Кабалдин Ю.Г., Шатагин Д.А., Колчин П.В.
Разработка «цифрового двойника» токарного станка с ЧПУ

*Нижегородский государственный технический университет им. Р.Е.Алексеева
(Россия, Нижний Новгород)*

doi: 10.18411/lj-12-2018-176

idsp: ljournal-12-2018-176

Аннотация

В статье рассмотрена возможность получения «цифрового двойника» токарного станка с ЧПУ с использованием нейросетевых моделей системы резания. Обучение искусственных нейронных сетей происходило на основе экспериментальных данных полученных в ходе производственных испытаний. В качестве основных выходных критериев при моделировании использовались: амплитуда и информационная энтропия сигнала виброакустической эмиссии (ВАЭ), фрактальная размерность аттрактора динамической системы резания, значения сил при резании и шероховатость обработанной поверхности. Показана возможность оптимизации режимов обработки с использованием «цифрового двойника» токарного станка с ЧПУ.

Ключевые слова: цифровой двойник, машинное обучение, искусственные нейронные сети, цифровое производство, промышленный интернет вещей, большие данные, станки с ЧПУ, кибер-физические системы

Интенсивное внедрение цифровых технологий, основанных на современных подходах машинного обучения (ML), системах промышленного интернета вещей (IIoT) и интеллектуальной обработки больших данных (Big Data и Data Mining), обуславливает развитие принципиально новых технологических объектов - кибер-физических систем и их цифровых двойников.

Кибер-физическая система (КФС) - это основная технологическая единица "цифрового" производства, характеризующаяся высокими адаптивными и интеллектуальными возможностями за счет ассоциативного восприятия информации и постоянного обучения, оценки текущего состояния и прогнозирования будущего, способностей автономно решать задачи оптимизации и принимать правильные решения на основе анализа многомерных данных, учитывая различные, зачастую скрытые факторы реального производства [1,2]. Основной задачей при организации КФС является создание "цифровых" двойников. Цифровым двойником является ансамбль математических моделей характеризующих различные состояния оборудования, технологических и бизнес процессов во времени, в соответствии с текущими производственными условиями, а также детализированные сборочные 3D модели объектов, отражающие связи и взаимодействия между узлами. Однако в настоящее время цифровые двойники в основном разработаны для ведения бизнеса, имеются также примеры успешно работающих двойников в нефте- и газовой промышленности. Двойники для механообрабатывающих производств недостаточно развиты.

Получение "цифровых" двойников возможно, как с использованием традиционных аналитических подходов, основываясь на математическом описании физических процессов, так и с использованием современных статистических методов, в том числе машинного обучения.

В настоящее время существует большое множество методов машинного обучения используемых для построения статистических моделей, однако их можно отнести к трем основным группам: модели регрессионного анализа, модели классификации и модели выявления аномалий [3].

Выбор конкретного метода машинного обучения зависит от размера, качества и природы данных, а также от типа решаемых задач. Существующие методы машинного обучения требуют различных вычислительных мощностей и обладают различной степенью точности. Как правило, это сводится к возможности наиболее точной аппроксимации данных и выявлению границ в пространстве данных. Наиболее универсальным и точным методом, способным работать с большим количеством данных и строить нелинейные зависимости, являются искусственные нейронные сети (ИНС). Нейронные сети используют большое количество параметров настройки, что позволяет создавать высокоточные модели процессов работающих в режимах регрессионного анализа, классификации и выявления аномалий. К недостатком ИНС можно отнести высокие требования к вычислительным ресурсам на этапе обучение. Большое количество переменных и собранных данных могут привести к значительному времени обучение нейросетевых моделей.

С учетом вышесказанного, был разработан комплекс статистических моделей использующих машинное обучение. Полученные модели являются основой для "цифрового двойника" токарного станка с ЧПУ и позволяют решать задачи регрессионного анализа для прогнозирования динамики процесса резания для различных условий обработки, шероховатости обработанной поверхности и сил при резании. Процесс создания цифрового двойника представлен на рисунке 1.

Обучающая выборка была получена на основе сбора телеметрических данных, в процессе механической обработки с использованием распределенной системы датчиков сигнала виброакустической эмиссии, динамометра и технологии промышленного интернета вещей (IIoT). Количество используемых датчиков, их тип и

пространственная ориентация определялась в соответствии с компоновкой оборудования. Наличие в системе большого числа датчиков с различной пространственной ориентацией объясняется неоднородностью материалов и конструкций в разных направлениях, особенностями распространения сигналов, а также возможностью перестройки колебательной системы в процессе эксплуатации. Таким образом, использование гетерогенной системы сенсоров позволило получить наиболее полную динамическую картину процессов в n-мерном пространстве "состояние-время". В качестве протокола приема-передачи данных в рамках сети промышленного интернета вещей был использован стандартный протокол TCP/IP, а также текстовый формат передачи обмена данными JSON (JavaScript Object Notation). Для предварительной обработки сигналов были использованы аналоговые и цифровые полосовые фильтры, а также Wavelet фильтры. Использование Wavelet фильтров позволило исключить влияние шумовой составляющей в сигналах ВАЭ и осуществлять декомпозицию на периодическую и хаотическую составляющую на основе энтропийных показателей. Предварительная обработка данных осуществлялась на "пограничном" устройстве (Edge), вычисляющее значения параметров сигнала ВАЭ и формирующее пакеты данных для отправки в виртуальное облачное хранилище. При построении математических моделей, на основе методов машинного обучения, необходимо структурирование и разметка данных. Однако учитывая особенности технологии работы IoT, построение реляционных БД не всегда возможно, поэтому был применен подход на основе технологий NoSQL. Для этого хранение и обработка данных была реализована на виртуальном сервере имитирующем работу вычислительного кластера. На данном виртуальном сервере была развернута специальная распределенная, масштабируемая файловая система. В качестве основы были использованы свободно распространяемые утилиты, библиотеки и фреймворки проекта Hadoop, являющейся одной из наиболее успешной и общепринятой технологией "Больших данных", в частности распределенная файловая система HDFS и база данных HBase под управлением программной оболочки Hadoop Common [4].

Рисунок 1 – Создание цифрового двойника станка с ЧПУ

Для осуществления распределенных вычислений и обработке больших объемов данных была использована система MapReduce, обеспечивающая автоматическое распараллеливание и распределение задач на кластере. Для ускорения времени обучения нейросетевых моделей использовались графические процессоры nVidia CUDA.

Для создания статистической модели динамического состояния процесса резания, была выбрана рекуррентная ИНС с сигмоидальной функции активации нейронов. В качестве обучающей выборки были использованы данные полученные в

ходе работы промышленного оборудования. Обучение производилось с использованием алгоритма обратного распространения ошибки. После окончания процесса обучения проводилась верификация полученной модели, на основе рассчитанных значений средней квадратичной ошибки.

В итоге полученная ИНС (рис.2) состоит из 13 основных нейронов во входном слое, на которые поступает информация о векторе технологических параметров, и дополнительных нейронов, на которые поступают значения вектора предыдущего динамического состояния с выходных нейронов. Тем самым нейросетевая модель учитывает текущие условия обработки, а также предыдущее динамическое состояние процесса резания.

Рисунок 2 - Нейросетевая модель динамической устойчивости процесса резания

Выходной слой состоит из 4 основных нейронов, которые характеризуют вектор текущего динамического состояния процесса резания, содержащий сведения об амплитуде автоколебаний, фрактальной размерности аттрактора, энтропии сигнала, старшего показателя Ляпунова и ряда дополнительных нейронов, каждый из которых отвечает за определенную частоту в спектре сигнала ВАЭ. Промежуточные нейроны образуют 2 скрытых слоя. Полученная нейронная сеть способна моделировать динамическое состояние процесса резания в различные моменты обработки.

Оценка качества полученной модели осуществлена на основе моделирования обработки на токарном станке заготовки из стали 12X18H10T установленной в центрах, проходным резцом с режущей частью из твердого сплава ВК 6 (рис. 3, а) Режимы обработки были определены в соответствии с имеющимися производственными нормами для обработки деталей данного типа на токарном станке с ЧПУ. В качестве переменной составляющей вектора St_m , была выбрана величина Z – положение суппорта станка по оси Z мм, которая изменялась с шагом 0.01 мм от 0 до 350 мм. Такой прием позволил сформировать вектор Sdm на всем протяжении обработки заготовки. Всего было смоделировано 35 000 динамических состояний процесса резания.

По окончании нейросетевого моделирования была построена спектрограмма, отражающая амплитуду и частоту колебаний, а также определены фрактальные размерности аттракторов. На полученной в ходе нейросетевого моделирования спектрограмме (рис. 3б) заметны две доминирующие частоты колебаний 3,5 кГц и 6,5 кГц и два фазовых перехода. Для оценки адекватности полученных результатов, была

произведена обработка заготовки с идентичным вектором технологических параметров St с регистрацией сигнала ВАЭ. После обработки сигнала ВАЭ была получена спектрограмма и реконструированы аттракторы (рис. 3а). На данной спектрограмме аналогично наблюдается две доминирующие частоты в областях 3,5 кГц и 6,5 кГц и фазовых перехода. Сравнение результатов натурного эксперимента с результатами нейросетевого моделирования позволяют судить о высокой степени адекватности полученной нейросетевой модели. Максимальная погрешность моделирования не превышает 3,6%. Как видно из рисунка 3, предложенные производственные нормы не позволяют получить изделие заданного качества, что в свою очередь может привести к риску возникновения брака, а учитывая биения заготовки и к поломке инструмента.

Рисунок 3 - Результаты нейросетевого моделирования
(а - схема обработки, б - моделируемый процесс резания, в - реальный процесс резания, г - процесс резания после оптимизации)

Для корректировки режимов заложенных в нормах производства, был произведен расчет оптимальных значений вектора St_m на основе дополнительного нейросетевого моделирования. Для этого в качестве переменных значений вектора St_m были выбраны: V , f_y , а критериями оптимальности: амплитуда колебаний и фрактальная размерность аттрактора. Оптимальными считались те значения вектора St_m при которых амплитуда колебаний и фрактальная размерность были минимальными. В ходе моделирования, по всей длине обработки формировалось пространство динамического состояния процесса резания, точки которого соответствовали различным значениям вектора St_m , а определение оптимальных значений изменяемых параметров, соответствующих минимуму целевых функций, осуществлялся с использованием методов многомерной оптимизации - симплекс-метода (метод деформируемого многогранника). После окончания процессов

моделирования и оптимизации были выбраны новые значения вектора Stm отвечающие минимумам значений целевых функций - $V = 90$ м/мин, $S = 0.1$ мм/об, $f_y = 0,2$ мм.

Для проверки полученных результатов была проведена дополнительная обработка прутка из стали 12X18H10T скорректированными режимами обработки и построена спектрограмма. Как видно из полученной спектрограммы (рис. 3, г) оптимизация условий обработки позволила снизить значение амплитуды колебаний в 2 раза и обеспечить устойчивое протекание процесса резания, о чем свидетельствует значение фрактальной размерности $Df = 1.1$. Таким образом, повышалось динамическое качество механической обработки, без потери производительности.

Аналогичным образом были получены модели для прогнозирования значений шероховатости обработанной поверхности и сил при резании (рис.4).

Рисунок 4 – Нейронные сети шероховатости поверхности (а) и сил резания (б)

Силы резания определяют точность обработки, вызывая упругое отжатие детали и инструмента, а следовательно, и погрешность формы детали. Данные нейросетевые модели представляют собой многослойные искусственные нейронные сети прямого распространения.

Входом ИНС прогнозирования шероховатости обработанной поверхности (рис.4а) являются 5 нейронов характеризующих значения: V - скорости резания (м/мин), S - подача (мм/об), t - глубина резания (мм), r - радиус при вершине (мм), вспомогательный угол в плане $-\phi_1$. Нейронная сеть состоит из двух скрытых слоев. Выходом ИНС является численное значение шероховатости R_a .

Входом ИНС прогнозирования силы резания (рис.4б) являются 4 нейрона характеризующих значения: V - скорости резания (м/мин), S - подача (мм/об), t - глубина резания (мм), σ - предел прочности материала (МПа). Выходом ИНС является численное значение шероховатости R_a .

Применение данных математических моделей в составе “цифрового двойника” возможно не только в реальных производственных условиях, но и на этапе выбора и обоснования закупки оборудования потребителем, что позволяет осуществлять подбор оптимальных характеристики оборудования и отладку планируемого технологического процесса на “цифровых двойниках”.

Использование “цифровых” двойников оборудования на этапе планирования производства позволяет выявить наиболее узкие места в технологических операциях, повысить качество продукции и снизить риски поломки инструмента и нештатной работы оборудования.

1. Искусственный интеллект и кибер-физические механообрабатывающие системы в цифровом производстве: монография / Ю.Г. Кабалдин [и др.]; под ред. Ю.Г. Кабалдина; Нижегород. гос. техн. ун-т им. Р.Е. Алексеева. – Нижний Новгород, 2018. – 271 с.
 2. Кабалдин Ю.Г., Лаптев И.Л., Шатагин Д.А., Серый С.В. Диагностика выходных параметров процесса резания в режиме реального времени на основе фрактального анализа и вейвлет-анализа с использованием программно-аппаратных средств National Instruments и Nvidia CUDA // Вестник машиностроения. 2014. № 8. С. 80-82.
 3. Шитиков В.К., Мастицкий С.Э. (2017) Классификация, регрессия и другие алгоритмы Data Mining с использованием R. 351 с. – Электронная книга
 4. Уайт Т. U13 Hadoop: Подробное руководство. — СПб.: Питер, 2013. — 672 с.:
-