

Создание нейросетевых моделей для решения задач прогнозирования геометрической точности изделий

В.А. Печенин¹, М.А. Болотов¹, Н.В. Рузанов¹, Е.Ю. Печенина¹

¹Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

Аннотация. В статье рассматриваются проблемы создания инструмента оперативного прогнозирования показателей качества (сборочных параметров) наукоемких изделий. В основе прогнозирования лежит создание и использование действительных геометрических моделей деталей, содержащих данные их геометрических отклонений, а также численных моделей сопряжений деталей. Действительные геометрические модели создаются на основании данных координатных измерений деталей. На примере сборочной единицы, состоящей из трех деталей ротора турбины авиационного двигателя проведена апробация разработанных моделей. Для снижения вычислительных ресурсов рассмотрено применение радиально-базисной нейронной сети для вычисления сборочных параметров. Произведено моделирование обучающих и тестовой выборки, оптимизация параметра работы сети и обобщение полученных результатов.

1. Введение

Важнейшим показателем качества машиностроительных изделий является геометрическая точность машин, оказывающая существенное влияние на их эксплуатационные показатели. Повышение геометрической точности изделий и снижение стоимости их производства может быть достигнуто за счёт разработки и внедрения цифровых технологий в процессы проектирования и производства изделий. Высокотехнологичная промышленность нового поколения основана на использовании данных. Перспективным подходом для улучшения процессов проектирования и производства высокотехнологичных изделий является разработка цифровых двойников объектов, которые являются цифровыми аналогами реальных объектов [1]. Применительно к сборочным операциям двигателей и энергетических установок, цифровой двойник представляет собой связанные между собой действительные модели деталей.

Для прогнозирования показателей качества (в частности, сборочных параметров) используются математические модели, реализованные в виде компьютерных моделей. Прямое моделирование процесса сопряжений с использованием численных моделей сопряжений и конечно-элементных моделей сборок требует существенных вычислительных ресурсов [2] и зачастую сопровождается проблемами сходимости решений. Для повышения производительности прогнозирования сборочных параметров могут быть использованы искусственные нейронные сети.

В статье приведен разработанный вариант решения задачи прогнозирования геометрической точности изделий, основанный на использовании данных измерений отдельных деталей, нейросетевых моделях и цифровых двойников сборок.

2. Объект исследования

В качестве объекта рассматривается сборка трех деталей турбины: вала, проставки и диска. На рисунке 1 приведен эскиз рассматриваемой сборочной единицы.




Рисунок 1. Сборочная единица и контролируемые поверхности, 1 – вал, 2 – проставка, 3 – диск.

На рисунке 1 базы *A* и *B* образуют ось вращения (базовую ось). Относительно базовой оси заданы требования на торцевое биение $\Pi_{m_б}$ поверхности 3 диска и радиальное биение $\Pi_{p_б}$ поверхности *П* диска. Рассмотрим модели и алгоритмы, позволяющие виртуально проводить прогнозирование биений.

3. Цифровой двойник сборки ротора

Цифровой двойник сборки включает в себя: цифровые модели деталей, включающих в себя реальную геометрию, содержащую производственные отклонения; расчет сопряженных состояний деталей [3, 4]; расчет сборочных геометрических параметров.

3.1. Создание моделей деталей с реальной геометрией

Для моделирования действительной геометрии необходима информация по ней в виде данных измерений поверхностей деталей. Поверхности деталей измерялись на координатно-измерительной машине (КИМ) DEA Global Performance.

В процессе измерения количество измеряемых точек на плоскостях и цилиндрических поверхностях составило 200 точек. Измерения граней деталей производилось по сечениям. В случае цилиндрических поверхностей сечения представляют собой линии пересечения поверхности и плоскостей, перпендикулярных оси вращения. Для торцевых поверхностей сечения представляют собой линии пересечения поверхности и цилиндрических поверхностей, ось и центр которых совпадают с нормальным вектором плоскости. Координаты измеренных точек сохранялись в файлы *.txt для дальнейшего анализа в системе MATLAB.

После загрузки координат точек по поверхностям производится их обработка и приведение к определенной структуре для дальнейшего построения действительных поверхностей. Обработка координат точек заключается в сглаживании выпадающих значений и вычислении координат точек, которых не достаёт для построения структуры данных. Сглаживание осуществлялось методом скользящей средней. Вычисление координат точек заключается в формировании сечений поверхностей деталей посредством аппроксимации или интерполяции измеренных массивов координат точек поверхностей посредством сплайнов в виде профилей или поверхностей [5].

В общем виде сложные поверхности деталей представляются в порционном виде, т.е. похожем на лоскутное одеяло. Кривые и поверхности сложной формы в CAD-системах и метрологическом обеспечении измерительного оборудования описываются сплайновыми уравнениями. Для математического представления пространственных кривых использован нормализованный кубический сплайн 3-й степени – Эрмитова кривая [6]. Для описания поверхностей деталей, имеющих геометрические отклонения формы, использовались поверхности, образованные из бикубических порций (порции Кунса [6]).

Итак, цифровые модели деталей представляют собой набор взаимоувязанных поверхностей деталей, участвующих в сборке и контроле.

3.2. Выполнение виртуального расчета сборки деталей, сохранение результатов

Для решения контактной задачи с использованием моделей поверхностей, был разработан итерационный алгоритм, позволяющий рассчитать сопряжение деталей без учета деформаций деталей в процессе сборки, подробно описанный в [3]. Алгоритм нахождения сопряжённого состояния предполагает итерационное перемещение одной сопрягаемой поверхности относительно другой с вектором приложения усилия сборки поверхностей \vec{D}_1 . Для выполнения процедуры наилучшего совмещения используется итерационный алгоритм ближайших точек (ICP) [7, 8]. Согласно данному алгоритму, на каждой итерации методами нелинейного оптимизационного поиска рассчитываются углы поворота и перемещения вдоль координатных осей. Для исключения пересечений двух поверхностей используется система неравенств, представленную в работе [9], которая накладывает ограничения на функцию зазора $G(\vec{V})$. В результате работы алгоритма вычисляется матрица вращения и вектор перемещения подвижной детали, определяющие преобразование ее начальной системы координат в систему координат в собранном состоянии.

3.3. Расчёт геометрических параметров сборки

Расчет радиального биения между контрольной поверхностью Π и базами A и B (рисунок 1) производится в следующей последовательности:

1. Главная ось системы координат элементов совпадает с нормальным вектором оси вращения \vec{a}_Π , заданного по базам A и B .

2. Рассчитываются расстояния от измеренных точек Π до оси вращения.

3. Величина радиального биения δ_{r_r} рассчитывается как разность между наибольшим d_{\max} и наименьшим d_{\min} от измеренных точек поверхности Π до оси вращения.

Торцевое биение поверхности Z , рассчитывается как разность максимального и минимального расстояний от измеренных точек торца Z до плоскости, перпендикулярной оси вращения.

Сходимость результатов моделирования с действительными параметрами, полученными в ходе сборки, оценивалось посредством вычисления абсолютных отклонений:

$$\delta_a = \Pi_{\text{изм}} - \Pi_m, \quad (1)$$

и относительных отклонений:

$$\delta_{\text{отн}} = \delta_a / \Pi_{\text{изм}} \cdot 100\%, \quad (2)$$

где Π_m – параметр, вычисленный в результате моделирования;

$\Pi_{\text{изм}}$ – измеренный параметр.

4. Нейросетевая модель прогнозирования геометрической точности

Для получение адекватного прогноза с использованием нейронной сети требуется: определиться с составом входных параметров в сеть; создать достаточно большую обучающую выборку; выбрать подходящую архитектуру нейронной сети. Достаточный объем обучающей выборки как правило превышает доступную статистику измерений. К тому же полученные в конкретной партии детали могут не охватывать все возможные случаи, и в следующей партии

деталей встретятся сочетания отклонений, отсутствующие в предыдущей, что скажется на качестве прогноза. По этой причине был выбран путь искусственного моделирования обучающего множества действительных моделей, основанного на данных доступной производственной статистики.

4.1. Создание множества действительных моделей деталей

Используя производственную статистику по геометрическим отклонениям цилиндрических и плоских поверхностей деталей сборки, было выполнено моделирование измеренных точек для формирования обучаемых и тестовых наборов данных. Рассматриваются цилиндрические и плоские грани деталей. Координату точки можно задать по формуле:

$$\vec{P}_p = (\vec{P}_n + \vec{n} \cdot \delta_\phi) \cdot \mathbf{R} + \vec{t}, \quad (3)$$

где \vec{P}_p , \vec{P}_n – вектор координат точек (x, y, z) соответственно измеряемой (моделируемой) и номинальной (CAD) поверхностей; \vec{n} – вектор нормали в точке \vec{P}_n ; δ_ϕ – величина отклонения формы в точке \vec{P}_n ; \mathbf{R}, \vec{t} – матрица поворота и вектор транспонирования координат точки \vec{P}_n , характеризующие отклонение расположения.

Для задания отклонения формы δ_ϕ использовался ряд Фурье [10].

4.2. Обучение нейронной сети, оценка ошибок прогнозирования

В качестве нейронной сети была выбрана широко применяемая архитектура для задач прогнозирования – полносвязанные радиально-базисные сети [11]. Архитектура обобщенно-регрессионной нейронной сети (GRNN, Generalized Regression Neural Networks) имеет два слоя – скрытый радиальный базисный слой и выходной линейный слой. Радиально-базисный нейрон преобразовывает расстояние от данного входного вектора до соответствующего ему "центра" по некоторому нелинейному закону (обычно функция Гаусса). Изменяемым параметром сети является параметр влияния P_{spread} , влияющем на смещения в нейронах, который является настраиваемым параметром нейрона. Число нейронов радиального базисного слоя равно числу элементов обучающего множества. На рисунке 2 приведена архитектура сети в случае, когда количество случаев обучающей выборки равно 9500.




Рисунок 2. Архитектура GRNN для прогнозирования параметров.

На вход в сеть необходимо подавать данные, от которых сборочные параметры находятся в прямой корреляционной зависимости. В качестве таких входов использовались производные параметры: параметры гармонического ряда, описывающего отклонение формы всех поверхностей; отклонения радиусов в случае цилиндрических граней; параметры параллельности плоскостей; смещение центров цилиндрических граней. Всего для рассматриваемой сборки трех деталей было использовано 128 параметров. Входные данные нормировались в диапазон $[0; 1]$.

Для оценки результатов прогноза параметров сборок и уточнения структуры выбранной нейросетевой модели необходимо производить оценку ошибок прогнозирования. Оценка ошибок прогнозирования параметров производится по двум критериям:

1. Доля спрогнозированных величин в пределах допустимой погрешности δ_{don} .

2. Среднеквадратичная ошибка (*RMSE*) предсказанных и фактических параметров. Приведём последовательность вычислений данных величин:

1. Вычислить погрешность между прогнозируемым и фактическим параметрами:

$$\Delta_n = P_{np} - P_{ф}. \quad (4)$$

2. Производится подсчёт количества ошибок в пределах допустимой области $N_{\Delta доп}$. Допустимая область ошибок вычисляется как процент от максимальной величины прогнозируемого параметра – 10%.

3. Точность прогноза рассчитывается как отношение количества $N_{\Delta доп}$ к общему объёму выборки:

$$\delta_{доп} = N_{\Delta доп} / N_{общ}. \quad (5)$$

4. Величина среднеквадратической ошибки вычисляется по формуле:

$$RSME = \sqrt{\Delta_n^2 / N_{общ}}. \quad (6)$$

5. Результаты работы

В результате измерений деталей были получены необходимые данные по отклонениям деталей сборки. Была произведена сборка ротора. Сборка была перемещена в специальное приспособление, производилось измерение на КИМ. Данный этап сборки производится для четырех положений вала, вращаем вала под 90° для каждого нового положения. Производится измерений точек поверхностей *З* и *П* (рисунок 1) относительно баз вала и расчет торцевых и радиальных биений. В системе MATLAB проводилась обработка измеренных данных отдельных деталей и виртуальный расчет сборочных параметров. В таблице 1 приведены результаты измеренных в ходе экспериментов и полученных в результате виртуального моделирования параметров сборки.

Таблица 1. Сравнение параметров сборки, полученных в ходе моделирования и измерения.

Сборочный параметр	Угол, °	Величина параметра, мм		Отклонения	
		Моделирование	Измерение	δ_a , мм	$\delta_{отн}$, %
$P_{p-б}$	0	0,133	0,13	0,003	2,31
	90	0,139	0,14	-0,001	-0,71
	180	0,150	0,15	0,000	0,00
	270	0,111	0,13	-0,019	-14,62
$P_{m-б}$	0	0,078	0,10	-0,022	-22,00
	90	0,107	0,09	0,017	18,89
	180	0,109	0,10	0,009	9,00
	270	0,090	0,09	0,000	0,00

Исходя из результатов в таблице 1, можно сделать вывод о том, что результаты моделирования в большинстве случаев достаточно близки к экспериментальным данным при использовании разработанного цифрового двойника. Расхождения объясняются погрешностями измерения и создания моделей поверхностей деталей; необходимостью учёта жёсткости деталей; принятыми допущениями при разработке модели сборки. Устранение названных причин для снижения отклонений является дальнейшим развитием цифровой модели.

Для проведения прогноза с помощью нейронных сетей было проведено моделирование различных случаев рассматриваемой сборки. Всего было проведено моделирование 10000 случаев, расчет которых длился 72 часа машинного времени на компьютере с процессором AMD Ryzen 7 2700 Eight-Core, с тактовой частотой 3,2 ГГц, объемом ОЗУ в 32 Гб. Для каждого случая сохраняются 128 параметров геометрических отклонений поверхностей и

результатирующие биения. Допустимая область ошибок вычисляется как процент от максимальной величины прогнозируемого параметра принята 10%. По параметру $\Pi_{p_б}$ допуск на ошибку получился (исходя из 10 % от максимальной величины параметра для сборки) $\pm 0,047$ мм; для параметра $\Pi_{m_б}$ $\pm 0,049$ мм. Подбиралась величина параметра P_{spread} исходя из того, чтобы суммарная величина параметра $RSME$ была минимальной, а величина $\delta_{отн}$ – максимальной. Параметр P_{spread} подбирался из диапазона 0,001 – 3. Тестовая выборка не менялась и составила 500 случаев. Рассматривались различные объемы обучающих выборок $N_{об}$: 500, 1000, 2500, 5000 и 9500 случаев.

Таблица 2. Результаты нейросетевого моделирования.

Сборочный параметр	Угол, °	$P_{spread}=1$	$P_{spread}=1$	$P_{spread}=0,5$	$P_{spread}=0,5$	$P_{spread}=1$
		$N_{об}=500$	$N_{об}=1000$	$N_{об}=2500$	$N_{об}=5000$	$N_{об}=9500$
$\Pi_{p_б}$	0	0,117	0,115	0,122	0,116	0,116
	90	0,113	0,114	0,119	0,111	0,111
	180	0,117	0,121	0,125	0,111	0,119
	270	0,125	0,123	0,123	0,119	0,121
$\Pi_{m_б}$	0	0,111	0,110	0,106	0,109	0,115
	90	0,109	0,112	0,109	0,112	0,115
	180	0,114	0,115	0,108	0,106	0,113
	270	0,115	0,112	0,107	0,108	0,113

После подбора параметра P_{spread} и обучения сети на вход подавались 128 параметров с измеренных поверхностей, параметры сборки которых для четырех положений приведены в таблице 1. В таблице 2 представлены результаты работы сети по прогнозу параметров радиального и торцевого биений для случая измеренной сборки.

В таблице 3 рассмотрены величины относительных отклонений $\delta_{отн}$ данных из таблицы 2. За базу приняты результаты измерений из таблицы 1. Кроме того в таблице 3 приведены средние арифметические величины отклонений параметров.

Таблица 3. Величины $\delta_{отн}$ для прогноза.

Сборочный параметр	Угол, °	$N_{об}=500$	$N_{об}=1000$	$N_{об}=2500$	$N_{об}=5000$	$N_{об}=9500$
$\Pi_{p_б}$	0	-10,00	-11,54	-6,15	-10,77	-10,77
	90	-19,29	-18,57	-15,00	-20,71	-20,71
	180	-22,00	-19,33	-16,67	-26,00	-20,67
	270	-3,85	-5,38	-5,38	-8,46	-6,92
$\Pi_{m_б}$	0	11,00	10,00	6,00	9,00	15,00
	90	21,11	24,44	21,11	24,44	27,78
	180	14,00	15,00	8,00	6,00	13,00
	270	27,78	24,44	18,89	20,00	25,56
Среднее значение по восьми параметрам		16,13	16,09	12,15	15,67	17,55
Среднее значение по $\Pi_{p_б}$		13,78	13,71	10,80	16,49	14,77
Среднее значение по $\Pi_{m_б}$		18,47	18,47	13,50	14,86	20,33

Обобщая результаты таблиц 2 и 3, можно отметить, что наибольшая точность достигается в случае объема обучающей выборки в 2500 случаев. Исходя из средних и предельных значений $\delta_{отн}$ в таблице 3, погрешности прогноза радиального биения меньше погрешностей прогноза

торцевого биения. В то же время абсолютные значения предельных погрешностей прогноза с помощью прямого моделирования и нейронной сети (результаты из таблиц 1 и 3) близки: для $\Pi_{p_б}$ – (-14,62%) и (-16,67%) соответственно при прямом прогнозе и прогнозе с помощью нейронной сети; для $\Pi_{m_б}$ – 21,11% и (-22%). Ни одно из отклонений не превысило допуска в 10% на максимальную величину параметра. Результаты позволяют судить о том, что выбранная архитектура нейронной сети, при величине обучающей выборки в 2500 случаев и параметре $P_{spread}=0,5$ позволяет добиваться такой же точности, как и разработанная цифровая модель, основанная на прямом моделировании поверхностей деталей и сборочного процесса.

6. Заключение

В статье приведены результаты исследований, позволяющие на основании измеренных данных проводить прогноз результирующих сборочных геометрических параметров. Была решена задача создания цифрового двойника сборки ротора, позволяющего воспроизводить процесс сборки деталей по действительным поверхностям. Решены задачи, связанные с моделированием действительных поверхностей с использованием небольшой статистики, моделирование самих данных измерений. Относительные погрешности прогнозирования сборки трех деталей ротора турбины не превышают 22% и позволяют говорить об адекватности предложенного решения. Подобрано 128 влияющих параметров геометрических отклонений, создана и обучена радиально-базисная нейронная сеть, пригодная для проведения прогнозов сборочных параметров, точность работы которой сопоставима с прямым моделированием с использованием цифрового двойника сборки. Использование обученной нейронной сети для прогнозирования сборочных параметров рассматриваемой сборки позволяет существенно снизить трудоемкость расчетов и использовать разработанное решение непосредственно после измерения деталей и обработки измеренных данных. Помимо решенных задач существуют и ряд других (трудоемкость измерений, учёт жесткости деталей при моделировании сборок), на решение которых будут направлены дальнейшие исследования.

7. Благодарности

Работа выполнена при финансовой поддержке Министерства науки и высшего образования Российской Федерации в рамках стипендии Президента Российской Федерации (номер СП-262.2019.5).

8. Литература

- [1] Фурсов, В.А. Информационная технология реконструкции цифровой модели местности по стереоизображениям / В.А. Фурсов, Е.В. Гошин // Компьютерная оптика. – 2014. – Т. 38, № 2. – С. 335-342.
- [2] Морунов, Н.Д. Особенности построения блочных алгоритмов FDTDметода при организации вычислений на графическом процессоре с использованием языка MATLAB / Н.Д. Морунов, Д.Л. Головашкин // Компьютерная оптика. – 2019. – Т. 43, № 4. – С. 671-676. DOI: 10.18287/2412-6179-2019-43-4-671-676.
- [3] Болотов, М.А. Метод оценки неопределённостей пространственного сопряжения высокоточных оптических и механических деталей / М.А. Болотов, В.А. Печенин, С.П. Мурзин // Компьютерная оптика. – 2016. – Т. 40, № 3. – С. 360-369.
- [4] Болотов, М.А. Нейросетевая модель в цифровом прогнозировании геометрических параметров относительного положения деталей авиационных двигателей / М.А. Болотов, В.А. Печенин, Н.В. Рузанов, Д.М. Балякин // Сборник трудов V международной конференции и молодежной школы «Информационные технологии и нанотехнологии» (ИТНТ). – Самара: Новая техника, 2019. – Т. 4. – С. 608-616.
- [5] Печенин, В.А. Модель и программный модуль для прогнозирования погрешностей координатных измерений в NX OPEN API / В.А. Печенин, Н.В. Рузанов, М.А. Болотов //

- Сборник трудов IV международной конференции и молодежной школы «Информационные технологии и нанотехнологии» (ИТНТ), 2018. – С. 1454-1460.
- [6] Rogers, D.F. *Mathematical Elements for Computer Graphics* / D.F. Rogers, J.A. Adams // New York, London: McGrawHill, 1990. – 604 p.
- [7] Besl, P.J. A method for registration of 3-D shapes / P.J. Besl, N.D. McKay // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. – 1992. – Vol. 14(2). – P. 239-256.
- [8] Tian, H. ICP registration technology based on the coordinate system direction fit / H. Tian, P. Yang, C. Su, Z. Dong // *International Journal of Security and its Applications*. – 2015. – Vol. 9(12). – P. 47-56.
- [9] Pierce, R.S. Simulation of mating between nonanalytical programming formulation / R.S. Pierce, D. Rosen // *Journal of Computing and Information Science in Engineering*. – 2007. – Vol. 7(4). – P. 314-321.
- [10] Болотов, М.А. Нейросетевая модель в цифровом прогнозировании геометрических параметров относительного положения деталей авиационных двигателей / М.А. Болотов, В.А. Печенин, Н.В. Рузанов, Д.М. Балякин // Сборник трудов V международной конференции и молодежной школы «Информационные технологии и нанотехнологии» (ИТНТ) – Самара: Новая техника, 2019. – Т. 4. – С. 608-616.
- [11] Vasserman, P.D. *Advanced methods in neural computing* / P.D. Vasserman – New York: Van Nostrand Reinhold, 1993. – 255 p.

Creation neural network models for solving the problems of predicting the products geometric accuracy

V.A. Pechenin¹, M.A. Bolotov¹, N.V. Ruzanov¹, E.J. Pechenina¹

¹Samara National Research University, Moskovskoe Shosse 34A, Samara, Russia, 443086

Abstract. The article discusses the problems of creating a tool for operational forecasting of quality indicators (assembly parameters) of high-tech products. The basis of forecasting is the creation and use of valid geometric models of parts containing data of their geometric deviations, as well as numerical models of mates of parts. Valid geometric models are created based on coordinate measurements of parts. On the example of an assembly unit consisting of three parts of an aircraft engine turbine rotor, the developed models were tested. To reduce computing resources, the use of a radial basis neural network for calculating assembly parameters is considered. The training and test samples were simulated, the network operation parameter was optimized, and the obtained results were generalized.