Кабалдин Ю.Г., Шатагин Д.А., Кузьмишина А.М.
Разработка цифрового двойника режущего инструмента для
механообрабатывающего производства

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

doi: 10.18411/lj-12-2018-177

idsp: ljjournal-12-2018-177

Аннотация

Разработана цифровая модель (двойник) режущего инструмента на основе нейросетевого моделирования. Показано, что разработанные модели позволяют путем варьирования входных данных оптимизировать состав и структуру износостойкого покрытия и определить режимы обработки, обеспечивающие максимальную износостойкость режущего инструмента. Рассмотрены вопросы информационной безопасности.

Ключевые слова: режущий инструмент, нейросетевые модели, цифровой двойник, выбор состава покрытия, оценка интенсивности износа.

Abstract

A digital model (twin) of a cutting tool based on neural network modeling has been developed. It is shown that the developed models allow, by varying the input data, to optimize the composition and structure of the wear-resistant coating and to determine the processing modes that ensure the maximum wear resistance of the cutting tool. Considered issues of information security.

Keywords: cutting tool, neural network models, digital twin, choice of coating composition, assessment of wear intensity.

Механообрабатывающее производство в зависимости от заказов потребителей вынуждено постоянно изменяться и трансформироваться. Каждый год научные исследования указывают нам новые, до сих пор невиданные возможные пути развития производства, особенно с использованием IT-технологий. Имеются долгосрочные глобальные тренды, с указанием конечного результата к которому придет производство.

В области механообрабатывающего производства таким трендом в РФ является программа Индустрия 4.0, которая призвана изменить его, сделать более современным и цифровым. Производство станет более интеллектуальным, гибким, эффективным и прогнозируемым.

В настоящее время на отечественных предприятиях под “цифровизацией” в основном понимают разработку 3D моделей. Однако, на наш взгляд, “цифровизация”- это разработка цифровых моделей, близких к реальным различных производственных процессов, оборудования, других устройств.

Цифровой двойник (digital twin) новое слово в моделировании оборудования, техпроцессов и планировании производствах [1]. Это совокупность цифровых (математических) моделей, достоверно описывающих процессы и взаимосвязи как на отдельном объекте, так и в рамках целого производственного предприятия с использованием анализа больших данных (Big data).

Применение цифрового двойника, являющегося точной копией реального актива, помогает быстро найти наиболее эффективные режимы работы, выявить потенциальные риски, встроить новые технологии в существующие производственные линии, сократить сроки и стоимость реализации проектов. Кроме того, цифровой двойник помогает определить шаги по обеспечению информационной безопасности.

Современные технологии дают возможность построить цифровые двойники абсолютно любых производственных предприятий, будь то машиностроительный завод или металлургическая компания [2]. В будущем эти технологии позволят удаленно управлять всем производственным процессом в режиме реального времени. На базе цифрового двойника можно объединить все системы и модели, используемые для планирования и управления производственной деятельностью, что повысит прозрачность процессов, точность и скорость принятия решений.

В этой связи, цифровой двойник можно рассматривать как электронный паспорт оборудования, его цифровую идентичность, а также режущего инструмента и в целом механообрабатывающего предприятия, в котором фиксируются все данные о обрабатываемых материалах, произведенных технологических операциях, испытаниях и тестовых исследованиях.

Это значит, что вся информация, начиная с 3D модели и технологии производства, заканчивая правилами техобслуживания, утилизации и т.д., будет оцифрована и доступна для считывания устройствами и людьми. Такой принцип позволяет отслеживать, подобно технологии блокчейн, все происходящие последовательные действия над ним, и гарантировать качество продукции.

Важной особенностью цифрового двойника, например, оборудования, или техпроцесса. является то, что для задания на него входных воздействий используется информация с датчиков реального устройства, работающего параллельно [3]. Работа возможна как в онлайн, так и в офлайн режимах. Далее возможно проведения сравнения информации виртуальных датчиков цифрового двойника с датчиками реального устройства, выявление отклонений (брака) и причин их возникновения.

Главная задача двойника — дать возможность управлять всеми факторами, влияющими на стоимость и качество продукта ещё до начала его производства. Цифровые двойники, прежде всего, создаются, чтобы существенно ускорить сроки вывода новых изделий на рынок путем моделирования, потому позволяют представить все этапы его жизненного цикла в виртуальной среде.

Ещё одна функция цифрового двойника — это наследование данных об изделии при создании его новых модификаций. Другими словами, максимальное использование предыдущего опыта проектирования, изготовления и испытаний при разработке новых изделий.

В этой связи, “цифровизация” машиностроительного производства — это в том числе и отработка ситуаций на виртуальных цифровых моделях, которая позволяет экономить денежные и материальные средства. Ряд крупных фирм за рубежом, уже сейчас, не дожидаясь поступления металлорежущего оборудования для производства деталей, получив его виртуальный образ, начинает отладку технологических процессов, не теряя времени. С появлением Интернета вещей (IoT), цифровых датчиков, параллельных вычислений и развитых беспроводных технологий, идея цифровых двойников получила право на жизнь и в плане финансовой доступности, и в плане вычислительных возможностей сбора и анализа больших данных. Поэтому предприятия уже внедрившие IoT, параллельно используют и технологии цифровых двойников. Однако в настоящее время цифровые двойники в основном разработаны для ведения бизнеса, имеются также примеры успешно работающих двойников в металлургической промышленности [2]. Двойники для механообрабатывающих производств отсутствуют.

В НГТУ им. Р.Е. Алексеева разработана единая базовая платформа расширения функциональных возможностей различных систем ЧПУ технологического оборудования на базе встраивания в них нейро- модулей, применения высокопроизводительных параллельных вычислений, промышленного интернета и глубокого обучения искусственных нейронных сетей (ИНС) с использованием технологий nVidia CUDA [3,5-10].

Искусственный интеллект трактуется сегодня как системы, которые могут понимать, прогнозировать и потенциально способны функционировать без участия человека, т.е. создавать уже не «безлюдные», а «умные» производства. Системы (алгоритмы) ИИ могут реагировать на голосовые команды, а также самообучаться и выдавать готовые решения, обеспечивая информационную безопасность, используя их обучение на основе криптографии.

Искусственные нейронные сети (ИНС) представляют собой новую перспективную вычислительную технологию, дающую новые подходы к исследованию задач цифрового производства [4]. Первоначально нейронные сети открыли новые возможности в области распознавания образов, затем к этому прибавились статистические и основанные на методах искусственного интеллекта средства поддержки принятия решений для задач в различных областях техники.

Способность к моделированию различных процессов, устройств и приборов, работе с зашумленными данными и адаптивность дают возможности применять нейронные сети для решения широкого класса задач. Приложения нейронных сетей охватывают самые разнообразные области интересов: распознавание образов, обработка зашумленных данных, дополнение образов, ассоциативный поиск, классификация, оптимизация, прогноз, диагностика, обработка сигналов, абстрагирование, управление процессами, сегментация данных, сжатие информации, сложные отображения, моделирование сложных процессов, машинное зрение, распознавание речи и т.д.

Нейронные сети могут иметь различные архитектуры. Можно выделить три основных типа нейронных сетей [4]:

- полносвязные сети (рис. 1.2, а),
- многослойные сети (рис. 1.2, б),
- слабосвязные сети (нейронные сети с локальными связями) (рис. 1.2, в, г).

Рис. 1. Основные типы нейронных сетей:

а – полносвязная сеть; б – многослойная сеть; в, г – слабосвязные сети

В слабосвязных сетях нейроны располагаются в узлах прямоугольной решетки. Каждый нейрон связан с четырьмя или восемью своими ближайшими соседями. В полносвязной сети каждый нейрон связан со всеми остальными (на входы каждого нейрона подаются выходные сигналы остальных нейронов). В многослойных сетях нейроны объединяются в слои. Слой – это совокупность нейронов с единым входным сигналом. Внешние входные сигналы подаются на входы нейронов первого слоя, а выходами сети являются выходные сигналы последнего слоя. Кроме входного и выходного слоев в многослойной нейронной сети, есть один или несколько промежуточных (скрытых) слоев.

Процесс функционирования ИНС, то есть сущность действий, которые она способна выполнять, зависит от величин синаптических связей, поэтому, задавшись определенной структурой ИНС, разработчик сети должен найти оптимальные значения всех переменных весовых коэффициентов [4,3,5].

Этот этап называется обучением ИНС, и от того, насколько качественно он будет выполнен, зависит способность сети решать поставленные перед ней задачи во

время эксплуатации. На этапе обучения кроме параметра качества подбора весов важную роль играет время обучения. Как правило, эти два параметра связаны обратной зависимостью и их приходится выбирать на основе компромисса. Существует ряд методов обучения ИНС: с учителем, без учителя. В последние годы разработано новые архитектуры ИНС (сверточные) и способы их обучения, в частности глубокое обучение ИНС [5]. Таким образом, “цифровым” двойником может являться комплекс статистических моделей использующих различные комбинации методов машинного обучения и прошедших различные стадии верификации и улучшения.

Применение подходов ИНС к решению задач в области машиностроения нами начато в конце девяностых годах [3]. Однако отсутствие ЭВМ с большими вычислительными возможностями, отсутствие больших данных существенно тормозило их применение к решению вышеперечисленных проблем. Задача широкого внедрения цифровых технологий в настоящее время, 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 электронных моделей оборудования, процессов и их цифровых двойников.

Как показали исследования [5], нейронносетевую модель оборудования, режущего инструмента и т.д. можно рассматривать как электронную модель, так и как цифровой двойник, поскольку на вход нейронной сети можно вводить характеристики обрабатываемого материала, параметры технологических процессов и т.д.

На рис. 2 приведена схема получения цифрового двойника инструмента, включающая сбор данных для построения нейронной сети на основе облачных технологий [5].

Рис.2 Схема построения цифрового двойника

Как указывалось выше, в общем случае цифровой двойник-это многофакторная электронная модель оборудования, инструмента и других их элементов, включающая ансамбль электронных моделей, т.е. нейронносетевых моделей, некоторые из которых являются определяющими. Для режущего инструмента с износостойким покрытием-это нейронная сеть прочности инструмента (рис. 1), нейронная сеть его износостойкости и нейронная сеть выбора оптимального состава и структуры износостойкого наноструктурного покрытия. Применение данных математических нейронносетевых моделей в составе “цифрового двойника” возможно не только в реальных производственных условиях, но и на этапе выбора и обоснования закупки инструмента потребителем.

Таким образом, появляется возможность заменить сложную многомерную функциональную зависимость, например, износостойкости режущей части инструмента нейронносетевой структурой. Иначе говоря, использование нейросетевого имитационного моделирования контактных процессов при резании позволяет сформировать «виртуальный» датчик для оценки интенсивности J изнашивания режущего инструмента. Исследования показывают [5], что интенсивность J изнашивания твердых сплавов с покрытием определяются силой F_z трения на контактной площадке, скоростью перемещения трущихся тел (прирезцовых слоев стружки и передней части инструмента) и прочностью межатомных связей в зернах тугоплавких соединениях покрытия, которая характеризуется их удельной предельной энергией разрушения ΔE_{np} :

$$J = \frac{L \cdot F_3}{\Delta E}, \quad (1)$$

где L – путь резания.

При вычислении интенсивности износа в реальных условиях механической обработки наибольшее затруднение вызывает определение величины силы F_3 трения. Для нахождения силы трения расчетным путем проводится на основе измерений ряда характеристик в процессе резания.

На практике такой метод нахождения F_3 означает периодическую остановку процесса резания для определения длины контакта C путем трудоемких оптических измерений остаточного следа стружки (которые к тому же сложно выполнить непосредственно на станке) и, поэтому, совершенно непригоден в автоматизированном производстве.

Значения F_3 для некоторых инструментальных материалов можно рассчитать, используя известные зависимости сил трения и температур [4]. Но в этом случае возникает необходимость использования на металлорежущем станке датчиков для качественного измерения температуры и вычисления множества температурных поправок, связанных с тем, что термодатчики практически невозможно разместить в зоне резания.

Выходом из этой ситуации является использование в качестве температурного датчика естественной термопары, образующейся на участке непосредственного соприкосновения инструмента и детали. Естественно, что параметры такого датчика не статичны, а динамическим образом зависят от площади контакта твердосплавного инструмента и стружки, то есть, в конечном счете, зависят от силы трения F_3 , для которой выражение можно переписать в виде:

$$F_3 = \tau_F \cdot S_F, \quad (2)$$

где τ_F – касательные напряжения.

Экспериментальные исследования показывают, что выходной параметр естественной термопары U_t – термо-ЭДС является функцией от скорости резания [6]. Таким образом, интенсивность изнашивания режущего инструмента можно представить в виде зависимости трех аргументов:

$$J = f(U_t(F_3, v), v, \Delta E_{np}), \quad (3)$$

где f – неизвестный функционал, определяемый по экспериментальным данным.

По исходным данным строим нейронную сеть. Для нахождения f используем двухслойную (имеющую два слоя активных нелинейных элементов) нейронную сеть обратного распространения [5].

Поиск оптимальной структуры нейронной сети проводился путем имитационного моделирования при помощи пакета программ Matlab 6. В результате моделирования было рассмотрено несколько структур нейронных сетей с различными преобразующими функциями нейронов. Их обучение проводилось на обучающей выборке, полученной путем проведения серии однофакторных экспериментов по точению стали 45 и твердосплавными пластинками с покрытием на различных режимах резания. За оптимальную принята структура сети, дающая наименьшую максимальную ошибку за определенный период времени обучения.

Рис. 3. Структура нейронной сети оценки износостойкости инструмента

Как показали расчеты, имеется скорость резания V , при которой J является минимальной.

Структура оптимальной нейронной сети представлена на рис.3. Первый слой сети содержит 6 нейронов, второй, выходной слой состоит из одного нейрона. В качестве функции активации нейронов обоих слоев используется экспоненциальный сигмоид.

Построенная нейронная сеть (рис.4) для выбора структуры и состава износостойкого покрытия - сеть прямого распространения (Feed Forward).

Рис. 4 – ИНС прямого распространения

На вход подаются следующие параметры: V , м/мин – скорость резания; S_0 , мм/об – подача на оборот; t , мм – глубина резания; HV_{OM} – твердость обрабатываемого материала (по Виккерсу).

На выходе: HV_{μ} – микротвердость износостойкого покрытия.

На рис.5 представлена зависимость твердости обрабатываемого материал от микротвердости износостойких покрытий.

Рис. 5. Зависимость микротвердости износоустойчивого покрытия от твердости обрабатываемого материала

Анализ рис.5 показывает, что имеется линейная зависимости микротвердости покрытия от твердости обрабатываемого материала (ОБ), т.е. чем выше твердость ОБ, тем выше должна быть микротвердость покрытия, что достигается использованием таких жаропрочных элементов как Zr и многоэлементных покрытий (AlTiN). Можно полагать, что с увеличением базы данных по инструменту появится более широкий выбор и структура покрытий [11, 12].

Таким образом, на основе электронных моделей (двойников), основанных на разработке нейросетевых моделей реального процесса механообработке можно выбрать состав и структуру износоустойчивого покрытия для режущего инструмента, определять оптимальные режимы резания при обработке того или иного обрабатываемого материала в разрабатываемом технологическом процессе обработки детали. Следовательно, появляется возможность симулировать различные параметры инструмента перед построением технологического процесса, и определять его производительность и себестоимость.

Если рассматривать цифровой двойник не конкретного изделия, а всего производства, то имеется преимущество в возможности симулировать в виртуальной среде все процессы, определении необходимого количества и оптимального расположения оборудования в зависимости от объема и номенклатуры выпускаемых изделий. Цифровой двойник обеспечивает обратную связь между реальным и виртуальным миром, что позволяет оптимизировать процессы изготовления различных деталей, оборудования и тд.

При этом, если цифровой двойник разрабатывается для вновь создаваемого производства, появляется возможность через симуляцию его работы выявить возможные риски и недочёты, скорректировать проект. Цифровой двойник существующего производства позволяет прорабатывать внедрение или изменение технологических процессов без реального вмешательства в работу реального процесса.

1. Есть способ лучше: цифровой двойник повышает эффективность процессов конструкторско-технологического проектирования и производства // CAD/CAM/CAE Observer, №3, 2016, С. 36-40.
2. Бурико А.В. Цифровая эволюция, или почему Русал "уходит" в цифру // Цифровое производство, №2, 2017, С. 18-23.
3. Кабалдин Ю.Г., Биленко С.В., Серый С.В. Управление динамическими процессами в технологических системах механообработки на основе искусственного интеллекта, Комсомольск-на-Амуре: ГОУ ВПО "Комсомольский-на-Амуре гос. техн. ун-т", 2003. -201 с.
4. Короткий С. Нейронные сети: основные положения, (<http://www.orc.ru/~stasson>).

5. 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.
 6. Бобров В.Ф. Основы теории резания металлов. М.: Машиностроение, 1975. 344 с.
 7. 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
 8. Кабалдин Ю.Г., Лаптев И.Л., Шатагин Д.А., Зотов В.О., Серый С.В. Интеллектуальные системы диагностики состояния оборудования и износа инструмента // Машиностроение: сетевой электронный научный журнал. 2014. № 2. с. 47-50.
 9. Кабалдин Ю.Г., Лаптев И.Л., Шатагин Д.А., Вытнов Ю.В., Голубев С.В. Оценка состояния режущего инструмента в режиме реального времени на основе подходов нелинейной динамики с использованием NVIDIA CUDA в программной среде LABVIEW // Труды НГТУ им. Р.Е. Алексеева. 2013. № 5 (102). с. 114-121.
 10. Кабалдин Ю.Г., Шатагин Д.А., Лаптев И.Л., Сидоренков Д.А. Разработка динамического паспорта станка на основе нейросетевого моделирования его рабочего пространства с использованием технологии NVIDIA CUDA и подходов глубокого обучения // Известия высших учебных заведений. Машиностроение. 2016. № 10 (679). с. 49-56.
 11. Верещака А.С. Работоспособность режущего инструмента с покрытием. М.: Машиностроение, 1993, - 336 с.
 12. Кабалдин Ю.Г., Кретинин О.В., Шатагин Д.А., Власов Е.Е. Выбор состава и структуры износостойких наноструктурных покрытий для твердосплавного режущего инструмента на основе квантово-механического моделирования. М.: Инновационное машиностроение, 2017. – 216 с
-