ПРИМЕНЕНИЕ КОМПЬЮТЕРНОГО МОДЕЛИРОВАНИЯ ПРИ ОБУЧЕНИИ СИСТЕМ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

Жураева Камила Комиловна
Ташкентский университет прикладных наук,
e-mail: lade00@bk.ru
Тешабоев Хужамиёр Норматжон угли
ТУИТ имени Мухаммада ал-Хоразмий,
e-mail: teshaboyev@tuit.uz

Аннотация. *В статье рассматривается использование компьютерного моделирования для формирования данных и обучения систем искусственного интеллекта, применяемых при анализе состояния промышленного оборудования. Охарактеризованы этапы построения математической модели, получения синтетических данных, подготовки обучающих выборок и оценки качества прогнозирования. На концептуальном примере вибрационного мониторинга показана возможность использования модельных зависимостей для подготовки алгоритма прогнозирования. Обсуждается значение прогнозных оценок для планирования технического обслуживания и поддержки организационно-управленческих решений на предприятии. Отмечены ограничения подхода, связанные с адекватностью компьютерной модели и необходимостью проверки на реальных данных.*

Ключевые слова: *компьютерное моделирование, искусственный интеллект, машинное обучение, синтетические данные, прогнозирование технического состояния, промышленное оборудование, поддержка принятия решений.*

Abstract. *The article examines the use of computer modeling to generate data and train artificial intelligence systems used in the analysis of the condition of industrial equipment. The stages of constructing a mathematical model, obtaining synthetic data, preparing training datasets, and assessing the quality of forecasting are described. Using a conceptual example of vibration monitoring, the possibility of using model dependencies to prepare a forecasting algorithm is demonstrated. The importance of forecast estimates for planning maintenance and supporting organizational and managerial decisions at the enterprise is discussed. The*

limitations of the approach, related to the adequacy of the computer model and the need to verify it using real data, are noted.

Keywords: *computer modeling, artificial intelligence, machine learning, synthetic data, technical condition forecasting, industrial equipment, decision support.*

Annotatsiya. *Maqolada ma'lumotlarni shakllantirish va sanoat uskunalari holatini tahlil qilishda ishlatiladigan sun'iy intellekt tizimlarini o'qitish uchun kompyuter simulyatsiyalaridan foydalanish ko'rib chiqilgann. Matematik modelni yaratish, sintetik ma'lumotlarni olish, o'quv namunalarini tayyorlash va prognozlash sifatini baholash bosqichlari tavsiflangan. Vibratsiyali monitoringning kontseptual misoli bashorat qilish algoritmini tayyorlash uchun modelga bog'liqliklardan foydalanish imkoniyatini ko'rsatadi. Korxonada texnik xizmat ko'rsatishni rejalashtirish va tashkiliy va boshqaruv qarorlarini qo'llab-quvvatlash uchun prognoz baholarining ahamiyati muhokama qilinadi. Kompyuter modelining yetarliligi va haqiqiy ma'lumotlarni tekshirish zarurati bilan bog'liq yondashuv cheklovlari qayd etilgan.*

Kalit so'zlar: *kompyuter simulyatsiyasi, sun'iy intellekt, mashinani o'rganish, sintetik ma'lumotlar, texnik holatni bashorat qilish, sanoat uskunalari, qarorlarni qo'llab-quvvatlash.*

Введение

Развитие информационных технологий сопровождается расширением областей применения искусственного интеллекта в промышленности, энергетике, транспорте и других направлениях технической деятельности. Интеллектуальные системы используются для обработки больших массивов информации, выявления закономерностей, классификации объектов и прогнозирования изменений технических параметров.

Одним из основных условий разработки подобных систем является наличие данных, необходимых для обучения алгоритмов. В реальных условиях получение достаточного объёма информации может сопровождаться определёнными трудностями. Некоторые режимы работы оборудования возникают редко, экспериментальные исследования требуют значительных затрат, а проведение испытаний при аварийных ситуациях не всегда возможно по соображениям безопасности.

В таких обстоятельствах особое значение приобретает компьютерное моделирование, позволяющее воспроизводить различные состояния исследуемого объекта без непосредственного воздействия на реальную

техническую систему. На основе математического описания формируется компьютерная модель, с помощью которой можно изменять исходные параметры, анализировать характеристики процессов и получать дополнительные данные для обучения алгоритмов.

В исследованиях, посвящённых использованию синтетических данных, отмечается возможность применения компьютерных моделей для подготовки обучающих выборок и решения задач, связанных с недостаточным количеством реальных наблюдений [1].

Вместе с тем качество результатов зависит не только от выбранного алгоритма искусственного интеллекта, но и от степени соответствия модели реальным физическим процессам. Поэтому компьютерное моделирование следует рассматривать как составную часть комплексного подхода к разработке и исследованию интеллектуальных систем.

Целью статьи является рассмотрение последовательности применения компьютерного моделирования при обучении систем искусственного интеллекта и определение возможностей использования прогнозных оценок в информационном обеспечении решений о техническом обслуживании промышленного оборудования.

Материалы и методы исследования

Методологическую основу исследования составляют методы математического и компьютерного моделирования, системного анализа и машинного обучения.

Исследование имеет аналитико-методический характер и основано на рассмотрении научных публикаций и разработке концептуального примера формирования обучающих данных. Собственные экспериментальные измерения и обучение программной модели в рамках данной статьи не проводились.

Компьютерное моделирование предполагает представление исследуемого объекта в форме математических зависимостей, логических условий или программных алгоритмов, отражающих его наиболее существенные характеристики. В качестве общего методического приёма моделирование используется и в образовательных задачах [2]; в настоящей работе этот подход рассматривается применительно к подготовке данных для интеллектуального анализа промышленного оборудования.

В общем виде динамическую модель технической системы можно представить выражением:

$$x_{k+1} = f(x_k, u_k, p) + w_k,$$

где:

x_k – вектор состояния объекта в момент времени (k);

u_k – вектор входных воздействий;

p – параметры модели;

f – функция, описывающая изменение состояния;

w_k – составляющая, учитывающая случайные воздействия и неопределённость модели.

На основе изменения входных параметров и условий функционирования объекта формируется множество модельных состояний. Полученные результаты могут использоваться для создания синтетических обучающих данных.

При подготовке данных необходимо учитывать допустимые диапазоны параметров, физические ограничения и взаимосвязи между отдельными характеристиками. Использование случайно сформированных значений без учёта закономерностей работы объекта может привести к получению недостоверной обучающей выборки.

В зависимости от решаемой задачи для анализа подготовленной информации могут применяться алгоритмы линейной регрессии, Random Forest, методы опорных векторов и искусственные нейронные сети. Метод Random Forest, предложенный Л. Брейманом, применяется в том числе для решения задач регрессии и оценки значимости признаков [3].

Выбор конкретного метода определяется характером данных, сложностью зависимостей и требованиями к интерпретируемости результатов прогнозирования.

Постановка задачи

При разработке интеллектуальных систем одной из основных проблем является обеспечение алгоритмов машинного обучения данными, отражающими различные режимы функционирования исследуемого объекта.

Для технического оборудования особенно важно учитывать не только нормальные эксплуатационные состояния, но и отклонения, возникающие при изменении нагрузки, температурных условий, механических воздействий и других факторов.

Получение подобных данных исключительно на основании реальных наблюдений не всегда позволяет сформировать достаточно разнообразную выборку. В частности, редкие отклонения и переходные процессы могут отсутствовать в доступных записях измерительных систем. Обзор исследований по предиктивному обслуживанию подтверждает

востребованность методов машинного обучения для обработки эксплуатационных данных [4].

Для решения указанной проблемы предлагается использовать компьютерную модель, обеспечивающую воспроизведение различных сочетаний входных параметров и формирование соответствующих выходных характеристик.

Рассматриваемая задача включает создание математического описания объекта, определение диапазонов изменения параметров, формирование синтетических данных и последующее использование полученной информации для обучения алгоритма искусственного интеллекта.

Особое значение имеет оценка соответствия моделируемых процессов реальным режимам работы оборудования, поскольку наличие большого объёма синтетических данных само по себе не гарантирует высокой точности прогнозирования. Для использования прогнозов в управлении обслуживанием необходимо также учитывать последствия ошибочных оценок состояния оборудования.

Решение задачи

Применение компьютерного моделирования при обучении искусственного интеллекта целесообразно осуществлять последовательно, начиная с определения параметров исследуемого объекта и заканчивая проверкой результатов работы обученного алгоритма.

На первом этапе выполняется анализ объекта и определяются основные характеристики, оказывающие влияние на его техническое состояние. Для промышленного оборудования такими характеристиками могут выступать температура, вибрация, давление, частота вращения и величина нагрузки.

На втором этапе осуществляется построение математической модели, описывающей взаимосвязь между входными воздействиями и выходными параметрами. При этом учитываются ограничения, соответствующие установленным режимам эксплуатации.

На третьем этапе формируется компьютерная среда моделирования. Изменение входных параметров позволяет воспроизводить различные условия функционирования оборудования и получать соответствующие результаты расчёта.

На четвёртом этапе полученные данные подвергаются предварительной обработке. Выполняются проверка допустимости значений, нормализация признаков и формирование обучающей выборки.

На пятом этапе проводится обучение алгоритма искусственного интеллекта. Полученные закономерности используются для решения задачи прогнозирования или классификации технических состояний.

Завершающий этап предусматривает оценку качества обученной модели на независимых данных, в том числе на реальных измерениях, которые не применялись при обучении. При промышленном внедрении необходимо учитывать не только ошибку прогноза, но и зависимости от качества данных и сопровождения программной системы [5].

Таблица 1. Этапы компьютерного моделирования и подготовки данных для интеллектуального анализа оборудования

Этап	Содержание работы	Результат
1. Анализ объекта	Определение основных параметров и факторов воздействия	Перечень входных и выходных характеристик
2. Математическое описание	Разработка зависимостей между параметрами	Математическая модель
3. Компьютерное моделирование	Воспроизведение режимов функционирования	Синтетические данные
4. Подготовка информации	Проверка, обработка и структурирование данных	Обучающая выборка
5. Обучение алгоритма	Настройка модели машинного обучения	Модель прогнозирования
6. Оценка результатов	Проверка точности и способности к обобщению	Показатели качества прогнозирования

В качестве иллюстративного примера рассмотрим применение компьютерного моделирования для обучения алгоритма прогнозирования вибрационного состояния технического оборудования. Такое прогнозирование может служить информационной основой при определении очередности диагностических проверок и планировании технического обслуживания.

Предположим, что величина вибрации зависит от частоты вращения механизма, действующей нагрузки и температуры отдельных элементов конструкции.

Для приближённого описания указанных зависимостей может использоваться следующая модель:

$$V = a_0 + a_1 n + a_2 P + a_3 T + \varepsilon,$$

где V – моделируемый показатель вибрации; n – частота вращения механизма; P – нагрузка; T – температура; a_0, a_1, a_2, a_3 – коэффициенты модели; ε – составляющая, учитывающая случайные отклонения.

Представленная зависимость является упрощённым учебным примером и не описывает в полном объёме сложные динамические процессы, характерные для реального оборудования. Коэффициенты модели должны определяться на основании физических закономерностей либо экспериментальных измерений.

Изменяя значения входных параметров в установленных диапазонах, можно сформировать набор модельных наблюдений. Каждому сочетанию параметров будет соответствовать определённое значение выходной характеристики.

Полученный массив информации может использоваться для обучения алгоритма регрессии, задачей которого является определение прогнозируемой величины вибрации по заданным параметрам работы оборудования.

Обучение направлено на минимизацию расхождения между рассчитанными значениями и прогнозами алгоритма. Для количественной оценки такого расхождения может применяться среднеквадратичная ошибка:

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2,$$

где N – количество наблюдений, y_i – эталонное значение параметра, $\hat{y}_i$ - значение, рассчитанное обученной моделью.

Уменьшение ошибки на синтетических данных характеризует способность алгоритма воспроизводить закономерности компьютерной модели. Однако для оценки практической пригодности интеллектуальной системы необходима дополнительная проверка на реальных эксплуатационных данных.

Если модель технического объекта не учитывает существенные физические зависимости, алгоритм может демонстрировать хорошую точность при работе с синтетической выборкой, но давать значительные ошибки в реальных условиях.

В исследованиях переноса нейронных сетей из компьютерной среды в реальные условия показана возможность варьирования параметров моделируемой среды для повышения устойчивости обучаемых систем [6].

Подобный подход представляет интерес и для задач технической диагностики. Изменение характеристик модели в пределах физически допустимых значений позволяет создавать дополнительные варианты эксплуатационных условий.

Вместе с тем применение искусственно сформированной информации требует контроля её достоверности. Для этого необходимо сравнивать

статистические характеристики синтетических данных с результатами реальных измерений, анализировать ошибки прогнозирования и проверять устойчивость обученного алгоритма к изменению условий эксплуатации.

Таким образом, компьютерное моделирование может использоваться не только как средство исследования физических процессов, но и как инструмент формирования данных для интеллектуального мониторинга. Прогнозные результаты могут учитываться специалистами при планировании проверок и обслуживания, однако автоматическое принятие управленческих решений требует отдельной оценки рисков и достоверности модели.

Обсуждение результатов

Рассмотренный подход показывает методическую возможность объединения математического описания технического объекта и алгоритмов машинного обучения в рамках единой процедуры подготовки интеллектуальной системы.

Основное преимущество компьютерного моделирования заключается в возможности управляемого изменения параметров и воспроизведения условий, которые затруднительно исследовать непосредственно на реальном оборудовании.

Кроме того, применение моделей позволяет систематизировать входные данные, исследовать влияние отдельных факторов и формировать выборки с заранее определёнными характеристиками.

В то же время использование синтетической информации связано с определёнными ограничениями. Прежде всего это необходимость проверки адекватности математической модели, учёта случайных воздействий и различий между моделируемой и реальной средой.

Для практического применения обученных алгоритмов целесообразно сочетать синтетические данные с реальными измерениями. Такая организация исследования позволяет учитывать особенности функционирования конкретного оборудования. Прогнозные оценки могут использоваться как дополнительная информация в цифровых системах планирования технического обслуживания, но не заменяют инженерную диагностику. При переносе моделей между различающимися условиями работы возникает задача адаптации к другому распределению данных, рассматриваемая в исследованиях трансферного обучения [7].

При использовании прогнозов в системе технического обслуживания необходимо учитывать не только обнаружение отклонений, но и этапы

формирования диагностических показателей и оценки остаточного ресурса оборудования. Подобная последовательность рассматривается в систематическом обзоре исследований по прогнозированию состояния машин [8].

Для задач классификации редких неисправностей одной общей точности может оказаться недостаточно. При несбалансированных классах полезно дополнительно анализировать точность и полноту положительного класса, а также кривую precision–recall, что подтверждается сравнительным исследованием показателей качества классификации [9].

Программная реализация изложенной методики в дальнейшем может быть выполнена с применением библиотек машинного обучения, например scikit-learn, объединяющей алгоритмы классификации, регрессии и средства оценки моделей [10]. При этом выбор программного обеспечения не заменяет проверку синтетических данных на соответствие реальным эксплуатационным режимам.

Представленный пример носит концептуальный характер. Для подтверждения эффективности предложенной последовательности в дальнейшем необходимо провести вычислительный эксперимент, определить параметры исследуемого объекта и выполнить количественное сравнение результатов обучения на реальных, синтетических и смешанных данных.

Заключение

Рассмотрено применение компьютерного моделирования при подготовке данных и обучении систем искусственного интеллекта для анализа состояния промышленного оборудования. Математические и компьютерные модели позволяют воспроизводить различные режимы функционирования технических объектов и формировать дополнительные обучающие выборки.

Предложена последовательность применения компьютерного моделирования, включающая анализ объекта, математическое описание, получение синтетических данных, обучение алгоритма и проверку результатов.

На концептуальном примере прогнозирования вибрационного состояния оборудования рассмотрена возможность использования модельных зависимостей для подготовки алгоритма машинного обучения. Прогнозные оценки потенциально полезны при определении приоритетов диагностики и планировании технического обслуживания.

На уровне методического анализа выявлено, что применимость подхода зависит от точности математического описания, качества данных и проверки результатов на реальных измерениях. Количественная оценка влияния такого подхода на качество управленческих решений требует самостоятельного исследования.

Дальнейшие исследования могут быть направлены на сравнение обучения на реальных, синтетических и смешанных данных, изучение устойчивости прогнозов, а также на оценку их практической полезности в системах поддержки принятия решений о техническом обслуживании.

Список литературы

1. Nikolenko S. I. Synthetic Data for Deep Learning. Cham: Springer, 2021. Vol. 174. DOI: 10.1007/978-3-030-75178-4.

2. Василишина Н. В. Применение метода компьютерного моделирования в обучении математике // Вестник Адыгейского государственного университета. 2016. Вып. 2 (178). С. 62–67.

3. Breiman L. Random Forests // Machine Learning. 2001. Vol. 45. P. 5–32. DOI: 10.1023/A:1010933404324.

4. Carvalho T. P., Soares F. A. A. M. N., Vita R., Francisco R. P., Basto J. P., Alcalá S. G. S. A systematic literature review of machine learning methods applied to predictive maintenance // Computers & Industrial Engineering. 2019. Vol. 137. Art. 106024. DOI: 10.1016/j.cie.2019.106024.

5. Sculley D., Holt G., Golovin D. et al. Hidden Technical Debt in Machine Learning Systems // Advances in Neural Information Processing Systems. 2015. Vol. 28. P. 2503–2511.

6. Tobin J., Fong R., Ray A., Schneider J., Zaremba W., Abbeel P. Domain Randomization for Transferring Deep Neural Networks from Simulation to the Real World // 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems. 2017. DOI: 10.1109/IROS.2017.8202133.

7. Pan S. J., Yang Q. A Survey on Transfer Learning // IEEE Transactions on Knowledge and Data Engineering. 2010. Vol. 22, No. 10. P. 1345–1359. DOI: 10.1109/TKDE.2009.191.

8. Lei Y., Li N., Guo L., Li N., Yan T., Lin J. Machinery health prognostics: A systematic review from data acquisition to RUL prediction // Mechanical Systems and Signal Processing. 2018. Vol. 104. P. 799–834. DOI: 10.1016/j.ymssp.2017.11.016.

9. Saito T., Rehmsmeier M. The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets // PLOS ONE. 2015. Vol. 10, No. 3. Art. e0118432. DOI: 10.1371/journal.pone.0118432.

10. Pedregosa F., Varoquaux G., Gramfort A. et al. Scikit-learn: Machine Learning in Python // Journal of Machine Learning Research. 2011. Vol. 12. P. 2825–2830.