

ПРИЧИННЫЙ ПОДХОД К ПОСТРОЕНИЮ БИОНИЧЕСКИХ ВЫЧИСЛЕНИЙ НА ОСНОВЕ РЕКУРСИВНЫХ МОДЕЛЕЙ АНАЛИЗА ДАННЫХ

Р. В. НАСЫРОВ

nrash@yandex.ru

ФГБОУ ВО «Уфимский государственный авиационный технический университет» (УГАТУ)

Поступила в редакцию 24 ноября 2021 г.

Аннотация. В рамках концепции причинного подхода рассматриваются рекурсивные модели и схемы анализа данных в форме последовательностей значений. Существующие методы, использующие рекуррентные схемы при обработке данных включают рекурсивный метод наименьших квадратов (МНК) и его производные, рекурсивные цифровые фильтры, рекурсивные искусственные нейронные сети. В отличие от известных методов рассматривается парадигма событийного ревербератора, порождающего последовательности событий и на его основе дается теоретическое обоснование рассмотрения данных в форме последовательностей значений как объектов, порождаемых повторяющимися процессами, которые можно представить в рекуррентной форме. Рассматривается возвратная рекурсия как модель бионических вычислений, позволяющая строить совокупность вычислительных схем, которые реализуют функцию усвоения простейших закономерностей, формирующую варибельность исходных данных представленных в форме последовательности значений. Практическое применение результатов исследований на основе предлагаемого подхода возможно в области технических и информационных компонентов, обладающих ограниченными ресурсами памяти и вычислительной мощности.

Ключевые слова: причинная парадигма; бионические вычисления; рекурсивные модели; анализ данных.

ВВЕДЕНИЕ

В различных областях деятельности специалисты явно или неявно опираются на эмпирические причинные представления в своей деятельности. Вместе с тем, научно обоснованное применение причинного подхода может быть продуктивно при решении широкого круга задач в разных предметных областях. Для этого необходимо рассмотреть идейные и теоретические основания причинных представлений, позволяющие построить продуктивные модели и алгоритмы обработки данных.

В философском смысле под причинной, или каузальной (от латинского слова *causa* –

«причина») связью понимается связь причины и действия (следствия). Состоит эта связь в том, что каждое явление природы и общества обязательно вызывается каким-либо другим явлением или явлениями. Находясь во всеобщей связи, всякое явление непременно обусловлено другими явлениями.

При этом причинная связь характеризуется особенностями [1]: наличие релевантно сопутствующих обстоятельств; причинная связь является всеобщей; причинная связь есть необходимая связь; причинная связь обладает свойством определенности и однозначности; причина и действие последовательны во времени.

В связи с достаточно универсальным характером причинных связей представляется важным разработка теоретических основ и практических подходов к использованию причинных представлений в составе методов анализа данных, описывающих объекты и процессы во времени. Они, как правило, представляются в форме последовательностей данных, временных рядов и т.д.

В связи с этим, цель работы заключается в разработке теоретических основ и основ математического аппарата анализа данных на основе причинной парадигмы.

Для этого необходимо решить следующие задачи: провести теоретическое обоснование причинного подхода к анализу данных; построить базовые модели анализа данных; исследовать свойство масштабной инвариантности предлагаемой модели анализа данных; исследовать возможность разложения функций по произвольному базису; исследовать возможность реализации рекурсивного разложения функций.

СОСТОЯНИЕ ВОПРОСА

Теоретические основания причинности, как правило, рассматриваются в философских и методологических работах, как в более ранних, например [2], так и более поздних [1]. Однако в таких работах дается только общеметодологическое описание и методы общего вида. При этом в них слабо представлены или не представлены совсем вопросы и примеры решения прикладных задач. Кроме того, в таких работах не обнаружены примеры использования рекуррентных моделей как инструмента представления причинных зависимостей и решения прикладных задач.

Подход к анализу данных на основе рекуррентных моделей достаточно часто обладает большой эффективностью по сравнению с нерекуррентными моделями, поскольку позволяет строить более компактные вычислительные схемы анализа данных. Кроме того они позволяют реализовать эффект «памяти» в таких схемах. Это позволяет получать не только теоретические результаты, но и обладает большей практической направленностью. В связи с этим рассмотрим ряд научных направлений.

Рассматривая классические задачи анализа данных и управления, в которых используется рекуррентный подход, выделим ряд наиболее интересных исследований. В работе [3] изложены накопленные результаты по методам рекуррентного оценивания, в частности, рекуррентный подход к методу наименьших квадратов и рекуррентной псевдолинейной регрессии. Представленные методы и алгоритмы направлены на применение в задачах анализа данных в реальном масштабе времени.

Примером более поздних исследований являются работы [4–8], которые развивают метод рекурсивного оценивания параметров наблюдения, в идейном смысле развивающий положения работы [3].

В работе [9] разрабатываются прикладные вопросы рекуррентного метода наименьших квадратов в направлении, заданном работой [3].

В работе [10] рассматриваются вопросы рекуррентной идентификации для решения задач адаптивного управления нестационарными объектами, что является достаточно существенным движением вперед по сравнению с работой [3].

Прикладные разделы теории управления дискретными системами исследуют рекурсивные модели под названием «рекурсивные фильтры» или фильтры с бесконечной импульсной характеристикой [11], подчеркивая или интересуясь в основном частотными функциями передачи дискретных сигналов.

Новая волна исследования с использованием рекуррентного подхода возникла на базе механизма искусственных нейронных сетей (ИНС). Отметим, что рекуррентные нейронные сети, как механизм, учитывающий динамику изменений, впервые предложены в работе [12]. Данный подход в терминах поиска структур во времени был развит в работе [13]. В настоящее время это направление получило достаточно интенсивное развитие как область новых приложений, так и разработки новых механизмов. Это можно наблюдать, например, в текущих публикациях [14, 15]. В работе [14] исследуются новые подходы к оценке возможных решений уравнений с использованием кон-

фигураций древовидной рекурсивной нейронной сети (Tree-RNN). В работе [15] представлено сравнение скрытых марковских моделей и рекурсивных нейронных сетей, чтобы выделить их преимущества и недостатки.

Еще одно направление развития предложено в работе [16] где описан новый вариант структуры рекуррентных нейронных сетей в форме долгой краткосрочной памяти. Это направление получило развитие в ряде исследований, среди которых упомянем представляющие интерес [17–19]. В первом из них предлагается адаптивный метод обновления памяти LSTM в соответствии с изменением входной последовательности на каждом временном шаге. Во втором исследовании рассматривалась задача описания последовательности событий с помощью сетей LSTM. В третьей статье исследуется применимость рекуррентных сетей долгой краткосрочной памяти (long short-term memory, LSTM) для бинарной классификации текстовых сообщений социальной сети Twitter. Еще одна работа в этом направлении [20] посвящена решению задачи глубокого обучения на базе механизма LSTM.

Таким образом, основные направления исследования представлены работами либо посвященными применению рекуррентных ИНС, либо направленными на решение задачи рекуррентной идентификации сложных динамических объектов.

Несмотря на то, что ИНС базируются на аналогии с биологическими нейронными сетями, необходимо отметить, что естественные реализации, как правило, не столь расточительны структурно к ИНС. Вместе с тем, они обладают более широкими адаптивными возможностями по сравнению с различными реализациями метода наименьших квадратов. Подход на основе рекурсивных фильтров предназначен только для анализа частотных свойств объекта исследования. Предлагается так же как в случае ИНС в качестве аналогии использовать биологические структуры центральной нервной системы, но в другой интерпретации, ближайшей из которых являются кортикальные колонки [21, 22]. В связи с этим

в работе предлагается использовать в качестве основы для описания бионических вычислений один из наиболее простых математических аппаратов. Поскольку предлагается оригинальное представление, то оно требует определенного теоретического и идейного обоснования.

ПРЕДЛАГАЕМЫЙ ПОДХОД

Причинные основания рекурсивных моделей. Начнем рассмотрение с известных фактов, опубликованных ранее. Система аксиом (предпосылок) причинного анализа, изложенная в работе [23], позволяет представить связь причины и следствия в виде орграфа, у которого вершинам соответствуют события, дугам – связи (или совместные области существования) событий, а направление дуги, обозначаемое стрелкой, соответствует направлению перехода от причины к следствию. В соответствии с аксиомами 4 и 5, дугам обязательно соотносятся характеристики исходных, вторичных или смежных событий и в соответствии с аксиомами 2 и 3, также в обязательном порядке дуге причинного графа сопоставляется один шаг относительного времени или такт времени – T . Это сразу приводит к представлению причинной взаимосвязи явлений в виде рекурсивной схемы (рекурсивного процессора).

Поскольку наблюдению доступны для восприятия только события настоящего и прошлого (если последние «записаны» в памяти), то очевидно, что память позволяет субъекту строить причинные последовательности, которые устойчиво повторяются и поэтому надежно фиксируются с ростом числа повторений.

Сказанное позволяет предложить в качестве общего теоретического аппарата исследования бионических вычислений математическую модель возвратной рекурсии [24].

Построим концептуальное обоснование. Для этого представим, что событиям соответствуют вершины некоторого графа, а переходам между ними – ориентированные ребра. Рассмотрим графы связей событий, описывающих множества следствий. Предварительно примем следующие предположения.

– Будем рассматривать причину – X в точке регенерации, то есть в такой области существования события-причины, в которой оно воспроизводится через некоторое (возможно очень большое) число причинных переходов. Причем эта регенерация события X осуществляется как с участием предшествующих событий в самой этой области, так и событий в смежных областях.

– Будем считать, что в соответствии с аксиомами 1–5 работы [23] событие-причина X порождает событие-следствие, которые могут находиться как в точке регенерации, так и вне ее. При этом причинное преобразование X в некоторое следствие в точке регенерации обозначим оператором R , а аналогичное преобразование X в событие-следствие в смежной области обозначим оператором P .

Таким образом, за один шаг преобразования X порождает событие RX в точке регенерации и событие PX в какой-либо смежной области существования событий.

Возможность влияния некоторого события Y , находящегося в смежной области на следствия в точке регенерации, обозначим оператором Q .

– Событие \bar{X} , где черта означает логическое отрицание («исчезновение» X , «все кроме» X), также является событием, порождаемым оператором типа R .

– Все причинные операторы будем считать некоммутативными, что следует из известных законов физики, описываемых либо функциональными, либо матричными преобразованиями, обладающими этими свойствами.

Учитывая принятые предположения и допущения, последовательные фазы причинных преобразований могут быть представлены следующими операторными графами (рис. 1).

Схема демонстрирует, что система событий, порождающая их последовательность в точке регенерации, является рекурсивной. Кроме того, наличие сложной системы обратных связей (операторы типа Q) позволяет считать схему возвратно-рекурсивной, если учесть, что каждый из операторов R , P и Q содержит неявно шаг (такт) времени, означающий реализацию преобразования. В зависимости от интер-

претации характера этих операторов возможно построение как детерминированных, так и вероятностных моделей.

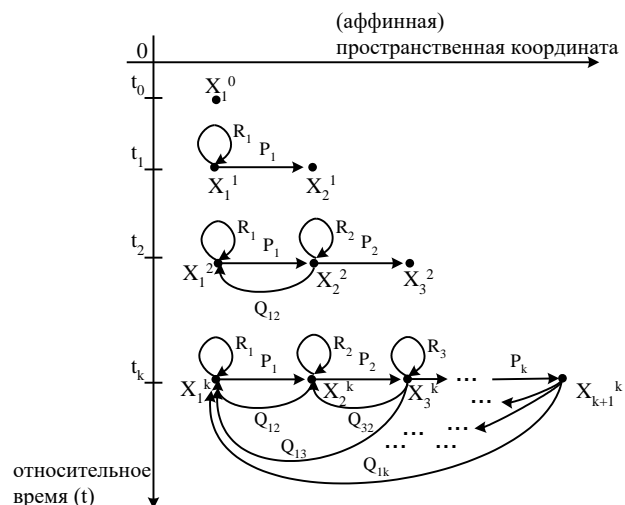


Рис. 1. Операторные графы причинных преобразований

Дальнейшее исследование на базе предложенных операторных графов можно продолжить, если дополнительно определить свойства причинных операторов, сопоставленных дугам.

Рассмотрим простейший вариант и ограничимся типовым случаем, когда все операторы линейны и некоммутативны. Первое свойство – линейности, наиболее естественно для причинных преобразований изучаемых естественными науками, которые при изучении связей всегда пользуются, хотя бы в первом приближении, линейными методами описания. Некоммутативность причинных операторов следует хотя бы из того факта, что многие (если не большинство) известных преобразований имеет характер математических функций. Например, количество выделенного в проводнике тепла (следствие) пропорционально квадрату тока в этом проводнике (причина): $Q = kI^2$. В то же время функциональные операторы не коммутативны ($\varphi(f(x)) \neq f(\varphi(x))$). Тем более некоммутативность характерна для преобразований событий, описываемых векторами параметров и линейными матричными операторами.

Исходя из изложенного и ограничив горизонт наблюдаемых событий (поскольку любая память конечна), можно записать матричную структуру причинного оператора в следующей форме.

$$\begin{pmatrix} x_1 \\ x_2 \\ \dots \\ x_k \end{pmatrix}_{n+1} = \begin{pmatrix} R_1 & Q_{12} & Q_{13} & \dots & \dots & Q_{1k} \\ P_1 & R_2 & Q_{23} & \dots & \dots & Q_{2k} \\ & P_2 & R_3 & \dots & \dots & Q_{3k} \\ & & P_3 & \dots & \dots & \dots \\ & & & \dots & \dots & Q_{k-1,k} \\ & & & & P_{k-1} & R_k \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \dots \\ x_k \end{pmatrix}_n \quad (1)$$

Выражение (1) можно конкретизировать, если использовать особенности информационной причинности [25, 26] характерной для живых систем. События здесь хранятся в памяти системы и поэтому можно принять $R_i = 0, i > 1; P_i = I, i = 1, \dots, k-1, Q_{ij} = 0, i > 1$, где I – единичный (тождественный) оператор (поскольку события перезаписываются).

В этом случае выражение (1) превращается в схему классической возвратной рекурсии, и может быть представлено в матричной форме [27].

$$\begin{pmatrix} x_1 \\ x_2 \\ \dots \\ x_k \end{pmatrix}_{n+1} = \begin{pmatrix} R_1 & Q_{12} & Q_{13} & \dots & \dots & Q_{1k} \\ 1 & & & \dots & \dots & \\ & 1 & & \dots & \dots & \\ & & 1 & \dots & \dots & \\ & & & \dots & \dots & \\ & & & & 1 & 0 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \dots \\ x_k \end{pmatrix}_n \quad (2)$$

От выражения (2) можно вернуться к графу возвратно-рекурсивной модели бионических вычислений, который представлен на рис. 2.




Рис. 2. Граф рекурсивной модели

Таким образом, адекватной моделью отражения бионических вычислений является возвратно-рекурсивная модель, матричная форма (2) которой соответствует канонической форме представления линейных систем [27–29]. Здесь важно отметить, что переходная матрица системы по форме является матрицей Фробениуса [30].

Таким образом, проблему отображения непрерывных динамических систем в дискретные предлагается на концептуальном уровне решать путем конструирования аналитической процедуры перехода от линейных дифференциальных уравнений к их возвратно-рекурсивным аналогам. Прототипы последних можно наблюдать в природе как самовозпроизводящиеся причинные цепи. Как указывалось выше, такой переход представляет собой сложную не полностью решенную проблему, рассмотрение которой предложено ниже.

Возвращаясь к алгебраической форме представления рекурсивных моделей бионических вычислений, отметим, что эта форма в математической литературе носит названия: возвратная последовательность [24, 27], разностное уравнение или разностная схема [31].

Возвратная рекурсия как модель бионических вычислителей для анализа данных. Для описания модели биологических вычислений в дальнейшем будет использоваться классическая форма возвратной рекурсии в виде, задаваемом линейным рекуррентным соотношением (3).

$$x_n = a_1 x_{n-1} + a_2 x_{n-2} + \dots + a_k x_{n-k} \quad (3)$$

Выражение (3) можно рассматривать, как разностное уравнение с общим видом

$$\sum_0^k b_i x_{n-i} = 0; \quad \left(a_i = -\frac{b_i}{b_0}, i > 0 \right).$$

Такому представлению соответствует решение, выражаемое в примитивно рекурсивной форме (4) [27]. При этом значение x_n явно выражается через значения номера шага, как сумма квазимногочленов от n :

$$x_n = \sum_{l=1}^m \lambda_l^n p_l(n), \quad (4)$$

где λ_l – корни характеристического уравнения:

$$\lambda^k + a_1\lambda^{k-1} + a_2\lambda^{k-2} + \dots + a_k = 0,$$

а $p_l(n)$ – полином степени меньше l , где l – кратность корня λ_l .

Выражения (3) и (4) совместно можно рассматривать как форму представления рекурсивных функций заданного вида. Эта форма обладает рядом особенностей, например, в работе [24] утверждается, что выражение

$$u_{n+k} = C_k^{k-1}u_{n+k-1} - C_k^{k-2}u_{n+k-2} + \dots + (-1)^{k-1}C_k^0u_n, \quad (5)$$

воспроизводит последовательность k -х степеней натуральных чисел $\{u_n^k\}$. Однако, выражение (5) и его свойства представляют интерес, как объект представления и изучения процессов бионических вычислений.

Для этого рассмотрим выражение (5), как разностное уравнение, что позволяет выявить следующие особенности. Во-первых, его решение зависит только от набора фиксированных коэффициентов $C_k^0, C_k^1, \dots, C_k^{k-1}$ и, во-вторых, вид решения (4) не зависит от начальных условий, то есть от того, какие числа последовательности $u_{n+k-1}, u_{n+k-2}, \dots, u_n$ подставить в (5), чтобы продолжить вычисления следующих членов последовательности. Следовательно, если рассматривать (4) и (5) как две формы задания значений одной и той же функции, то при любых, даже случайных числах $u_{n+k-1}, u_{n+k-2}, \dots, u_n$ общий вид функции u_n типа (4) не изменится. Таким образом, любая произвольная последовательность может быть представлена квазимногочленом детерминированного вида.

Практическая реализация (5) позволяет построить один из вариантов моделей бионических вычислителей для анализа данных. При этом общие требования к компонентам формулируются следующим образом. В составе схемы вычисления:

1. Должен быть реализован конвейерный полифункциональный преобразователь данных с оперативной памятью (регистрами или кэшем), хранящей набор значений $\{u_{n+k-1}, u_{n+k-2}, \dots, u_n\}$.

2. Должна быть реализована система обратных связей с коэффициентами передачи связей равными коэффициентам возвратной последовательности

$$u_{n+k} = a_1u_{n+k-1} + a_2u_{n+k-2} + \dots + a_ku_n. \quad (6)$$

Значения в преобразователе данных [32] перемещаются в порядке поступления, а выбранные из ячеек памяти значения, масштабированные соответствующими коэффициентами, суммируются во входной ячейке преобразователя (точке регенерации).

3. Все операции преобразователя данных синхронизируются так, что общий цикл вычисления всех $\{u_i\}$, входящих в (6), занимает один такт времени T (рассматриваемый как запаздывание).

Реализация этих общих требований к бионическим вычислителям для анализа данных позволяет построить класс устройств, автоматически решающих разнообразные задачи, то есть самопроизвольно преодолевающих неопределенность этих задач. Это возможно благодаря тому, что вычислительные структуры, соответствующие выражениям (5), (6), обладают определенными свойствами.

Прямое сравнение выражений (5) и (6) показывает, что первое из них является разностным уравнением с постоянными коэффициентами $\{C_k\}$, при этом во второе входят коэффициенты $\{a_k\}$, которые в общем случае могут быть функциями от параметров или номера шага рекурсии.

При постоянных коэффициентах возвратно-рекурсивные схемы проявляют способность усваивать некоторые закономерности в поведении последовательности величин, составляющих временные ряды. Использование функционально-зависимых коэффициентов существенно расширяет круг таких зависимостей за счет усложнения процедуры идентификации.

В контексте модели бионических вычислителей отметим, что важнейшим для биосистем является возможность выявить как смену закономерности событий внешнего окружения, так и закономерность такой смены. Это означает, что система, реализующая такую схему вычисления, должна уметь усваивать жизненно важные закономерности в наблюдаемых явлениях и процессах. Признаки успешного усвоения закономерностей хорошо описаны в работе [33].

Например, можно считать, что закономерность усвоена, если:

а) при сообщении обучаемой системе имени или предъявления её части (обучающей последовательности) значений она может быть построена или воспроизведена этой системой полностью;

б) при предъявлении этой закономерности она может быть правильно (адекватно) описана обучаемой системой или распознана;

в) система может произвольно использовать известную ей закономерность, манипулируя последней по мере необходимости.

Легко убедиться, что система, реализующая вычисления по формуле (5), удовлетворяет приведенным критериям.

Возьмем, например, частный случай (5) вида

$$x_{n+1} = 2x_n - x_{n-1}. \quad (7)$$

Если подставить в правую часть любые два числа, то они будут «восприняты» системой (7) как последовательные значения полинома первой степени $x_n = C_1n + C_2$, степень которого меньше кратности $\nu = 2$ корня характеристического уравнения: $\lambda^2 - 2\lambda + 1 = 0$.

Действительно легко проверить, что независимо от значений коэффициентов C_1 и C_2 .

$$\begin{aligned} x_{n+1} &= 2(C_1n + C_2) - (C_1(n-1) + C_2) = \\ &= 2nC_1 + 2C_2 - nC_1 + C_1 - C_2 = \\ &= nC_1 + C_1 + C_2 = C_1(n+1) + C_2. \end{aligned} \quad (8)$$

Аналогично показывается способность схемы воспроизводить зависимость $x_n = \text{const}$. Это говорит о способности схемы (7) выполнить тест а).

Слегка изменив (7) и представляя его в более общем виде

$$x_{n+1} = g_n x_n - x_{n-1},$$

где g_n – некоторый переменный коэффициент, можно по любым предъявленным трем равноотстоящим отсчетам зависимости определить, распознать тип зависимости. Действительно, определим g_n как

$$g_n = \frac{x_n - x_{n-1}}{x_{n+1}}.$$

Легко понять, что $g_n = 2$ только для линейной последовательности (это очевидно из сравнения (7) и (8)). Отличия g_n от двух свидетельствуют об отклонении, предъявленной закономерности от линейной. Таким образом, рекурсивные схемы вида (7), (8) выполняют тест б).

Рассматривая внимательно (7), легко заметить, что схема обратима, то есть она работает независимо от того, в какой последовательности вводятся x_{n-1} и x_n .

Действительно из (7) следует также, что

$$x_{n-1} = g_n x_n - x_{n+1},$$

то есть с помощью (7), можно восстанавливать линейные последовательности как в прямом, так и в обратном направлении по любым двум ее точкам. Это говорит о выполнении теста в).

Таким образом, схемы возвратной рекурсии способны усваивать закономерности, заключенные в отрезках последовательности отсчетов, что можно интерпретировать как способность обучаться в беспорядочном режиме с первого предъявления. Предполагается далее, что механизмы такого типа, реализующие бионические вычисления, обладают уникальной способностью. Подобные механизмы могут лежать в основе той гибкости и разнообразия, которые характерны для процессов обучения мозга человека и животных. На базе таких механизмов они способны воспроизводить действия, которые им просто показаны или продемонстрированы, и усваиваются путем подражания. Причем, как известно эта способность подражать как правило тем выше, чем выше уровень организации нервной системы [34].

Такие представления позволяют осуществить технические реализации вычислительных алгоритмов и устройств, которые мы будем называть *бионическими рекурсивными процессорами*, имея в виду их довольно широкие возможности по решению задач анализа зависимостей, прогноза, моделирования. Отметим, что форма возвратной последовательности (3) соответствует алгоритму вычисления значения текущего члена последовательности на основе предыдущих значений на одном шаге рекурсии. Покажем

это следующим образом. Очевидно, что (3) легко представить в матричной форме, при которой один шаг вычисления имеет вид [27] (9).

$$\begin{bmatrix} x_n \\ x_{n-1} \\ \dots \\ x_{n-k+1} \end{bmatrix} = \begin{bmatrix} a_1 & a_2 & \dots & a_k \\ 1 & & & \\ & 1 & & \\ & & \dots & \\ & & & 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} x_{n-1} \\ x_{n-2} \\ \dots \\ x_{n-k} \end{bmatrix}. \quad (9)$$

С этой точки зрения выражение (3) можно понимать, как превращение на шаге i последовательности (вектора) $(x_{n-1} \div x_{n-k})$ длины k в последовательность $(x_n \div x_{n-k+1})$ также длины k , а затем подстановки нового вектора в правую часть. Иначе говоря, при матричном преобразовании k -шаговая скалярная возвратная рекурсия превращается в одношаговую векторную (рекуррентную формулу). Например, схема (7) дает выражение

$$\begin{bmatrix} x_{n+1} \\ x_n \end{bmatrix} = \begin{bmatrix} 2 & -1 \\ 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} x_n \\ x_{n-1} \end{bmatrix} \quad \text{в прямом}$$

направлении и $\begin{bmatrix} x_n \\ x_{n-1} \end{bmatrix} = \begin{bmatrix} 2 & -1 \\ 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} x_{n+1} \\ x_n \end{bmatrix}$ - в обратном.

ЗАКЛЮЧЕНИЕ

Таким образом, в результате сформированы теоретические основания анализа данных на основе причинного подхода и разработаны основы математического аппарата на основе возвратной рекурсии.

Для этого сформулировано теоретическое обоснование подхода к анализу данных на основе причинных представлений, отличающееся интерпретацией и позволяющее построить модели анализа данных на новых основаниях.

Кроме того, построены базовые модели анализа данных на основе линейных рекуррентных соотношений, отличающихся простотой формирования и позволяющие использовать их программные реализации в системах с ограниченным ресурсами.

СПИСОК ЛИТЕРАТУРЫ

1. **Войшвилло Е. К., Дегтярев М. Г.** Логика: учеб. для студ. высш. учеб. заведений. М.: ВЛАДОС-ПРЕСС, 2001. 528 с. [E. K. Voishvillo, M. G. Degtyarev, *Logic: Textbook for stud.*

higher. study. Institutions, (in Russian). Moscow: VLADOS-PRESS, 2001.]

2. **Heise D. R.** Causal analysis. New York: A Wiley inter-science publishing, 1975. 301 p.

3. **Ljung L.** System Identification: Theory for the User. Sweden: Prntice-Hall, 1987. 609 p.

4. **Волынский М. А.** Обработка сигналов в оптической когерентной томографии с использованием рекурсивной обратной свертки / под ред. В. В. Тучина [и др.] // Проблемы оптической физики и биофотоники. Саратов: Новый ветер, 2009. С. 33–37. [M. A. Volynsky, "Optical Coherence Tomography Signal Processing Using Recursive Inverse Convolution", (in Russian), in *Problems of Optical Physics and Biophotonics*. V. V. Tuchina, et al. (eds.). Saratov: Novyy veter, 2009.]

5. **Дмитриева Е. Л, Волынский М. А.** Исследование характеристик алгоритма на основе рекуррентного метода наименьших квадратов для динамической обработки интерферометрических сигналов / Гл. ред. В. О. Никифоров // Сборник тезисов докладов конференции молодых ученых. Выпуск 2. Труды молодых ученых. СПб.: СПбГУ ИТМО, 2011. С. 154. [E. L. Dmitrieva, M. A. Volynsky, *Investigation of the characteristics of the algorithm based on the recurrent least squares method for dynamic processing of interferometric signals*, (in Russian), in *Collection of abstracts of the conference of young scientists, Issue 2. Proceedings of young scientists*. O. F. Nikiforov (ed.-in-chief). Saint Petersburg: SPbGU ИТМО, 2011.]

6. **Волынский М. А.** Рекуррентные алгоритмы обработки данных в оптической когерентной томографии: автореф. дис. ... канд. техн. наук: 05.13.01. Санкт-Петербург, 2013. 20 с. [M. A. Volynsky, *Recurrent algorithms for data processing in optical coherence tomography*: D.E.S. diss. Abstr., (in Russian). Saint Petersburg, 2013. 20 p.]

7. **Волынский М. А., Гуров И. П.** Рекуррентная обработка данных в спектральной оптической когерентной томографии на основе фильтрации Калмана // Научно-технический вестник информационных технологий, механики и оптики. 2013. № 2 (84). С. 40–44. [M. A. Volynsky, I. P. Gurov, "Recurrent data processing in spectral optical coherence tomography based on Kalman filtering", (in Russian), in *Nauchno-tehnicheskij vestnik informacionnyh tehnologij, mehaniki i optiki*, no. 2 (84), pp. 40-44, 2013.]

8. **Волынский М. А., Гуров И. П.** Метод динамической обработки данных в спектральной оптической когерентной томографии компенсацией влияния дисперсии // Научно-технический вестник информационных технологий, механики и оптики. 2013. № 6 (88). С. 50–55. [M. A. Volynsky, I. P. Gurov, "The method of dynamic data processing in spectral optical coherence tomography by compensating for the effect of dispersion", (in Russian), in *Nauchno-tehnicheskij vestnik informacionnyh tehnologij, mehaniki i optiki*, no. 6 (88), pp. 50-55, 2013.]

9. **Воевода А. А., Трошина Г. В.** Рекуррентный метод оценивания параметра в динамическом объекте // Научный вестник НГТУ. 2016. Т. 65, № 4. С. 7–18. [A. A. Voevoda, G. V. Troshina, "Recurrent method for estimating a parameter in a dynamic object", (in Russian), in *Nauchnyj vestnik NGTU*, vol. 65, no. 4, pp. 7-18, 2016.]

10. **Жиров М.В., Макаров В.В.** Рекуррентная идентификация в задачах адаптивного управления нестационарными объектами // XIII Всероссийское совещание по проблемам управления ВСПУ-2019 (Москва, 17–20 июня 2019).

М.: Институт проблем управления им. В. А. Трапезникова РАН, 2019. С. 491–496. [M. V. Zhirov, V. V. Makarov, "Recurrent identification in the problems of adaptive control of non-stationary objects", (in Russian), in *XIII All-russian meeting on problems of control (VSPU-2019)*, 2019, pp. 491-496.]

11. **Hamming R. W.** Digital filters. Englewood cliffs, New Jersey: Prentice-hall, 1977. 226 p.

12. **Jordan M. I.** Serial order: A parallel distributed processing approach // Institute for Cognitive Science Report 8604. San Diego: University of California, 1986.

13. **Elman J.** Finding structure in time // Cogn. Sci. 1990. Vol. 14. Pp. 179-211. DOI: 10.1207/s15516709cog1402_1.

14. **Solving Arithmetic Word Problems by Scoring Equations with Recursive Neural Networks / K. Zaporjets, et al. // Expert Systems with Applications. 2021. Vol. 174. Article number: 114704. DOI: 10.1016/j.eswa.2021.114704.**

15. **Talarico E., Leao W., Grana D.** Comparison of Recursive Neural Network and Markov Chain Models in Facies Inversion // Mathematical Geosciences. 2021. Vol. 53, Iss. 3. Pp. 395-413. DOI: 10.1007/s11004-020-09914-w.

16. **Hochreiter S., Schmidhuber J.** Long short-term memory // Neural Computation. 1997. Vol. 9, no. 8. Pp. 1735-1780. DOI: 10.1162/neco.1997.9.8.1735.

17. **Huang P.** Exploration of event segmentation theory using LSTM // Thesis submitted in partial fulfillment of the requirements for the degree Master of Science. Tübingen, 2016. 24 p.

18. **Исследование** применимости рекуррентных сетей LSTM в задаче поиска пользователей-экспертов социальных сетей / П. И. Банюкин [и др.] // Программные системы и вычислительные методы. 2017. № 4. С. 53–60. [P. I. Banokin, et al., "Investigation of the applicability of recurrent LSTM networks in the problem of finding users-experts of social networks", (in Russian), in *Programmnye sistemyi vychislitelnye metody*, no. 4, pp. 53-60, 2017.]

19. **ALSTM: Adaptive LSTM for Durative Sequential Data / D. Niu, et al. // 2018 IEEE 30th International Conference on Tools with Artificial Intelligence. 2018. Pp. 151-157. DOI 10.1109/ICTAI.2018.00032.**

20. **Fu L.** Time Series-oriented Load Prediction Using Deep Peephole LSTM // 12th International Conference on Advanced Computational Intelligence. 2020. Pp. 86-91. DOI: 10.1109/ICACI49185.2020.9177688.

21. **Mountcastle V. B.** Modality and topographic properties of single neurons of cat's somatic sensory cortex // Journal of Neurophysiology. 1957. Vol. 20, Iss. 4. Pp. 408-434. DOI: 10.1152/jn.1957.20.4.408.

22. **Hubel D. H., Wiesel T. N.** Shape and arrangement of columns in cat's striate cortex // J. Physiol. 1963. Vol. 165, Iss. 3. Pp. 559-568. DOI: 10.1113/jphysiol.1963.sp007079.

23. **Бакусов Л. М.** Методы и модели причинно-структурного анализа в исследовании самоорганизующихся систем. М.: Машиностроение, 2005. (Уфа : Уфимский полиграфический комбинат, 2005). 227 с.: ил., табл. [L. M. Bakusov, *Methods and models of cause-structural analysis in the study of self-organizing systems*, (in Russian). Moscow: Mashinostroenie, 2005. (Ufa : Ufimskij poligraficheskij kombinat, 2005).]

24. **Маркушевич А. И.** Возвратные последовательности. М.: Наука, 1983. 48 с. [A. I. Markushevich, *Recurrent sequences*, (in Russian). Moscow: Nauka, 1983.]

25. **Урсул А. Д.** Отражение и информация. М.: Политиздат, 1973. 233 с. [A. D. Ursul, *Reflection and information*, (in Russian). M.: Politizdat, 1973. 233 p.]

26. **Бакусов Л. М., Насыров Р. В., Лебедев Е. Г.** Причинный анализ для принятия решений. Уфа: УГАТУ, 1993. 96 с. [L. M. Bakusov, R. V. Nasyrov, E. G. Lebedev, *Causal analysis for decision-making*, (in Russian). Ufa: UGATU, 1993.]

27. **Арнольд В. И.** Обыкновенные дифференциальные уравнения. М.: Наука, 1971. 240 с. [V. I. Arnold, *Ordinary differential equations*, (in Russian). Moscow: Nauka, 1971.]

28. **Porter W. A.** Modern foundation of system engineering. New York: The MacMillan Company, 1966. 493 p.

29. **Теория** автоматического управления / под ред. А. А. Красовского. М.: Наука. Гл. ред. Физ.-мат. лит., 1987. 712 с. [A. A. Krasovsky (ed.), *Theory of automatic control*, (in Russian). Moscow: Nauka. Gl. red. Fiz.-mat. lit., 1987.]

30. **Гантмахер Ф. Р.** Теория матриц. М.: Физматлит, 2010. 558 с. [F. R. Gantmakher, *Matrix theory*, (in Russian). Moscow: Fizmatlit, 2010.]

31. **Korn G. A., Korn T. M.** Mathematical handbook. New York: McGraw Hill Company, 1968. 1129 p.

32. **Прангишвили И. В., Пащенко Ф. Ф., Бусыгин Б. П.** Системные законы и закономерности в электродинамике, природе и обществе. М.: Наука, 2001. 525 с.: ил. [I. V. Prangishvili, F. F. Pashchenko, B. P. Busygin, *System laws and patterns in electrodynamics, nature and society*, (in Russian). Moscow: Nauka, 2001.]

33. **Бакусов Л. М., Сафин Ш. М., Насыров Р. В.** Компарментные модели нейронных механизмов усвоения закономерностей на основе теории самообучающихся рекурсивных фильтров // Вестник новых медицинских технологий. 2002. Т. 9, № 3. С. 72–75. [L. M. Bakusov, Sh. M. Safin, R. V. Nasyrov, "Compartmental models of neural mechanisms of assimilation of regularities based on the theory of self-learning recursive filters", (in Russian), in *Vestnik novykh medicinskih tehnologij*, no. 3, pp. 72-75, 2002.]

34. **Краткий** психологический словарь. М.: Политиздат, 1985. 431 с. [*A Brief Psychological Dictionary*, (in Russian). Moscow: Politizdat, 1985.]

ОБ АВТОРЕ

НАСЫРОВ Рашит Вильевич, доц. каф. ТК. Дипл. Инж.-системотехник (УАИ, 1989). Канд. техн. наук по автоматизированным системам принятия решений (УГАТУ, 1994). Канд. фарм. наук по моделям и технологиям лекарственного обеспечения в чрезвычайных ситуациях (РУДН, 2005). Иссл. в обл. обработки экспериментальных и статистических данных, функциональная биомеханика, имитационное и математическое моделирование систем и процессов, модели и алгоритмы обеспечения принятия решений.

METADATA

Title: A causal approach to the construction of bionic calculations based on recursive data analysis models.

Author: R. V. Nasyrov

Affiliation: Ufa State Aviation Technical University (UGATU), Russia.

Email: nrash@yandex.ru.

Language: Russian.

Source: SIIT (scientific journal of Ufa State Aviation Technical University), vol. 4, no. 1 (8), pp. 27-36, 2022. ISSN 2686-7044 (Online), ISSN 2658-5014 (Print).

Abstract: Within the framework of the concept of the causal approach, recursive models and data analysis schemes in the form of sequences of values are considered. Existing methods using recursive schemes in data processing include recursive OLS and its derivatives, recursive digital filters, and recursive artificial neural networks. In contrast to the well-known methods, the paradigm of the event re-verberator is considered, which generates a sequence of events, and on its basis, a theoretical justification is given for considering data in the form of sequences of values as objects generated by repeated processes that can be represented in a recurrent form. The reverse recursion is considered as a model of bionic computations, which allows constructing a set of computational schemes that implement the function of assimilating the simplest regularities that form the variability of the initial data presented in the form of a sequence of values. Practical application of the research results based on the proposed approach is possible in the field of technical and information components with limited resources of memory and computing power.

Key words: causal paradigm; bionic computing; recursive models; data analysis.

About author:

NASYROV, Rashit Vilyevich, Assoc. Prof., Dept. of TC. Dipl. Systems Engineer (UAI, 1989). Cand. of Tech. Sci. on automated decision-making systems (USATU, 1994). Cand. of Farm. Sci. on models and technologies of pharmaceutical provision in emergency situations (RUDN, 2005). Research in the field of experimental and statistical data processing, functional biomechanics, simulation and mathematical modeling of systems and processes, models and algorithms for providing solutions.