

# СОВРЕМЕННЫЕ МЕТОДЫ И СРЕДСТВА РЕШЕНИЯ КОМПЛЕКСНЫХ ЗАДАЧ УПРАВЛЕНИЯ И ПРОИЗВОДСТВА

УДК 621.7/9:681.5

## Повышение качества чистовой обработки металлов при торцевом фрезеровании на станках с ЧПУ с использованием нейросетевой модуляцией режимов резания

Э. Ю. Яковлев

СЗТУ — Северо-Западный технический университет, С.-Петербург, Россия

*В работе решена комплексная задача анализа возможностей оптимизации архитектуры нейронной сети с учетом особенностей производственного процесса и проведено его сравнение с известными методами.*

*Ключевые слова:* качество, обработка металлов, торцевое фрезерование, оптимизация, сеть.

В технологических процессах обработки металлов резанием удельный вес операций фрезерования составляет до 35 % от общего числа операций металлообработки, из которых доля операций торцевого фрезерования составляет 25 %. Таким образом, очевидно, что торцевое фрезерование является одним из первых по применяемости технологическим приемом изготовления точных деталей машин и механизмов, что вызвано достаточно высокой производительностью и исключительной точностью данного вида обработки металлов.

В то же время применение в машиностроении новых конструкционных материалов, повышение уровня автоматизации металлорежущих операций, а также повышенные требования к точности и качеству обработки ставят перед наукой о резании металлов ряд проблем. В частности, большое внимание уделяется математическому описанию влияния условий резания на основные характеристики процесса резания, что необходимо для разработки самонастраивающихся систем и программного управления процессом резания на автоматических станках и линиях [1]. Так, в задаче управления качеством поверхностного слоя деталей машин при обработке резанием актуальным направлением является разработка моделей, адекватно отражающих процесс достижения необходимого уровня шероховатости и позволяющих управлять им.

В настоящее время существует большое число экспериментальных исследований, направленных на анализ влияния параметров инструмента, обо-

рудования и режимов обработки на характеристики процесса фрезерования. Однако вопросы формирования и прогнозирования точности обработанной поверхности при фрезеровании не нашли достаточного отражения [2]. Этот недостаток можно решить только с использованием методов математического моделирования.

Так, общеизвестно, что использование интенсивных режимов резания при черновом и получистовом фрезеровании сдерживается главным образом потерей динамической стабильности технологической системы (ТС). Возникающие автоколебания недопустимо большой амплитуды кроме ограничения производительности резко снижают стойкость инструмента, срок службы оборудования, точность и качество обработанных поверхностей и даже могут приводить к аварийным ситуациям вследствие поломки наименее прочных элементов ТС [3]. В процессе фрезерования неизбежно возникают вынужденные колебания (вибрации), а также автоколебания элементов системы фрезерного станка, которые ухудшают результаты обработки материала. Способами снижения вредных последствий колебаний являются:

- контроль прерывистости процесса резания;
- регулировка дисбаланса вращающихся частей;
- устранение дефектов в передачах станка;
- контроль недостаточной жесткости и деформаций заготовки.

Эффективность фрезерования при устранении вредных автоколебаний, таким образом, может быть повышена путем установления рациональных

режимов резания, учитывающих все вышеперечисленные факторы, вызывающие вибрации.

Подобного эффекта удалось достичь при рассмотрении процесса фрезерования как колебательной системы, в результате чего было определено, что динамическая нестабильность ТС механической обработки на интенсивных режимах резания определяется преимущественно вторичным возбуждением автоколебаний. Управление же вторичными автоколебаниями возможно теми же способами, что и первичными: повышением жесткости ТС, снижением силовой напряженности процесса резания, демпфированием и рядом других. Более эффективным является воздействие на сам механизм регенерации автоколебаний путем искусственного изменения их фазы, которое можно осуществлять подбором неравномерности шага зубьев инструмента или модуляцией скорости резания с использованием встроенного нейросетевого регулятора.

Нейросетевые системы в отличие от классических сами набирают опыт диагностики в результате обучения, основываясь на ассоциациях при обучении характерным примерам из предметной области. Основной задачей при выборе и моделировании архитектуры нейронной сети при этом являются описание значений и параметров выборки, а также генерация этой выборки либо создание адекватной выборки примеров. Это — прямое указание на использование нейросетевого подхода к диагностике и наладке автоматических систем управления производственными процессами.

Для реализации системы достижения заданных качеств чистоты на основе нейронных сетей с использованием аппарата нейронечетких сетей, которые обладают высокой скоростью обучения, простотой алгоритма и оптимальной проработанностью программного обеспечения в системе математического моделирования Statistica Neural Networks [4], необходимо выявить:

взаимосвязь между параметрами качества получаемой поверхности, режимами резания и конструктивно-геометрическими параметрами режущего инструмента;

влияние режимов резания на величину дефектного поверхностного слоя детали.

Подобная задача была решена путем использования многослойных нейронных сетей обратного распространения, ошибка  $E$  в которых минимизируется согласно алгоритму Видроу — Хопфа:

$$E = \frac{1}{N} \sum_{i=1}^N (q_i - P_i)^2,$$

где  $q_i$  — желаемое выходное состояние сигнала сети;

$P_i$  — реальное выходное состояние нейрона выходного слоя.

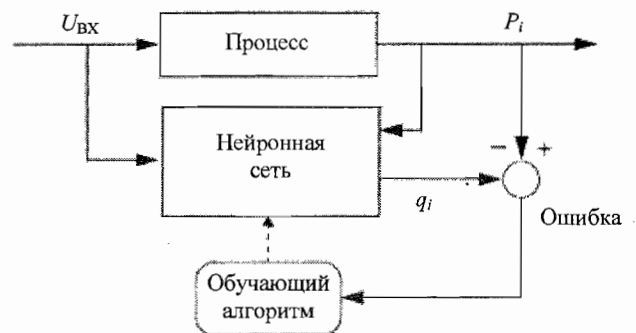
Суммирование ведется по всем нейронам выходного слоя и по всем обрабатываемым сетью образам. Минимизация выполняется методом градиентного спуска:

$$\Delta w_{ij}^{(n)} = -\eta \frac{\partial E}{\partial w_{ij}},$$

где  $w_{ij}$  — весовой коэффициент синаптической связи, соединяющей  $i$ -й нейрон слоя  $n-1$  с  $j$ -м нейроном слоя  $n$ ;

$\eta$  — коэффициент скорости обучения,  $0 < \eta < 1$ .

Первая стадия образцового прогнозирующего управления должна обучить нейронную сеть динамике процесса [5]. Значение ошибки выходного сигнала процесса и выходного параметра нейронной сети используется для обучения сети. Данный процесс схематично отображен на рис. 1.



**Рис. 1. Схематичное представление технологического процесса фрезерования с использованием нейронной сети**

Данная архитектура подразумевает использование модуля ассоциативной памяти, который осуществляет следующие функции:

информационное обеспечение в виде базы данных, позволяющее моделировать процессы формообразования при фрезеровании с помощью управляющего нейросетевого регулятора;

информационное обеспечение в виде базы данных, позволяющее выбирать рациональные технические решения и синтезировать эффективные конструкции специализированных инструментов при проектировании технологических процессов.

Базы данных состоят из таблиц обучающей выборки, составленных в соответствии с матрицей проведенных экспериментов, позволяющей формировать нейросетевые модели, характеризующие процесс торцевого фрезерования, а также таблицы тестирующей выборки, используемых для оценки качества "обучения" нейросетевых моделей для их дальнейшего применения в составе системы автоматизированного проектирования.

Процесс обучения сети осложняется отсутствием баз данных, содержащих информацию о входных и выходных характеристиках процесса форм-

мообразования при механической обработке резанием. Построение нейросетевой модели требует наличия набора готовых примеров, описывающих входные и выходные параметры исследуемого процесса. Поэтому процесс обучения для нейронных сетей обратного распространения при решении задач достижения требуемых качеств чистоты при торцевом фрезеровании состоит из четырех этапов:

- 1) сбор данных для обучения;
- 2) создание объекта сети;
- 3) обучение сети;
- 4) симуляция реакций сети на ранее неподаваемые входные сигналы.

Используемая для диагностики автоколебаний технологического процесса резания линейная нейронная сеть представляется сетью без скрытых слоев в выходном слое, она содержит только элементы с линейной функцией активации. Веса соответствуют элементам матрицы, а пороги — компонентам вектора смещения. Во время работы сеть умножает векторы входов на матрицу весов, к полученному вектору прибавляет вектор смещения. Если модель сети записывается в матричном виде, то динамическая линейная модель анализа и диагностики технологической системы может быть представлена уравнением:

$$Y = f(W_p + b),$$

где  $Y$  — выходной сигнал сети  $f(x)$  — активизирующая функция сети;

$W_p$  — суммарный вес  $p$  входных сигналов сети;  
 $b$  — пороговое значение.

Подобрать сразу такую структуру сети, которая может решить задачу, невозможно. Поэтому подбор структуры нейронной сети, способной решить поставленную задачу, происходит перебором различных наборов архитектур в соответствии с процессом моделирования обработки деталей с помощью нейросетевых технологий. В связи с этим при решении задач идентификации параметров, диагностики и прогнозирования технического состояния вибрирующих (динамических) объектов необходима измерительная информация о входе (возмущении) и выходе (реакции). Это вызвано тем, что "в ряде случаев довольно сложно или практически невозможно контролировать возмущения" [6].

Известно, что процесс фрезерования описывается математически следующей совокупностью входных элементов: скорость резания  $v$ , глубина резания  $t$  и подача  $s$ . В результате превращения механической энергии, расходуемой при обработке, в тепловую возникают тепловые источники, влияющие на стойкость режущего инструмента и качество поверхностного слоя обработанной детали. Поэтому для построения нейросетевой модели

ТС обработки деталей на фрезерных станках с ЧПУ были определены входные параметры процесса механической обработки заготовок из материалов различного вида: режимы резания ( $v, t, s$ ), геометрия ( $\alpha, \gamma, \phi, \phi_1$ ).

Следуя предложенной методике моделирования процессов, для обеспечения оптимальных режимов резания детали были опробованы семь нейросетевых моделей. Выбранная схема построения наиболее оптимальной нейросетевой модели для ТС обработки деталей из различных материалов с учетом условий заданных параметров качества поверхности обрабатываемых деталей приведена на рис. 2. На основании вышеизложенного имитационную модель динамики процесса торцевого фрезерования можно представить в виде трех моделей: упругой системы станка, инструмента и процесса резания (рис. 3).




Рис. 2. Пример нейросетевой модели для определения режимов резания




Рис. 3. Схема технологического процесса многолезвийного торцевого фрезерования

Модель каждого объекта динамической системы включает в себя описание входных и выходных параметров, а также связывающие их основные зависимости. Для решения рассмотренных задач, связанных с регулированием вибраций, была использована нейронная сеть прямого распространения с линейной активационной функцией, которая позволяет формировать графики изменения во времени составляющих силы резания и вибропе-

ремонтов фрезы в обеих системах координат, а также крутящего и изгибающего моментов во вращающейся системе координат  $O_1x_1y_1z_1$ .

Для построения нейросетевых моделей процесса фрезерования заготовок из различных материалов в работе была использована программа Statistica Neural Networks, предлагающая к использованию сети многослойной слоистой архитектуры. В программе были реализованы градиентные методы обучения сети. Весовые коэффициенты адаптивных связей при создании нейросетевой модели принимают случайные значения и при обучении могут изменяться в диапазоне  $[-1, +1]$ .

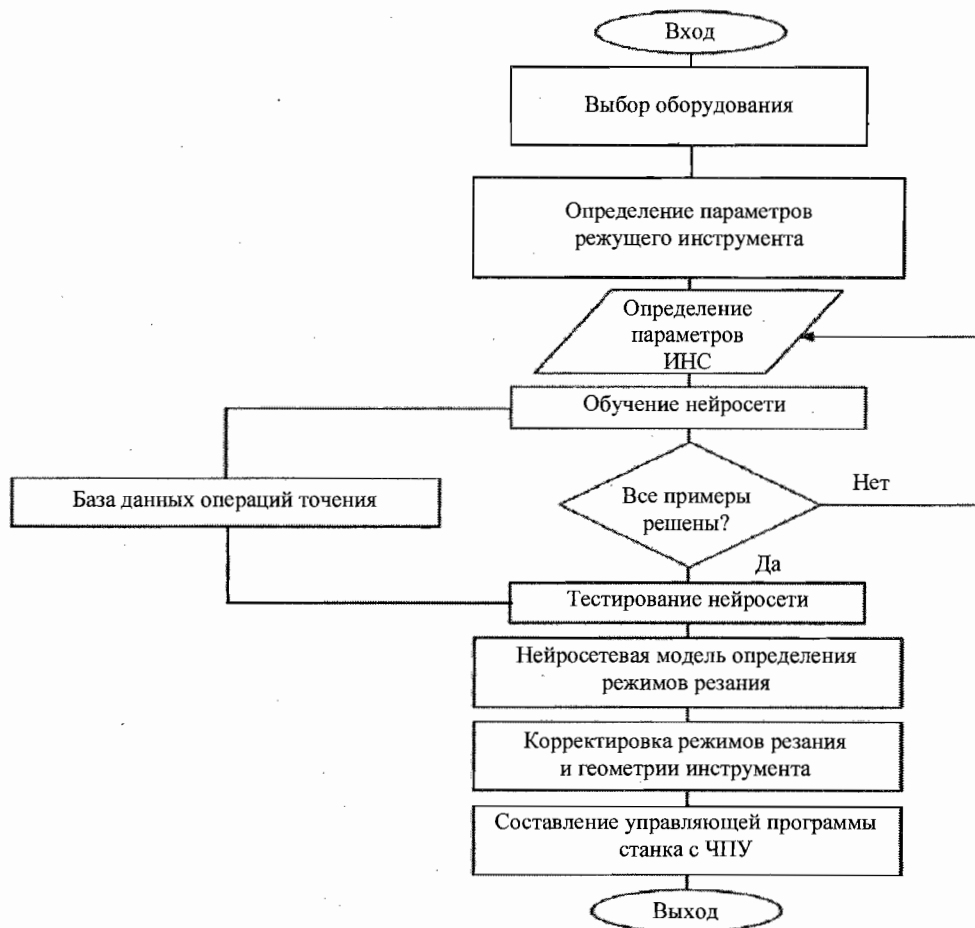
Данная нейронная сеть позволяет назначить рациональные режимы обработки в зависимости от требуемого показателя качества чистоты обработанной поверхности. Автоматизация процесса проектирования технологической операции торцевого фрезерования на основе нейросетевого регулятора производится согласно алгоритму, приведенному на рис. 4.

дискретные кинематические перемещения [7]. Имитация сопровождается накоплением в отдельных файлах данных об изменении составляющих силы и момента резания, кинематических и динамических параметров движения элементов упругой системы, а также данных о геометрии обработанной поверхности.

Исследуемая модель была развита как обучаемая сеть обратного распространения с четырьмя слоями (входной, нормализованный, слой Кохонена и выходной).

Путем комбинации слоя Кохонена и правил обучения Видроу – Хопфа получается новый тип нейронной сети, который позволяет очертить преобразование входных сигналов в выходные путем комбинирования обучения с учителем и без учителя, ограничивая, таким образом, время обучения сети тем временем, которое в общем случае требуется для обучения сети обратного распространения.

Каждый слой сети полносвязный по отношению к предшествующему. Входной слой формируется



**Рис. 4. Алгоритм проектирования операций торцевого фрезерования на основе нейросетевых моделей**

В процессе имитационного моделирования процесса торцевого фрезерования происходят дискретные изменения модельного времени, в течение которого исполнительные органы станка получают

из элементов, которые функционально полно описывают характеристики выбранного производственного процесса в ходе его анализа. Выбранные характеристики записываются в два файла, которые в

дальнейшем используются при обучении нейронной сети: тестовый файл, составленный на основании определения характеристик производственного процесса — технологическая карта, и тренировочный файл, составленный на основе входных переменных и желаемых выходных значений, которые представляют собой ничто иное, как параметры, определяемые в результате исследований. Тренировочное множество представляет собой наборы входных и желаемых значений, используемых при обучении с учителем. Каждая пара при этом считается фактором. Таким образом, вся информация, которая используется при обучении сети, располагается в тренировочном файле, в который заносятся ассоциированные факторы. Программная реализация при этом необходима для преобразования данных в формат, приемлемый для анализа данных нейросетевой моделью. В рассматриваемом примере тренировочный файл содержит 10 столбцов (первые пять содержат значения входных переменных, а остальные — выходные значения, ассоциированные с ними) и столько строк, сколько характеристик производственного процесса было выбрано (в рассматриваемом примере их семь).

В качестве тестовой была выбрана следующая последовательность значений и характеристик:

0.15	0.05	0.25	0.35	0.20	0.20	0.25	0.10	0.15	0.40
0.05	0.00	0.25	0.35	0.25	0.25	0.30	0.05	0.10	0.40
0.05	0.05	0.25	0.35	0.25	0.20	0.30	0.05	0.10	0.40
0.20	0.30	0.25	0.35	0.25	0.25	0.30	0.05	0.10	0.40
0.00	0.00	0.10	0.20	0.55	0.25	0.10	0.05	0.15	0.45
0.05	0.00	0.25	0.35	0.25	0.25	0.30	0.05	0.10	0.40
0.35	0.05	0.25	0.35	0.25	0.25	0.30	0.05	0.10	0.40

Каждая колонка описывает один набор характеристик, используемых для обучения сети. Подобные правила устанавливаются в результате апробирования результатов для каждой группы и включенных в тренировочный файл, который используется для обучения с учителем, позволяющем нейронной сети обновлять и оптимизировать веса для автоматизации системы управления производственными процессами.

В рассматриваемом примере количество нейронов в слое Кохонена равно семи и, соответственно, равно количеству правил, установленных для нейронной сети. Количество желаемых выходов было установлено в результате реакций каждой группы. Файл при этом формируется из комбинаций переменных, которые были использованы в качестве тренировочного файла, и реакций на них. Файл содержит около 30 000 записей для каждой из групп. Базовым правилом при этом является соответствие количества устойчивых сочетаний в слое Кохонена количеству нейронов в слое [8]. В связи со сложностью подобного определения количество нейронов в слое Кохонена было установлено равным 450 в соответствии с теоретически максималь-

но возможным для данной модели. Подобное построение требует протоколирования ошибок, которые выражаются в недостаточном обучении ряда нейронов в слое, и отличия выходных значений от желаемых, и неизбежно возникают, когда количество параметров больше, чем количество нейронов в слое Кохонена. Решением данной проблемы является оптимизация тренировочного файла к некоторому значению, которое позволяет проводить обучение нейросети с минимальным количеством ошибок. Подобную оптимизацию возможно провести с использованием второй нейронной сети, аналогичной вышерассмотренной, но при обучении которой используются оценочные значения. Это позволяет устранить ошибочно обученные наборы при внесении результатов в базу данных [9].

Для проверки эффективности работы сети и ее возможностей в процессе обучения по образцам были построены и протестированы по приведенной выше последовательности разнообразные нейросетевые архитектуры, каждая из которых была сконструирована путем соотношения времени на обучение для достижения наибольшей эффективности нейронной сети при обработке приложений. При тестировании были использованы сети обратного распространения и сети Кохонена. Для оценки производительности сети была вычислена общая ошибка (разница входного и желаемого выходного значений при трансформации функции ошибки в каждом слое, умноженная на фактор ошибки тестируемого элемента) для всех эпох обучения по каждой архитектуре. В результате тестирования на 520 примерах (приблизительно 12 % от общего объема базы данных) было выявлено, что время реакции и обучения при проведении тестирования на архитектуре с сетями Кохонена и использованием 4-слоевой модели было в 2 раза меньше, чем при тестировании других моделей. Значение ошибки сети было вычислено для каждого обучаемого элемента и среднее для каждого этапа по формуле

$$E_p = 1 / 2(O_{pj} - y_{pj}),$$

где  $O_{pj}$  — ошибка между желаемым выходным значением  $j$ -го нейрона и актуальным выходным значением  $y_{pj}$  сети для  $p$ -го набора.

Результаты наглядно продемонстрировали превосходство сети Кохонена с обратным распространением по сравнению с другими сетями обратного распространения уже после обучения 50 эпох, что позволило с точки зрения оптимальности остановиться на выборе данной архитектуры.

Таким образом, в работе решена комплексная задача анализа возможностей оптимизации архитектуры нейронной сети с учетом особенностей

производственного процесса и проведено его сравнение с известными методами. В ходе проведения диагностики технологических процессов было определено, что возможности сетей обратного распространения при генерализации параметров и поступающих данных, не включенных в тренинговые наборы, определяются выбором входных параметров процесса и количеством нейронов в слое Кохонена в целях переназначения или ассоциации этих параметров и установления устойчивых зависимостей, обеспечивающих адекватную настройку процессов.

#### Литература

1. Абдуллаев М. И., Абдуллаев С. А., Козлов К. Ю. Гибридная информационная технология для анализа состояния вибрирующих объектов при неконтролируемых возмущениях // Междунар. науч. конф. "Проблемы кибернетики и информатики" 24–26 октября 2006 г. — Саратов: Изд-во Сар. гос. ун-та, 2006. — 128 с.

2. Некрасов В. Н. Управление качеством деталей путем прогнозирования топографии обработанной поверхности с использованием имитационного моделирования (на примере торцевого фрезерования): Автореф. дис... канд. техн. наук. — Барнаул, 2007. — 19 с.

3. Бобров В. Ф. Основы теории резания металлов. — М.: Машиностроение, 1975. — 344 с.

4. Вейц В. Л., Максаров В. В. Динамика и управление процессом стружкообразования при лезвийной механической обработке. — СПб.: СЗПИ, 2000. — 220 с.

5. Галушкин А. И. Теория нейронных сетей. — М.: Радиотехника, 2000. — 415 с.

6. Круглов В. В., Борисов В. В. Искусственные нейронные сети. Теория и практика. 2-е изд. стереотип. — М.: Горячая линия-Телеком, 2002. — 382 с.

7. Нейронные сети. Statistica Neural Networks: Методология и технология современного анализа данных / Под ред. В. П. Боровикава. 2-е изд., перераб. и доп. — М.: Горячая линия-Телеком, 2004. — 176 с.

8. Свинин В. М. Управление регенеративными автоколебаниями при фрезеровании на основе модуляции скорости резания: Дис... д-ра техн. наук. — Иркутск, 2008. — 38 с.

9. Ritter H., Schulden K. Kohonen's self-organizing maps: exploring their computational capabilities. In Proceedings of the ICNN'88, IEEE International Conference on Neural Networks. 1988. V. I. P. 109–116; IEEE Service Center, Piscataway, NJ. 1988. — 730 с.

## Improvement of quality of fair processing of metals at face milling on machine tools with numerical programmed control with using neironetwork by modulation of modes of cutting

E. U. Yakovlev

NWTU — North Western State Technical University, St.-Petersburg, Russia

*In technological processes of processing of metals by cutting relative density of operations of mil-ling makes to 35 % from total of operations of metal working of which the share of operations of face milling makes 25 %. Face milling, is one of the first on applicability technologically reception of manufacturing of exact details of cars and mechanisms that is caused by enough high efficiency and exclusive. In work the complex problem of the analysis of possibilities of optimization of architecture of a neural network taking into account features of production is solved and its comparison with known methods is spent.*

*Keywords:* quality, processing of metals, face milling, optimization, network.

Яковлев Эдуард Юрьевич, аспирант. Тел. +7 (812) 312-94-84.  
E-mail: fpkr@bk.ru