

Разработка цифрового двойника процесса точения на основе машинного обучения

© 2021

Расторгуев Дмитрий Александрович^{*1}, кандидат технических наук,
доцент кафедры «Оборудование и технологии машиностроительного производства»

*Севастьянов Александр Александрович*², магистрант

кафедры «Оборудование и технологии машиностроительного производства»

Тольяттинский государственный университет, Тольятти (Россия)

*E-mail: rast_73@mail.ru

¹ORCID: <https://orcid.org/0000-0001-6298-1068>

²ORCID: <https://orcid.org/0000-0002-7465-650X>

Аннотация: На сегодняшний день производственные технологии развиваются в рамках концепции «Индустрия 4.0», которая представляет собой внедрение информационных технологий в промышленности. Одной из наиболее перспективных цифровых технологий, находящей все большее применение в производстве, является цифровой двойник, представляющий собой ансамбль математических моделей технологического процесса, который обменивается информацией со своим физическим прототипом в режиме реального времени. В работе рассматривается пример формирования нескольких взаимосвязанных прогнозирующих модулей, входящих в структуру цифрового двойника процесса точения и предназначенных для прогнозирования качества обработки, характера стружкообразования, силы резания. Проведен трехфакторный эксперимент по твердому точению стали ХВГ, закаленной до твердости 55 HRC. На примере проведенного эксперимента описан процесс разработки диагностического модуля цифрового двойника на основе искусственных нейронных сетей. Выявлены более высокие точность, адаптивность и универсальность искусственных нейронных сетей при разработке математической модели для прогнозирования и диагностики процесса резания. Разработанная математическая модель онлайн-диагностики процесса резания для определения качества поверхности и типа стружки при обработке использует фактическое значение снимаемого припуска, определяемого косвенно по силовой нагрузке на приводе. При этом модель использует только сигналы датчиков, входящих в диагностическую подсистему на станке с ЧПУ. В качестве информативного признака, отражающего силовую нагрузку на приводе главного движения станка, выбрано значение энергии сигнала силы тока в моторе привода шпинделя. Установлено, что развитие цифрового двойника возможно за счет разработки дополнительных модулей, прогнозирующих точность размеров, геометрический профиль, износ инструмента.

Ключевые слова: твердое точение; станки с ЧПУ; цифровой двойник; машинное обучение; искусственные нейронные сети.

Благодарности: Проект реализуется при поддержке Фонда содействия развитию институтов гражданского общества в ПФО.

Для цитирования: Расторгуев Д.А., Севастьянов А.А. Разработка цифрового двойника процесса точения на основе машинного обучения // Вектор науки Тольяттинского государственного университета. 2021. № 1. С. 32–41. DOI: 10.18323/2073-5073-2021-1-32-41.

ВВЕДЕНИЕ

Одной из актуальных тенденций в современном машиностроении является активное внедрение цифровых технологий на производстве в рамках концепции «Индустрия 4.0» [1]. Многие исследователи называют цифровой двойник одной из наиболее перспективных технологий современности. Цифровой двойник представляет собой ансамбль математических моделей, отражающих различные аспекты процесса обработки и состояния элементов технологической системы, включая заготовку, и обменивающихся данными между собой и с физическим объектом-прототипом в режиме реального времени [2; 3].

Задачи, которые решаются при совместном использовании нескольких моделей для обрабатываемой технологической системы, касаются вопросов диагностики и определения состояния различных элементов оборудования, контроля процесса обработки, оптимизации

параметров системы и управления [4]. Объектами этих процессов являются оборудование, станочное приспособление, режущий инструмент, заготовка, сам процесс обработки. На основе собранной информации, полученной от реального процесса и в результате моделирования, принимаются решения по коррекции проведения операции, режимов обработки, замены инструмента. Алгоритм взаимодействия показан на рис. 1.

С одной стороны, оснащение технологического оборудования комплексом датчиков различного назначения и принципов действия расширяет технологические возможности по мониторингу разнохарактерных процессов (силовых, тепловых, вибрационных), повышает надежность получаемой информации за счет дублирования информационных каналов, что позволяет повысить точность анализа и прогнозирования выходных данных. С другой стороны, это значительно усложняет и удорожает систему контроля, что снижает надежность ее функционирования, усложняет алгоритмы



Рис. 1. Схема взаимодействия объекта контроля, цифрового двойника и данных
Fig. 1. Scheme of interaction of control object, digital twin and data

обработки данных из-за необходимости сбора и согласования различных данных моделирования и данных, получаемых по разнообразным каналам с неодинаковой степенью дискретности. Необходимо при минимальном количестве информационных каналов и датчиков обеспечить максимум достоверной информации по максимально разнообразным аспектам функционирования технологической системы. Использование встроенных систем контроля приводов движения, дополняемых минимумом диагностических каналов, требует минимального времени и затрат на модернизацию оборудования с максимально возможным эффектом [5; 6].

Современная концепция применения цифровых двойников технологических систем предполагает интеграцию для комплексного моделирования элементов и процессов различных программ, в том числе основанных на использовании метода конечных элементов, интеграции различных моделей (механических, электромеханических, гидро- и пневматических) из разных математических пакетов. Этот подход отличается сложностью объединения различных по форматам выходных данных виртуальных моделей, различающихся временем выполнения расчетов, сложностью их подготовки, включая идентификацию параметров моделей.

В условиях единичного, мелко- и среднесерийного производства подготовка и проведение сложных аналитических расчетов нецелесообразны и не для всякого производства возможны. Использование сложных аналитических моделей требует идентификации большого количества трудно определяемых конструктивных и технологических параметров [7]. На станке с ЧПУ отслеживание сигналов встроенных контуров управления дает информацию только по позиционированию рабочих органов станка, исключая положение вершины инструмента, которое из-за силовых и температурных воздействий может отклоняться от текущего нуля инструмента, заложенного в программе [8]. Как правило, при обработке доминирующей колебательной системой является заготовка. Характер ее деформации определяется конструктивными особенностями, габаритами, материалом, схемой установки и условиями закрепления. Взаимодействие заготовки и инструмента проявляется в относительных смещениях формообразующих подсистем заготовки и инструмента. При точении упру-

гая деформация инструмента от сил резания незначительна по сравнению с деформацией заготовки. Тепловую деформацию резца можно рассчитать. При растачивании упругие деформации расточного инструмента будут отличаться значительной величиной и нестабильностью по длине обработки. Возникает задача определения фактического профиля заготовки после прохода, что определяется несоответствием снимаемого припуска заданной величине. Деформация технологической системы при точении непостоянна из-за переменного припуска по длине заготовки и переменной жесткости вала как вдоль оси, так и в поперечном сечении. Разработаны методы аналитического расчета деформаций заготовки в функции положения зоны резания по длине вала с учетом динамического характера процесса обработки [9]. Здесь помимо собственных конструктивных параметров заготовки с геометрическими отклонениями сильно влияет характер закрепления, состояние и вид установочно-зажимных поверхностей станочного приспособления, состояние и вид технологических баз, усилие закрепления. Каждый из этих факторов отличается определенной нестабильностью. Эти же соображения касаются и подсистемы режущего инструмента. В совокупности конструктивные и технологические параметры определяют собственные частоты формообразующих подсистем, а вариации этих параметров приводят к разбросу собственных частот подсистем, что сильно изменяет характер динамических деформаций при обработке [10].

Использование датчиков деформации заготовки предоставляет информацию, которая позволяет судить о формировании профиля детали и величине снимаемого фактического припуска. Если есть данные об исходной поверхности обрабатываемой заготовки, использование дополнительного датчика относительных колебаний заготовки и инструмента формирует фактически полную картину деформации технологической системы и значения фактического припуска. Встраивание таких датчиков усложняет эксплуатацию оборудования, поскольку, находясь в рабочей зоне, они подвергаются опасности повреждения от ударов, загрязнений, воздействия технологических сред. В то же время удаление источника сигнала от непосредственно контролируемого процесса вносит помехи в анализируемый сигнал, содержит меньше полезной информации.

С точки зрения размерных параметров заготовки, отслеживание деформаций формообразующих подсистем в ходе обработки позволяет сформировать геометрический образ заготовки с распределением фактического профиля, что позволяет далее формировать программы движения инструмента с учетом реального распределения припуска с целью компенсаций отклонений, вызванных переменными силами резания. На последнем переходе получается 3D-образ готовой детали.

Рассматривается задача обратного моделирования: по текущему значению энергии процесса обработки восстанавливается значение фактического припуска, который отличается от заданного значения из-за ряда возмущающих факторов – погрешности геометрии исходной заготовки, погрешности позиционирования инструмента по траектории его движения, силовых и температурных деформаций, износа элементов технологической системы. На основе фактических значений технологических режимов (глубины резания, фактической подачи и скорости, отслеживаемых по диагностическим показателям на соответствующих приводах) происходит прогнозирование сил резания, качества обработанной поверхности и вида стружки.

Рассогласование данных моделирования и фактических параметров обработки приводит к ошибке прогнозирования, которая может снижаться периодической подстройкой параметров моделей. В случае использования нейронных сетей для моделирования обработки обратная связь такой сети с технологическим процессом может быть эффективно использована для подстройки модели. Для этого для нейросетевых модулей старые наборы обучающих данных дополняются новыми данными и на их основе проводится повторное обучение. Цикличность процесса переобучения может повторяться через каждую деталь, партию деталей, смену, за период работы инструмента между заменами.

Цель исследования – разработка комплекса взаимосвязанных модулей, которые на основе данных, получаемых в режиме реального времени, обеспечивают комплексную диагностику параметров обработки (качества обработанной поверхности и характера стружкообразования).

МЕТОДИКА ИССЛЕДОВАНИЯ

Методика эксперимента подробно описана авторами в статье [11]. Эксперимент проведен на токарном станке модели 16Б16Т1С1 с системой ЧПУ Flex NC. Заготовки представляли собой кольца из стали ХВГ твердостью 55 HRC со следующими геометрическими параметрами: внешний диаметр 55 мм, внутренний диаметр 30 мм, толщина 20 мм. Сталь ХВГ применяется для изготовления режущего и мерительного инструмента с высокими требованиями к точности размеров и отсутствию коробления после термической обработки. Охлаждение в ходе обработки не использовалось. Торцевое подрезание образцов производилось с помощью PCLNR 2525M 12 пластины NP-CNGA120404GA2 Mitsubishi, материал пластины – кубический нитрид бора (КНБ), на следующих режимах: скорость резания – 150, 250, 300, 400 м/мин; подача – 0,1, 0,2, 0,3 мм/об; глубина резания – 0,1, 0,2, 0,3, 0,4 мм. При обработке фактическая глубина резания могла отличаться от заданной из-за погрешности установки заготовки, настройки станка, упругой деформации. Для каждого опыта определялось значение фактического припуска как разница исходного размера и размера после обработки.

С помощью средств диагностической подсистемы ЧПУ станка производилась запись сигналов датчиков, установленных на моторах, с частотой дискретизации 227 Гц (рис. 2).

Процесс резания проявляется на графике силы тока в виде соответствующего подъема уровня сигнала (на рис. 2 промежуток примерно между 9 и 18 с). Это является следствием увеличения механической нагрузки на приводе по сравнению с холостым ходом в результате процесса резания.

Ток привода главного движения станка может быть найден по формуле

$$K \cdot I = J \cdot \omega + B \cdot \dot{\omega} + T_{l0} + T_S + T_v + T,$$

где K – константа крутящего момента мотора;
 I – ток привода мотора в А;
 J – механическая инерция;




Рис. 2. Осциллограмма значений силы тока привода главного движения, образец № 1
 Fig. 2. The oscillogram of main motion drive current values, sample № 1

B – эквивалентное вязкое демпфирование для холостого хода;
 T_{l0} – сухое трение для холостого хода;
 T_S – крутящий момент резания;
 T_v – прирост крутящего момента за счет вязкого трения при резании;
 T_f – прирост крутящего момента за счет трения при резании.

Из записанных сигналов тока привода получены данные для холостого хода и резания. После анализа тока при резании соответствующая тангенциальная компонента силы резания F_c находится по формуле

$$F_c = \frac{T_S}{K_f},$$

где K_f – коэффициент пропорциональности для силы резания.

Таким образом, на основе анализа токовых данных получена информация о динамике силы резания при обработке.

Проведены статистические исследования для установления корреляции между параметрами силы резания (а именно ее средним значением и размахом) и выходными параметрами процесса, качеством поверхности и типом стружки. Методика исследования основана на анализе диаграмм размаха (boxplots) указанных параметров (рис. 3–6). При последующем анализе в качестве информативного показателя динамики силы резания была выбрана энергия сигнала тока привода.

Энергия дискретного сигнала вычислена по формуле [13]

$$E = \sum_{i=0}^{N-1} |x_i|^2,$$

где E – энергия сигнала;
 N – число отсчетов сигнала, нумеруемых от 0 до $N-1$;
 x_i – значение i -го отсчета сигнала.

В данной работе число отсчетов $N=90$, что соответствует примерно 0,4 с.

Проведено исследование зависимости силовой нагрузки и энергии сигнала E от режимов резания v, s, t [14]. Вся работа с данными проведена в пакете прикладных программ MATLAB.

Для аппроксимации нелинейной зависимости $E(v, s, t)$ использована искусственная нейронная сеть [15; 16]. Первый шаг работы с нейросетью состоял в подготовке исходных данных, которые необходимо представить в виде пар «вход – выход», объединенных в соответствующие матрицы. Таким образом, матрица входов содержит данные о режимах резания v, s, t для всех 47 опытов. При этом режимы расположены по столбцам, и каждому опыту соответствует своя строка матрицы Input. Матрица Output представляет собой вектор-столбец значений энергии сигнала резания E .

После подготовки массива данных необходимо определиться с архитектурой и параметрами нейронной сети. Для решения задач аппроксимации нелинейных функций хорошо зарекомендовала себя двухслойная сеть прямого распространения, скрытый слой которой




Рис. 3. Диаграммы размаха для средней силы резания для классов качества поверхности
 Fig. 3. Boxplots for mean force for surface quality classes




Рис. 4. Диаграммы размаха для средней силы резания для морфологии стружки
 Fig. 4. Boxplots for mean force for chip morphology




Рис. 5. Графики размаха для размаха силы для классов качества поверхности
 Fig. 5. Boxplots for force range for surface quality classes




Рис. 6. Графики размаха для размаха силы для морфологии стружки
Fig. 6. Boxplots for force range for chip morphology

использует сигмоидальную функцию активации (в данном случае гиперболический тангенс), а выходной слой – линейную [17]. Число нейронов скрытого слоя равно 10, выходного – 1 (рис. 7).

В ходе обучения исходные данные разбивались на три выборки: обучающую (training), проверочную (validation) и тестовую (testing) в пропорции 70:15:15 % (33, 7 и 7 экспериментальных наборов соответственно). Обучающая выборка использована для настройки весов и смещений сети (обучения). Проверочная использована для остановки обучения сети в случае, если ее способность к обобщению данных уменьшается, т. е. при возникновении эффекта переобучения сети (метод Байесовской регуляризации) [18]. Тестовый набор данных использован для финальной проверки работоспособно-

сти обученной нейронной сети на новых данных. Для обучения сети использовался алгоритм Левенберга – Марквардта.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Результаты обучения сети представлены на рис. 8.

Как видно из рис. 8, сеть качественно воспроизводит зависимость энергии сигнала от режимов обработки. Большинство (81 %) значений ошибок не превосходит 20 %.

На практике, однако, часто возникает обратная задача. Скорость резания и подачу можно узнать в ходе процесса резания с помощью тахогенераторов, стоящих на моторах станка с ЧПУ, а энергию сигнала можно




Рис. 7. Архитектура нейронной сети
Fig. 7. The neural network architecture




Рис. 8. Результаты обучения сети
Fig. 8. Results of the network learning

вычислять в онлайн-режиме по сигналу датчика силы тока привода главного движения. В то же время значение глубины резания может колебаться во время обработки, главным образом из-за деформации технологической системы, погрешности размеров и формы заготовки. Поэтому актуальной задачей также является определение в режиме реального времени глубины резания: обучив сеть решать задачу прогнозирования энергии сигнала по режимам, нужно обучить новую модель обратной задаче – по двум известным режимам (v и s) и значению энергии E вычислить текущее значение глубины резания t . Для этого можно использовать уже обученную нейронную сеть следующим образом: на вход сети подаем режимы v , s , а также массив $[t_1:t_2]$, где t_1 , t_2 – границы интервала, на котором предположительно находится искомое значение припуска t ; Δt – шаг выборки (задается требуемой точностью определения припуска). На выходе сети получаем вектор значений энергии E , значения которого соответствуют различным значениям глубины резания из отрезка $[t_1:t_2]$. Для определения глубины резания находим $\min|E - E_0|$, то есть среди элементов вектора E ищем значение энергии E_0 , ближайшее к текущему значению энергии E . Затем находим соответствующую энергии E_0 глубину резания t , зная, что индексы соответствующих элементов массивов совпадают. В итоге получаем методику онлайн-диагностики текущего значения глубины резания без датчиков смещений технологической системы.

Полученные фактические значения режимов обработки могут быть использованы совместно с ранее разработанными авторами нейросетевыми моделями качества поверхности и типа стружки [12]. Для этого на вход классификационных моделей подаются опреде-

ленные ранее режимы резания, после чего сети выдают прогнозируемые значения качества поверхности и типа стружки. Полученный ансамбль нейросетевых моделей можно называть цифровым двойником процесса твердого точения (рис. 9).

ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Использование искусственных нейронных сетей в качестве основы разработанной математической модели продиктовано тем, что именно нейросети являются на сегодняшний день наиболее эффективным инструментом моделирования сложных нелинейных экспериментальных зависимостей, возникающих в технологических системах [16; 19]. Машинное обучение превосходит другие известные алгоритмы, такие как регрессионный анализ, решающие деревья, нечеткая логика, по нескольким ключевым параметрам [20]. Среди них точность моделирования, простота разработки модели, объем оперативной памяти и вычислительных ресурсов, необходимых для работы алгоритма в реальном времени. Недостатком нейросетевого подхода является необходимость сбора и анализа большого массива экспериментальных данных для обучения нейронной сети (датасета).

ОСНОВНЫЕ РЕЗУЛЬТАТЫ

В работе приведен пример построения математической модели в виде комплекса взаимосвязанных модулей, которые на основе данных, получаемых в режиме реального времени, обеспечивают комплексный прогноз по параметрам обработки (качество обработанной поверхности и характер стружкообразования). Развитие данной структуры возможно за счет модулей, прогнозирующих точность размеров, геометрический профиль,

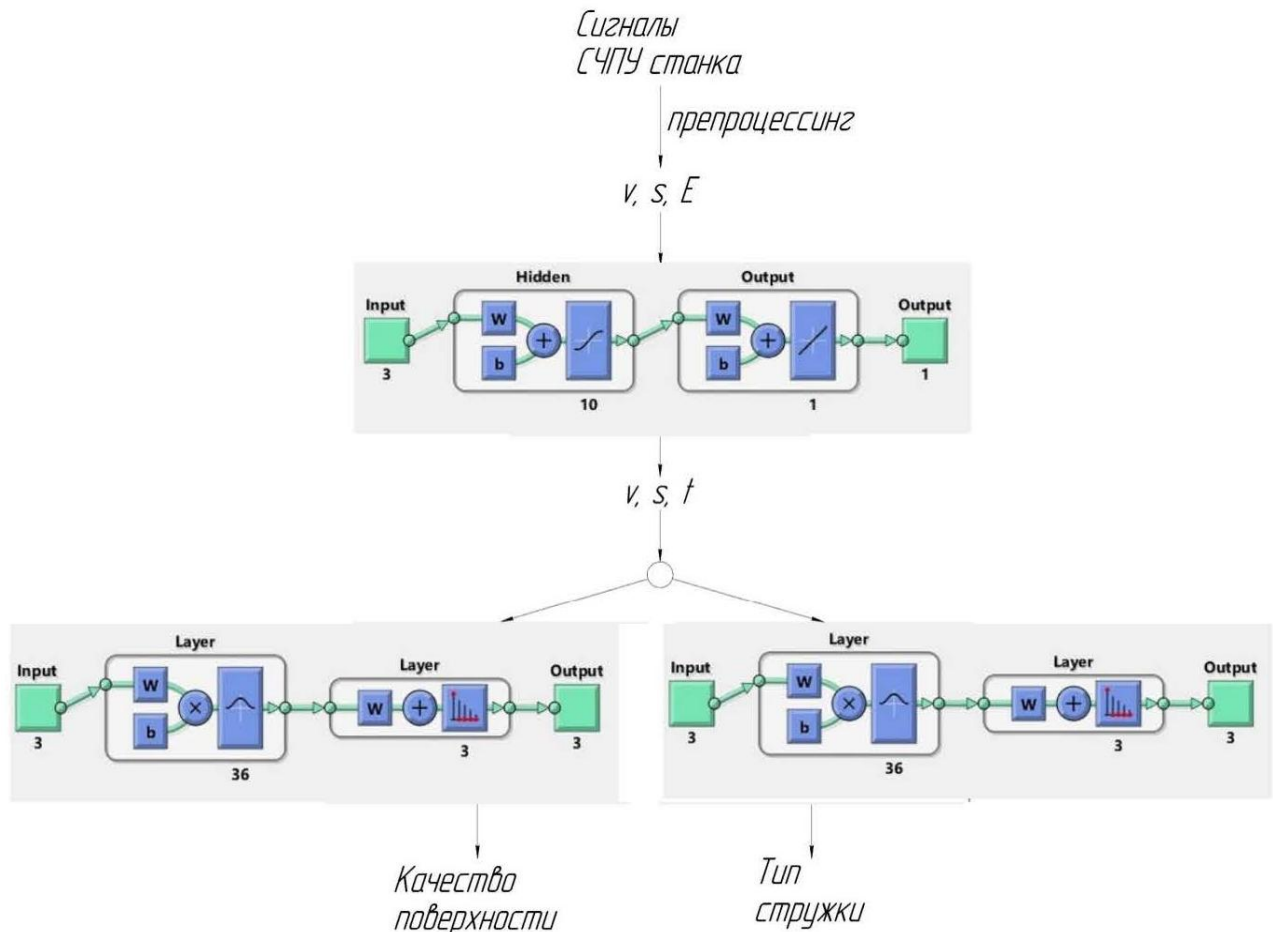


Рис. 9. Архитектура разработанного цифрового двойника
 Fig. 9. Architecture of the developed digital twin

износ инструмента. Включение в структуру цифрового двойника модуля состояния режущего инструмента позволит отслеживать его фактическое состояние (состояние режущей кромки, наличие, форма, размер фаски износа).

СПИСОК ЛИТЕРАТУРЫ

- Altintas Y. Manufacturing automation. UK: Cambridge University Press, 2012. 366 p.
- Кабалдин Ю.Г., Шатагин Д.А., Колчин П.В. Разработка «цифрового двойника» токарного станка с ЧПУ // Тенденции развития науки и образования. 2018. № 45-8. С. 44–50.
- Кабалдин Ю.Г., Шатагин Д.А., Кузьмишина А.М. Разработка цифрового двойника режущего инструмента для механообрабатывающего производства // Тенденции развития науки и образования. 2018. № 45-8. С. 50–57.
- Переверзев П.П. Особенности разработки математической модели съема металла для цифрового двойника процесса круглого шлифования с ЧПУ // Вестник Южно-Уральского государственного университета. Серия: Машиностроение. 2020. Т. 20. № 3. С. 72–81.
- Li X. Real-Time Prediction of Workpiece Errors for a CNC Turning Centre, Part 3. Cutting Force Estimation Using Current Sensors // International Journal of Advanced Manufacturing Technology. 2001. Vol. 17. № 9. P. 659–664.
- Li X. Real-Time Prediction of Workpiece Errors for a CNC Turning Centre, Part 4. Cutting-Force-Induced Errors // International Journal of Advanced Manufacturing Technology. 2001. Vol. 17. № 9. P. 665–669.
- Altintas Y. Virtual High Performance Machining // Procedia CIRP. 2016. Vol. 46. P. 372–378. DOI: [10.1016/j.procir.2016.04.154](https://doi.org/10.1016/j.procir.2016.04.154).
- Yeung C.-H., Altintas Y., Erkorkmaz K. Virtual CNC system. Part I. System architecture // International Journal of Machine Tools and Manufacture. 2006. Vol. 46. № 10. P. 1107–1123. DOI: [10.1016/j.ijmactools.2005.08.002](https://doi.org/10.1016/j.ijmactools.2005.08.002).
- Заковоротный В.Л., Лукьянов В.Ф., Фам Д.Т., Фам Т.Х. Кинематические возмущения стационарных траекторий формообразующих движений в динамической системе резания // Вестник Донского государственного технического университета. 2011. Т. 11. № 9. С. 1555–1563.
- Васин С.А. Прогнозирование виброустойчивости инструмента при точении и фрезеровании. М.: Машиностроение, 2006. 384 с.

11. Расторгуев Д.А., Севастьянов А.А. Исследование твердого точения стали ХВГ // Вектор науки Тольяттинского государственного университета. 2018. № 4. С. 24–32.
12. Rastorguev D., Sevastyanov A. Diagnostics of chip formation and surface quality by parameters of the main drive current in the hard turning // *Materials Today: Proceedings*. 2019. Vol. 19. P. 1845–1851. DOI: [10.1016/j.matpr.2019.07.025](https://doi.org/10.1016/j.matpr.2019.07.025).
13. Лозовский И.Ф. Цифровая обработка сигналов в РЛС обзора. Новосибирск: НГТУ, 2016. 270 с.
14. Kim D., Jeon D. Fuzzy-logic control of cutting forces in CNC milling processes using motor currents as indirect force sensors // *Precision Engineering*. 2011. Vol. 35. № 1. P. 143–152. DOI: [10.1016/j.precisioneng.2010.09.001](https://doi.org/10.1016/j.precisioneng.2010.09.001).
15. Khajavi M.N., Nasernia E., Rostaghi M. Milling tool wear diagnosis by feed motor current signal using an artificial neural network // *Journal of Mechanical Science and Technology*. 2016. Vol. 30. № 11. P. 4869–4875. DOI: [10.1007/s12206-016-1005-9](https://doi.org/10.1007/s12206-016-1005-9).
16. Labidi A., Tebassi H., Belhadi S., Khettabi R., Yallese M.A. Cutting Conditions Modeling and Optimization in Hard Turning Using RSM, ANN and Desirability Function // *Journal of Failure Analysis and Prevention*. 2018. Vol. 18. № 4. P. 1017–1033. DOI: [10.1007/s11668-018-0501-x](https://doi.org/10.1007/s11668-018-0501-x).
17. Хайкин С. Нейронные сети. 2-е изд. М.: ИД Вильямс, 2016. 1104 с.
18. Ерыгин Е.В., Дуюн Т.А. Прогнозирование шероховатости поверхности при чистовом фрезеровании с использованием нейронных сетей // Вестник Белгородского государственного технологического университета им. В.Г. Шухова. 2019. № 10. С. 135–141.
19. Chavoshi S.Z., Tajdari M. Surface roughness modelling in hard turning operation of AISI 4140 using CBN cutting tool // *International Journal of Material Forming*. 2010. Vol. 3. № 4. P. 233–239. DOI: [10.1007/s12289-009-0679-2](https://doi.org/10.1007/s12289-009-0679-2).
20. Gupta A.K., Guntuku S.C., Desu R.K., Balu A. Optimisation of turning parameters by integrating genetic algorithm with support vector regression and artificial neural networks // *International Journal of Advanced Manufacturing Technology*. 2015. Vol. 77. № 1-4. P. 331–339. DOI: [10.1007/s00170-014-6282-9](https://doi.org/10.1007/s00170-014-6282-9).
5. Li X. Real-Time Prediction of Workpiece Errors for a CNC Turning Centre, Part 3. Cutting Force Estimation Using Current Sensors. *International Journal of Advanced Manufacturing Technology*, 2001, vol. 17, no. 9, pp. 659–664.
6. Li X. Real-Time Prediction of Workpiece Errors for a CNC Turning Centre, Part 4. Cutting-Force-Induced Errors. *International Journal of Advanced Manufacturing Technology*, 2001, vol. 17, no. 9, pp. 665–669.
7. Altintas Y. Virtual High Performance Machining. *Procedia CIRP*, 2016, vol. 46, pp. 372–378. DOI: [10.1016/j.procir.2016.04.154](https://doi.org/10.1016/j.procir.2016.04.154).
8. Yeung C.-H., Altintas Y., Erkorkmaz K. Virtual CNC system. Part I. System architecture. *International Journal of Machine Tools and Manufacture*, 2006, vol. 46, no. 10, pp. 1107–1123. DOI: [10.1016/j.ijmactools.2005.08.002](https://doi.org/10.1016/j.ijmactools.2005.08.002).
9. Zakovorotniy V.L., Lukyanov V.F., Pham D.T., Pham T.H. Kinematic perturbations of stationary trajectories shape generating movements in cutting dynamic system. *Vestnik Donskogo gosudarstvennogo tekhnicheskogo universiteta*, 2011, vol. 11, no. 9, pp. 1555–1563.
10. Vasin S.A. *Prognozirovanie vibroustoychivosti instrumenta pri tochenii i frezerovanii* [Predicting vibration resistance of tools during turning and milling]. Moscow, Mashinostroenie Publ., 2006. 384 p.
11. Rastorguev D.A., Sevastyanov A.A. The study of hard turning of 105WCR6 steel. *Vektor nauki Tolyattinskogo gosudarstvennogo universiteta*, 2018, no. 4, pp. 24–32.
12. Rastorguev D., Sevastyanov A. Diagnostics of chip formation and surface quality by parameters of the main drive current in the hard turning. *Materials Today: Proceedings*, 2019, vol. 19, pp. 1845–1851. DOI: [10.1016/j.matpr.2019.07.025](https://doi.org/10.1016/j.matpr.2019.07.025).
13. Lozovsky I.F. *Tsifrovaya obrabotka signalov v RLS obzora* [Digital signal processing in the radar surveillance system]. Novosibirsk, NGTU Publ., 2016. 270 p.
14. Kim D., Jeon D. Fuzzy-logic control of cutting forces in CNC milling processes using motor currents as indirect force sensors. *Precision Engineering*, 2011, vol. 35, no. 1, pp. 143–152. DOI: [10.1016/j.precisioneng.2010.09.001](https://doi.org/10.1016/j.precisioneng.2010.09.001).
15. Khajavi M.N., Nasernia E., Rostaghi M. Milling tool wear diagnosis by feed motor current signal using an artificial neural network. *Journal of Mechanical Science and Technology*, 2016, vol. 30, no. 11, pp. 4869–4875. DOI: [10.1007/s12206-016-1005-9](https://doi.org/10.1007/s12206-016-1005-9).
16. Labidi A., Tebassi H., Belhadi S., Khettabi R., Yallese M.A. Cutting Conditions Modeling and Optimization in Hard Turning Using RSM, ANN and Desirability Function. *Journal of Failure Analysis and Prevention*, 2018, vol. 18, no. 4, pp. 1017–1033. DOI: [10.1007/s11668-018-0501-x](https://doi.org/10.1007/s11668-018-0501-x).
17. Khaykin S. *Neyronnye seti* [Neural networks]. 2nd ed. Moscow, Vilyams Publ., 2016. 1104 p.
18. Erygin E., Duyun T. Forecasting of the surface roughness in finishing milling using neural networks. *Vestnik Belgorodskogo gosudarstvennogo tekhnologicheskogo universiteta im. V.G. Shukhova*, 2019, no. 10, pp. 135–141.
19. Chavoshi S.Z., Tajdari M. Surface roughness modelling in hard turning operation of AISI 4140 using CBN cutting tool. *International Journal of Material Forming*,

REFERENCES

1. Altintas Y. *Manufacturing automation*. Cambridge University Press, 2012. 366 p.
2. Kabaldin Yu.G., Shatagin D.A., Kolchin P.V. Development of “digital twin” of CNC lathe. *Tendentsii razvitiya nauki i obrazovaniya*, 2018, no. 45-8, pp. 44–50.
3. Kabaldin Yu.G., Shatagin D.A., Kuzmishina A.M. Development of cutting tool digital twin for machining production. *Tendentsii razvitiya nauki i obrazovaniya*, 2018, no. 45-8, pp. 50–57.
4. Pereverzev P.P. Features of developing the mathematical model of metal removal for the digital twin of process of circular grinding with CNC. *Vestnik Yuzhno-Uralskogo gosudarstvennogo universiteta. Seriya: Mashinostroenie*, 2020, vol. 20, no. 3, pp. 72–81.

2010, vol. 3, no. 4, pp. 233–239. DOI: [10.1007/s12289-009-0679-2](https://doi.org/10.1007/s12289-009-0679-2).

20. Gupta A.K., Guntuku S.C., Desu R.K., Balu A. Optimisation of turning parameters by integrating genetic algo-

rithm with support vector regression and artificial neural networks. *International Journal of Advanced Manufacturing Technology*, 2015, vol. 77, no. 1-4, pp. 331–339. DOI: [10.1007/s00170-014-6282-9](https://doi.org/10.1007/s00170-014-6282-9).

Development of turning process digital twin based on machine learning

© 2021

Dmitriy A. Rastorguev^{*1}, PhD (Engineering),

assistant professor of Chair “Equipment and Technologies of Machine Building Production”

*Aleksandr A. Sevastyanov*², graduate student

of Chair “Equipment and Technologies of Machine Building Production”

Togliatti State University, Togliatti (Russia)

*E-mail: rast_73@mail.ru

¹ORCID: <https://orcid.org/0000-0001-6298-1068>

²ORCID: <https://orcid.org/0000-0002-7465-650X>

Abstract: Today, manufacturing technologies are developing within the Industry 4.0 concept, which is the information technologies introduction in manufacturing. One of the most promising digital technologies finding more and more application in manufacturing is a digital twin. A digital twin is an ensemble of mathematical models of technological process, which exchanges information with its physical prototype in real-time. The paper considers an example of the formation of several interconnected predictive modules, which are a part of the structure of the turning process digital twin and designed to predict the quality of processing, the chip formation nature, and the cutting force. The authors carried out a three-factor experiment on the hard turning of 105WCr6 steel hardened to 55 HRC. Used an example of the conducted experiment, the authors described the process of development of the digital twin diagnostic module based on artificial neural networks. When developing a mathematical model for predicting and diagnosing the cutting process, the authors revealed higher accuracy, adaptability, and versatility of artificial neural networks. The developed mathematical model of online diagnostics of the cutting process for determining the surface quality and chip type during processing uses the actual value of the cutting depth determined indirectly by the force load on the drive. In this case, the model uses only the signals of the sensors included in the diagnostic subsystem on the CNC machine. As an informative feature reflecting the force load on the machine’s main motion drive, the authors selected the value of the energy of the current signal of the spindle drive motor. The study identified that the development of a digital twin is possible due to the development of additional modules predicting the accuracy of dimensions, geometric profile, tool wear.

Keywords: hard turning; CNC machines; digital twin; machine learning; artificial neural networks.

Acknowledgements: The project is supported by the Fund for the Promotion of the Development of Civil Society Institutions in Privolzhsky Federal District.

For citation: Rastorguev D.A., Sevastyanov A.A. Development of turning process digital twin based on machine learning. *Vektor nauki Tolyattinskogo gosudarstvennogo universiteta*, 2021, no. 1, pp. 32–41. DOI: 10.18323/2073-5073-2021-1-32-41.