

УДК 004.02+303.4.

А.Б. Иващенко (аспірант)

Донецкий национальный технический университет
alesya_iva@list.ru

ТРАДИЦИОННЫЕ И СОВРЕМЕННЫЕ ПОДХОДЫ В ПРОГНОЗИРОВАНИИ ВРЕМЕННЫХ РЯДОВ

Рассмотрены классификационные схемы методов прогнозирования, встречаемые в научной литературе. Описаны традиционные методы прогнозирования временных рядов. Представлены преимущества и недостатки таких методов. На основании обзора научных работ, выполненной за последнее десятилетие, проведен анализ современных подходов, используемых в прогнозировании сложных систем.

Ключевые слова: прогнозирование, временной ряд, достоинства и недостатки, интеллектуальный анализ, нелинейная динамика, регрессионная модель

Введение

Одна из важнейших целей анализа временных рядов (ВР) – построение прогнозов. Непрерывающееся развитие и усовершенствование старых методов, разработка гибридных и принципиально новых подходов, спрос на создание эффективных аналитических прогнозных систем связаны с постоянным наличием неустраняемых проблем в теории прогнозирования, которые не дают ученым остановиться на достигнутом. В работе [1] они описываются так.

Первая – это определение необходимых и достаточных параметров для оценки состояния исследуемого процесса, а также целевых функций, т.е. выбор критериев эффективности действий.

Вторая проблема – это проблема размерности. Желание учесть в модели как можно больше показателей и критериев оценки может привести к нереализуемым практически вычислительным сложностям.

Третья проблема возникает в силу проявления надсистемности. Известно, что взаимодействующие системы образуют надсистему – систему более высокого уровня, обладающую собственными свойствами, которых не имеют составляющие её системы. Проблема заключается в принципиальной невозможности выявить указанные проявления надсистемного отображения при анализе взаимодействующих систем.

Последнее десятилетие – это начало активного изучения и переосмысливание вопросов математического моделирования сложных процессов и систем. Пришедшие на смену классическим новые подходы к прогнозированию появились именно с целью преодоления некоторых из перечисленных проблем. Эти подходы базируются на применении

разделов современной математики: нейроинформатика, теория стохастического моделирования (теория динамического хаоса), теория катастроф, синергетика, интеллектуальный анализ данных и теория самоорганизующихся систем. Считается, что эти методы позволят увеличить глубину прогноза для сложных систем за счет выявления скрытых закономерностей, присущих таким системам. Исследованию этих вопросов посвящены работы В. Б. Занга, Б. Мандельброта, Э. Петерса, А. И. Пригожина, Э. Сигела, Г. Г. Малинецкого, А. А. Меклера, Н. Г. Макаренко, Д. А. Смирнова, Б. П. Безручко, А. Г. Белякова.

Большой вклад в развитие исследований временных рядов внесли труды таких зарубежных ученых, как Х. Акаике, А. Андерсон, Д. Бокс и Г. Дженкинс, Р. Браун, В. Виллингер, Н. Виннер, О. М. Кендел, Ф. Такенс. В бывшем СССР также проводились серьезные прогностические исследования. Отметим труды известных советских и российских ученых: С. А. Айвазяна, В. Н. Вапника, Л. В. Канторовича, В. А. Кардаша, Ю. П. Лукашина, В. И. Максименко, А. В. Морозова, Н. П. Федоренко, Е. М. Четыркина. Большое внимание уделяется моделированию по временным рядам и в работах украинских ученых – в трудах П. И. Бидюка, В. С. Дейнеки, А. Г. Ивахненко, И. Н. Ляшенко, В. С. Степашко.

При большом числе серьезных работ, широте исследований, обилии полученных в прогнозировании результатов, по-прежнему находятся разделы прогностической науки, в которых новые методы могут улучшить решение, сделать его более универсальным, конструктивным и точным. А такое внушительное количество работ лишь только еще раз подтверждает предположение о больших перспективах в этом направлении и наличие неподдельного всеобщего интереса к вопросам анализа ВР и к прогнозированию на их основе, в частности.

Классификация методов прогнозирования

По оценкам зарубежных и отечественных систематиков прогностики, как указывается в работе [2], насчитывается свыше ста методов прогнозирования. Анализ публикаций, посвященных методам и моделям прогнозирования, позволяет утверждать о существовании большого количества классификационных схем методов прогнозирования [1, 2, 3]. При этом, названия самих моделей и названия соответствующих им методов чаще всего совпадают. Рассмотрим основные варианты классификаций, предлагаемых в научной литературе.

В диссертационной работе [4] математические методы построения прогнозов классифицируют в зависимости от типа математической модели, выделяя детерминированные и стохастические модели. Для детерминированных моделей используют две группы методов: функциональные (построение моделей в пространстве время-значение) и

рекуррентные (построение моделей в пространстве значение-значение, т.е. в фазовом пространстве). Существуют также гибридные модели, сочетающие в себе и функциональные и рекуррентные свойства.

Детерминированные рекуррентные модели прогнозирования органично укладываются в рамки полинома Коломогорова-Габора:

$$x_p = \sum_{j=1}^{d_1} \alpha_j x_{p-j} + \sum_{j=1}^{d_2} \sum_{k=1}^{d_2} \alpha_{jk} x_{p-j} x_{p-k} + \dots + \sum_{j_1=1}^{d_3} \dots \sum_{j_k=1}^{d_3} \alpha_{j_1, \dots, j_k} x_{p-j_1} \dots x_{p-j_k}, \quad (1)$$

из которых можно строить как линейные, так и нелинейные, выбирая разное число компонент. Как отмечено в работе [2], именно рекуррентные модели вида (1) соответствуют требованиям рефлексии и потенциально могут быть использованы для прогнозирования сложных наблюдаемых ВР.

К стохастическим моделям относятся авторегрессионные модели.

В работе [3] методы прогнозирования делят на две группы: интуитивные и формализованные (рисунок 1).



Рисунок 1 – Классификация традиционных методов прогнозирования

Наиболее удачная классификация методов приводится в работе [1]. Вкратце, эту классификацию можно представить в виде схемы (рисунок 2). Она является более полной, в сравнении с предыдущей схемой.

Отметим, что подавляющее большинство традиционных принципов моделирования (регрессионные, автокорреляционные, спектральные и др.) заточены под анализ непосредственно стационарных ВР. Обычно ряд представляется в виде суммы некоторой детерминированной составляющей и остатка, причем желательно, чтобы автокорреляционная функция остатка с достаточной точностью была близка к нулю, что свидетельствует о близости остатка к белому шуму. После этого параметрическими или иными методами находят наиболее близкую статистику, моделирующую поведение остатка. Естественно, такие методы

предполагают проведение предварительной проверки на стационарность. Для стационарного ряда такие методы действительно обычно дают высокую эффективность. Тем не менее, на практике, большинство исследуемых процессов, нестационарные. И многие исследователи часто прибегают к этим методам, не придавая вопросу о стационарности особого значения. Иногда эти подходы дают неплохие результаты и в случае нестационарности, но в целом, для таких рядов они неприемлемы и корректно не обоснованы.

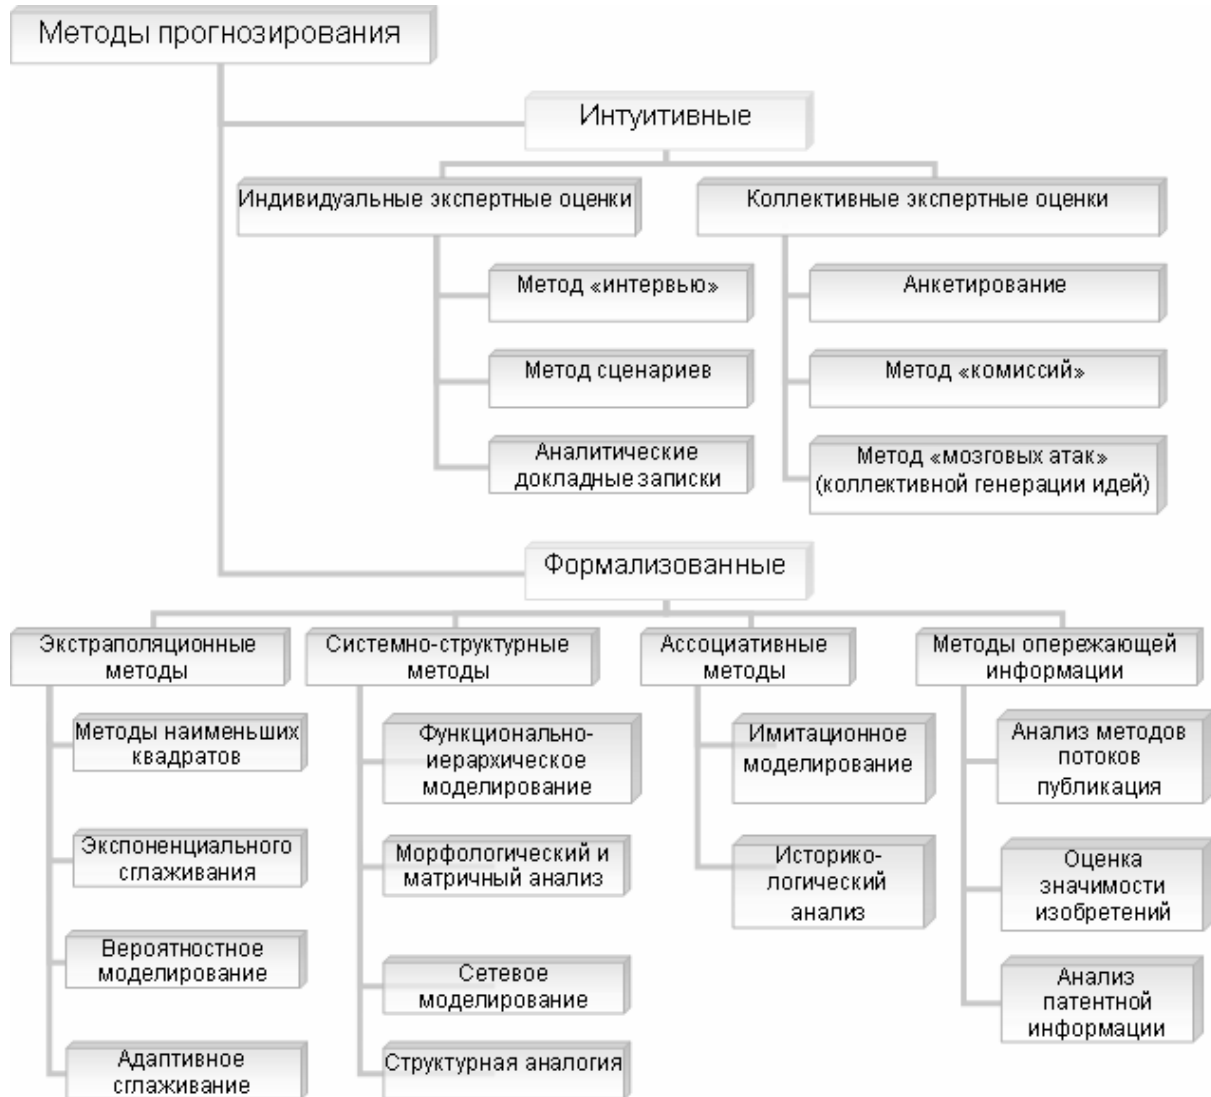


Рисунок 2 – Классификация методов прогнозирования (вариант)

Рассмотренные классификации методов не являются исчерпывающими. Нижние уровни открыты для внесения новых элементов. Хотя не исключено, что современные методы и подходы не смогут вписаться в рамки таких схем, поскольку все чаще совмещают в себе алгоритмы различных направлений.

Обзор традиционных направлений в прогнозировании ВР

Изучению и описанию алгоритмов традиционных направлений в прогнозировании ВР посвящено огромное количество литературы и Интернет-ресурсов. Традиционными (или классическим) методами можно считать такие, опыт использования которых насчитывается десятилетиями и детальную информацию о которых, включая суть алгоритмов, программную реализацию и примеры применения, легко найти в Интернет.

Регрессионные модели. Цель регрессионного анализа – определение зависимости между исходной переменной и множеством внешних факторов (регрессоров). При этом коэффициенты регрессии могут определяться по методу наименьших квадратов или методу максимального правдоподобия [5]. Самый простой вариант модели – линейная регрессия. В основу модели положено предположение, что существует внешний фактор $X(t)$, оказывающий влияние на процесс $Z(t)$, при этом связь между ними линейна. Если рядов несколько, то применяют множественную регрессию. В основу нелинейной регрессионной модели положено предположение о том, что существует некоторая функция F , внешний вид которой известен заранее, и описывающая зависимость между процессом $Z(t)$ и внешним фактором $X(t)$. На практике редко встречаются процессы с известным видом функциональной зависимости, поэтому нелинейная регрессия применяется редко.

На сегодняшний день существует множество модификаций и «производных» регрессионных методов, которые уже даже оформились в самостоятельные подходы. К их числу можно отнести методы индуктивного моделирования, которые используют синтез и агрегирование частных моделей в одну финальную модель. Также сюда можно отнести методы, основанные на полных и частичных переборах различных вариантов регрессионных моделей, где формирование финальной модели формируется на базе нескольких «конкурирующих» моделей.

Это не столько совершенно отдельные методы, как скорее целенаправленные методики или техники для «оптимизации процесса выбора наилучшей модели», внутри которых уже используются известные стандартные методы анализа данных. Для этих методик характерно использование различных критериев селекции моделей и всевозможных операторов их генерации, незначительно отличающихся от метода к методу. Чаще всего в этих подходах строятся полиномиальные модели. Хотя по названиям этих подходов это понять трудно, но все они базируются на принципах регрессионного анализа.

У таких подходов много общего, например, механизмы поиска, перебора и отбора лучших моделей в финальную модель. Такие подходы достаточно ресурсоемки и времязатратны. Более того, хотя эти подходы действительно часто оказываются эффективны (силу того, что,

фактически, перебирают множество вариантов и наконец-то находят оптимальный вариант). Тем не менее, имеют место и случаи, когда в качестве «лучшего» решения в результате долгого поиска предлагается не очень удачная и (или) громоздкая модель. Хотя в реальности «самая лучшая» модель значительно проще предложенной алгоритмом.

Эти алгоритмы характеризуются высокой степенью самоорганизации, поскольку с помощью различных критериев и проверок такие алгоритмы стремятся автоматизировать процесс выбора оптимальной модели и минимизировать участие пользователя в процессе поиска и избавить его от принятия субъективных решений. Среди таких методик можно выделить методы группового учета аргументов (А.Г.Ивахненко), методику синтеза аппроксимирующей функции (О.Эглайс) и ее модификации (А.Б. Ивашенко), адаптивный подход конструирования базисных функций (Г.Джекабсонс).

Первоначально эти подходы были предназначены для статистического анализа табличных данных и поиска регрессионных связей. Применительно же к длинным и сложным ВР эти подходы применяются редко, т.к. требуют больших вычислительных мощностей.

Для наглядности, вкратце, опишем идеи одного из этих подходов, а именно метода группового учета аргументов, разработанного отечественными учеными во главе с А.Г. Ивахненко. Модель имеет вид

$$Z(t) = \alpha_0 + \sum_{i=1}^s \alpha_i X_i(t) + \sum_{i=1}^s \sum_{j=1}^s \alpha_{i,j} X_i(t) X_j(t) + \sum_{i=1}^s \sum_{j=1}^s \sum_{k=1}^s \alpha_{i,j,k} X_i(t) X_j(t) X_k(t) + \dots \quad (2)$$

Уравнение (2) называется опорной функцией. Используя её, строят варианты моделей для некоторых или всех аргументов. Например, строятся полиномы с одной переменной, со всевозможными парами и тройками переменных и т.д. Для каждой модели определяют её линейные коэффициенты $\alpha_{i,j,k,\dots}$. Далее выбираются несколько наилучших моделей. Качество моделей определяется, например, среднеквадратичным отклонением или иным критерием. Если среди выбранных есть модель, качество которой достаточно для использования полученных прогнозных значений, то процесс перебора моделей прекращается. Иначе отобранные модели используются в качестве аргументов $X_1(t), \dots, X_s(t)$ для опорных функций следующего этапа итерации – уже найденные модели участвуют в формировании более сложных.

Авторегрессионные модели. В основу авторегрессионных моделей заложено предположение о том, что значение процесса $Z(t)$ линейно зависит от некоторого количества предыдущих значений того же процесса $Z(t-1), \dots, Z(t-p)$. При анализе ВР модели авторегрессии (autoregressive, AR) и скользящего среднего (moving average, MA) являются одними из наиболее используемых. Модель AR аналогична регрессионной модели, но в ней в качестве регрессоров выступают p предыдущих значений ряда.

Модель скользящего среднего предполагает, что последующее значение ряда формируется на основании усреднения некоторого числа q предыдущих элементов ряда. Существуют простые, взвешенные, кумулятивные, экспоненциальные модели скользящего среднего. Общая модель $ARMA(p, q)$ соединяет в себе фильтр в виде скользящего среднего порядка q и авторегрессию фильтрованных значений процесса порядка p .

Если в качестве входных данных используются не сами значения BP , а их разность d -того порядка (на практике d необходимо определять, но в большинстве случаев $d \leq 2$), то модель носит название авторегрессии проинтегрированного скользящего среднего (autoregression integrated moving average, $ARIMA(p, d, q)$). Еще совсем недавно данные модели считались современными и наиболее перспективными, но с развитием всё более новых подходов, они становятся всё менее и менее актуальными.

Развитием $ARIMA(p, d, q)$ является модель $ARIMAX(p, d, q)$, которая характеризуется учетом внешних факторов $X_1(t), \dots, X_s(t)$ [1].

Авторегрессионная модель с условной гетероскедастичностью (autoregressive conditional heteroskedasticity, GARCH) является моделью остатков для модели $AR(p)$. Сначала определяется модель $AR(p)$. Далее полагают, что ошибка модели ε_t имеет вид

$$\varepsilon_t = \sigma_t \cdot \zeta_t, \quad (3)$$

где σ_t – стандартное отклонение; ζ_t – случайная величина, имеющая нормальное распределение с нулевым средним значением и единичным стандартным отклонением. Здесь σ_t описывается уравнением

$$\sigma_t^2 = \beta_0 + \beta_1 \varepsilon_{t-1}^2 + \dots + \beta_q \varepsilon_{t-q}^2 + \gamma_1 \sigma_{t-1}^2 + \dots + \gamma_p \sigma_{t-p}^2. \quad (4)$$

Здесь β_0, \dots, β_q и $\gamma_1, \dots, \gamma_p$ – коэффициенты.

Уравнение (4) называется моделью GARCH(p,q) и имеет два параметра: p характеризует порядок авторегрессии квадратов остатков; q – количество предшествующих оценок остатков. На сегодняшний день существуют модификации модели: NGARCH, IGARCH, GARCH-M и др.

Модели экспоненциального сглаживания и адаптивные модели. Модели экспоненциального сглаживания разработаны в середине XX века и до сегодняшнего дня являются широко распространенными в силу их простоты и наглядности. В основу экспоненциального сглаживания (exponential smoothing, ES) заложена идея постоянного пересмотра прогнозных значений по мере поступления фактических. Модель ES присваивает экспоненциально убывающие веса наблюдениям по мере их старения. Таким образом, последние доступные наблюдения имеют большее влияние на прогнозное значение, чем старшие наблюдения.

Модели экспоненциального сглаживания называются также адаптивными, поскольку являются самокорректирующимися, т.е. способны отражать изменяющиеся во времени свойства BP .

Функция простейшей модели ES имеет вид

$$\begin{aligned} Z(t) &= S(t) + \varepsilon_t, \\ S(t) &= \alpha \cdot Z(t-1) + (1-\alpha) \cdot S(t-1), \end{aligned} \quad (5)$$

где α – коэффициент сглаживания, $0 < \alpha < 1$; начальные условия определяются как $S(1) = Z(0)$. В модели (5) каждое сглаженное значение $S(t)$ является взвешенным средним между предыдущим значением ряда $Z(t)$ и предыдущего сглаженного значения $S(t-1)$.

Существуют и более сложные варианты экспоненциальных сглаживаний, например, модель Хольта, а также модель Хольта-Винтерса.

Искусственные нейросетевые модели. В последние годы наблюдается повышенный интерес к нейронным сетям (artificial neural network, ANN), которые нашли применение в самых различных областях человеческой деятельности – бизнесе, медицине, технике. Их впечатляющий успех определяется несколькими причинами. Нейронные сети – это исключительно мощный метод имитации процессов и явлений, позволяющий воспроизводить чрезвычайно сложные зависимости. Нейронные сети по своей природе являются нелинейными, в то время как на протяжении многих лет для построения моделей использовался линейный подход. Кроме того, во многих случаях нейронные сети позволяют преодолеть «проклятие размерности», обусловленное тем, что моделирование нелинейных явлений в случае большого числа переменных требует огромного количества вычислительных ресурсов.

Другие подходы. Кроме отмеченных подходов, к традиционным методам, характеризующимся многолетним опытом их использования, также можно отнести генетические алгоритмы, модели на базе цепей Маркова и модели на базе классификационно-регрессионных деревьев.

Также существуют и другие более-менее проработанные методы и модели прогнозирования, но, пожалуй, менее распространенные. Это такие подходы, как вейвлет анализ, аппроксимация рядами Фурье, гармонический и спектральный анализ (метод «гусеница»), методы теории нечётких множеств, метод бутстрепа. Не смотря на самостоятельность и достаточную зрелость этих подходов, чаще всего они оказываются малоэффективными при анализе временных рядов, порождаемых сложными физическими или техническими системами или процессами. Поэтому такие подходы по отдельности не рекомендуется применять для успешного решения задачи прогнозирования сложных наблюдаемых ВР. Главным недостатком этих моделей и методов является недостаточная методологическая база – недостаточно подробное описание возможностей как моделей, так и путей определения их параметров. Кроме того, в открытом доступе можно найти лишь небольшое количество статей, посвященных применению данных методов. Возможно, этот факт косвенно также свидетельствует об их низкой эффективности.

Основные преимущества и недостатки подходов

Достоинства и недостатки рассмотренных подходов наглядно представлены в табл. 1. Нужно дополнительно отметить, что ни для одной из рассмотренных групп методов в достоинствах не указана точность прогнозирования, т.к. точность прогнозирования того или иного процесса зависит не только от модели, но и от опыта исследователя, от доступности данных, от располагаемой аппаратной мощности и других факторов.

Таблица 1. Преимущества и недостатки классических подходов

Достоинства подхода	Недостатки подхода
Регрессионные модели и методы	
<ul style="list-style-type: none"> • Простота, единообразие их анализа и проектирования, быстрые результаты • Прозрачность моделирования и доступность для анализа промежуточных вычислений 	<ul style="list-style-type: none"> • Сложность определения вида функциональной зависимости • Низкая адаптивность линейных моделей и отсутствие способности моделирования нелинейных процессов
Авторегрессионные модели и методы	
<ul style="list-style-type: none"> • Простота и единообразие их анализа и проектирования • Прозрачность моделирования • Доступность множества примеров применения 	<ul style="list-style-type: none"> • Большое число параметров модели, идентификация которых неоднозначна и ресурсоемка • Низкая адаптивность моделей • Линейность и отсутствие способности моделирования нелинейных процессов
Методы экспоненциального сглаживания и адаптивные модели	
<ul style="list-style-type: none"> • Простота и единообразие их анализа и проектирования • Объем данных не значим • Ясность и простота математической формулировки 	<ul style="list-style-type: none"> • Отсутствие гибкости • Требуют весьма тонкой настройки сглаживающих функций, даже для стационарных процессов оптимальный выбор этих функций является отдельной достаточно сложной задачей
Нейросетевые модели и методы	
<ul style="list-style-type: none"> • Нелинейность, способность улавливать нелинейные зависимости • Адаптивность • Масштабируемость (параллельная структура ANN ускоряет вычисления) • Единообразие их анализа и проектирования 	<ul style="list-style-type: none"> • Отсутствие прозрачности моделирования • Сложность выбора архитектуры • Высокие требования к непротиворечивости обучающей выборки и ресурсоемкость процесса обучения • Невозможность интерпретации модели в терминах предметной области • Неясность в выборе числа слоев и элементов в слое • Невозможность добавления нейронов в процессе самообучения нейросети
Генетические алгоритмы	
<ul style="list-style-type: none"> • Адаптивность • Возможности для распараллеливания 	<ul style="list-style-type: none"> • Недостаточная методологическая база • Узость и специфичность применения • Поисковый алгоритм требует затрат времени, не гарантирует оптимального решения, может вообще привести к «тупиковому» результату
Модели и методы на базе цепей Маркова	
<ul style="list-style-type: none"> • Простота, единообразие анализа и проектирования 	<ul style="list-style-type: none"> • Не подходит для моделей процессов с длинной памятью • Узкая применимость
Модели на базе классификационно-регрессионных деревьев	
<ul style="list-style-type: none"> • Наглядность и понятность • Масштабируемость • Обработка сверхбольших объемов данных • Быстрота и однозначность процесса обучения дерева 	<ul style="list-style-type: none"> • Неоднозначность алгоритма построения структуры дерева • Сложность вопроса останова • Отсутствие единообразия их анализа и проектирования • Реализуется наивный принцип последовательного просмотра признаков, создавая лишь иллюзию логического вывода

Современные тенденции в развитии методов прогнозирования по ВР

Наряду с классическими подходами, история использования которых исчисляется десятилетиями, на сегодняшний день всё большее внимание исследователей обращают на себя относительно свежие направления. Обзор научных работ и диссертационных исследований [1, 4-13 и др], выполненных за последнее десятилетие, показывает, что интерес к этим направлениям постоянно растет. Это обусловлено, кроме прочего, желанием постигнуть законы сложных систем и процессов, для которых математический аппарат классических подходов не является достаточным.

Фрактальный анализ. Изначально фрактальные представления создавались Бенуа Мандельбротом как метод и средство для описания иррегулярной и фрагментированной геометрии окружающей природы принципиально новой сложности (по сравнению с традиционной линейной и евклидовой геометрией). Сложность, инициировавшая появление фрактальной геометрии, содержалась в таких объектах наблюдаемой части окружающего мира как облака, горы, формы рельефов, деревья, береговые линии и принципиально основывалась на идее и свойстве самоподобия.

Теория фракталов этимологически противоположна традиционной алгебраической теории, поскольку рассматривает объекты с точки зрения неправильности их форм. В рамках фрактальных представлений изучаются геометрические свойства рассматриваемых объектов с точки зрения специальных фрактальных размерностей.

В рамках фрактального анализа широко используется метод нормированного размаха Хёрста. Метод нормированного размаха или R/S-анализ был предложен Г. Э. Херстом в начале XX века, когда он занимался проблемой резервуарного контроля и исследовал неуправляемый приток воды от дождей. Сейчас показатель Херста H широко применяется в анализе ВР благодаря своей устойчивости, а также благодаря тому, что он содержит минимальные предположения об изучаемом объекте, который описывается исследуемым временным рядом. Считается, что показатель Херста позволяет отличить случайный ВР от неслучайного даже в том случае, если он не является гауссовским.

Для анализа обобщенного ВР определим размах

$$R = \text{Max}(X_{t,N}) - \text{Min}(X_{t,N}), \quad (6)$$

где R – размах отклонения $X_{t,N}$; $\text{Max}(X_{t,N})$ и $\text{Min}(X_{t,N})$ – максимальное и минимальное значение для $X_{t,N}$. Отклонение $X_{t,N}$ в (6) определяется как

$$X_{t,N} = \sum_{u=1}^t Z_u - M_N, \quad (7)$$

где $X_{t,N}$ – накопленное отклонение за N периодов; Z_u – значение ВР в момент времени u ; M_N – среднее значение Z_u за N периодов.

Для сравнения различных типов ВР разделим размах R в (6) на стандартное отклонение исходных наблюдений для нормировки и получения значения, независящего от масштаба значений анализируемого ВР. Этот нормированный размах должен увеличиваться со временем. Херстом было введено следующее гипотетическое соотношение:

$$R/S = (aN)^H, \quad (8)$$

где R/S – нормированный размах; N – число наблюдений; a – константа.

На сегодняшний день сложилась следующая классификация диапазонов значений показателя Херста H :

1) $H = 0.5$: временной ряд является случайным, отдельно взятые значения некоррелированы; настоящее не влияет на будущее;

2) $0 \leq H < 0.5$: временной ряд является антиперсистентным или эргодическим, за ростом следует спад, за спадом следует подъем; чем ближе H к нулю, тем больше значения отрицательно коррелированы;

3) $0.5 < H \leq 1$: ВР является персистентным или трендоустойчивым, смещенные случайные блуждания с выраженным трендом, сила тренда тем сильнее, чем ближе H к единице или положительной корреляции.

Теория нелинейных динамических систем. В рамках теории нелинейных динамических систем (НДС) предполагается, что имеется временной ряд $Z(t)$ непрерывной по времени природы. Предполагается также, что этот ВР описывает поведение некоторой динамической системы и является единственной доступной информацией об этой системе. Далее полагают, что наличия такого единственного ВР достаточно для адекватного описания всей динамической системы в целом. Это основывается на известной теореме Такенса, обосновывающей восстановление аттрактора по единственной динамической траектории.

Анализ ВР методами описания НДС приобретает все более широкое распространение. В терминах данного описания исследуемые процессы называются хаотическими или, как еще говорят, содержат в себе детерминированный хаос. С точки зрения линейных методов анализа эти процессы – стохастические. Однако нелинейный анализ показывает, что, хоть их и нельзя причислить к детерминированным, абсолютно случайными они тоже не являются. Другими словами, предсказание системы с определенной точностью оказывается возможным, но лишь на ограниченное число шагов. Для описания формальных характеристик хаотических процессов, рассматриваются такие параметры теории сложных систем как фазовое пространство и аттрактор.

Математическим образом всех движений ДС является ее фазовый портрет. Фазовый портрет дает не только геометрическое изображение отдельных движений, состояний равновесия, периодических, хаотических и стохастических движений, но и определяет «логику» поведения ДС, ее зависимость от параметров. Если поведение системы стохастично, то фазовая траектория заполняет некоторый объем фазового пространства;

если это детерминированный периодический процесс, то траектория заполнит поверхность какой-либо симметричной фигуры. Фазовые портреты систем с хаотическим поведением также заполняют некоторую ограниченную область фазового пространства. В связи с этой особенностью фазовый портрет называют аттрактором.

Для динамического хаоса характерен нерегулярный характер – так называемый странный аттрактор, похожий на клубок траекторий. Данный термин ввели в 1971г. Рюэль и Такенс. Размерность странного аттрактора всегда фрактальна. Таким образом, имеет место взаимосвязь между фракталами и хаосом, хотя термин «фрактал» относится к некоторой статичной геометрической конфигурации, а «хаос» – термин динамики.

В [14] была предложена процедура реконструкции аттрактора в фазовом пространстве методом запаздываний и определения m размерности вложения. Идея реконструкции уравнений динамической системы по наблюдаемой реализации вкратце состоит в следующем. Сначала определяется размерность вложения, то есть размерность фазового пространства конструируемой модели. Далее за основу берут некоторую форму уравнений, содержащую набор неопределенных коэффициентов. Чтобы наблюдаемая реализация оптимальным образом описывалась данной моделью, используется метод наименьших квадратов. Далее формулируется условие минимума некоторой положительной величины типа суммы квадратов невязок. Минимизация этой величины позволяет найти неопределенные коэффициенты.

Одной из особенностей хаотических режимов является неустойчивость каждой траектории, принадлежащей хаотическому аттрактору. Количественной мерой этой неустойчивости оказались характеристические показатели Ляпунова. Они являются одной из важнейших характеристик аттрактора, поскольку позволяет оценить: фрактальную размерность аттрактора, энтропию динамической системы и характерное время предсказуемости поведения системы.

Поскольку критерием хаотической динамики служит присутствие положительного старшего ляпуновского показателя, представляет большой интерес возможность его оценки на основании обработки ВР (реализаций). Эти показатели характеризуют скорость разбегания близких изначально траекторий с течением времени в фазовом пространстве. В работе [4] предлагается эффективный алгоритм оценивания показателей Ляпунова. Эта оценка осуществляется, исходя из сравнения точек эволюции фазовой траектории. По этой методике можно оценить два самых больших показателя Ляпунова. Для этого постоянно сравниваются начальная точка и некоторая текущая точка ВР. Сравнивая изменения расстояний между этими точками, можно оценить наибольший показатель Ляпунова

$$\lambda_1 = \frac{1}{t_M - t_0} \sum_{k=1}^M \log_2 \frac{L'(t_k)}{L(t_{k-1})}, \quad (9)$$

где $L'(t_0)$ – расстояние между текущей и начальной точкой; $L'(t_1)$ – новое расстояние в последующий момент времени t_1 между текущей и начальной точками; M – общее количество точек дискретизации.

Для оценивания второго по значению показателя Ляпунова λ_2 пользуются его связью с первым значением λ_1 :

$$\lambda_1 + \lambda_2 = \frac{1}{t_M - t_0} \sum_{k=1}^M \log_2 \frac{A'(t_k)}{A(t_{k-1})} \quad (10)$$

где A и A' является площадями, замечаемыми траекториями при движении текущей точки относительно начальной (как для L и L' в (9)).

Существует еще один довольно простой способ оценки хаотичности процесса. Суть метода заключается в вычислении размера алфавита, необходимого для передачи сигнала. Сначала исходный ВР представляется в виде последовательности нулей и единиц. Единицы подставляются вместо значений ряда, больших медианы, а нули – вместо меньших. Затем исходная последовательность разбивается на отдельные пакеты (слова) минимальной длины таким образом, чтобы ни один пакет не повторялся. Например, если мы имеем исходный ряд вида

0 1 1 0 0 0 1 1 1 0 1 0 0 0 1 0 1 1,

то после разбивки получатся такие пакеты

0 1 10 00 11 101 000 1011.

Иначе говоря, избегая повторения слов, мы увеличиваем их длину. Если сигнал по своим свойствам близок к детерминированному, то будет наблюдаться тенденция к повторению одних и тех же слов, что приведет к быстрому росту их длины. В результате количество слов, задействованных для передачи исходного ряда, будет меньше, чем в случае со случайным процессом. Мету C_{LZ} стохастичности процесса вычисляют по формуле [15]

$$C_{LZ} = \limsup_{N \rightarrow \infty} \frac{L(N)}{N}, \quad L(N) \sim N_w(N) (\lg N_w(N) + 1), \quad (11)$$

где N - длина исходной последовательности, а N_w - количество использованных слов. При росте стохастичности процесса новые слова появляются чаще, и C_{LZ} растет. Так, например, для синусоидального сигнала рассчитанное значение $C_{LZ} = 0.044$, а для белого шума $C_{LZ} = 1.047$ (при одинаковом числе точек) [15].

При анализе ВР, описывающих сложные процессы, задолго до выбора конкретных методов реконструкции, исследователю требуется определиться с набором переменных, на основе которых и будет строиться реконструкция. В реальном мире при исследовании каких-либо сложных процессов оказывается возможным получение временной последовательности значений какой-либо одной величины. Однако такой числовой ряд, сформированный по одной единственной наблюдаемой, может дать гораздо больше информации обо всей системе, чем это может показаться на первый взгляд. Одним из важнейших достижений теории

сложных систем стала теорема Такенса, на основании которой по эволюции одной переменной можно составить представление о динамике всей системы, построив аттрактор. Суть этой реконструкции следующая.

Пусть имеется исходный процесс – последовательность измеренных мгновенных значений переменной Z . Отобразим данный процесс на плоскость следующим образом: каждому исходному значению процесса $Z(t_i)$ будет соответствовать точка на плоскости, одна координата которой будет равна $Z(t_i)$, а другая – $Z(t_i + \tau)$, где τ – некоторая произвольно выбранная величина, так называемый лаг или временная задержка. В результате мы получим некоторое множество точек на плоскости. Аналогично, можно отобразить исходный процесс в трехмерное пространство. В этом случае координаты по одной оси будут равны $Z(t_i)$, по другой – $Z(t_i + \tau)$, а по третьей – $Z(t_i + 2\tau)$. Итак, при отображении исходной последовательности в m -мерное пространство каждая точка $Z(t_i)$ будет отображаться на точку этого пространства с координатами $\{Z(t_i), Z(t_i + \tau), \dots, Z(t_i + (D-1) \cdot \tau)\}$. Согласно теореме Такенса, можно подобрать такие D и τ , что полученное в результате описанного преобразования множество точек будет по своим метрическим свойствам воспроизводить аттрактор исследуемой системы.

Пространство, задаваемое для восстановления исходного аттрактора, называют пространством вложения или лаговым пространством; множество точек, моделирующее аттрактор – псевдофазовой реконструкцией. Размерность восстановленного аттрактора можно рассматривать как меру стохастичности процесса – чем она меньше, тем сильнее этот процесс детерминирован.

Первоначальным и по сути предопределяющим успешность всей дальнейшей реконструкции этапом является выбор оптимальных D и τ . На самом деле эта задача чрезвычайно сложна. Величина задержки τ теоретически может быть любой, но на практике нежелательны как слишком малые «шаги», которые ведут к сильной корреляции компонент вектора состояния, так и слишком большие, при которых может слишком усложниться структура восстановленного аттрактора. Обычно предлагается выбирать величину τ , равной первому нулю автокорреляционной функции или первому минимуму функции взаимной информации. Каждый из подходов хорош для своего круга систем, часто ведет к сложным вычислениям и не гарантирует успеха в общем случае.

Таким образом, анализ хаотических процессов заключается, в первую очередь, в определении параметров вложения динамической системы, а именно в выборе подходящей временной задержки сигнала τ и размерности D пространства вложения для псевдофазовой реконструкции.

При выборе оптимальной размерности лагового пространства D , самое простое, что можно сделать – это задаться размерностью пространства вложения заведомо большей, чем предполагаемая размерность восстановленного аттрактора, и использовать ее для всех вычислений в рамках одного эксперимента.

Накопленный на сегодняшний день опыт исследований показывает, что в зависимости от применяемых методов вычислений и условий эксперимента размерность D часто принимает значения от 4 до 8. Хотя, например, в работе [15] рекомендуют задаваться величиной D в пределах 10–15. Также существуют утверждения, что можно уверенно задаваться размерностью лагового пространства $D \geq 2D_2 + 1$, где D_2 – корреляционная размерность восстановленного аттрактора.

Вышеупомянутые способы выбора D позволяют задаваться значениями ее величины с точки зрения достаточности. Также можно выбирать минимально необходимую размерность лагового пространства. Для этого существует ряд методов: метод «ближайших ложных соседей» (False Nearest Neighbors, FNN), метод главных компонент, метод Грассбергера–Прокаччия, метод хорошо приспособленного базиса и гамма–тест. Однако, часто приходится просто перебирать разные пробные значения размерности D , начиная с самых малых и постепенно увеличивая, и строить модельные уравнения для каждого D , пока не будет получена «хорошая» модель. Тогда подбор размерности и даже временных задержек становится частью единого процесса моделирования.

Методы интеллектуального анализа ВР. Интеллектуальные методы прогнозирования применяют в тех случаях, когда невозможно учесть влияние многих факторов из-за значительной сложности объекта прогнозирования. Исследования данных и методов их анализа в последние десятилетия оформились в виде отдельного направления, называемого интеллектуальным анализом данных или Data Mining, в котором анализ ВР получил название интеллектуального анализа ВР или Time Series Data Mining (TSDM). Data Mining – это процесс обнаружения в сырых данных ранее неизвестных, нетривиальных, практически полезных и доступных интерпретации знаний, необходимых для принятия решений в различных сферах человеческой деятельности. Это технология, которая предназначена для поиска в больших объемах данных неочевидных, объективных и полезных на практике закономерностей. Методы Data Mining условно делятся на три группы: технологические методы, статистические методы, кибернетические методы.

К технологическим методам относят:

- непосредственное использование данных, или сохранение данных (кластерный анализ, метод ближайшего соседа, метод k -ближайшего соседа, рассуждение по аналогии);

- выявление и использование формализованных закономерностей, или дистилляция шаблонов (логические методы; методы визуализации; методы кросс-табуляции; методы, основанные на уравнениях).

Статистические методы, используемые в Data Mining:

- дескриптивный анализ и описание исходных данных;
- анализ связей (корреляционный и регрессионный анализ, факторный анализ, дисперсионный анализ);
- анализ ВР (динамические модели и прогнозирование).

В группу кибернетических методов относятся:

- искусственные нейронные сети (распознавание, кластеризация);
- эволюционное программирование (в том числе алгоритмы метода группового учета аргументов);

- генетические алгоритмы (оптимизация);
- ассоциативная память (поиск аналогов, прототипов);
- нечеткая логика;
- деревья решений;
- системы обработки экспертных знаний.

Методы и технологии извлечения знаний с использованием ВР должны оперировать паттернами ВР, отыскивать ассоциации между ними и извлекать знания. На основе новой методологии Data Mining решается расширенная совокупность задач анализа ВР:

1. Сегментация – разбиение ВР на значимые сегменты;
2. Кластеризация – поиск группировок ВР или их паттернов;
3. Классификация – назначение ВР или их паттернам одного из заранее определенных классов;
4. Резюмирование – формирование краткого описания ВР, содержащего существенные черты с точки зрения решаемой задачи;
5. Обнаружение аномалий – поиск новых, не типичных паттернов ВР;
6. Частотный анализ – поиск часто проявляющихся паттернов ВР;
7. Прогнозирование – прогноз очередного значения на основе истории ВР;
8. Извлечение ассоциативных правил – поиск правил для паттернов ВР.

Методологическую базу интеллектуального анализа данных составляют интегрированные и усовершенствованные методы классических направлений анализа данных.

Методы локальной аппроксимации или системы рассуждений на основе аналогичных случаев. В данном направлении существует определенная путаница в терминологии, так как разные авторы в многочисленных работах называют этот подход по-разному. Можно выделить наиболее распространенные: прогнозирование по образцу, метод «ближайших соседей», методы поиска подобных траекторий, системы рассуждений на основе аналогичных случаев, прогнозирование по прецедентам, методы максимального правдоподобия, методы локальной аппроксимации, метод подобных векторов (паттернов, кластеров и т.п.).

Некоторые авторы относят эти подходы к методам нелинейной динамики, а некоторые считают их чисто интеллектуальными подходами. В любом случае можно с уверенностью утверждать, что эти методы фактически оформились в отдельное направление и представляют отдельный интерес, в первую очередь в смысле их развития и комбинирования с другими подходами. Идеи этого подхода достаточно просты для понимания, одновременно гибкие и универсальные. А в некоторых сложных ситуациях дают наилучший прогноз.

В общих чертах идея систем рассуждений на основе аналогичных случаев (паттернов, образцов, case based reasoning) на первый взгляд крайне проста. Для того, чтобы сделать прогноз на будущее, такие системы находят в прошлом близкие аналоги данной ситуации и выбирают тот ответ, который был для них правильным в прошлом. В последнее время распространение получил также термин memory based reasoning, который акцентирует внимание на то обстоятельство, что решение принимается на основании всей информации, накопленной в памяти.

Такой подход показывает неплохие результаты в самых разнообразных задачах. Главным их минусом считают то, что они вообще не создают каких-либо моделей и правил, обобщающих предыдущий опыт.

Другой минус заключается в неоднозначности критериев при выборе меры близости (или метрики). Пусть имеется два вектора X_i и X_k длиной N . Тогда формулы для расчета основных мер близости этих векторов приводятся в табл. 2.

Таблица 2. Основные метрики

№	Наименование метрики	Тип признаков	Формула для оценки меры близости
1	Евклидово расстояние	Количественные	$d_{ik} = \left(\sum_{j=1}^N (x_{ij} - x_{kj})^2 \right)^{1/2}$
2	Манхэттенская (городская) метрика	Количественные	$d_{ik}^{(1)} = \sum_{j=1}^N x_{ij} - x_{kj} $
3	Мера сходства Хэмминга	Номинальные (качественные)	$\mu_{ik}^H = \frac{n_{ik}}{N}$, где n_{ik} – число совпавших у X_i и X_k признаков,
4	Расстояние Махаланобиса	Количественные	$d_{ik}^M = \left((x_{ij} - x_{kj})^T W^{-1} (x_{ij} - x_{kj}) \right)^{1/2}$, где W - ковариационная матрица выборки $X = \{X_1, X_2, \dots, X_n\}$
5	Максимальное расстояние по признакам	Количественные	$d_{ik}^{(m)} = \max_{1 \leq j \leq N} x_{ij} - x_{kj} $
6	Расстояние Журавлева	Смешанные	$d_{ik}^g = \sum_{j=1}^N I_{ik}^j$, где $I_{ik}^j = \begin{cases} 1, & \text{если } x_{ij} - x_{kj} < \varepsilon \\ 0, & \text{если } x_{ij} - x_{kj} \geq \varepsilon \end{cases}$

От этой меры самым решительным образом зависит объем множества прецедентов, которые нужно хранить в памяти для достижения удовлетворительного прогноза. Поэтому выбор меры близости заслуживает особого внимания, поскольку именно от него зависит способ поиска или определения близкого соседа. Вообще, в каждой конкретной задаче этот выбор производится по-своему, с учетом физической и статистической природы входной информации.

Также в качестве неудобств такого рода моделей указывают: невозможность учитывать внешние факторы, неоднозначность критерия определения похожей выборки, сложность определения эффективной комбинации двух параметров: длины вектора (паттерна) M и их количества K .

Комбинированные модели. Одной из популярных современных тенденций в области создания моделей прогнозирования является создание комбинированных моделей и методов. Подобный подход дает возможность компенсировать недостатки одних моделей при помощи других и направлен на повышение точности прогнозирования, как одного из главных критериев эффективности модели. Отметим, что формулировки и определения для таких моделей также не однозначны от автора к автору. Синонимами понятия «комбинирования моделей» также являются понятия «ансамблевых подходов», «коллективов прогнозов».

В работе [5] подчеркивается, что методика построения коллективов прогнозных моделей основана на двух идеях. Первая – создание множества линейных моделей прогноза, построенных на разных обучающих последовательностях и с разной глубиной памяти. Вторая – выбор «лучшей» модели прогноза среди всех моделей на основе множества критериев «качества» различной природы.

В результате обзора моделей прогнозирования выяснилось, что на сегодняшний день большинство комбинаций используют сочетание нейронной сети (ANN) с дополнительным методом, например: ANN + нечеткая логика; ANN + ARIMA; ANN + регрессия. Применение комбинированных моделей является направлением, которое при корректном подходе позволяет повысить точность прогнозирования. Главным недостатком комбинированных моделей является сложность и ресурсоемкость их разработки: нужно разработать модели так, чтобы компенсировать недостатки каждой из них, не потеряв достоинств.

Заключение

Задача прогнозирования ВР имеет высокую актуальность для многих предметных областей. Установлено, что к настоящему времени разработано множество моделей для решения задачи прогнозирования, среди которых в последние десятилетия наиболее широко применялись

авторегрессионные и нейросетевые модели. Тем не менее, на сегодняшний день их популярность уменьшается, ввиду относительной неэффективности этих подходов, особенно при анализе сложных систем.

В работе были рассмотрены традиционные методы моделирования по временным рядам, выявлены их достоинства и недостатки. В результате обзора классических подходов был сделан вывод о их недостаточности и даже несостоятельности при анализе нестационарных ВР, которыми описываются сложные системы и которые представляют научный интерес для современных исследователей.

На основании обзора научных публикаций и диссертационных исследований последнего десятилетия, были выявлены актуальные и перспективные подходы в моделировании по временным рядам. К перспективным методам можно отнести такие подходы, как интеллектуальный анализ ВР, методы фрактального анализа данных, методы нелинейной динамики и детерминированного хаоса, методы локальной аппроксимации и поиска подобных траекторий. В последнее время этим подходам уделяется все большее внимание в части прогнозирования временных рядов. Это достаточно новые направления, которые представляют собой популярные и активно развивающиеся разделы математики. В силу недостатков существующих традиционных методов прогнозирования и их неэффективности для нестационарных динамических рядов, имеет место необходимость разработки эффективных методик для их анализа на базе современных подходов.

В качестве средства для компенсации недостатков отдельных подходов, была отмечена целесообразность и необходимость разработки комплексных подходов, основанных на базе указанных выше методов.

Список литературы

1. Беляков, С. С. Использование агрегирования в методах нелинейной динамики для анализа и прогнозирования временных рядов котировок акций / С.С. Беляков // Дисс. на соиск. уч. ст. к. эк. н., Ставрополь– 2005.
2. Ярушкина, Н.Г. Интеллектуальный анализ временных рядов: Учебное пособие / Н.Г. Ярушкина, Т.В. Афанасьев, И.Г. Перфильева. – Ульяновск : 2010. – 320 с.
3. Тихонов Э.Е. Прогнозирование в условиях рынка. – Невинномысск, 2006. 221 с.
4. Павлов, С.В. Технология прогнозирования сложных наблюдаемых временных рядов / С. В. Павлов // Диссертация на соискание ученой степени к. т. н., Красноярск– 2007.
5. Щипин, К.С. Система прогнозирования на основе многокритериального анализа временных рядов / К.С. Щипин // Дисс. на соиск. уч. ст. к.т.н., Москва – 2004.
6. Осьминин, К. П. Алгоритмы прогнозирования нестационарных временных рядов / К.П. Осьминин // Автореферат дисс. на соиск. уч. ст. к.ф.-м. н., Москва – 2008.
7. Чучуева, И. А. Модель прогнозирования временных рядов по выборке максимального подобия / И.А. Чучуева // Дисс. на соиск. уч. ст. к. т. н., Москва – 2012

8. Демківська, Т.І. Методи та засоби прогнозування екологічних та економічних процесів на основі комп'ютерного моделювання часових рядів / Т.І. Демківська // Автореферат дисс. на здоб. наук. ст. к. т. н., Київ – 2001.
9. Безрукавний, Д. С. Анализ и управление данными в виде временных рядов / Д.С. Безрукавний // Автореферат дисс. на соиск. уч. ст. к. т. н., Москва – 2007
10. Антипов, О.И. Фрактальные методы анализа и прогнозирования для самоорганизованных технических, биологических и экономических систем/ О.И. Антипов // Автореферат дисс. на соиск. уч. ст. д. ф-м. н., Самара – 2011
11. Егошин, А.В. Анализ и прогнозирование сложных стохастических сигналов на основе методов выделения границ реализаций динамических систем / А.В. Егошин // Автореферат дисс. на соиск. уч. ст. к. т. н., Санкт-Петербург – 2009
12. Зражевський, О.Г. Системний підхід до відновлення функціональних залежностей нестационарних часових рядів різної структури / О.Г. Зражевський // Автореферат дисс. на здоб. наук. ст. к. т. н., Київ – 2011
13. Немец, С. Ю. Комбинированные методы прогнозирования на основе ретроспективных оценок и внутренних характеристик временных рядов / С.Ю. Немец // Автореферат дисс. на соиск. уч. ст. к. т. н., Воронеж – 2007
14. Брур, Х. В. Структуры в динамике. Конечномерные детерминированные системы / Х.В.Брур, Ф.Дюмортье, С. ван Стрин, Ф.Такенс. – Москва-Ижевск: Институт компьютерных исследований, 2003. – 336 с.
15. Меклер, А.А. Применение аппарата нелинейного анализа динамических систем для обработки сигналов ЭЭГ. / А. А. Меклер // Актуальные проблемы современной математики: учёные записки. Т. 13 (вып. 2). п/ред. проф. Калашникова Е.В., С.-Пб., 2004 г., 153 стр., стр. 112 – 140.

Надійшла до редакції 21.09.2012 р.

Рецензент: канд.техн.наук, проф. Анопрієнко О.Я.

А.Б. Иващенко

Донецький національний технічний університет

Традиційні та сучасні підходи до прогнозування часових рядів. Розглянуто існуючі класифікаційні схеми методів прогнозування. Описано традиційні методи прогнозування. Наведено недоліки та позитивні сторони таких методів. На підставі огляду наукових робіт останнього десятиріччя виконано аналіз сучасних підходів, що використовуються при прогнозуванні складних систем.

Ключові слова: прогнозування, часовий ряд, переваги і недоліки методів, інтелектуальний аналіз, нелінійна динаміка, регресійна модель

A.B. Ivashchenko

Donetsk National Technical University

Traditional and modern approaches in time series forecasting. Classification schemes of forecasting methods are reviewed. Traditional methods of time series prediction are described. Positive aspects and disadvantages of the methods are presented. Based on investigation of scientific papers of last decade an overview of modern approaches in forecasting of complex systems is made.

Keywords: forecasting, time series, advantages and disadvantages of the methods, data mining, nonlinear dynamics, regression model