

Нейросетевая модель в цифровом прогнозировании геометрических параметров относительного положения деталей авиационных двигателей

М.А. Болотов¹, В.А. Печенин¹, Н.В. Рузанов¹, Д.М. Балякин¹

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

Аннотация. Качество авиационных и ракетных двигателей зависит прежде всего от геометрической точности сборочных единиц и 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 и зачастую сопровождается проблемами сходимости решений. Для решения приведенных проблем возможно использование нейросетевых моделей, описывающих основные закономерности процесса сопряжения на основе накопленных результатов. В работе приведена нейросетевая модель для прогнозирования сборочных параметров деталей на основе использования действительных поверхностей деталей, полученных в результате математического моделирования. Рассмотрена сборка по коническим поверхностям. Для прогноза параметров сборок использована свёрточная нейронная сеть.

1. Введение

Сложные промышленные и наукоёмкие изделия характеризуются высокими требованиями к геометрической точности деталей и сборочных единиц. К таким изделиям относятся современные авиационные двигатели, к которым предъявляются высокие требования по надежности, минимальной массе, экономичности и ресурсу. Перечисленные характеристики обеспечиваются в том числе благодаря совершенствованию технологии изготовления деталей и узлов. В производстве и сборке выполняется обеспечение размерной точности. Пути достижения размерной точности определяются на этапе конструкторско-технологической подготовки производства [1,2,3]. Решение указанных задач на каждом из этапов может быть упрощено за счёт наличия математических моделей [4] и средств, позволяющих прогнозировать и определять действительное значение геометрических параметров [5,6], характеризующих достижимую точность.

В работе предложена модель, основанная на использовании нейронных сетей, позволяющая прогнозировать сборочные параметры деталей при сопряжении их по плоским, цилиндрическим и коническим поверхностям с размерами, характерными для деталей газотурбинных двигателей.

2. Объект исследования

В качестве объекта рассматривается сборка двух конусных колец. На рисунке 1 приведена модель сборки деталей по коническим элементам.




Рисунок 1. Модель механической системы для сборки двух конусных колец.

На рисунке 1 для конусных колец K_1 и K_2 заданы локальные конструкторские системы координат R_1 и R_2 . Сопряжение деталей происходит по поверхностям B_1 и B_2 . Каждая из поверхностей задаётся в локальных координатах детали. Одно кольцо является охватываемым и лишённым шести степеней свободы, второе охватывающим и перемещаемым [7]. Параметрами сборки двух конусных колец являются координата точки пересечения оси с верхней торцевой гранью перемещаемого кольца. Координаты точки в плоскости, перпендикулярной оси конуса, представлены полярной системе координат и характеризуется полярным радиусом ρ_{ij} и соответствующим полярным углом φ_{ij} , изменяющимся от 0 до 360° .

Координата вдоль оси вращения характеризует смещение δ_o вдоль соответствующего вектора торцевых поверхностей внешнего кольца относительно внутреннего. Перекосы осей пренебрежительно малы в данном случае сборки.

Для того, чтобы создать нейросетевую модель прогнозирования сборочных параметров необходимо создать обучающие наборы и проверить качество работы сети на тестовых данных. Для этого необходимо либо накопить достаточно большую статистику измеренных данных (от нескольких тысяч случаев), либо произвести аугментацию данных из меньшего количества статистических данных. При этом необходимо достаточно точно вычислить сборочные параметры, которые будут прогнозироваться. Рассмотрим подробнее этапы создания нейросетевой модели прогнозирования геометрических параметров относительного положения деталей.

3. Нейросетевая модель в цифровом прогнозировании геометрических параметров относительного положения конусных колец

В общем виде контакт сопрягаемых соответственно пар поверхностей происходит по конечному множеству точек. Такие задачи являются контактными [8]. Известны аналитические решения контактных задач поверхностей, не имеющих отклонения формы. В общем случае, для моделирования контактных задач поверхностей, имеющих отклонения формы, используется метод конечных элементов. Названный метод позволяет учесть особенности геометрии поверхностей и решать задачи прогнозирования сборки.

Разработанная модель включает в себя следующие этапы:

1. Создание действительных моделей деталей.
2. Построение триангуляционных сеток на поверхностях деталей.
3. Выполнение виртуального расчета сборки деталей, сохранение результатов.
4. Обучение нейронной сети, оценка ошибок прогнозирования.

3.1. Создание действительных моделей деталей

Создание действительных моделей деталей осуществлялось в следующей последовательности. На первом этапе выполнялось построение конечного множества номинальных точек сопрягаемых деталей. На втором этапе рассчитывались действительные (модельные) сопрягаемые поверхности точек на основе координат номинальных точек, функций отклонения формы и параметров отклонения расположения.

Для описания отклонения формы подбирается гармонический ряд, при помощи которого можно с достаточной точностью описать дискретный ряд данных отклонения формы, полученных из измеренной геометрии. Гармонический ряд имеет следующий вид:

$$\delta_n(x) = \sum_{k=1}^{+\infty} A_k \sin(k \cdot (2 \cdot \pi \cdot x / \tau + \theta_k) + (1 + (-1)^k) \cdot \pi / 2), \tag{1}$$

где A_k – набор амплитуд членов гармонического ряда; θ_k – фазы членов гармонического ряда; k – частоты членов гармонического ряда; τ – период функции (длина кривой); x – текущая длина кривой от начальной до текущей точки (угол).

Рассматриваемые детали представляют собой тела вращения. Сопрягаемые грани, имеющие отклонение геометрии являются заметающими: их можно получить путём перемещения объекта, например отрезка, ломаной или кривой вдоль некоторой направляющей кривой, в пространстве.

Вектор координат каждой точки направляющей кривой сечения для конусной грани, ось которой перпендикулярна XOY можно описать при помощи выражения:

$$\vec{p}_y = \left| (r_k - \delta r_h + \delta r_y + \delta_n(\chi)) \cdot \cos(\chi) \quad (r_k - \delta r_h + \delta r_y + \delta_n(\chi)) \cdot \sin(\chi) \quad h \right| + \vec{t}, \tag{2}$$

где r_k – номинальный радиус точек сечения; δr_y – постоянная величина отклонения радиуса от номинального значения; χ – полярный угол точки p_y ; δ_n – моделируемое отклонение формы при помощи ряда (1) в точке p_y ; h – высота сечения. δr_h – изменение радиуса конуса по высоте. Вычисляется по формуле:

$$\delta r_h = h \cdot \operatorname{tg}(90 - \gamma / 2), \tag{3}$$

где γ – угол при вершине конуса.

3.2. Построение триангуляционных сеток на поверхностях деталей

Соответственно кривая, которая будет перемещаться вдоль полученной направляющей, представляет собой отрезок. Таким образом точки конусных граней можно задать с использованием двух уравнений (2), соответственно в местах минимальной и максимальной высот h . После чего наборы из трех соседних точек (две на одном сечении и одна на другом) образуют фасеты конечно-элементной модели.

3.3. Выполнение виртуального расчета сборки деталей, сохранение результатов

Для решения контактной задачи с использованием разработанной конечно-элементной модели, был разработан итерационный алгоритм, позволяющий рассчитать сопряжение деталей без учета деформаций деталей в процессе сборки, подробно описанный в [9]. Алгоритм нахождения сопряжённого состояния предполагает итерационное перемещение одной сопрягаемой поверхности относительно другой с вектором приложения усилия сборки поверхностей \vec{D}_1 . Введено понятие функции зазора $G(\vec{V})$, характеризующее достижение сопряжённого состояния поверхностей деталей и зависящее от вектора взаимного расположения поверхностей \vec{V} . Для расчёта функции $G(\vec{V})$ на каждом этапе выполняется наилучшее совмещение сопрягаемых поверхностей. Для выполнения процедуры наилучшего совмещения используется итерационный алгоритм ближайших точек (ICP) [10, 11]. 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 [12], 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:

$$\vec{p}_{сб} = \vec{p}_o \cdot \mathbf{R}_{сб} + \vec{t}_{сб}, \tag{4}$$

где $\vec{p}_{сб}$, \vec{p}_o – вектор координат точек (x, y, z) детали соответственно после сборки и в начальном состоянии;

$\mathbf{R}_{сб}$, $\vec{t}_{сб}$ – матрица поворота и вектор перемещения координат точки \vec{p}_o , характеризующие перемещение детали в процессе сборки.

Параметры сборки конусных колец ρ_{ψ} , φ_{ψ} и δ_o , ввиду того что перекосы осей пренебрежительно малы, содержатся в векторе перемещения \vec{t} из уравнения (4).

3.4. Обучение нейронной сети, оценка ошибок прогнозирования

Нейронная сеть для прогнозирования является последовательностью соединённых между собой слоёв, начинающихся со свёрточного слоя и заканчивающейся слоем регрессии (рисунок 2).

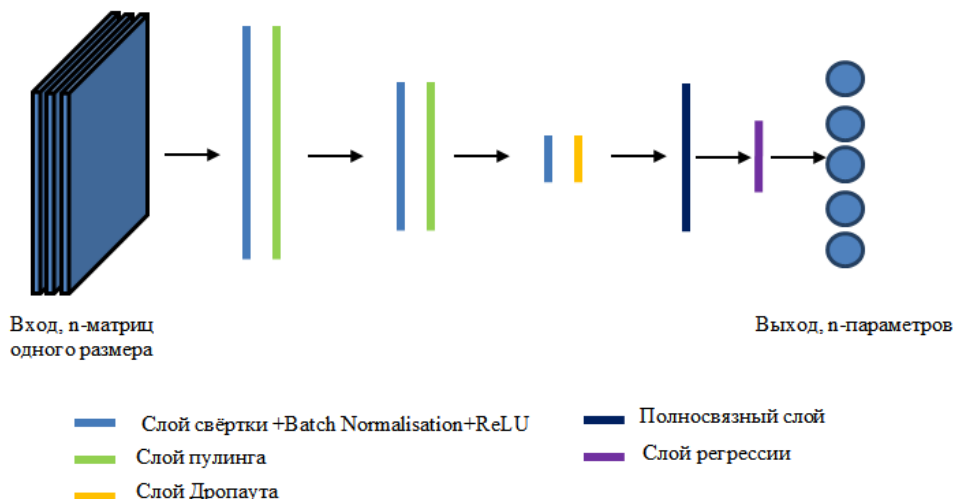


Рисунок 2. Архитектура свёрточной нейронной сети для прогнозирования параметров.

На вход в сеть подаётся набор из прямоугольных матриц чисел равных размеров. Дадим краткую характеристику слоям рассматриваемой сети.

Слой свёртки (англ. convolutional layer) — это основной блок свёрточной нейронной сети. Слой свёртки включает в себя для каждого канала свой фильтр, ядро свёртки которого обрабатывает предыдущий слой по фрагментам (суммируя результаты матричного произведения для каждого фрагмента).

Скалярный результат каждой свёртки попадает на функцию активации, которая представляет собой некую нелинейную функцию. Слой активации обычно логически объединяют со слоем свёртки (считают, что функция активации встроена в слой свёртки). Выбрана кусочно-линейная функция *ReLU*.

Нормализация по мини-батчам (batch normalization) описана например в [13], из русских источников в [14]. Мини-батч – небольшая коллекции данных, которая обычно выбирается из всего обучающего множества случайно. Батч-нормализация решает проблему несоответствий градиентов на разных уровнях сети, препятствующую эффективному обучению, за счёт нормализации входных данных таким образом, чтобы получить нулевое математическое ожидание и единичную дисперсию. Нормализация выполняется перед входом в каждый слой.

Слой пулинга (иначе подвыборки, субдискретизации) представляет собой нелинейное уплотнение карты признаков, при этом группа пикселей (обычно размера 2×2) уплотняется до

одного пикселя, проходя нелинейное преобразование. Наиболее употребительна при этом функция усреднения, которая используется в данной сети.

Слой дропаута [15]. Дропаут – метод регуляции нейронных сетей. Для каждого нейрона (кроме самого последнего, выходного слоя) устанавливается некоторая вероятность p , с которой он будет выброшен из сети. Алгоритм обучения меняется таким образом: на каждом новом тренировочном примере каждый нейрон с вероятностью p либо используется как обычно, либо его выход устанавливается строго равным нулю. Дальше все происходит без изменений; ноль на выходе приводит к тому, что нейрон фактически выпадает из графа вычислений: и прямое вычисление, и обратное распространение градиента останавливаются на этом нейроне и дальше не идут.

Полносвязный слой. После нескольких прохождений свёртки изображения и уплотнения с помощью пулинга система перестраивается от конкретной сетки пикселей с высоким разрешением к более абстрактным картам признаков, как правило на каждом следующем слое увеличивается число каналов и уменьшается размерность изображения в каждом канале. В конце концов остаётся большой набор каналов, хранящих небольшое число данных (даже один параметр), которые интерпретируются как самые абстрактные понятия, выявленные из исходного изображения.

Эти данные объединяются и передаются на обычную полносвязную нейронную сеть, которая тоже может состоять из нескольких слоёв. При этом полносвязные слои уже утрачивают пространственную структуру пикселей и обладают сравнительно небольшой размерностью (по отношению к количеству пикселей исходного изображения).

Последний слой представляет собой слой регрессии, в котором используется функция потерь MSE (среднеквадратическая ошибка). Соответственно на выходе из сети вычисляются непосредственно параметры сборки.

В случае сборки двух плоскостей и конусных колец на входе в сеть достаточно подавать одну матрицу расстояний, характеризующих начальный зазор в соединении. Начальный зазор – это матрица расстояний между точками одной поверхности (неподвижной детали в соединении) и сопрягаемой с ней поверхностью другой (подвижной детали), когда детали находятся в номинальном положении. Или же подвижная деталь сдвинута на некоторое небольшое расстояние от неподвижной, вдоль одной из осей.

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 $\delta_{доп}$.
- 2 Среднеквадратичная ошибка ($RMSE$) предсказанных и фактических параметров.

Приведём последовательность вычислений данных величин:

- 1 Вычислить погрешность между прогнозируемым и фактическим параметрами:

$$\Delta_n = \Pi_{np} - \Pi_{ф} \tag{5}$$

- 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:

$$\delta_{доп} = N_{\Delta доп} / N_{общ} \tag{6}$$

- 4 Величина среднеквадратической ошибки вычисляется по формуле:

$$RSME = \sqrt{\Delta^2 / N_{общ}} \tag{7}$$

4. Результаты применения виртуальной сборки для прогноза сборочных параметров

Производится моделирование точек двух конусных поверхностей, с использованием формул (1-3). Всего было произведено моделирование 10000 наборов точек для конусов двух типов (по 5000 каждого типа). Каждый набор содержит 720 точек (по 360 точек, принадлежащих двум направляющим кривым). Номинально точки направляющих лежат в плоскостях, параллельных XOY . В таблице 1 приведены статистические характеристики (математическое ожидание \bar{X} и среднеквадратические отклонения σ) параметров геометрических отклонений двух конусов.

Таблица 1. Значение параметров отклонений точек двух сопрягаемых конусов.

Параметр	Первый конус				Второй конус			
	A_k , мм	k	θ_k , рад	δr_{iy} , мм	A_k , мм	k	θ_k , рад	δr_{iy} , мм
\bar{X}	0,0041	5,9	1,9783	0,0665	0,0010	5,8	1,9556	0,0001
σ	0,0067	2,3	1,8823	0,0219	0,0009	2,3	1,8308	0,0085

Высоты конусов h составляют 40 мм; радиус у основания r_k 27,36 мм; угол при вершине составляет γ 6 градусов.

Статистические характеристики и минимальные-максимальные значения параметров сборки конусных колец, полученных в результате моделирования, с использованием сформированных наборов измеренных точек соединяемых деталей приведены в таблице 2.

Таблица 2. Сборочные параметры двух конусных колец.

Параметры	\bar{X}	σ	Min	Max
φ_{iy} , град	131,0174	75,8793	0,0652	359,9210
ρ_{iy} , мм	0,0104	0,0068	0,0001	0,0453
δ_o , мм	-0,4318	0,7330	-2,3640	0,9730

На рисунке 3 приведен пример одного из начальных зазоров в соединениях конусных поверхностей.

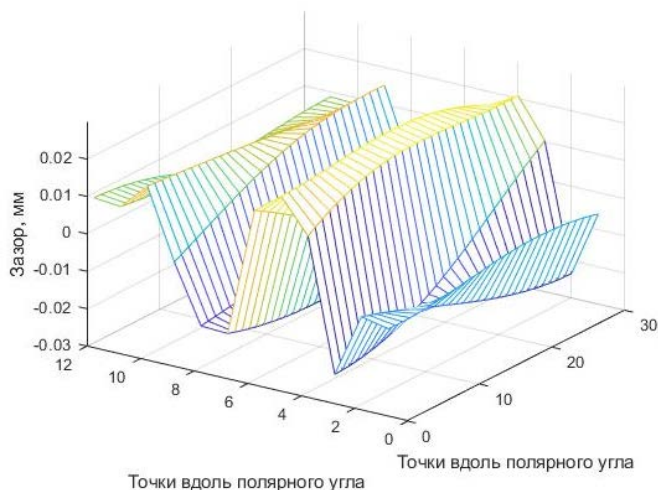


Рисунок 3. Начальный зазор в соединении двух конусов.

Размерности матриц составляют 12×30 точек для конусных колец. Так как в рассматриваемой задаче углы наклона подвижного кольца на начальном этапе сборки, в процессе и в конце сборки отсутствуют, зазор будет одинаковым по высоте в нулевом положении. По этому был взят зазор в одном сечении (360 точек) и чтобы выполнить несколько операций свёртки один ряд разбит на 12 рядов по 30 значений в каждом. После расчёта всех матриц их значения нормируются в диапазон $[0 \ 1]$.

Подбираемыми параметрами свёрточной нейронной сети с регрессионным слоем являются: глубина сети, характеризуемая количеством свёрточных подсетей N_c , включающих свёрточные слои субдискретизации; размер ядра свёртки ($N_{яс} \times N_{яс}$); количество каналов свёртки M_k ; вероятность p в дропауте. Размер окна в пулинге не меняется – 2×2 . После подбора архитектуры сети, производится оптимизация процесса обучения сети по следующим параметрам: размер пакета (батча) данных при обучении N_b ; количество эпох обучения N_ε ; количество эпох для снижения скорости обучения $N_{эсо}$; фактор снижения скорости обучения $F_{со}$ (изменяется от 0 до 1); алгоритм обучения («SGDM» [16, 17] или «RMSProp» [18]).

В таблице 3 приведены результаты прогнозирования параметров для сборки двух плоскостей и двух конусных колец.

Таблица 3. Оценка работы сети.

Параметры	Конусные кольца		
	$\varphi_{ц}$	$\rho_{ц}$	δ_o
$\delta_{дон}$	0,864	0,866	0,998
<i>RMSE</i>	0,647	0,003	0,056

В таблице 4 приведены параметры сетей, при которых достигается наибольшая точность прогнозирования сборочных параметров.

Таблица 4. Оптимальные параметры сетей для прогнозирования сборки конусных колец.

Параметр	N_c	$N_{яс}$	M_k	p	N_b	N_ε	$N_{эсо}$	$F_{со}$	Алгоритм обучения
Значение	2	4	6	0,4	40	70	30	0,1	«SGDM»

Как следует из результатов, приведённых в таблице 2, величина $\delta_{дон}$ параметра δ_o наибольшая, полярные координаты центра определяются с меньшей точностью. При этом нужно учитывать, что величина $\rho_{ц}$ имеет почти в 19 раз меньший показатель *RMSE* чем δ_o , так как значения смещения центра в плоскости, перпендикулярной оси вращения существенно ниже, чем его смещение вдоль оси вращения.

5. Заключение

В работе приведена модель для прогнозирования точности сопряжения деталей по результатам измерений геометрии, основанный на использовании цифровых моделей и свёрточной нейронной сети. В качестве объекта для расчетов выбрано соединение двух конусных колец. Данные, полученные с помощью моделирования, используются для обучения свёрточной нейронной сети, позволяющие по картам отклонений геометрии измеряемых поверхностей деталей прогнозировать сборочные параметры соединения.

6. Литература

- [1] Soifer, V.A. Synthesis of a binary DOE focusing into an arbitrary curve, using the electromagnetic approximation / V.A. Soifer, N.L. Kazanskiy, S.I. Kharitonov // Optics and Lasers in Engineering. – 1998. – Vol. 29(4-5). – P. 237-247.
- [2] Казанский, Н.Л. Оптимизация параметров инжекционного литья мультилинз из термопластичных полимеров / Н.Л. Казанский, И.С. Степаненко, А.И. Хаймович, С.В. Кравченко, Е.В. Бызов, М.А. Моисеев // Компьютерная оптика. – 2016. – Т. 40, № 2. – С. 203-214. DOI: 10.18287/2412-6179-2016-40-2-203-214.

- [3] Досколович, Л.Л. Расчёт дифракционных оптических элементов для фокусировки во внеосевые радиальные фокальные области / Л.Л. Досколович, Н.Л. Казанский, В.С. Павельев, В.А. Сойфер // *Автометрия*. – 1995. – № 1. – С. 114-119.
- [4] Deng, X. Research on the manufacturing of mechanical parts based on the theory of space symmetry group / X. Deng, J. Wang // *Academic Journal of Manufacturing Engineering*. – 2017. – Vol. 15(1). – P. 64-71.
- [5] Zakharov, O.V. Minimization of the systematic error in centerless measurement of the roundness of parts / O.V. Zakharov, A.V. Kochetkov // *Measurement Techniques*. – 2016. – Vol. 58(12). – P. 1317-1321.
- [6] Печенин, М.В. К вопросу разработки методики измерения параметров зубчатых колес с гиперболоидной делительной поверхностью и назначения норм точности / М.В. Печенин, А.Р. Абзалов, В.Э. Шустов // *Вестник ИжГТУ им. М.Т. Калашникова*. – 2017 – Т. 20, № 2. – С. 87-90.
- [7] Печенин, В.А. Модель сопряжения деталей с коническими поверхностями / В.А. Печенин, М.А. Болотов, Н.В. Рузанов, И.А. Грачев, И.В. Щербаков // *СТИН*. – 2017. – № 3. – С. 87-90.
- [8] Kovalenko, P. Investigation of tribological properties of friction pairs duralumin – fluoropolymer used for design and manufacturing of biomechatronic devices / P.Kovalenko, S. Perepelkina, T. Korakhanov // *Tribology in Industry*. – 2017. – Vol. 39(2). – P. 192-197.
- [9] Болотов, М.А. Метод оценки неопределённости пространственного сопряжения высокоточных деталей с использованием оптических измерений / М.А. Болотов, В.А. Печенин, С.П. Мурзин // *Компьютерная оптика*. – 2016. – Т. 40, № 3. – С. 360-369. DOI: 10.18287/2412-6179-2016-40-3-360-369.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] Ioffe, S.Y. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift / S.Y. Ioffe, C. Szegedy // *Proc. 32nd ICML, 2015*. – P. 448-456.
- [14] Николенко, С.И. Глубокое обучение / С.И. Николенко, А. Кадури, Е. Архангельская. – СПб.: Питер, 2018. – 480 с.
- [15] Srivastava et al., N. Dropout: A Simple Way to Prevent Neural Networks from Overfitting // *Journal of Machine Learning Research*. – 2014. – Vol. 15(1). – P. 1929-1958.
- [16] Sutskever, I. On the importance of initialization and momentum in deep Learning // *Proceedings of the 30th international conference on machine learning (ICML-13), 2013*.
- [17] Чабаненко, В. Д. Модификации метода стохастического градиентного спуска для задач машинного обучения с большими объёмами данных. – М: Московский государственный университет, 2016. – 26 с.
- [18] Tijmen, T. Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude / T. Tijmen, G. Hinton // *COURSERA: Neural Networks for Machine Learning 4, 2012*.

Благодарности

Работа выполнена при финансовой поддержке Министерства образования и науки Российской Федерации в рамках выполнения государственного задания на 2019 год. Шифр проекта 9.11978.2018/11.12.

Neural network model in predicting digital geometric parameters relative position of aircraft engine parts

M.A. Bolotov¹, V.A. Pechenin¹, N.V. Ruzanov¹, D. M. Balyakin¹

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

Abstract. The quality of aircraft and rocket engines depends primarily on the geometrical accuracy of assembly units and parts. To predict the quality parameters (in particular, the assembly parameters) used mathematical models implemented in the form of computer models. Direct modeling of the process of assembly using numerical models of conjugations and finite-element models of assemblies requires significant computational resources and is often accompanied by problems of convergence of solutions. To solve the above problems, it is possible to use neural network models describing the main regularities of the pairing process based on the accumulated results. The paper shows a neural network model for predicting the parameters of assembly parts based on the use of real surfaces of parts obtained as a result of mathematical modeling. Considered assembly on conical surfaces. To predict the parameters of the assemblies, a convolutional neural network was used.