

УДК 004.94  
DOI: 10.15827/0236-235X.122.353-361

Дата подачи статьи: 12.12.17  
2018. Т. 31. № 2. С. 353–361

## **ИСПОЛНЕНИЕ МОДЕЛЕЙ СИСТЕМНОЙ ДИНАМИКИ НА ОСНОВЕ НЕПРЕРЫВНОГО ПОТОКА ВХОДНЫХ ДАННЫХ**

*И.А. Перл*<sup>1</sup>, к.т.н., доцент, *ivan.perl@corp.ifmo.ru*  
*М.М. Петрова*<sup>1</sup>, аспирант, *maria.petrova@corp.ifmo.ru*  
*А.А. Мулюкин*<sup>1</sup>, аспирант, *alexprey@ya.ru*  
*О.В. Каленова*<sup>1</sup>, аспирант, *ovkalyonova@corp.ifmo.ru*

<sup>1</sup> Санкт-Петербургский национальный исследовательский университет информационных технологий, механики и оптики (Университет ИТМО), Кронверкский просп., 49, г. Санкт-Петербург, 197101, Россия

В статье описывается новый подход к расчету моделей системной динамики. Входными данными для работы модели является набор статических известных данных. В результате моделирования разработчик получает набор системных или событийных характеристик, вычисленных на базе входных параметров модели. Данный подход широко применяется в различных отраслях, однако не является единственным сценарием.

С ростом популярности таких концепций, как Интернет вещей, значительно растет спрос на основанные на моделировании решения, которые в качестве входных данных принимают непрерывный поток данных. Такой поток формируется с большинства устройств, входящих в единую инфраструктуру систем Интернета вещей. Облачные решения, такие как *sdCloud*, стали разумным ответом на требования промышленности. По сравнению с автономными моделирующими системами пользователя эти системы способны обеспечивать непрерывный расчет моделей системной динамики любой сложности, собирать и предоставлять данные моделирования с различных удаленных точек. Другими словами, они готовы принимать входной поток данных и выполнять расчет модели, в результате чего конечный пользователь получит ответ (непрерывного) потокового моделирования.

В данной статье рассматриваются несколько сценариев сбора данных с удаленных устройств инфраструктуры Интернета вещей. Запуск моделей системной динамики параллельно с процессом, описывающим их, позволяет прогнозировать состояния системы, а также находить дополнительные скрытые внешние влияния на модель. В статье раскрываются все преимущества использования такого подхода по сравнению с аналитическим предсказанием состояния системы, базирующимся на анализе исторических данных. Например, подход непрерывного моделирования может стать хорошей основой для прогнозируемого обслуживания сложных технических систем, так как позволяет эффективнее вычислять ближайшее время технического обслуживания.

**Ключевые слова:** *системная динамика, непрерывное моделирование, моделирование как сервис, облачные вычисления, Интернет вещей, потоковая обработка данных, sdCloud.*

Системная динамика – универсальный механизм для описания и симуляции динамичного поведения систем из сфер бизнеса, экономики, локальной среды и социологии. В настоящее время этот подход широко применяется для описания таких сложных технических систем, как Интернет вещей (Internet of things – IoT) и других областей, связанных с анализом больших данных. В большинстве случаев для определения значений набора характеристик системы или события одной только возможности запустить модель на наборе уже известных параметров недостаточно.

Говоря как о выполнении модели в общем, так и о системной динамике в частности, предполагаем, что есть определение модели заданного формата и механизм расчета для этой модели. За стартовую точку процесса моделирования принимается входной поток данных. В большинстве случаев такие входные данные моделирования отображают некоторые известные свойства системы и, таким образом, на их основе производится моделирование для выявления неизвестных свойств системы. Во время разработки и отладки моделей наиболее часто встречается ситуация, когда исторические данные используются как для ввода, так и для вы-

вода модели. Когда все свойства системы определены, разработчик может судить о работе модели и настроить параметры так, чтобы разница между ожидаемыми и полученными результатами исследуемой области стала минимальной.

Такой подход отлично работает, когда достаточно исторических данных, описывающих систему, а цель пользователя – уметь прогнозировать поведение системы или проводить детальный анализ ее внутренних процессов. Часто разработчики используют локальную среду для таких операций. В больших компаниях или при моделировании комплексных систем используется общая среда моделирования на производительных серверах. Учитывая существующую тенденцию внедрения разных программных решений в облачную среду, меняется и моделирование. Наряду с парадигмами «Платформа как сервис» (PaaS), «База данных как сервис» (DBaaS) и «Программное обеспечение как сервис» (SaaS) вводится новое понятие «Моделирование как сервис» (MaaS).

В общем случае расчет модели направлен на работу в локальной среде, но внедрение в облачную среду может привести к появлению новых свойств, которые могли бы улучшить базовые концепции

моделирования и перевести его в облачной среде на новый уровень [1].

### Предпосылки для исследования

Стремительное развитие окружающего мира приводит к усложнению модели, так как для получения достоверных выводов необходимо описывать множество свойств с достаточно высокой точностью. В связи с этим возрастает потребность сбора различной информации, что приводит к необходимости обработки большого объема собранных данных. Самой популярной научной областью по сбору, анализу, хранению и обработке всех видов данных огромного объема стала специальная область исследования, называемая Big Data. Конечно, тенденции роста не могут обойти стороной индустрию моделирования, и облачное MaaS-решение стало обоснованным ответом на задачи моделирования современного мира в терминах Big Data.

По своему определению Big Data связана не только с большим объемом информации, которая хранится в дата-центрах, но и с интенсивным потоком данных, проходящим между разными системами. Этот важный аспект должен быть рассмотрен во время переноса системы моделирования в облако и преобразования из него MaaS-решения. В качестве примера рассмотрим Интернет вещей (IoT). В статье [2] показано, как методы системной динамики могут применяться в разных областях деятельности, где используется IoT. Одной из таких сфер применения является инфраструктура общественного транспорта в населенных пунктах [3]. Для изучения различных аспектов транспортных систем некоторые авторы предлагают использовать системную динамику [3–6].

Решения IoT используют миллионы подключенных устройств, способных производить экстремально большие объемы данных, которые должны быть сохранены и проанализированы. Анализ таких потоков данных стал критической функциональностью во всех системах. Нет смысла собирать терабайты данных со всех устройств за несколько минут, поскольку человек не способен проанализировать такой большой поток данных. Поэтому необходима универсальная интеллектуальная система, которая позволяет агрегировать и понимать полученные данные, поступающие со всех устройств, и оповещает пользователя только о важных событиях и критических изменениях в системе. Таким образом, полезность такой системы значительно растет.

Для решения большинства проблем, связанных с IoT-решениями, необходимо иметь специальный механизм, который позволит предсказывать направление изменения состояния системы. В докладе [7] описывается следующий подход к моделированию системной динамики для IoT: «Цель

моделирования системной динамики в целом определяется двумя путями. Первая цель моделирования заключается в понимании и описании поведения системы. Для понимания поведения системы исследователи описывают поведение через временной граф. С другой стороны, разработчик системно-динамической модели исполняет модель для прогнозирования будущего состояния на основе текущей структуры системы. Эти два подхода моделирования обычно проводятся одновременно». Например, система мониторинга трафика на дороге на основе инфраструктуры Интернета вещей легко может ответить на такие вопросы, как «Какой трафик мы могли увидеть в прошлую среду?» или «Какой трафик сейчас в районе АБВ?». Ответ на эти вопросы уже представлен в большом наборе данных, который был собран с сенсоров машин и других дополнительных датчиков, установленных на улицах. Однако интереснее найти ответы на такие вопросы, как «Что случится, если дорога Б будет закрыта для ремонта в четверг с 11 утра до 4 вечера?». И в этом случае в зависимости от сложности и специфики механизма предсказания понятие «случится» может трактоваться по-разному и включать такие ожидаемые моменты, как скорость движения на ближайших улицах, задержки общественного транспорта в прилегающих районах, влияние на сервисы экстренного обслуживания, ожидаемые изменения в воздушной среде из-за образования новых пробок на дорогах.

### Опережающее обслуживание

Приведенные ожидаемые моменты – это просто высокоуровневые ответы, полученные путем прогнозирования временных рядов на основе анализа данных. В их перечень могут быть включены и возможные интересные случаи из других областей знаний, которые необходимы для конкретного приложения, например, владельцам транспортных компаний, использующих IoT-устройства в своем автобусном парке или на другом общественном транспорте. Компания, бережно относящаяся к своей технике и оборудованию, должна осуществлять их обслуживание своевременно и качественно. В противном случае последующее обслуживание может потребовать больших финансовых затрат на замену сломанных или поврежденных деталей, а также на исправление последствий поломки.

Одно из популярных приложений IoT – опережающее обслуживание (PM – Predictive maintenance). Оно заключается в том, что собирается информация об использовании оборудования и затем на основе ключевых моментов, выявленных из этой информации, предпринимаются попытки его обслуживания. В таком случае нельзя придерживаться простой схемы «обслуживание каждые 30 дней», более точный подход – «обслуживание каж-

дые 1 000 часов работы двигателя» или более сложная комбинация характеристик, которые отслеживаются датчиками. Если учитывать данные во время анализа, например, планируемых дорожных ремонтных работ, необходимо предсказать, как это повлияет на план обслуживания. В большинстве случаев для решения проблемы с дорожными работами есть два пути: оставить маршрут движения без изменений (если это возможно) и продолжать движение с меньшей скоростью или найти другой маршрут. Предполагая, что первоначальный маршрут был оптимальным, любая иная схема проезда увеличит длительность маршрута, а это, в свою очередь, увеличит время работы двигателя. Данный случай можно представить в виде схемы, изображенной на рисунке 1.

### Непрерывное моделирование

Один из способов предсказания поведения системы – это сбор исторических данных и моделирование в течение требуемого времени. Такой вид предсказания часто работает, когда имеем дело с системами, которые повторяют свое поведение с некоторой периодичностью, пропорциональной функции с линейными или простыми нелинейными коэффициентами. Например, можно сказать, что движение в некотором направлении, предположим, между 7 и 10 часами утра, в целом одинаково для каждого дня по той причине, что люди в основном едут на работу и это повторяется регулярно. Для улучшения предсказания такой модели можно разделить неделю на рабочие и выходные дни, так как шаблон действий для них будет отличаться. Если углубиться, то можно различить отдельные дни недели и сказать, что все движение по всем понедельникам/вторникам и т.д. одинаково. Это позволит рассматривать регулярные события, например, такие, как подача топлива на АЗС во вторник и пятницу в 20:30, что затрудняет движение на некото-

рых участках дорог, вызванных парковкой грузовиков на АЗС. За следующий шаг можно взять разделение дней по фактической дате. Такое разделение позволит рассматривать события, которые происходят, например, в каждые 11-й и 25-й дни месяца. Но такая детализация значительно снижает статистическую основу данных, которую можно использовать. Когда предположим, что все дни одинаковы, получим 365 контрольных точек в течение всего года. Если будем считать, что только рабочие дни имеют одинаковое поведение, их будет всего 250. Если разбить данные на группы по дням недели, получим 52 точки для каждого дня недели, а в случае группировки статистических данных по количеству дней в месяце их будет 12. С другой стороны, если попытаться расширить область сбора данных с одного года до трех лет, будет включено так много скрытых параметров, влияющих на статистику, что с этими данными будет трудно работать.

Помимо статистических методов, существуют и другие подходы к получению разумных прогнозов. Большинство IoT-систем являются динамическими, развивающимися с течением времени. По этой причине они хорошо описываются в терминах системной динамики. Существует множество работ, связанных с разработкой моделей системной динамики для покрытия различных аспектов на различных системах с поддержкой IoT. С точки зрения системной динамики очень важно, чтобы IoT вошел во многие области, которые изучались и исследовались в течение долгого времени, например, планирование и мониторинг движения. Будучи проблемой системной динамики, планирование трафика изучалось во многих работах и описывалось с хорошо продуманными и изученными моделями. В последнее время IoT обосновался в этой области, и относительно легко извлечь выгоду из синергии существующих исследований и способности собирать большие объемы актуальных

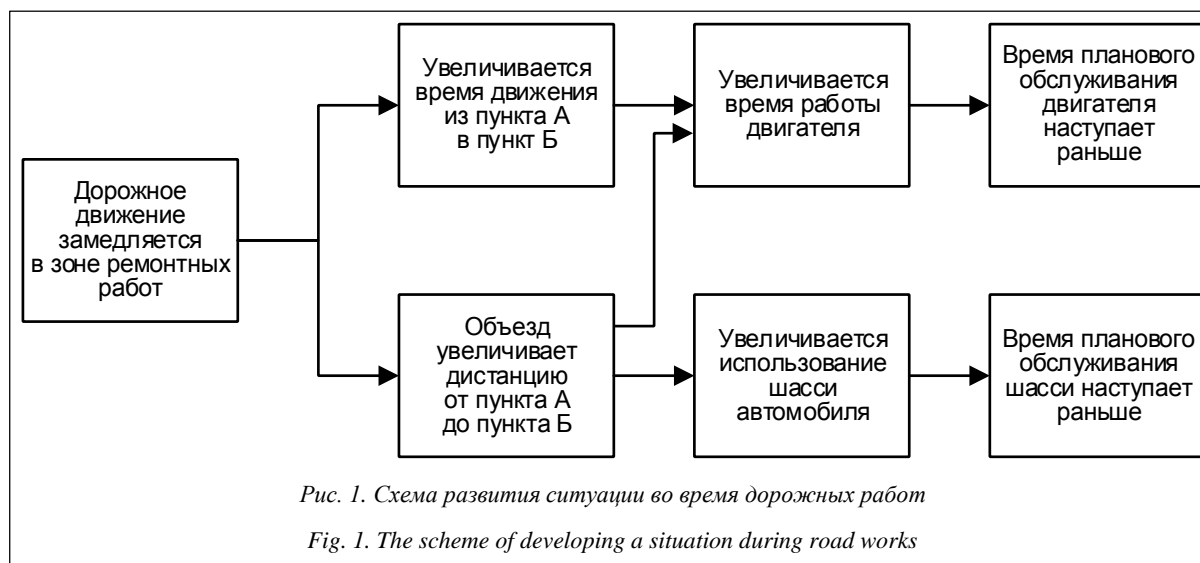


Рис. 1. Схема развития ситуации во время дорожных работ

Fig. 1. The scheme of developing a situation during road works

данных. Первоначально модели системной динамики выполнялись на наборах исторически накопленных данных. Для систем с поддержкой IoT такой подход все еще легко применим. Например, можно собирать данные в течение 24 часов, после чего, базируясь на этих данных, выполнять модель для прогнозирования следующих 24 часов. Поскольку данные IoT являются бесконечным потоком, будет намного выгоднее ввести новую парадигму для выполнения моделей динамических систем – непрерывное выполнение модели в потоке данных в реальном времени. Эта парадигма особенно целесообразна для подхода MaaS, когда выполнение модели происходит в облаке, обеспечивая фактически прогнозы в реальном времени в зависимости от входного потока данных.

На рисунке 2 приведена блок-схема выполнения моделей системной динамики в потоке данных реального времени.

Такой подход непрерывного моделирования не только обеспечивает постоянно обновляемый прогноз для системы, но и имеет две контрольные петли для инкрементной настройки модели и проверки ее поведения. Первый контур управления предназначен для непрерывного сравнения и приближения входных данных с реальными данными IoT, которые поступают в облако моделирования с небольшой задержкой. Второй контур управления предназначен для сравнения трех результирующих потоков одновременно. Например, мы собираемся аппроксимировать входные данные для следующих 24 часов и выполнять модель системной динамики на основе полученных данных для того, чтобы сделать предположение о будущем состоянии системы. Через 24 часа расчет модели на реальных данных, поступающих из системы, будет выполнен и, в конце концов, появится возможность сравнить предсказанный результат с действительным. Это сравнение покажет, насколько близко результаты моделирования (рассчитанные на реальных данных и предсказанных) соответствуют действительному состоянию системы. Кроме того, время от времени можно производить реальные измерения и сравнивать эти фактические результаты с результатами моделирования на реальных и предсказанных данных. Такое сравнение показывает, насколько точно результаты моделирования соответствуют реальным данным.

Предсказание состояния и поведения системы в будущем не является единственным применением описанного подхода к моделированию. Модель, исполняемая совместно с реальной системой, может рассматриваться как гибкая теньевая система, которая позволит найти ответы на такие вопросы, как «Что, если...?», и т.д.

С одной стороны, в любой момент времени модель хранит последнее состояние, рассчитанное на основе реальных данных, определяемых организацией системы, а также операционной системой и



историей операций с моделью. Из этого состояния (описанный ранее случай) модель была рассчитана на будущее, а расчет основан на приближении входных данных модели. В дополнение к симуляции прогнозирования можно комбинировать модель с любым потоком искусственных входных данных, который может быть имитацией некоторого нового сценария использования для целевой системы. В этом случае модель позволит узнать, как система будет вести себя, если (учитывая ее текущее состояние) изменить сценарий ее использования. Этот прецедент будет полезен для планирования различных изменений в реальной системе, манипулируя с его тенью.

Одна из областей использования IoT, где такой подход к моделированию значим, – это прогностическое и профилактическое обслуживание [8, 9]. В [9] оно описывается следующим образом: «Прогностическое обслуживание является дополнением к профилактическому обслуживанию. Благодаря использованию различных методов неdestructивного контроля и измерений прогнозирование технического обслуживания определяет состояние оборудования до разрушения. Имея доступные в настоящее время интеллектуальные устройства, организации по техническому обслуживанию должны включать процесс прогностического обслуживания в свои программы технического обслуживания. Общая программа PPM абсолютно необходима для эффективного, надежного и безопасного производственного процесса. Такой подход имеет существенные преимущества, в том числе повышение качества продукции, увеличение срока службы автомобиля, предотвращение остановки работы, повышение безопасности, следовательно, увеличение эффективности и уменьшение затрат».

С другой стороны, прогностическая область была разработана для того, чтобы хорошо описывать методы и техники системной динамики. Применение моделей системной динамики и подходы для эффективного планирования и выполнения обслуживания по предсказанию описаны в [10, 11]. В [12, 13] применение этого подхода описывается следующим образом: «Системная динамика – это метод, который был создан для анализа и моделирования сложных динамических систем. Разработанные модели не только позволяют пользователю сравнивать эффективность различных работ по техническому обслуживанию друг с другом, но также дают возможность определить комбинацию этих действий, что приведет к общей стратегии обслуживания системы с минимальными затратами за счет оптимизации. Это позволяет менеджерам инфраструктуры оценивать текущую программу обслуживания и определять экономически улучшенную стратегию на будущее».

Предположим, что моделируемая система включает две группы параметров: входные параметры моделирования и результаты моделирования. Они измерены и взяты из реальной системы в определенный момент времени. При использовании метода непрерывного моделирования входные параметры моделирования измеряются и передаются в облачный сервис моделирования. В облачной службе для каждого нового набора данных вычисляется следующее состояние модели. После этого система моделирования выполняет экстраполяцию параметров входного моделирования за период, который используется для дальнейшего прогнозирования, посредством вычислений и моделирования на сгенерированных данных. В итоге будут получены результаты моделирования, осно-

ванные на экстраполированном входном потоке. Другими словами, имеются три потока данных:

- входные параметры моделирования, поступающие из реальной среды;
- экстраполированные входные параметры моделирования;
- выходные результаты моделирования.

Первая контрольная точка может быть описана следующим образом. Предположим, что прогнозируется система трафика в течение следующих 24 часов. Это означает, что если сделать экстраполяцию в момент  $T_1$ , можно было бы сравнить экстраполированные данные с реальными через 24 часа. Это сравнение предоставит информацию о качестве нашего экстраполяционного подхода о том, насколько сгенерированные данные близки к реальным, собранным в течение следующих 24 часов.

Вторая контрольная точка – сравнение измеренных параметров системы с прогнозом, предоставляемым системой. В результате выполнения модели можно получить вектор  $R$ , содержащий свойства системы, представляющие некоторые из параметров системы в течение следующих 24 часов. Через 24 часа можно измерить фактические системные параметры  $R'$ , и будет получен вектор  $R''$ , который является результатом расчета модели на реальных данных IoT. Разница между этими тремя векторами покажет, насколько хороша модель. Анализ этой разницы может помочь понять, как улучшить модель.

Существуют два варианта того, как данные реального времени могут быть привязаны к модели: синхронно и асинхронно.

Синхронный путь означает, что полный набор параметров моделирования ввода доставляется в модель в одном наборе данных. Другими словами, если у нас есть  $N$  параметров, необходимых для вычисления следующего шага модели, значит, все  $N$  параметров доставлены в механизм выполнения модели в одном сообщении, где определены все необходимые свойства.

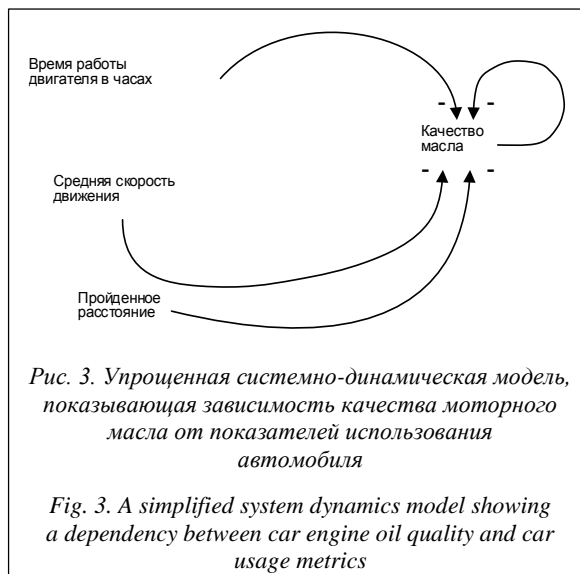
Асинхронный способ означает, что различные входные параметры моделирования передаются для выполнения модели отдельно от реальной системы. Требуется создать единый набор данных для следующего этапа выполнения модели на стороне ее исполнения, чтобы выровнять асинхронные изменения в поступающих данных. Решить эту проблему можно посредством различных стратегий для синхронизации входного потока. Один из простейших подходов – сохранить самые последние значения на входах модели и использовать отдельный канал в качестве импульса синхронизации для начала выполнения модели. Такой подход может обеспечить более безопасный канал трафика между датчиками и платформой выполнения, поскольку можно отправлять только измененные значения.

Принимая во внимание общие подходы к применению системно-динамического моделирования в области прогнозирующего обслуживания, составим простую модель, описывающую зависимость качества масла в автомобильном двигателе от использования автомобиля, чтобы проиллюстрировать подход к непрерывному моделированию.

Такая модель может широко использоваться различными компаниями для эффективного планирования технического обслуживания, в частности, замены моторного масла, в их автопарке. Дата смены масла зависит от таких параметров использования автомобиля, как количество часов работы двигателя, средняя скорость движения и загруженность автомобиля. В большинстве случаев, когда для мониторинга и управления автопарком прогнозическое обслуживание не применяется, техническое обслуживание парка, включая замену моторного масла, выполняется на основе календаря. Это значит, что для каждого транспортного средства существует набор фиксированных дат технического обслуживания, которые не коррелируют с фактическим использованием автомобиля. По статистике, более 25 % отказов двигателя автомобиля обусловлены низким качеством моторного масла. Исключение из рассмотрения метрик использования транспортного средства может привести к следующим отрицательным последствиям: заменить масло, когда его еще можно использовать (но такой подход неэффективен) или когда оно уже оказало негативное влияние на двигатель.

Прогностическое обслуживание на основе системно-динамической модели помогает прогнозировать качество моторного масла на основе фактической информации об использовании автомобиля. Поскольку основная роль масла в двигателе заключается в защите его деталей, интенсивное использование двигателя приведет к более быстрой потере противозносных свойств масла. Эта концепция была включена в иллюстративную модель, используемую в статье. На рисунке 3 показана системно-динамическая модель для описанного примера. Все три свойства негативно влияют на качество масла. Кроме того, оказывает влияние и расчетное качество масла, потому что в реальной системе ухудшение качества моторного масла является нелинейным процессом и, как следствие, чем ниже качество масла, тем быстрее оно становится непригодным.

Для проверки описанного подхода для системно-динамической модели в реальном времени с целью прогнозирования используем модель для прогнозирования качества моторного масла, описанную выше. Для оценки возьмем следующий сценарий. Экспериментальный автомобиль оснащен двумя датчиками: один сообщает о средней текущей скорости движения, другой – о загруженности машины. Автомобиль управляется в соответствии с маршрутом доставки им различных видов



товаров; это объясняет, почему уровень нагрузки изменяется со временем. Данные собираются каждую минуту и каждый час доставляются на сервер. Вот почему во время процесса моделирования существуют двукратные рамки two-time frames: модель работает на дату, поступившую из автомобиля, она настроена на реальные данные IoT; в течение следующего часа данные не поступают, поэтому модель работает на наборе, построенном на основе приближения исторических данных (приближение на основе данных предыдущего часа). Таким образом, процесс моделирования превращается в прогнозирование. В этом эксперименте видны два ключевых момента для проверки результатов моделирования и аппроксимации. Диаграммы, изображенные на рисунках 4 и 5, показывают разницу между реальной скоростью и загруженностью и вычисленными приближениями. Светлые линии показывают реальные данные IoT, темные – приближенные, используемые при моделировании для периодов, где данные IoT еще не были доступны.

На рисунке 6 видим разницу между результатами моделирования для качества моторного масла на основе реальных данных IoT по сравнению с результатами моделирования, основанными на аппроксимации входных данных, для потенциального прогнозирования целевого значения. Более светлая линия показывает результат моделирования на основе реальных данных, более темная – на основе приближения данных.

В этом примере использовалась функция тривиального приближения. Аппроксимация основана на простом усреднении двух значений, принятых в начале и в конце предыдущего периода. Даже при таком простом приближении видно, что результаты моделирования на реальных данных и приближении очень близки друг к другу.

Описанный пример показывает упрощенный подход к запуску системно-динамических моделей




Рис. 4. Скорость машины  
(действительная и аппроксимированная)

Fig. 4. Car speed (real and approximated)




Рис. 5. Загрузка машины  
(действительная и аппроксимированная)

Fig. 5. Car load (real and approximated)




Рис. 6. Предсказанное качество масла  
(по реальным и по приближенным данным)

Fig. 6. Predicted oil quality  
(on real and approximated data)

в реальном времени в основном из-за очень простого подхода приближения и очень короткого периода прогнозирования, взятого для запуска модели. В случае реального использования предлагаемого подхода необходимо провести дополнительные исследования для правильной идентификации функции аппроксимации и настройки системно-динамической модели на основе анализа разниц между предсказанием, полученным моделью по приближенным входным данным, и результатом модели, вычисленным по реальным данным через некоторое время, когда предсказанный момент действительно наступит.

Это и есть базовый рабочий процесс, необходимый для запуска модели динамики системы на реальном потоке данных в облачном решении sdCloud.

Описанный подход к моделированию для непрерывного выполнения системно-динамических моделей в потоке данных обеспечивает ряд преимуществ.

1. Независимое облачное решение, ориентированное на большие потоки данных.

2. Возможность непрерывного мониторинга разницы между реальными значениями потока данных и приближительными, генерируемыми для прогнозирования. Если выполнение модели вначале хорошо настроено, для большинства технических систем поведение может быть спрогнозировано с относительно высокой точностью. Если обнаружено, что с течением времени разница между приближенными и реальными значениями существенно меняется, значит, с системой происходит что-то непредсказуемое. Поэтому метрика может быть хорошим знаком, чтобы показать, что система требует внимания к операторам. Например, в рассматриваемом случае (качество масла в двигателе автомобиля) изменение разницы между реальной зарегистрированной скоростью и ее аппроксимацией означает, что автомобиль не может двигаться с той же скоростью, что и раньше, допустим, из-за изменений трафика во время дорожных работ или из-за некоторых проблем с самим автомобилем. В обоих случаях необходимо вернуть систему в прежнее рабочее состояние.

3. Возможность непрерывного мониторинга разницы между фактическим измерением параметров системы и результатами выполнения модели для реальных данных, передаваемых в систему, прогнозного моделирования на основе приближенного потока данных в тот же момент времени. Если результаты моделирования начали отличаться от реальных измеренных параметров системы, значит, по какой-то причине модель больше не отражает поведение системы и важно выяснить основную причину такой ситуации. Например, в случае, описанном в статье, реальные измерения лучше покажут более низкое качество моторного масла, чем вычисленные прогнозные или выполненные на реальных данных. Это может означать, что в системе появляется новый фактор, который влияет на качество масла. Например, такая проблема с двигателем, как грязный масляный фильтр.

## Вывод

Моделирование динамических систем – мощный инструмент для их мониторинга, прогнозирования и планирования. В настоящее время многие системы подключены к Интернету, например, в парадигме IoT, когда огромное количество устройств, большинство из которых были хорошо известны и работали в автономном режиме, подключились к Интернету. С одной стороны, такой сдвиг дает возможность собирать больше информации о фактическом поведении системы, что может улучшить управляемые, оптимизированные и эффективные системы. Но, с другой, большими объемами данных сложно управлять. Чтобы получить большую ценность из собранных данных, важно преобразо-

вать необработанные данные в информацию, что поможет принимать правильные решения. Что касается данных, то трудно принять какое-либо существенное решение, пока эти данные «сырые».

В течение долгого времени различные виды моделирования и математические модели использовались для того, чтобы понять, как ведут себя сложные системы и какие способы их улучшения существуют. При использовании метода непрерывного моделирования системной динамики, описанного в данной статье и реализованного платформой sdCloud, раскрывается новое приложение для них. Вместо запуска модели на основе некоторых теоретических выводов и поиска ответа на такие вопросы, как «Что делать, если у нас будет этот вход?» или «Какой вход приведет к требуемой цели?», непрерывное моделирование помогает найти ответ на вопрос «В каком состоянии конкретная система находится в данный момент времени?». Другими словами, непрерывное моделирование – подход для понимания данных и преобразования их в полезную информацию, необходимую для правильного и эффективного принятия решений.

Еще одно достоинство такого подхода в том, что эта модель является послушным инструментом, позволяющим проверять гипотезу «Что если?». Поскольку модель работает на реальных данных, поступающих из реальной системы, она становится ее тенью копией, помогая выяснить, например, что произойдет с системой, если изменить какой-либо из параметров. Ответ будет связан не с некоторой системой, описанной моделью, а с реальной пользовательской системой. Приложение, рассмотренное в решении sdCloud, обратило почти шестьдесят лет эволюции системной динамики в сторону современных облачных технологий и систем Big Data. Непрерывное моделирование обеспечивает не только способность создавать мо-

дель какой-либо системы и вычислять неизвестные аспекты на основе известных данных, но и выполнять различные виды мониторинга эволюции системы и управления временем.

#### Литература

1. Mulyukin A.A., Kossovich T., Perl I.A. Effective execution of systems dynamics models. Proc. 19th Conf. of Open Innovations Association FRUCT, 2016, pp. 358–364.
2. Marshall P. System dynamics modeling of the impact of Internet-of Things on intelligent urban transportation. Proc. Regional Conf. ITS, Los Angeles, CA, 2015.
3. Abbas K.A., Bell M.G. System dynamics applicability to transportation modeling. Proc. System Dynamics Conf., Transportation Research Part A: Policy and Practice, 1994, vol. 28, i. 5, pp. 373–390.
4. Bernardino J.P.R., van der Hoord M. Parking policy and urban mobility level of service – system dynamics as a modeling tool for decision making. Europ. Jour. of Transport and Infrastructure Research, 2013, i. 13, vol. 3, pp. 239–248.
5. Mitrea O. System dynamics modeling of intelligent transportation systems human and social requirements for the construction of dynamic hypothesis. Selected Topics in Nonlinear Dynamics and Theoretical Electrical Engineering, Springer, 2013, pp. 211–226.
6. Hennessy G., Cook J., Bean M., Dykes K. Economic dynamics for smarter cities. Proc. Intern. System Dynamics Society, 2011, 20 p.
7. Lee E.K., Dong-Hwan K., Won G.H. System dynamics modeling for the future IT development: applied to education, health care, and smart work system in Korea. Proc. 29th Intern. Conf. System Dynamics Society, 2011, 8 p.
8. Preventive and Predictive Maintenance, 700ZB00102, URL: <https://www.lce.com/pdfs/The-PMPdM-Program-124.pdf> (дата обращения: 10.12.2017).
9. Hashemian H.M., Wendell C. Bean, state-of-the-art predictive maintenance techniques. IEEE Transactions on Instrumentation and Measurement, 2011, vol. 60, no. 10, pp. 3480–3492.
10. Adolfo C.M., Ruiz U. Learning maintenance management through system dynamics. Proc. 13th Intern. Conf. System Dynamics Society, 1994, pp. 20–27.
11. Böhm T., Beck K., Knaak A., Jäger B. Efficient maintenance strategy through system dynamics. Computers in Railways XI (2008): Web. 7 Feb. 2017, pp. 755–764.
12. Sterman J. Business dynamics: systems thinking and modeling for a complex world. Cambridge, 2002, 1008 p.
13. Forrester J.W. The beginning of system dynamics. Cambridge, MIT, 1989, 16 p.

#### CONTINUOUS EXECUTION OF SYSTEM DYNAMICS MODELS ON INPUT DATA STREAM

*I.A. Perl*<sup>1</sup>, Ph.D. (Engineering), Associate Professor, [ivan.perl@corp.ifmo.ru](mailto:ivan.perl@corp.ifmo.ru)  
*M.M. Petrova*<sup>1</sup>, Postgraduate Student, [maria.petrova@corp.ifmo.ru](mailto:maria.petrova@corp.ifmo.ru)  
*A.A. Mulyukin*<sup>1</sup>, Postgraduate Student, [alexprey@ya.ru](mailto:alexprey@ya.ru)  
*O.V. Kalenova*<sup>1</sup>, Postgraduate Student, [ovkalyonova@corp.ifmo.ru](mailto:ovkalyonova@corp.ifmo.ru)

<sup>1</sup> The National Research University of Information Technologies, Mechanics and Optics, Kronverksky Ave. 49, St. Petersburg, 197101, Russian Federation

**Abstract.** This article describes a new approach to system dynamics models execution. In most cases when model execution is involved, the input data is a set of static and known data. It is expected that on the model output modeler will get a set of other system or event characteristics computed by the model based on the input parameters. This approach is still used widely in different industries, but it is not the only scenario.



With growing popularity of some concepts such as the Internet of Things, the demand on modeling-based solutions, which take continuous data streams as input, has grown significantly. In comparison with stand-alone client-side modeling systems, cloud-based solutions, such as sdCloud, became a reasonable answer to the industry request. Such systems can provide an ability of continuous execution of system dynamics models. In other words, these systems are ready to accept an incoming data stream and perform model execution that will result in streaming modeling results back to the end-user.

Running system dynamics models in parallel with the describing process allows performing predictive modeling of the system status in the future. It also allows finding additional hidden external impacts to the model. For example, such approach can be a base for predictive maintenance of complicated technical systems, because it allows computing nearest maintenance time more efficiently.

**Keywords:** system dynamics, continuous modeling, modeling as a service, cloud computing, Internet of Things, stream data processing, sdCloud.

### References

1. Mulyukin A.A., Kossovich T., Perl I.A. Effective execution of systems dynamics models. *Proc. 19th Conf. of Open Innovations Association FRUCT*. Univ. of Jyväskylä, 2016, pp. 358–364.
2. Marshall P. System dynamics modeling of the impact of Internet-of-Things on intelligent urban transportation. *Regional Conf. of the Intern. Telecommunications Society (ITS)*. Los Angeles, CA, 2015.
3. Abbas K.A., Bell M.G. System dynamics applicability to transportation modeling. *System Dynamics Conf., Transportation Research Part A: Policy and Practice*. 1994, vol. 28, i. 5, pp. 373–390.
4. Bernardino J.P.R., van der Hoord M. Parking policy and urban mobility level of service – system dynamics as a modeling tool for decision making. *European Jour. of Transport and Infrastructure Research*. 2013, i. 13 (3), pp. 239–248.
5. Mitrea O. System dynamics modeling of intelligent transportation systems human and social requirements for the construction of dynamic hypothesis. *Selected Topics in Nonlinear Dynamics and Theoretical Electrical Engineering*. Springer Publ., 2013, pp. 211–226.
6. Hennessy G., Cook J., Bean M., Dykes K. Economic dynamics for smarter cities. *Proc. of the System Dynamics Society*. 2011, 20 p.
7. Lee E.K., Dong-Hwan K., Won G.H. System dynamics modeling for the future IT development: applied to education, health care, and smart work system in Korea. *Proc. 29th Int. Conf. of the System Dynamics Society*. 2011, 8 p.
8. *Preventive and Predictive Maintenance*. 700ZB00102. Available at: <https://www.lce.com/pdfs/The-PMPdM-Program-124.pdf> (accessed December 10, 2017).
9. Hashemian H.M., Wendell C. Bean, state-of-the-art predictive maintenance techniques. *IEEE Trans. on Instrumentation and Measurement*. 2011, vol. 60, no. 10, pp. 3480–3492.
10. Adolfo C.M., Ruiz U. Learning maintenance management through system dynamics. *Proc. 13th Intern. Conf. of the System Dynamics Society*. 1994, pp. 20–27.
11. Böhm T., Beck K., Knaak A., Jäger B. Efficient maintenance strategy through system dynamics. *Computers in Railways XI (2008): Web. 7 Feb.* 2017, pp. 755–764.
12. Sterman J. *Business dynamics: systems thinking and modeling for a complex world*. Cambridge, 2002, 1008 p.
13. Forrester J.W. *The beginning of system dynamics*. Cambridge, MIT, 1989, 16 p.

### Примеры библиографического описания статьи

1. Перл И.А., Петрова М.М., Мулюкин А.А., Каленова О.В. Исполнение моделей системной динамики на основе непрерывного потока входных данных // Программные продукты и системы. 2018. Т. 31. № 2. С. 353–361. DOI: 10.15827/0236-235X.122.353-361.
2. Perl I.A., Petrova M.M., Mulyukin A.A., Kalenova O.V. Continuous execution of system dynamics models on input data stream. *Programmnye produkty i sistemy* [Software & Systems]. 2018, vol. 31, no. 2, pp. 353–361 (in Russ.). DOI: 10.15827/0236-235X.122.353-361.