

УДК 004.852

МЕТОДИКА ПОСТРОЕНИЯ МОДЕЛИ ОПРЕДЕЛЕНИЯ ПАРАМЕТРОВ ТЕХНОЛОГИЧЕСКОГО РЕЖИМА С ИСПОЛЬЗОВАНИЕ МЕТОДА ОПОРНЫХ ВЕКТОРОВ



К.С. Николаев

*Старший преподаватель института
СПИИТех, НИУ МИЭТ
knpreader@gmail.com*

К.С. Николаев

Окончил Московский институт электронной техники. Область научных интересов связана с разработкой интеллектуальных информационных систем.

Аннотация. Предложена методика построения модели определения параметров технологического режима на основе метода опорных векторов (SVR). Методика включает очистку данных, исключение выбросов, стандартизацию признаков и подбор гиперпараметров с использованием кросс-валидации. Для каждого выходного параметра формируется отдельная модель. Результаты подтверждают эффективность подхода при ограниченном объеме данных. Разработанные модели позволяют сократить число экспериментов и решить задачу «холодного старта» при внедрении новых технологических процессов.

Ключевые слова: метод опорных векторов, SVR, машинное обучение, математическое моделирование, технологический режим, подбор гиперпараметров, кросс-валидация, обработка данных, исключение выбросов, холодный старт.

Введение. Технологический режим в контексте лазерной обработки представляет собой набор (вектор) данных из числовых и категориальных значений. Эти значения делятся на группы [1], а именно:

- параметры материала – физические и химические свойства исходного материала обрабатываемого образца (например, теплоемкость);
- исходные параметры образца – физические параметры непосредственно обрабатываемого образца, например, толщина;
- исходные параметры установки – параметры и диапазоны, настроенные разработчиком установки;
- варьируемые параметры установки – значения, которые выставляет технолог для проведения операции (например, частота повторения импульсов, контурная скорость);
- результирующие параметры – параметры, полученные в ходе технологической обработки (например, в случае лазерной резки – ширина и глубина реза).

На рисунке 1 представлен пример организации данных технологических режимов в информационной системе.

Измеряемые					Задаваемые					
Геометрия изделия		Качество изделия		Производительность	Лазер			Кинематическая система машины	Пневмо и газовая система	
Ширина реза <i>мм</i>	Глубина реза <i>мм</i>	Зона загрязнения поверхности <i>мм</i>	Зона термического влияния <i>мм</i>	Время обработки изделия <i>с</i>	Частота повторения импульсов <i>кГц</i>	Длительность импульса <i>нс</i>	Средняя мощность <i>Вт</i>	Контурная скорость <i>мм/мин</i>	Тип защитного газа	Давление защитного газа <i>бар</i>
● Асферическая (16 мм) + ↓										
200		510	100	60	25	0,2	8,2	500,000000 ^h	Воздух ✕	6
190		410	100	60	25	0,4	8,2	500,000000 ^h	Воздух ✕	6
200		215	111	60	25	0,78	8,2	500,000000 ^h	Воздух ✕	6
200	600	189	100	60	25	4,6	8,2	500,000000 ^h	Воздух ✕	6

Рисунок 1. Пример организации данных технологических режимов в информационной системе

Проблемная ситуация обусловлена противоречием между высокой степенью нелинейности и многофакторности физико-химических процессов, протекающих в зоне взаимодействия лазерного излучения с веществом, и ограниченными возможностями эмпирических методов настройки оборудования, используемых инженерно-техническим персоналом [2].

Существующая практика формирования технологического режима базируется преимущественно на накопленном экспертном опыте операторов и итеративном методе «проб и ошибок». Данный подход характеризуется системными ограничениями, среди которых: многомерность пространства параметров (полный перебор комбинаций в ручном режиме является ресурсоемким и экономически нецелесообразным), стохастическая природа процессов (наличие случайных возмущений) и отсутствие универсальных детерминированных моделей (ввиду сложности теплофизических явлений, таких как фазовые переходы, гидродинамика расплава, плазмообразование [3]).

В рамках решения задачи определения параметров технологического режима следует рассмотреть применение искусственных нейронных сетей (ИНС) и методов машинного обучения.

Нейронные сети обладают универсальным свойством приближения: при достаточном числе нейронов они способны аппроксимировать произвольную непрерывную функцию $f: \mathbb{R}^n \rightarrow \mathbb{R}$ с заданной точностью.

Однако практическая реализация данного свойства требует выполнения ключевого условия – наличия репрезентативной обучающей выборки большого объема.

Для задач моделирования технологических режимов характерны следующие особенности:

- малый объем выборки – получение экспериментальных данных связано с проведением реальных испытаний, затратами материалов, времени и производственных ресурсов;
- высокая стоимость эксперимента – каждая точка данных соответствует реальному технологическому прогону, что делает невозможным формирование больших датасетов, типичных для задач компьютерного зрения или обработки текста;
- гетерогенность и неполнота данных – технологические параметры могут иметь пропуски, различную шкалу измерений, а также быть подвержены случайным возмущениям, что требует дополнительной обработки и увеличивает неопределенность модели.

Соответственно, несмотря на высокую гибкость и нелинейность аппроксимации, нейронные сети не являются оптимальным инструментом для решения задачи определения параметров технологического режима при ограниченном объеме экспериментальных данных. В условиях малых выборок более обоснованным представляется использование методов, основанных на принципе структурной минимизации риска, в частности метода опорных векторов (SVM).

Сам по себе SVM обычно используется в задачах классификации [4]. В контексте решаемой задачи, следует использовать расширение SVM – метод опорных векторов для регрессии (SVR). Цель метода – построить функцию $f(x)=\langle w, \phi(x) \rangle + b$, которая отклоняется от истинных значений не более чем на заданную величину и при этом обладает минимальной сложностью.

Разработка методики построения модели определения параметров технологического режима. Разработка универсальной модели определения параметров технологического режима представляет собой сложную научно-техническую задачу вследствие существенной разнородности физических процессов, лежащих в основе различных технологических операций (резка, сварка, абляция и др.).

Каждый из указанных процессов характеризуется собственной физической природой, отличающимися механизмами тепломассопереноса, фазовыми превращениями, динамикой расплава, а также спецификой взаимодействия инструмента или энергетического источника с обрабатываемым материалом. Так, при резке доминируют процессы локального плавления и удаления материала; при сварке – формирование сварочной ванны и кристаллизация; при абляции – интенсивное испарение и плазмообразование. Соответственно, выходные показатели качества (глубина проплавления, ширина шва, шероховатость, зона термического влияния и др.) могут отличаться, в зависимости от выполняемой операции.

Методика построения модели определения параметров технологического режима для конкретной операции определяется следующими этапами:

1. Определение входных и выходных числовых параметров режима, согласно специфике операции;
2. Предобработка данных (обработка пропусков и выбросов, нормализация);
3. Проверка на статистическую зависимость входных параметров между собой;
4. Обучение модели SRV для каждого выхода отдельно (т.е. требуется обучить столько моделей, сколько выходных параметров) и подбор гиперпараметров C ;
5. Оценка качества (RMSE, MAE, R^2).

Рассмотрим применение описанной методики на примере импульсной лазерной резки. Задача состоит в том, чтобы по требованиям заказчика (параметры образца и критерии качества) определить значения варьируемых параметров станка. В случае резки имеем (таблица 1):

Таблица 1. Перечень входных и выходных параметров импульсной лазерной резки

Входные параметры	Выходные параметры
Ширина реза (мкм) Глубина реза (мкм) Зона загрязнения поверхности (мкм) Зона термического влияния (мкм) Время обработки (с) Толщина материала (мкм)	Частота повторения импульсов (кГц) Длительность импульса (пс) Средняя мощность (Вт)

Имеем исходный набор размера (1542; 9). Фрагмент набора данных представлен на рисунке 2.

cut_width	cut_depth	surface_co	termo_affer	product_pr	material_tr	repeat_freq	pulse_dura	avg_power
0.0	20.0	0.0	0.0	0.0	0.0	10.0	0.01	0.3
0.0	20.0	0.0	0.0	0.0	0.0	25.0	0.01	1.5
0.0	400.0	0.0	0.0	0.0	0.4	25.0	0.01	10.0
0.0	400.0	0.0	0.0	0.0	0.4	25.0	0.01	8.0
0.0	400.0	0.0	0.0	0.0	0.4	25.0	0.01	5.0
0.0	400.0	0.0	0.0	0.0	0.4	25.0	0.01	7.0
50.0	0.0	0.0	0.0	0.0	0.0	50.0	13.0	19.0
50.0	420.0	15.0	115.0	2.0	1.0	50.0	20.0	18.0
40.0	300.0	70.0	0.0	0.0	0.3	50.0	15.0	15.5
50.0	150.0	77.0	0.0	0.0333	0.3	10.0	40.0	13.0
80.0	300.0	115.0	0.0	0.0	0.4	25.0	0.01	4.0
22.0	400.0	77.0	1205.0	0.0	0.4	25.0	0.01	5.0
83.0	300.0	95.0	520.0	0.0	0.4	25.0	0.01	8.0
75.0	300.0	110.0	316.0	0.0	0.8	25.0	0.01	5.0
90.0	300.0	130.0	220.0	0.0	0.8	25.0	0.01	5.0
80.0	300.0	115.0	240.0	0.0	0.8	25.0	0.01	4.0
42.0	450.0	60.0	300.0	0.005	0.8	50.0	15.0	18.0

Рисунок 2. Фрагмент исходных данных

На следующем шаге уберем неполные и пустые записи. В качестве пропуска значения параметра в исходном наборе данных используется число 0. Но, согласно физическому смыслу, некоторые параметры действительно могут иметь нулевое значение. Будем считать, что запись неполная, если нулевых параметров в ней 7 и более.

Далее, следует очистить данные от выбросов, применив метод межквартильного размаха (IQR) [5]. Вычисляется первый и третий квартили Q1 (25%) и Q3 (75%) как медианы нижней и верхней половин данных. Сам размах следует считать по формуле $IQR=Q3-Q1$. Получив значение размаха, определим границы допустимых значений: $zmin=Q1-k \cdot IQR$, $zmax=Q3+k \cdot IQR$, где k – коэффициент чувствительности ($k=1.5$). Соответственно, будем считать значение выбросом, если оно не принадлежит отрезку $[zmin, zmax]$. Этот метод применяется для всех столбов исходных данных поочередно, и в случае нахождения выбросов удаляется полная запись.

После применения указанных операций размер выборки составил (1361; 9). Для нормализации данных используется стандартизация признаков (z-нормализация) – $xi=xi-ii$.

В рамках анализа экспериментальных данных технологических режимов целесообразно предварительно оценить статистическую зависимость между входными параметрами, поскольку высокая коррелированность признаков может приводить к избыточности информации [6], ухудшению интерпретируемости модели и нестабильности оценки гиперпараметров.

Построим матрицы корреляций по Пирсону и Спирмену, чтобы удостовериться в статистической независимости параметров (рисунок 3, 4). По получившимся матрицам можно полагать, что параметры статистически независимы.




Рисунок 3. Матрица корреляций по Пирсону



Рисунок 4. Матрица корреляций по Спирмену

Для обучения модели SVR используется метод Grid Search («сетка»; это метод подбора гиперпараметров, основанный на полном переборе заранее заданных значений параметров модели) [7].

В качестве ядра будет использоваться радиальная базисная функция (RBF), что позволяет учитывать нелинейные зависимости, измеряя «близость» объектов в пространстве признаков. Значения сетки параметров представлены в таблице 2.

Таблица 2. Значения сетки параметров для обучения SVR

Параметр обучения	Значения
C	[1, 10, 100, 300]
	[0.01, 0.05, 0.1, 0.2]
	["scale", 0.01, 0.05, 0.1, 0.2]

Значение «scale» для параметра означает, что параметр ядра RBF вычисляется автоматически на основе дисперсии входных данных, т.е. $\gamma = 1/n \cdot \text{Var}(x)$, где n – число признаков; $\text{Var}(x)$ – дисперсия данных обучающей выборки. Стоит отметить, что вследствие использования нормализации по стандартным отклонениям $\text{Var}(x) \approx 1$.

Параметры SVR, полученные после обучения, представлены в таблице 3.

Таблица 3. Результаты обучения SVR

Параметр режима	C			CV RMSE	RMSE	MAE	R ²
Частота повторения импульсов	10	0.1	0.2	0.6522	0.6176	0.3406	0.5044
Длительность импульса	10	0.01	0.1	0.5329	7.2359	1.1615	-0.0257
Средняя мощность	100	0.01	scale	0.6001	0.3014	0.1278	0.9457

Проведем анализ полученных результатов:

- Частота повторения импульсов – ошибка на тесте сопоставима с кросс-валидацией, а значит, нет оснований предполагать переобучение; модель объясняет около 50% дисперсии.

- Длительность импульса – $R^2 < 0$, что означает, что модель непригодна для определения значения параметра. Причина такого поведения в исходном наборе данных: 84% значений этого параметра не заполнены.

- Средняя мощность – нет оснований предполагать переобучение; модель объясняет более 94% дисперсии.

Графическая иллюстрация полученных результатов представлена на рисунке 5.




Рисунок 5. Тестовые и предсказанные значения на графиках

Разработанные по описанной методике модели могут представлять практическую ценность для инженеров-технологов. Даже в случае получения не идеально точных прогнозных значений модель позволяет сформировать обоснованную стартовую оценку

технологического режима. Это способствует сокращению количества реальных экспериментов, снижению затрат времени и материалов, а также решению задачи «холодного старта» при внедрении нового материала, оборудования или технологического процесса. Использование модели в качестве инструмента предварительного расчёта позволяет сузить область поиска оптимального режима и повысить эффективность последующих экспериментов.

Заключение. В рамках настоящего исследования была разработана методика построения модели определения параметров технологического режима на основе метода опорных векторов (SVR). Полученные результаты показали, что для большинства исследуемых выходных характеристик модель SVR обеспечивает высокую или удовлетворительную точность прогнозирования. Результаты исследования подтверждают целесообразность применения метода опорных векторов для моделирования технологических режимов в условиях ограниченного объема данных.

Список литературы

- [1] Magdum V. B., Kittur J. K. A review on laser beam machining process modeling and optimization //IOP Conference Series: Materials Science and Engineering. – IOP Publishing, 2021. – Т. 1104. – №. 1. – С. 012015.
- [2] Cabrera M. L. et al. An overview of strategies for identifying manufacturing process window through design of experiments and machine learning techniques while considering the uncertainty associated with //The International Journal of Advanced Manufacturing Technology. – 2024. – Т. 134. – №. 11. – С. 4981-5019.
- [3] Агаповичев А. В., Сотов А. В., Смелов В. Г. Математическое моделирование процесса селективного лазерного сплавления порошка титанового сплава ВТ6 //VESTNIK of Samara University. Aerospace and Mechanical Engineering. – 2020. – Т. 19. – №. 2. – С. 53-62.
- [4] Yu H., Kim S. SVM Tutorial-Classification, Regression and Ranking //Handbook of Natural computing. – 2012. – Т. 1. – С. 479-506.
- [5] Дорофеев В. С., Волосатова Т. М. Ансамблирование методов обнаружения выбросов при подготовке обучающей выборки данных //Моделирование, оптимизация и информационные технологии. – 2022. – Т. 10. – №. 3. – С. 1.
- [6] Dhal P., Azad C. A comprehensive survey on feature selection in the various fields of machine learning //Applied intelligence. – 2022. – Т. 52. – №. 4. – С. 4543-4581.
- [7] Lameski P. et al. SVM parameter tuning with grid search and its impact on reduction of model over-fitting //Rough Sets, Fuzzy Sets, Data Mining, and Granular Computing: 15th International Conference, RSFDGrC 2015, Tianjin, China, November 20-23, 2015, Proceedings. – Cham : Springer International Publishing, 2015. – С. 464-474.

Авторский вклад

Николаев Константин Сергеевич – постановка задачи исследования, разработка методики построения модели определения параметров технологического режима, оценка полученных результатов.

METHODOLOGY FOR BUILDING A MODEL FOR DETERMINING TECHNOLOGICAL MODE PARAMETERS USING THE SUPPORT VECTOR MACHINE

K.S. Nikolaev

*Senior Lecturer, SPINTECH Institute,
National Research University MIET*

Abstract. A methodology for constructing a model for determining technological mode parameters based on the support vector method (SVR) is proposed. The methodology includes data cleaning, outlier exclusion, feature standardization, and hyperparameter selection using cross-validation. A separate model is formed for each output parameter. The results confirm the effectiveness of the approach with a limited amount of data. The developed models make it possible to reduce the number of experiments and solve the problem of a “cold start” when introducing new technological processes.

Keywords: support vector method, SVR, machine learning, mathematical modeling, technological mode, hyperparameter selection, cross-validation, data processing, outlier exclusion, cold start.