

Научная статья

Статья в открытом доступе

УДК 004.89

doi: 10.30987/2658-6436-2025-3-45-53

ИНТЕЛЛЕКТУАЛЬНАЯ СИСТЕМА ПОДБОРА ТЕХНОЛОГИЧЕСКИХ МАРШРУТОВ НА ОСНОВЕ ГРАФОВОЙ НЕЙРОСЕТИ И МАШИНОЧИТАЕМОЙ МОДЕЛИ ИЗДЕЛИЯ

Александр Николаевич Феофанов¹, Эдуард Эдуардович Веселов^{2✉},

Инна Евгеньевна Колошкينا³

^{1,2} МГТУ СТАНКИН, г. Москва, Россия

³ НИТУ МИСИС, г. Москва, Россия

¹ feofanov.fan1@yandex.ru, <https://orcid.org/0000-0003-4761-0538>

² Eduuaarrdd@yandex.ru, <https://orcid.org/0009-0007-8900-5535>

³ inna.koloshkina@yandex.ru, <https://orcid.org/0000-0001-9767-9555>

Аннотация. Целью исследования является создание интеллектуальной системы для автоматизации выбора технологических маршрутов на основе графовой нейросети и интерфейса кодировки признаков деталей. Задача статьи – представить метод формализации конструкции изделия в машиночитаемом виде и разработать модель GCN, способную классифицировать детали по структуре и выбирать технологический шаблон. Методы исследования включают ручной ввод признаков через интерфейс, построение ориентированного графа, кодировку параметров в one-hot формате, обучение нейросети на размеченной выборке и реализацию режима самообучения. Новизна заключается в объединении: интерфейса формирования структуры детали без использования 3D-моделей; графовой модели с узлами пересечений как отдельными сущностями; GCN-модели для выбора маршрутов; механизма включения пользовательских решений в обучение. Результаты: модель обучалась на 100 графах и достигла точности 78,6%. Динамика loss и ассигасы демонстрирует устойчивую сходимость. Выводы: система позволяет представлять детали в виде графа, автоматически подбирать шаблоны обработки и накапливать опыт технолога. Решение ориентировано на задачи гибкого производства и может использоваться в составе цифровых CAPP-платформ.

Ключевые слова: графовая нейросеть, GCN, интеллектуальная CAPP-система, формализация признаков, машиночитаемая модель, смежная матрица, технологический шаблон, самообучение, цифровизация производства

Для цитирования: Феофанов А.Н., Веселов Э.Э., Колошкينا И.Е. Интеллектуальная система подбора технологических маршрутов на основе графовой нейросети и машиночитаемой модели изделия // Автоматизация и моделирование в проектировании и управлении. 2025. №3 (29). С. 45-53. doi: 10.30987/2658-6436-2025-3-45-53.

Original article

Open Access Article

INTELLIGENT SYSTEM FOR SELECTING TECHNOLOGICAL ROUTES BASED ON A GRAPH NEURAL NETWORK AND MACHINE-READABLE PRODUCT MODEL

Alexander N. Feofanov¹, Eduard E. Veselov^{2✉}, Inna E. Koloshkina³

^{1, 2} Moscow State University of Technology STANKIN, Moscow, Russia

³ The National University of Science and Technology MISIS, Moscow, Russia

¹ feofanov.fan1@yandex.ru, <https://orcid.org/0000-0003-4761-0538>

² Eduuaarrdd@yandex.ru, <https://orcid.org/0009-0007-8900-5535>

³ inna.koloshkina@yandex.ru, <https://orcid.org/0000-0001-9767-9555>

Abstract. The aim of the study is to develop an intelligent system for automating the selection of technological routes based on a graph neural network and an interface for encoding part features. The objective of the article is to present a method for formalizing the product structure in a machine-readable format and to develop a GCN model ca-

pable of classifying parts by structure and selecting a technological template. The research methods include manual input of features through an interface, constructing a directed graph, encoding parameters in one-hot format, training the neural network on a labelled dataset, and implementing a self-learning mode. The novelty lies in combining an interface for forming the part structure without using 3D models; a graph model with intersection nodes as separate entities; a GCN model for selecting routes; and a mechanism for incorporating user decisions into the learning process. The results show that the model is trained on 100 graphs and achieves an accuracy of 78.6%. The dynamics of loss and accuracy demonstrates stable convergence. Findings state that the system allows representing parts as a graph, automatically selecting processing templates, and accumulating technologist experience. The solution is oriented towards flexible production tasks and can be used as part of digital CAPP platforms.

Keywords: graph neural network, GCN, intelligent CAPP system, feature formalization, machine-readable model, adjacency matrix, technological template, self-learning, production digitalization

For citation: Feofanov A.N., Veselov E.E., Koloshkina I.E. Intelligent System for Selecting Technological Routes Based on a Graph Neural Network and Machine-Readable Product Model. Automation and modeling in design and management, 2025, no. 3 (29). pp. 45-53. doi: 10.30987/2658-6436-2025-3-45-53.

Введение

Цифровизация производственной среды и развитие концепции *Industry 4.0* предъявляют новые требования к системе технологической подготовки производства (ТПП). Повышение вариативности изделий, индивидуализация заказов, сокращение жизненного цикла продукции – всё это требует от предприятий гибкости, скорости принятия решений и точности исполнения. Особенно остро стоит задача автоматизации проектирования технологических процессов для деталей, выпускаемых малыми партиями и с высокой повторяемостью, таких как базовые элементы штампов и пресс-форм.

Традиционные системы автоматизированного проектирования технологических процессов (CAPP) часто основываются на эвристических правилах и требуют значительного участия экспертов, что ограничивает их адаптивность и эффективность в условиях высокоизменчивого производства. В связи с этим возрастает интерес к интеллектуальным методам, способным анализировать структуру изделия и учитывать скрытые взаимосвязи между признаками без участия эксперта [1]. Одним из таких перспективных направлений являются графовые нейронные сети (GNN) [2].

Недавние исследования демонстрируют потенциал использования графовых нейронных сетей (GNN) для анализа структурной информации о деталях и автоматического выбора подходящих технологических маршрутов. Например, архитектура *MaProNet* использует графовое представление моделей и информацию о производственных характеристиках для прогнозирования процессов изготовления. [3]

Однако большинство существующих решений сосредоточены на анализе сложных 3D-моделей и требуют значительных вычислительных ресурсов, что затрудняет их применение в условиях малых и средних предприятий. Также их применение в промышленности осложняется необходимостью большого объёма обучающих данных [2].

В данной работе рассматривается подход, ориентированный на автоматизацию выбора типовых технологических маршрутов для плоских деталей – как наиболее распространённого и формализуемого класса изделий в ТПП. Для решения этой задачи в работе предложено двухкомпонентное решение:

1) интерфейс ручной кодировки признаков конструкции детали с формированием ориентированного графа, где узлы – это конструктивные элементы и их свойства (тип, точность, шероховатость и т.д.), а рёбра – взаимосвязи между ними;

2) графовая нейросеть (*Graph Neural Network, GNN*), обученная на выборке графов, способная по входной структуре подобрать наиболее близкий технологический шаблон из библиотеки типовых решений.

Такой подход позволяет: сократить время на разработку технологических процессов за счёт повторного использования существующих шаблонов; обеспечить воспроизводимость и масштабируемость решений; повысить точность выбора маршрутов обработки за счёт анализа структурной информации о детали [4].

Представленное решение обеспечивает формализованную связку между инженерным описанием детали и цифровым прототипом технологического процесса, облегчая интеграцию в системы цифровых двойников и повышая точность проектирования.

Формализация признаков и построение графа

Формализация информации о конструкции изделия является критическим этапом для последующего использования интеллектуальных алгоритмов, в частности графовых нейронных сетей. В рамках данной работы разработан и реализован специализированный интерфейс для ручного ввода структурных признаков детали, с автоматическим построением ориентированного графа и формированием машиночитаемой модели в виде матрицы смежности.

Назначение и область применения интерфейса. Интерфейс ориентирован на детали плоскостного типа, характерные для базовых элементов штампов и пресс-форм. Эти изделия обладают рядом особенностей, способствующих эффективной формализации:

- ограниченное множество конструктивных элементов;
- чётко выраженные связи между элементами (пересечения, группировки);
- высокая повторяемость в промышленных партиях;
- производимы на универсальных станках с ЧПУ, что делает их удобными объектами для цифровизации.

Выбор именно этой категории обусловлен возможностью отработки структуры признаков и графовой модели на относительно простых, но индустриально значимых объектах.

Структура графовой модели и кодировка признаков. Графовая модель изделия формируется на основе набора формализованных признаков, характеризующих как геометрию, так и технологические параметры конструктивных элементов. Каждый элемент вносится пользователем в интерфейс и представляет собой узел графа, а логические или технологические связи между элементами задаются в виде ориентированных рёбер.

Таблица 1

Коды и содержание признаков для идентификации конструкции изделия по конфигурации и параметрам качества

Table 1

Codes and content of features for identifying the product design by configuration and quality parameters

Код признака	Содержание признака
1	Плоскость
2	Отверстие
3	Карман
4	Стенка
5	Уступ
6	Фаска
7	Скругление
8	IT9...IT11
9	IT6...IT8
10	Ra 3,2...Ra 6,3
11	Ra 0,4...Ra 1,6
12-8202	Код, описывающий пересечение конструктивного элемента с другими конструктивными элементами
1-14	Количество идентичных конструктивных элементов не более 14

Для последующей подачи в графовую нейросеть каждый признак преобразуется в вектор *one-hot* кодировки. Итоговый вектор признаков для каждого узла включает по одному активному биту из каждой группы категорий.

Таким образом, каждый узел графа описывается в виде бинарного вектора фиксированной длины. Связи между узлами задаются через направленные рёбра в матрице смежности. Такой тип графа отражает предполагаемую последовательность обработки и допускает формализацию маршрута через ориентированную структуру, что также реализуется в ряде дру-

гих подходов к описанию технологических процессов [5].

На рис. 1 представлен пример ориентированного графа, формируемого по данным двух конструктивных элементов на основе заданных признаков

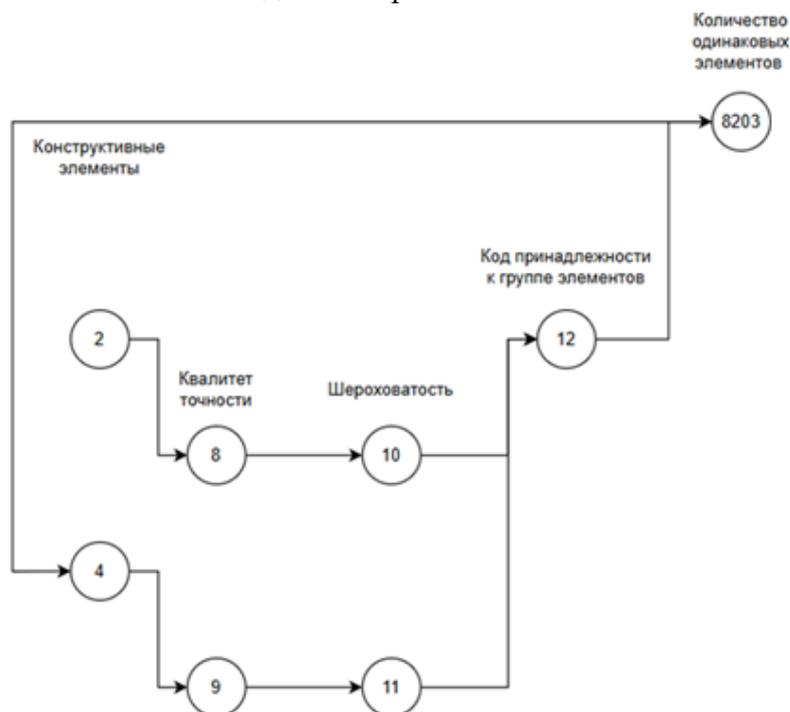


Рис. 1. Пример ориентированного графа, формируемого по данным двух конструктивных элементов на основе заданных признаков

Fig. 1. An example of a directed graph formed from data of two structural elements based on specified features

Этапы работы в интерфейсе. Интерфейс реализован в виде *Windows*-приложения на языке C++. Его архитектура основана на пошаговой логике.

1. Анализ изделия и задание числа конструктивных элементов. Пользователь указывает количество уникальных элементов, участвующих в обработке (рис. 2).

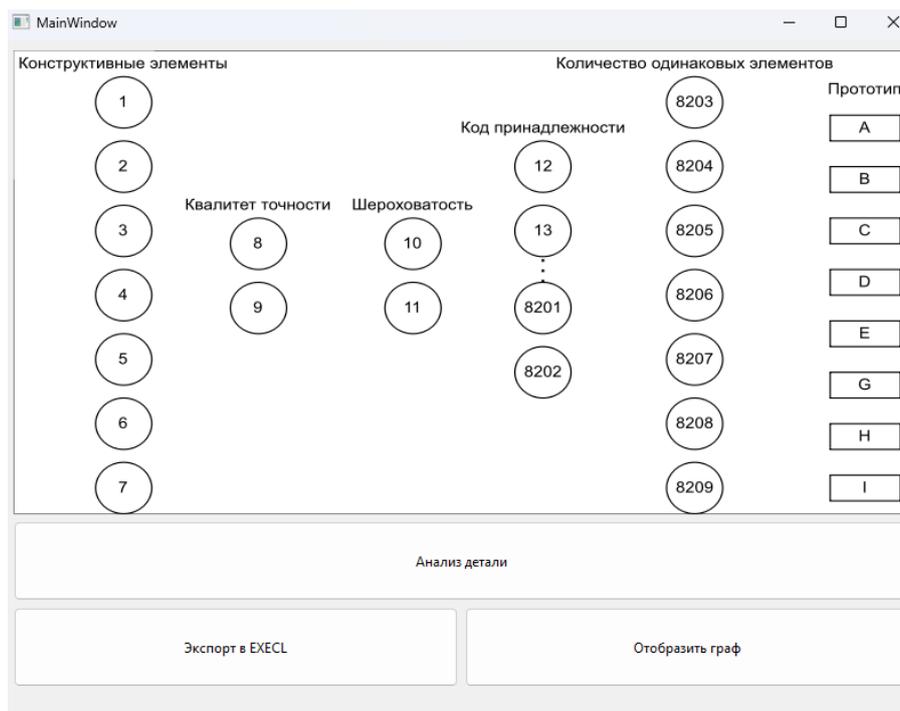


Рис. 2. Главное окно программы

Fig. 2. The main program window

2. Заполнение таблицы конфигурации (рис. 3).

	Конструктивный элемент	Квалитет точности	Параметры шероховатости	Код принадлежности элемента
1	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
2	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
3	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
4	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
5	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
6	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
7	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
8	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
9	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
10	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
11	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
12	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
13	Плоскость	IT9-IT11	Ra3.2-Ra6.3	
14	Плоскость	IT9-IT11	Ra3.2-Ra6.3	

Рис. 3. Окно с таблицей для анализа детали
Fig. 3. Window with a table for analyzing a part

Для каждого элемента задаются: тип (плоскость, отверстие, карман и др.); квалитет точности (например, IT6...IT8); параметры шероховатости (например, Ra 0,4...1,6); количество одинаковых элементов (кратность).

3. Задание связей между элементами. На следующем шаге формируется бинарная матрица (0/1), отражающая логические или технологические связи между элементами: вложенность, контакт, пересечение и т.д. (рис. 4).

	Плоскость 1	Плоскость 2	Плоскость 3	Плоскость 4	Плоскость 5	Плоскость 6	Плоскость 7	Плоскость 8	Плоскость 9	Плоскость 10	Плоскость 11	Плоскость 12	Плоскость 13	Плоскость 14
Плоскость 1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Плоскость 2	1	0	0	0	0	0	0	0	0	0	0	0	0	0
Плоскость 3	1	1	0	0	0	0	0	0	0	0	0	0	0	0
Плоскость 4	1	1	1	0	0	0	0	0	0	0	0	0	0	0
Плоскость 5	1	1	1	1	0	0	0	0	0	0	0	0	0	0
Плоскость 6	1	1	1	1	1	0	0	0	0	0	0	0	0	0
Плоскость 7	1	1	1	1	1	1	0	0	0	0	0	0	0	0
Плоскость 8	1	1	1	1	1	1	1	0	0	0	0	0	0	0
Плоскость 9	1	1	1	1	1	1	1	1	0	0	0	0	0	0
Плоскость 10	1	1	1	1	1	1	1	1	1	0	0	0	0	0
Плоскость 11	1	1	1	1	1	1	1	1	1	1	0	0	0	0
Плоскость 12	1	1	1	1	1	1	1	1	1	1	1	0	0	0
Плоскость 13	1	1	1	1	1	1	1	1	1	1	1	1	0	0
Плоскость 14	1	1	1	1	1	1	1	1	1	1	1	1	1	0

Рис. 4. Окно с таблицей для генерации кодов принадлежности элементов детали
Fig. 4. Window with a table for generating codes for the belonging of the elements of the part

4. Визуализация графа. Построенный ориентированный граф отображается на экране, позволяя пользователю визуально проверить корректность структуры и логики связей (рис. 5).

5. Экспорт в машиночитаемом виде. Программа сохраняет: матрицу смежности в формате *Excel*.

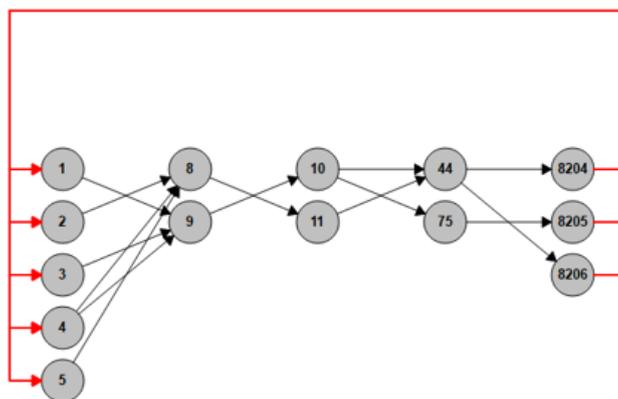


Рис. 5. Пример графа, сгенерированного программой
 Fig. 5. Example of a graph generated by the program

Архитектура графовой нейросети

Выбор графовой нейросети (*GNN*) в качестве основы для автоматизированного подбора технологических шаблонов обусловлен особенностями представления информации о детали. Структура изделия в разработанном интерфейсе формализуется в виде ориентированного графа, узлы которого отражают конструктивные элементы и их параметры (тип, шероховатость, точность и др.), а рёбра – логические или технологические связи между ними. В таком виде данные не поддаются обработке классическими полносвязными или сверточными нейронными сетями, так как они не учитывают топологию и локальные взаимосвязи между элементами. *GNN*, напротив, позволяет агрегировать информацию с учетом структуры графа, что делает её применимой к задачам анализа и классификации структурных объектов, таких как детали [6], а также к оптимизации проектирования маршрутных технологических процессов [7]. Совмещение графовой модели с нейросетевыми подходами успешно применяется и в других задачах технологического анализа [8].

Для реализации модели выбрана архитектура типа *GCN* (*Graph Convolutional Network*), как одна из наиболее интерпретируемых и устойчивых к переобучению. В отличие от более сложных моделей, таких как *GAT* или *GraphSAGE*, *GCN* агрегирует информацию о соседях каждого узла через нормализованную свёртку, что позволяет учитывать как локальные признаки, так и глобальную структуру графа при сравнительно малой вычислительной нагрузке. Это особенно важно в условиях, где размер графа невелик, а объём размеченной обучающей выборки ограничен.

Формат входных данных и предобработка. На вход модели подаётся файл в формате *Excel*, содержащий матрицу смежности, полученную из интерфейса ручной кодировки признаков. Каждая строка и столбец этой матрицы соответствует конструктивному элементу, а значение 1 в ячейке указывает на наличие направленной связи между соответствующими элементами.

После загрузки в нейросетевую систему *Excel*-файл проходит этап предобработки:

- сначала с помощью библиотеки *pandas* загружается матрица и преобразуется в графовую структуру с использованием *networkx*;
- для каждого узла формируется вектор признаков, включающий категориальные характеристики, такие как тип элемента, качество, шероховатость и др.;
- эти признаки автоматически кодируются в *one-hot* представление прямо в программе, на этапе подготовки данных к обучению. В результате каждый узел получает бинарный вектор фиксированной длины, пригодный для подачи в *GNN*.

В разработанной модели конструктивные признаки детали кодируются в вершинах графа. Однако, в отличие от традиционных подходов, где рёбра описывают взаимные связи между элементами напрямую, в данной системе применяется введение вершин-конфигураций пересечений. Это позволяет представить каждое пересечение как отдельную логическую сущность, связанную, например, с параметром шероховатости, что повышает выразительную мощность графа при последующей обработке в нейросети.

Архитектура модели. Архитектура реализованной *GCN*-модели включает три последо-

вательных слоя:

– первый слой принимает *one-hot* вектора признаков узлов и преобразует их в скрытое представление фиксированной размерности;

– второй слой выполняет агрегацию признаков от соседей по графу, формируя контекстуализированное описание каждого конструктивного элемента с учётом его окружения;

– третий слой агрегирует информацию по всему графу (глобальный *pooling*) и передаёт результат в классификатор, определяющий наиболее подходящий технологический шаблон.

В качестве функции активации применяется *ReLU*, между слоями используется механизм *Dropout*, а итоговое представление графа усредняется с помощью *Global Mean Pooling*. Это позволяет корректно работать с графами переменного размера и избежать переобучения.

Обучение и стек технологий. Модель обучается в режиме супервизии: каждому графу соответствует метка класса, отражающая шаблон технологического процесса. После подбора шаблона технолог может вручную внести корректировки. Если откорректированное решение признаётся удачным, граф и новая метка добавляются в обучающую выборку. Таким образом реализуется механизм постепенного самообучения, при котором база шаблонов расширяется за счёт накопления пользовательского опыта.

Реализация нейросети выполнена на стеке открытого программного обеспечения: *Python 3.10* – язык реализации; *PyTorch* – базовый фреймворк нейросетевого обучения; *PyTorch Geometric* – расширение для работы с графами; *NetworkX* – построение графов из матриц; *Pandas / NumPy* – обработка табличных данных из *Excel*.

Выбор именно этого стека обусловлен его открытостью, поддержкой со стороны научного сообщества, а также широкими возможностями для интеграции с другими системами автоматизированного проектирования.

Результаты

Разработанная система продемонстрировала эффективность применения графовой нейросети для задач автоматизации выбора технологических шаблонов на этапе технологической подготовки производства. В процессе обучения на выборке из 100 графов, охватывающих 10 различных классов маршрутов, модель достигла точности классификации 78,6 %, что подтверждается данными матрицы ошибок (рис. 6).

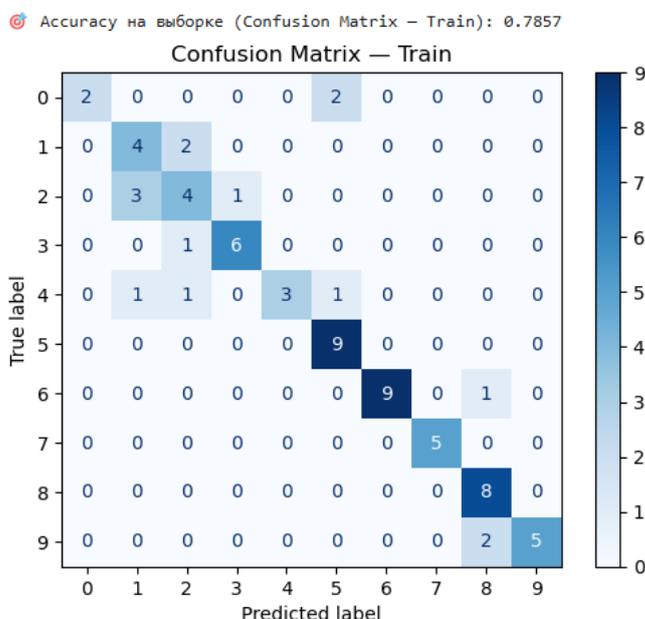


Рис. 6. Матрица ошибок на обучающей выборке
Fig. 6. Error matrix on the training sample

Рост точности и снижение функции потерь в течение 1000 эпох обучения (рис. 7) свидетельствуют о стабильной сходимости модели, несмотря на ограниченный объём обучающих данных. Это подчёркивает способность предложенной архитектуры эффективно выявлять закономерности в структурной информации, закодированной в виде ориентированных графов.

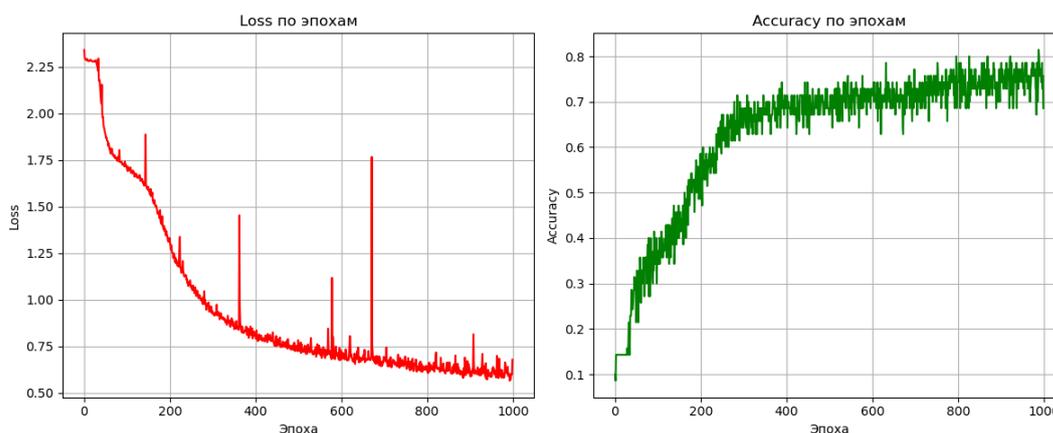


Рис. 7. Графики изменения функции потерь (*Loss*) и точности (*Accuracy*) по эпохам обучения
Fig. 7. Graphs of the change in the loss function (*Loss*) and accuracy (*Accuracy*) by training epochs

Заключение

Научный вклад данной работы заключается в объединении графовой модели изделия и графовой нейросети (*GCN*). Ключевые элементы новизны:

- формализация признаков детали в машиночитаемом виде без необходимости использования *3D*-моделей – позволяет преобразовать инженерную информацию о конструкции в структуру, пригодную для анализа и применения не только в задачах классификации, но и в других интеллектуальных подсистемах;
- введение узлов пересечений в структуру графа, отражающих топологические отношения между элементами, а не только параметры самих элементов, что расширяет выразительную мощность модели;
- автоматизированный интерфейс подготовки входных данных с визуализацией и экспортом в машиночитаемом виде (*Excel* и *one-hot* кодировка);
- механизм самообучения, в рамках которого пользовательские корректировки технолога включаются в базу для последующего переобучения модели;
- доказанная применимость *GCN* к структурированным графам с небольшим числом обучающих примеров, что актуально для задач *CAPP* в условиях малых и средних предприятий [9].

Предложенная система позволяет: сократить время на проектирование маршрутов; повысить воспроизводимость технологических решений; обеспечить накапливаемость и переиспользуемость знаний в машиночитаемом виде; интегрироваться с *CAM*-средами и цифровыми двойниками за счёт стандартизированного вывода (формат *Excel*) [10].

В дальнейшем планируется: тестирование на обобщающей выборке и в условиях реальных производств; масштабирование подхода на другие типы изделий; переход от ручного ввода признаков к автоматизированному извлечению информации из *3D*-моделей с последующим преобразованием геометрических и технологических характеристик изделия в машиночитаемое графовое представление (матрицу смежности); расширение интерфейса для автоматического генеративного проектирования на основе предсказанного шаблона.

Таким образом, разработанная методика, реализованный интерфейс формализации признаков и архитектура *GNN* совместно образуют надёжную основу для построения адаптивных и интерпретируемых интеллектуальных *CAPP*-систем. Система обеспечивает преобразование инженерных данных в машиночитаемый вид и их дальнейшее использование в задачах классификации, планирования и цифровизации технологических процессов в условиях гибкого производства.

Список источников:

1. Zhang C., Wang Y., Liu J. Framework for formalizing expert knowledge in manufacturing process planning // *Procedia CIRP*. – 2021. – Vol. 104. – P. 1614-1619.
2. Song H., Sun Y., Wang Z., Han Q. Graph Neural Networks in Manufacturing: A Review // *Journal of Manufacturing Systems*. – 2025. – Vol. 66. – P. 389-401.

References:

1. Zhang C., Wang Y., Liu J. Framework for Formalizing Expert Knowledge in Manufacturing Process Planning. *Procedia CIRP*. 2021;104:1614-1619.
2. Song H., Sun Y., Wang Z., Han Q. Graph Neural Networks in Manufacturing: A Review. *Journal of Manufacturing Systems*. 2025;66:389-401.

3. Hu K., Zhang X., Sun Y. MaProNet: A Manufacturing Process Route Prediction Network Based on Graph Representation of CAD Models // Computers in Industry. – 2022. – Vol. 137. – P. 103608.

4. Кулагин А.К., Фефанов А.Н. Повышение качества функционирования системы технической поддержки // Технология машиностроения. – 2023. – № 8. – С. 17-20.

5. Мелихов С. А., Нестеренко А. В. Оптимизация структуры наукоёмких технологических процессов с использованием графовых моделей // Информационные технологии и автоматизация. – 2023. – № 3.

6. Ильин А. С., Шапошников С. Д. Применение теории графов и нейросетевых методов в задачах технологического анализа // Инженерный вестник Дона. – 2020. – № 2.

7. Гришин Ю. В., Бондаренко А. В. Оптимизация системы планирования технологических процессов в механообрабатывающем производстве // Известия Тульского государственного университета. Технические науки. – 2021. – № 3.

8. Tao F., Sui F., Liu A., Qi Q. Digital twin-driven smart manufacturing: Connotation, reference model, applications and research issues // Journal of Manufacturing Systems. – 2020. – Vol. 64. – P. 426-439.

9. Wang Y., Zhang T., Li M. Application of GNNs in industrial process analysis and control // Journal of Manufacturing Systems. – 2024. – Vol. 65. – P. 312–321.

10. Третьякова А. В., Воронов А. П. Метод оптимизации проектирования маршрутных технологических процессов // Вестник Воронежского государственного университета инженерных технологий. – 2022. – № 1.

Библиографический список:

1. Колошклина И.Е. Методика автоматизированной разработки технологической документации в системе CAD/CAM/CAPP // Автоматизация в промышленности. – 2019. – №9. – С. 32-34.

Информация об авторах:

Фефанов Александр Николаевич

доктор технических наук, профессор МГТУ СТАНКИН, ORCID 0000-0003-4761-0538

Веселов Эдуард Эдуардович

аспирант МГТУ СТАНКИН, ORCID 0009-0007-8900-5535

Колошклина Инна Евгеньевна

кандидат технических наук, доцент НИТУ МИСИС, ORCID 0000-0001-9767-9555

3. Hu K., Zhang X., Sun Y. MaProNet: A Manufacturing Process Route Prediction Network Based on Graph Representation of CAD Models. Computers in Industry. 2022;137:103608.

4. Kulagin A.K., Feofanov A.N. Improving the Quality of Functioning Technical Support System. Technology of Mechanical Engineering. 2023;(8):17-20.

5. Melikhov S.A., Nesterenko A.V. Optimizing the Structure of High-Tech Technological Processes Using Graph Models. Informatics and Automation. 2023;(3).

6. Ilin A.S., Shaposhnikov S.D. Application of Graph Theory and Neural Network Methods in Technological Analysis Tasks. Engineering Journal of Don. 2020;(2).

7. Grishin Y.V., Bondarenko A.V. Optimizing the Planning System of Technological Process in Mechanical Engineering Production. Izvestiya Tula State University. Technical Sciences. 2021;(3).

8. Tao F., Sui F., Liu A., Qi Q. Digital Twin-Driven Smart Manufacturing: Connotation, Reference Model, Applications and Research Issues. Journal of Manufacturing Systems. 2020;64:426-439.

9. Wang Y., Zhang T., Li M. Application of GNNs in Industrial Process Analysis and Control. Journal of Manufacturing Systems. 2024;65:312-321.

10. Tretyakova A.V., Voronov A.P. Method of Optimizing Design of Route Technological Processes. Proceedings of the Voronezh State University of Engineering Technologies. 2022;1.

Bibliographic list:

1. Koloshkina I.E. Methodology of Automated Development of Technological Documentation in CAD/CAM/CAPP System. Automation in Industry. 2019;9:32-34.

Information about the authors:

Feofanov Alexander Nikolaevich

Doctor of Technical Sciences, Professor of Moscow State University of Technology STANKIN, ORCID: 0000-0003-4761-0538

Veselov Eduard Eduardovich

Postgraduate student of Moscow State University of Technology STANKIN, ORCID: 0009-0007-8900-5535

Koloshkina Inna Evgenievna

Candidate of Technical Sciences, Associate Professor of the National University of Science and Technology MISIS, ORCID: 0000-0001-9767-9555

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации.

Contribution of the authors: the authors contributed equally to this article.

Авторы заявляют об отсутствии конфликта интересов.

The authors declare no conflicts of interests.

Статья поступила в редакцию 27.06.2025; одобрена после рецензирования 18.07.2025; принята к публикации 13.08.2025.

The article was submitted 27.06.2025; approved after reviewing 18.07.2025; accepted for publication 13.08.2025.

Рецензент – Пугачев А.А., доктор технических наук, доцент, Брянский государственный технический университет.

Reviewer – Pugachev A.A., Doctor of Technical Sciences, Associate Professor, Bryansk State Technical University.