выходу из MultiHead Self-Attention и Position-wise Feedforward Networks применяются слои добавления и нормализации (например, Layer Normalization). Это помогает в более стабильном обучении модели. В каждом подблоке Encoder слоя используется субслой связи, который добавляет оригинальный вход к выходу сети. Это помогает в предотвращении затухания градиентов и улучшает обучение.

Transformer состоит из нескольких таких Encoder слоев, которые применяются последовательно. Каждый слой обрабатывает выход предыдущего слоя, постепенно извлекая более сложные признаки. Общая идея Encoder слоя в Transformer - эффективно обрабатывать входные последовательности, улавливая важные зависимости и позволяя модели работать с последовательностями переменной длины.

Описание механизма Self-attention. Self-attention - это механизм, который используется в нейронных сетях глубокого обучения для моделирования зависимостей между элементами в последовательности. Он работает путем вычисления весов для каждого элемента на основе его связи с другими элементами и использует эти веса для генерации нового представления элемента. Это позволяет моделировать зависимости между элементами и использовать эту информацию для решения различных задач, таких как предсказание будущих значений временных рядов.

Описание слоя Position-wise Feed Forward. Position-wise Feed Forward - это слой нейронной сети, который состоит из двух линейных преобразований с применением нелинейной функции активации между ними. Он применяется к каждому элементу входной последовательности отдельно (отсюда и название position-wise), без учёта контекста вокруг него.

Decoder-слои. Decoder-слои в архитектуре нейронной сети Transformer выполняют декодирование выходных последовательностей. На вход им подаются выходные данные encoder-слоев и новая последовательность. Включаем в новую последовательность последний момент времени, поданный в encoder-слои, а также произвольное количество моментов после последнего дня, поданного в encoder-слои d.

Они играют ключевую роль в задачах, таких как предсказание временных рядов, где требуется генерация последовательности на основе входных данных. Основные компоненты Decoder-слоя в Transformer:

- Self-Attention,
- Position-wise Feedforward,
- Layer Layer Normalization,
- Residual Connection.

Как и в Encoder, Transformer содержит несколько слоев Decoder, которые применяются последовательно для пошаговой генерации выходной последовательности. Decoder-слои в Transformer обеспечивают эффективное моделирование зависимостей внутри выходных последовательностей и взаимодействие с входными последовательностями для генерации правильных и качественных результатов.

Результаты экспериментов по предсказанию.

Для эксперимента возьмем открытый датасет от Walmart [6]. Датасет состоит из следующих колонок:

- Store - номер магазина,
- Dept - номер департамента,
- Date – дата,
- Weekly_Sales - недельные продажи,
- IsHoliday - был ли праздник в эту неделю,
- Size - размер магазина.

Также имеются следующие характеристики по каждой неделе:

- Temperature - средняя температура в данную неделю,
- Fuel_Price - стоимость бензина в регионе,
- CPI - индекс потребительских цен,
- Unemployment - показатель безработицы.

Данные представлены в период с 05.02.2010 по 26.10.2012.

Сравним предложенную модифицированную архитектуру Transformer с ее оригинальной версией, а также строим систему предсказания, изменяя лишь используемую нейронную сеть.

Для предобработки Weekly_Sales использовали Quantile Transformer. Для обучения использовали одну и ту же виртуальную машину (GPU: NVIDIA Tesla T4, ОЗУ: 16 ГБ). Конфигурация оригинальной нейронной сети представлена в табл. 1.

Таблица 1

Hidden Size	256
FeedForward Hidden Size	512
Encoder Layers Count	3
Decoder Layers Count	3
Self-attention Heads Count	8
Dropout Probability	0.2
Batch Size	128
Learning Rate	0.0001
Epoch Num	200
Optimizer	AdamW
Encoder Sequence Length	24
Decoder Sequence Length	2

Конфигурация модифицированной нейронной сети представлена на табл. 2.

Таблица 2

Hidden Size	256
Encoder-Decoder FeedForward Hidden Size	512
Embedding FeedForward Hidden Size	512
Encoder Layers Count	3
Decoder Layers Count	3
Self-attention Heads Count	8
Dropout Probability	0.2
Batch Size	128
Learning Rate	0.0001
Epoch Num	200

Используем одинаковые конфигурации сетей. В модифицированной версии добавляется параметр Embedding FeedForward Hidden Size, который описывает размер скрытого слоя FeedForward, в слое построения эмбедингов - используем ту же размерность скрытого слоя FeedForward, что и у Encoder-Decoder слоев. Результаты обучения моделей представлены в табл. 3.

Таблица 3

	MAE
Оригинальная архитектура Transformer	0.028
Архитектура Transformer с измененным слоем построения эмбедингов	<u>0.022</u>

Вычислительная система, способная обеспечивать обработку данных, необходимую для реализации заявленного решения, в общем случае содержит такие компоненты, как один или более процессоров, по меньшей мере одну память, средство хранения данных, интерфейсы ввода/вывода, средство ввода, средства сетевого взаимодействия. При исполнении машиночитаемых команд, содержащихся в оперативной памяти, конфигурируют процессор устройства для выполнения основных вычислительных операций, необходимых для функционирования устройства или функциональности одного или более его компонентов. Память, как правило, выполнена в виде ОЗУ, куда загружается необходимая программная логика, обеспечивающая требуемый функционал. При осуществлении работы предлагаемого решения выделяют объем памяти, необходимый для осуществления предлагаемого решения. Средство хранения данных может выполняться в виде HDD, SSD дисков, рейд массива, сетевого хранилища, флэш-памяти и т.п. Средство позволяет выполнять долгосрочное хранение различного вида информации, например вышеупомянутых файлов с наборами данных пользователей/пассажиров, базы данных, содержащих записи измеренных для каждого пользователя временных интервалов, идентификаторов пользователей и т.п. Интерфейсы представляют собой стандартные средства для подключения работы периферийных и прочих устройств, например USB, RS232, RJ45, COM, HDMI, PS/2, Lightning и т.п. Выбор интерфейсов зависит от конкретного исполнения устройства, которое может представлять собой персональный компьютер, мейнфрейм, серверный кластер, тонкий клиент, смартфон, ноутбук и т.п. В качестве средств ввода данных в любом воплощении системы, реализующей описываемый способ, может использоваться кла-

виатура. Аппаратное исполнение клавиатуры может быть любым известным: это может быть как встроенная клавиатура, используемая на ноутбуке или нетбуке, так и обособленное устройство, подключенное к настольному компьютеру, серверу или иному компьютерному устройству. Подключение при этом может быть как проводным, при котором соединительный кабель клавиатуры подключен к порту PS/2 или USB, расположенному на системном блоке настольного компьютера, так и беспроводным, при котором клавиатура осуществляет обмен данными по каналу беспроводной связи, например радиоканалу, с базовой станцией, которая, в свою очередь, непосредственно подключена к системному блоку, например к одному из USB-портов. Помимо клавиатуры, в составе средств ввода данных также может использоваться: джойстик, дисплей (сенсорный дисплей), проектор, тачпад, манипулятор мышь, трекбол, световое перо, динамики, микрофон и т.п. Средства сетевого взаимодействия выбираются из устройства, обеспечивающего сетевой прием и передачу данных, например Ethernet карту, WLAN/Wi-Fi модуль, Bluetooth модуль, BLE модуль, NFC модуль, IrDa, RFID модуль, GSM модем и т.п. С помощью средств обеспечивается организация обмена данными по проводному или беспроводному каналу передачи данных, например WAN, PAN, LBC (LAN), Интранет, Интернет, WLAN, WMAN или GSM. Компоненты устройства сопряжены посредством общей шины передачи данных.

Список источников информации, цитируемых в настоящем документе:

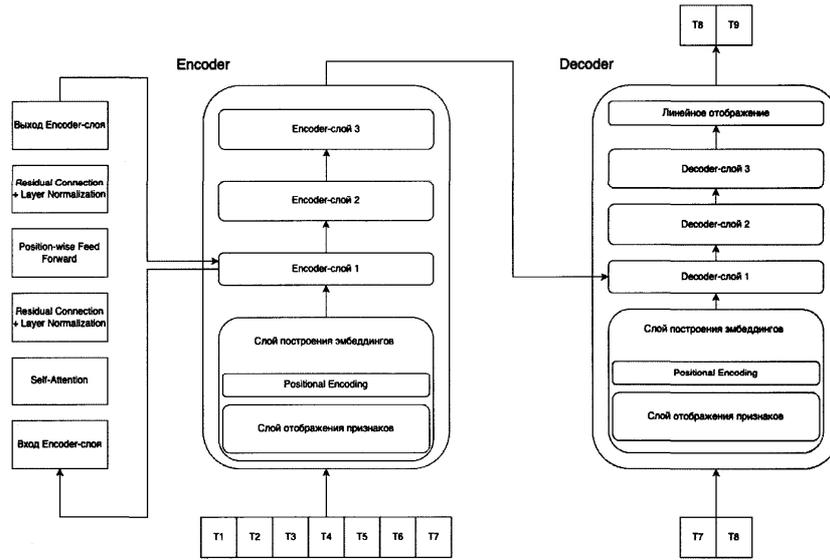
- [1] Wu, N., Green, B., Ben, X., & O'Banion, S. (2020). Deep Transformer Models for Time Series Forecasting: The Influenza Prevalence Case. ArXiv, abs/2001.08317.
- [2] Rajat Agarwal and Anand Muralidhar and Agniva Som and Hemant Kowshik, "Self-supervised Representation Learning Across Sequential and Tabular Features Using Transformers" in NeurIPS 2022 First Table Representation Workshop.
- [3] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N. Gomez, Lukasz Kaiser, and Illia Polosukhin. Attention Is All You Need. arXiv preprint arXiv:1706.03762, 2017.
- [4] Jimmy Lei Ba, Jamie Ryan Kiros, and Geoffrey E Hinton. Layer normalization. arXiv preprint arXiv:1607.06450, 2016.
- [5] G. Bebis and M. Georgiopoulos, "Feed-forward neural networks," in IEEE Potentials, vol. 13, no. 4, pp. 27-31, Oct.-Nov. 1994, doi: 10.1109/45.329294.
- [6] Walmart Store Sales Prediction - Regression Problem on Kaggle.

В настоящих материалах было представлено предпочтительное раскрытие осуществление заявленного технического решения, которое не должно использоваться как ограничивающее иные, частные воплощения его реализации, которые не выходят за рамки испрашиваемого объема правовой охраны и являются очевидными для специалистов в соответствующей области техники.

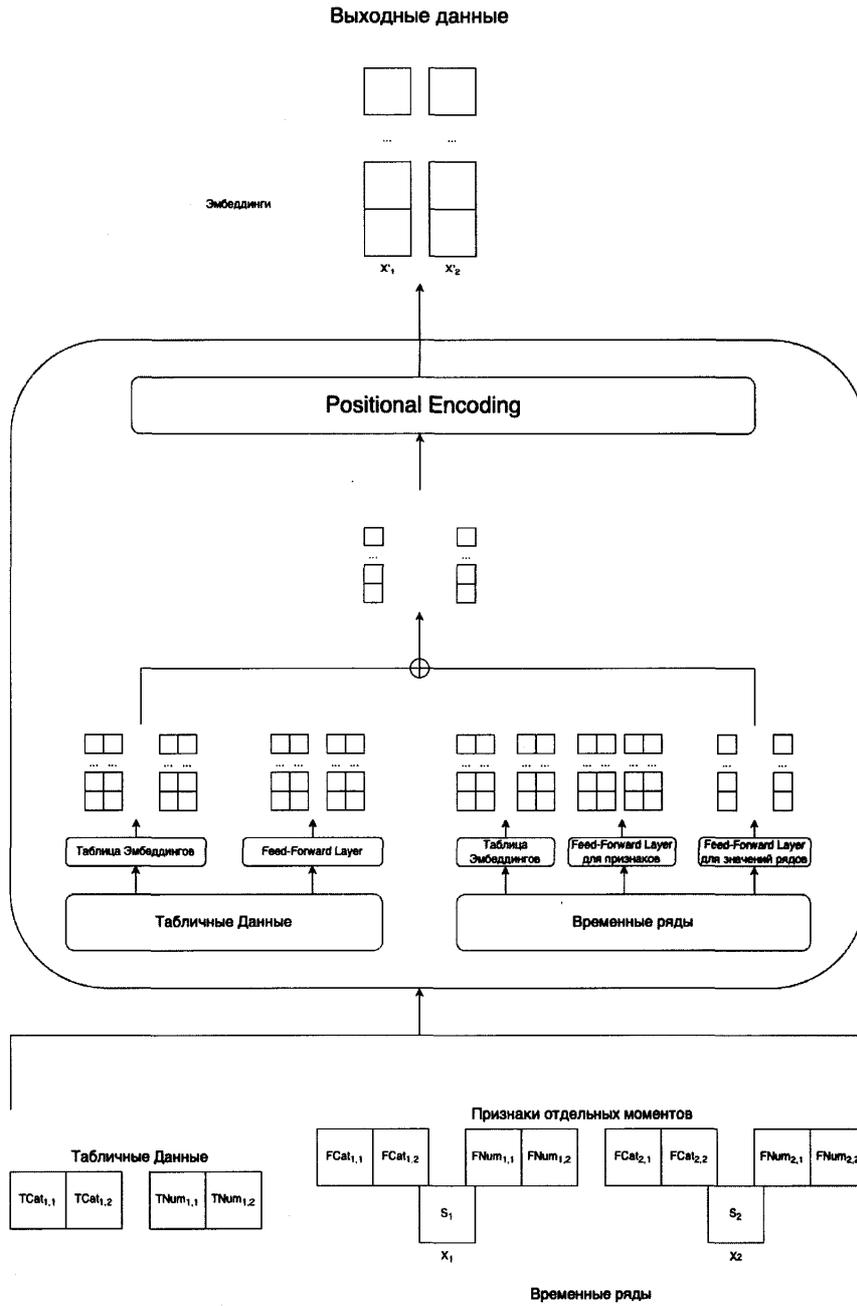
ФОРМУЛА ИЗОБРЕТЕНИЯ

1. Способ прогнозирования значений временных рядов, включающий этапы, на которых на вход адаптированной модели Transformer подают дополнительный набор признаков и набор значений прогнозируемого временного ряда t_{n-k}, \dots, t_{n-1} , причем модель осуществляет прогноз для значения t_n ; при этом для представления категориальных признаков целого временного ряда строят таблицы векторных представлений, где каждое отдельное векторное представление отражает значение категориального признака; для представления непрерывных признаков целого временного ряда конкатенируют все признаки и пропускают их через Feed-Forward Layer слой; для представления категориальных признаков отдельного события временного ряда строятся таблицы векторных представлений; для представления непрерывных признаков отдельного события временного ряда конкатенируют их и подают через отдельный Feed-Forward Layer слой.

2. Способ по п.1, в котором подаваемый в модель дополнительный набор признаков - это временные ряды или скалярные признаки.



Фиг. 1



Входные данные
Фиг. 2