

Прогнозирование профиля шероховатости поверхности детали на основе глубокой сети доверия

И. Н. Паламарь, email: irina.palamar@mail.ru¹

А.И. Гагарина, email: aig.rsatu@mail.ru¹

И. Е. Кулиманов, email: ivan.kulimanov@gmail.com¹

¹ Рыбинский государственный авиационный технический университет имени П.А. Соловьева

***Аннотация.** В данной работе рассматривается применение вероятностной генеративной модели для формирования первичного профиля поверхности детали, изготавливаемой по технологии селективного лазерного сплавления, оценена погрешность прогнозирования вероятностных параметров шероховатости.*

***Ключевые слова:** глубокая сеть доверия, модель генерации данных, прогнозирование профиля, шероховатость поверхности, вероятностные параметры, аддитивная технология.*

Введение

Одним из важных параметров, определяющих качество поверхностного слоя детали, является шероховатость поверхности. Контроль шероховатости поверхности должен обеспечивать высокую точность, локальность и воспроизводимость измерений. Непрерывный рост требований к эксплуатационным показателям деталей машин показывает, что оценка шероховатости только высотными стандартизированными параметрами в соответствии с ГОСТ 2789-73, которые широко применяются в промышленности, во многих случаях является недостаточной. Особенно необходимость исследования новых закономерностей формирования первичного профиля проявляется при разработке новых методов изготовления деталей и изучении способов обработки новых материалов. Одним из наиболее существенных факторов, затрудняющих математическое описание шероховатости, является ее нерегулярность, проявляющаяся вследствие физических особенностей способов образования поверхностей [1]. Предполагается, что в структуру шероховатости поверхности входят как закономерные, так и случайно расположенные неровности. Поэтому реальный профиль поверхности, полученный в результате ее обработки различными методами, представляет собой композицию систематической и случайной составляющих, а математическая модель профиля поверхности должна интегрально учитывать его вероятностный характер. Следовательно, разработка современного инструментария для

исследования вероятностных параметров шероховатости поверхности является актуальной.

1. Тенденции развития исследований по вероятностной оценке шероховатости поверхности

В основе вероятностных методов лежит предположение о случайном характере изменения геометрических свойств поверхности. Профиль поверхности или ее представление в трехмерном виде рассматривается как некоторая статистическая выборка высот или реализация случайного процесса [1]. При создании моделей шероховатости поверхностей следует идти не по пути построения общих моделей, целесообразно строить модели с учетом индивидуальных особенностей методов и условий обработки. Профилограммы поверхности хорошо интерпретируются как реализация стационарного процесса с нормальным распределением вероятностей. В такой модели параметры шероховатости будут числовыми характеристиками реализации случайного процесса, т. е. функционалами, заданными на множество реализаций случайной функции, а значит, и случайными величинами, для которых имеет смысл говорить о распределении вероятностей.

Вероятностно-статистическая оценка шероховатости поверхности используется при исследовании различных методов обработки деталей. В работе [2] числовой массив, соответствующий набору ординат профиля поверхности относительно выбранной линии отсчета используется для расчета значений корреляционной функции и сглаженной гистограммы профиля, а также параметра Ra. Для вероятностной оценки качества поверхности, получаемой в результате электроимпульсной полировки, строятся и анализируются коррелограммы и спектрограммы профилей. В работе [3] для оценки качества бесцентрового шлифования абразивными кругами анализ шероховатости выполнялся с помощью автокорреляционных функций и анализа среднего периода колебания T_{cp} . Данный подход требует получения аналитической зависимости Ra от исследуемого параметра T_{cp} , для чего в работе был использован интерполяционный метод Лагранжа. Существенным недостатком параметрического вероятностного подхода является то, что рассчитанные параметры не позволяют оценить весь процесс формирования шероховатости поверхности в целом и ограничены математическими зависимостями, которые сложно получить для большого числа зависимых параметров. Кроме того, полиномиальный характер зависимостей может давать выбросы в промежуточных точках замеров данных и невысокую точность.

В современных исследованиях для анализа данных все чаще применяют машинное обучение. Машинное обучение находится на стыке математической статистики, методов оптимизации и классических математических дисциплин, но имеет также и собственную специфику, связанную с проблемами вычислительной эффективности и переобучения.

Профиль поверхности можно рассматривать как последовательность наблюдений. Тогда для его описания можно использовать модели, основывающиеся на связанных наблюдениях.

В статистических моделях зависимость будущего значения от прошлого задаётся в виде некоторого уравнения. К таким моделям относятся: регрессионные модели; авторегрессионные модели; модели экспоненциального сглаживания; модели по выборке максимального подобия. В структурных моделях зависимость будущего значения от прошлого задаётся в виде некоторой структуры и правил перехода по ней. К таким моделям относятся: нейросетевые модели; модели на базе цепей Маркова; модели на базе классификационно регрессионных деревьев.

В работе [4] были проведены исследования для количественной оценки шероховатости. Автор устанавливает связь между шероховатостью поверхности и сигналами вибрации, полученные с помощью акселерометра закрепленного на держателе инструмента. Из полученных сигналов временной области извлекаются статистические признаки. В результате дальнейшего статистического анализа получают различные параметры, такие как: среднее значение, стандартная ошибка, медиана, стандартное отклонение, дисперсия выборки, эксцесс, асимметрия, диапазон, минимум, максимум и сумма. Таким образом, статистические характеристики были рассчитаны для 150 сигналов.

В работе [5] использовались три модели машинного обучения. Сначала в качестве экстрактора признаков используется быстрое преобразование Фурье (БПФ), а затем эти функции вводятся в прогностическую модель глубокой нейронной сети. Далее БПФ объединяется с долгой краткосрочной памятью (*LSTM*), а затем для решения задачи регрессии по сигналам вибрации используется подход полностью подключенных сетей (*FCN*). Затем для прогнозирования используется 1-*D* модель сверточной нейронной сети (*CNN*), основанная на сигналах временной вибрации. Модель *LSTM* предоставляет возможность временного моделирования для достижения хорошей производительности при более высоком значении R_a , и 1-*D CNN*, которая лучше извлекает признаки и демонстрирует высокую точность прогнозирования при более низких диапазонах R_a . Недостатком такого

метода является сложная структура и необходимости дополнительных данных с акселерометра, а также сильная зависимость от настроек и вида обработки поверхности.

В аддитивных технологиях ключевым критерием качества проектирования и исполнения сложно профильных изделий для различных сфер применения является точное соответствие деталей и узлов разработанным CAD-моделям, а также обеспечение прочностных характеристик изделия [6]. Для соответствия качества поверхности детали разработанной модели необходимо прогнозировать шероховатость поверхности при послойном изготовлении детали [7].

Для исследования многофакторных зависимостей различных параметров качества детали от технологических параметров метода изготовления детали предложено моделировать полный первичный профиль шероховатости, а не отдельные параметры. Для вероятностно-статистического анализа процесса изготовления применен генеративный подход с использованием в качестве модели глубокой сети доверия (DBN). DBN это порождающая графовая модель, состоящая из нескольких скрытых слоев, в которых нейроны внутри одного слоя не связаны друг с другом, но связаны с нейронами соседнего слоя. Следовательно, DBN подходит для обучения на размеченных данных с сохранением состояний каждого слоя. Для различных сочетаний технологических параметров (угол поворота платформы, толщина слоя) и соответствующих параметров шероховатости поверхности обучается своя модель, выполняющая генерацию профиля поверхности для заданной формы детали.

В результате применения модели появляется возможность более полного анализа профиля шероховатости и исследования влияния технологических параметров метода селективного лазерного сплавления (SLM) на качество поверхности с целью их оптимизации.

2. Описание модели и алгоритмов обучения

Глубокие сети доверия (DBN) – это вероятностные генеративные модели, состоящие из нескольких уровней стохастических скрытых переменных. Скрытые переменные обычно имеют двоичные значения и часто называются скрытыми модулями или детекторами признаков. Два верхних слоя имеют ненаправленные симметричные связи между собой и образуют ассоциативную память. Нижние уровни получают нисходящие направленные соединения от уровня выше. Блоки на самом нижнем уровне представляют вектор данных.

Механизм доверия основан на том, что DBN обучается по одному уровню за раз, после обучения первого уровня значения скрытых переменных поступают как входные данные для обучения следующего

уровня, таким образом, каждый уровень доверяет результатам нижестоящего уровня [8].

Глубокая сеть доверия представляет собой композицию простых ограниченных машин Больцмана (RBM). RBM можно задать с помощью двудольного неориентированного графа. Нейроны разделены на две группы, описывающие наблюдаемые и скрытые состояния. Особенностью этой модели является то, что при данном состоянии нейронов одной группы состояния нейронов другой группы будут независимы друг от друга [8]. Связи между нейронами противоположных слоев определяются матрицей весов W . DBN обучается без учителя методом контрастной дивергенции [9].

Первый блок, представляющий собой одну RBM, жадно обучается на входных данных, а все остальные уровни замораживаются. В результате получаются индивидуальные вероятности активации для первого скрытого слоя. Все нейроны первого скрытого слоя обновляются параллельно. Это называется положительной фазой обучения. Прямой связи видимых слоёв между двумя машинами Больцмана нет, поэтому необходимо произвести реконструкцию элементов видимого слоя. Это называется отрицательной фазой. Последним шагом в жадном обучении является обновление всех связанных весов, при этом скорость обучения умножают на разницу между положительным и отрицательным значениями фазы и добавляют к начальному значению веса. Этот процесс будет повторяться до тех пор, пока не будут получены требуемые пороговые значения.

Затем берется первый скрытый слой, который теперь действует как вход для второго скрытого слоя и так далее. Каждый слой принимает выходные данные предыдущего слоя в качестве входных данных для создания выходных данных. Сгенерированный результат – это новое представление данных. Веса для второго *RBM* – это транспонированная матрица весов для первого *RBM*. После обучения выполняется так называемая «тонкая настройка», которая может быть выполнена разными методами, например можно добавить ещё один слой, который бы представлял желаемые выходные данные и производные ошибок, тогда с помощью алгоритма обратного распространения можно произвести настройку сети.


Исследуемая глубокая сеть доверия структурно состоит из трех ограниченных машин Больцмана, где каждый скрытый слой является видимым слоем для следующей машины. Каждая ограниченная машина Больцмана состоит из двух слоёв: скрытый и видимый. Для каждой последующей *RBM* скрытый слой предыдущей машины является видимым слоем.

Сети глубокого доверия обладают двумя важными вычислительными свойствами. Во-первых, существует эффективная процедура для изучения нисходящих генеративных весов, которые определяют, как переменные в одном слое определяют вероятности переменных в слое ниже. Эта процедура изучает один уровень скрытых переменных за раз. Во-вторых, после изучения нескольких уровней значения скрытых переменных в каждом слое могут быть выведены с помощью одного восходящего прохода, который начинается с наблюдаемого вектора данных в нижнем слое и использует генеративные веса в обратном направлении.

Благодаря финальной настройке модели оптимизируются веса связей и минимизируется ошибка.

3. Результаты экспериментального исследования

Первоначально DBN была обучена на модельных данных – синусе с 100 итерациями (рис. 1, а) и 300 итерациями (рис. 1, б).



а – 100 итераций, б – 300 итераций

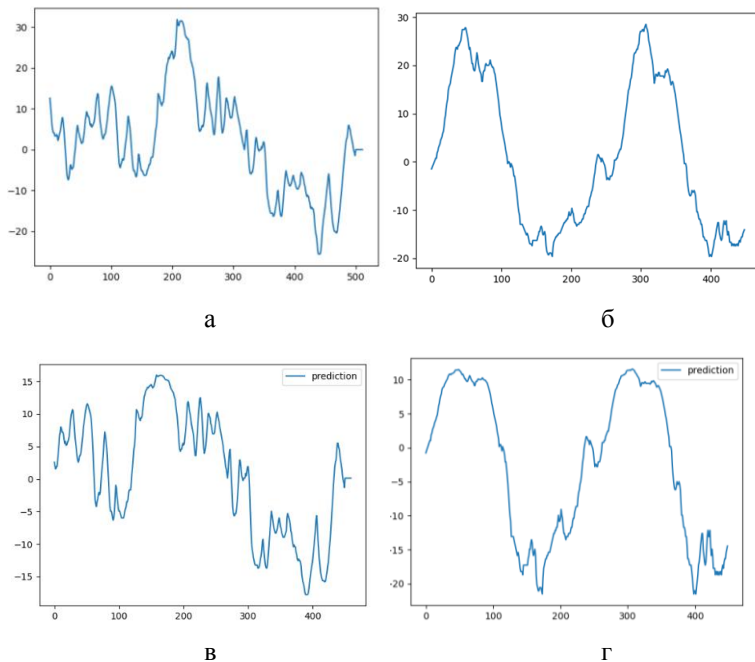
Рис. 1. Вид сигналов, сгенерированных глубокой сети доверия

Данная модель смогла повторить форму сигнала, но при этом исказила его по высоте. При увеличении количества итераций результат стал приближаться к исходному сигналу. Среднеквадратичная ошибка MSE уменьшилась с 1,15 до 0,065.

Модель обучалась на исходных данных в виде шероховатости, после чего происходил процесс генерации данных. Исходные данные являются профилем поверхности, полученным с помощью профилометра, и хранятся в файле с расширением *.csv*. Датасет состоит

из файлов, каждый файл представляет собой профиль поверхности виде сигнала, количество отсчётов 500.

На рис. 2 показаны два профиля поверхности используемых для обучения моделей и результаты генерации профилей с использованием глубокой сети доверия.



а – профиль № 1, б – профиль № 2, в – прогноз для профиля № 1, г – прогноз для профиля № 2

Рис. 2. Прогнозы, полученные с помощью DBN для профилей шероховатости

В глубокой сети доверия можно изменять количество итераций финальной настройки, для синуса они не имели большого значения, как и размер блока, и количество RBM, используемых в модели. Теоретически увеличение количества RBM позволяет выделить больше признаков, благодаря чему точность предсказания повышается. Однако экспериментально было выявлено, что для данной задачи увеличение количества RBM больше трех улучшает результат незначительно при существенном повышении вычислительной сложности.

В результате оценки параметров шероховатости для исходных и сгенерированных моделью DBN профилей №1 и №2 были рассчитаны значения основных параметров шероховатости, представленные в табл.1. Вычисленные значения параметров шероховатости соответствуют данным, полученным с помощью профилометра. Для глубокой сети доверия ошибка прогнозирования по параметру Ra лежит в интервале от 0,5 до 15 %.

Таблица 1

Основные параметры шероховатости

Параметр шероховатости	Реальные данные		Сгенерированные данные	
	№1	№2	№1	№2
Ra, мкм	8,7096	12,3541	6,7474	12,3855
Rz, мкм	6,1502	8,5214	2,8668	14,0178
Rmax, мкм	57,4275	48,1646	37,7836	52,7574
Sm, мкм	0,3658	0,8456	0,5101	1,2255
S, мкм	0,0758	0,0681	0,0723	0,0564
Tr, %	16,9137	26,2959	20,9871	15,5556

В табл. 2 представлены результаты расчета вероятностных параметров шероховатости в соответствии с разработанными алгоритмами.

Таблица 2

Вероятностные параметры шероховатости

Параметр шероховатости	Реальные данные		Сгенерированные данные	
	№1	№2	№1	№2
L_u , мкм	0,9222	1,1397	0,9681	0,6863
Q_u , мкм	2,8122	2,166	1,938	1,19357
R_q , мкм	12,1945	14,6021	10,2719	16,4153
$M(L_u)$	0,7078	0,6616	0,711	0,6297
$D(L_u)$	0,0085	0,0115	0,0084	0,0137
$M(Q_u)$	0,6038	0,0854	0,8601	0,0115
$D(Q_u)$	6,2021	9,0173	4,3967	11,5176
$M(R_q)$	3,4921	3,8213	3,205	4,0516
$D(R_q)$	5,9482	8,5289	4,2205	10,7785
$M(R_a)$	9,7298	11,6508	8,1958	13,0975
$D(R_a)$	2,1567	3,0924	1,5303	3,9081
N_u	20	14	25	6
u	12	8	13	7

Из сравнения R_a , его математического ожидания $M(R_a)$, R_q и уровня опорной линии u видно их малое расхождение, что косвенно подтверждает гипотезу о нормальности распределения. Количество пересечений с опорной линией u и длительность пребывания процесса над уровнем $L(u)$ вместе со значением площади областей, ограниченных процессом, и горизонтальной прямой $Q(u)$ позволяют судить о виде шероховатости поверхности, размерах выступов и впадин [1]. Математическое ожидание и дисперсия этих параметров позволяют понять их распределение на случайном процессе.

Полученные вероятностные значения параметров шероховатости соответствуют значениям основных параметров, полученным непосредственных измерением. Разработанные алгоритмы вычисления дополнительных функционалов предоставляют возможности изучения вероятностных параметров качества поверхности более глубоко.

Ошибка прогнозирования по вероятностным параметрам, например длительность пребывания процесса над уровнем для прогноза профиля, сгенерированного DBN, не превышает 5%. Таким образом, вероятностные параметры позволяют более точно сравнить спрогнозированный профиль с реальным профилем поверхности.

Заключение

Для обеспечения полноты исследования профиля поверхности была исследована генеративная модель DBN и показано, что аппроксимация профиля шероховатости вероятностной моделью машинного обучения адекватно отражает вероятностно-статистическую природу исследуемых параметров качества поверхности.

Алгоритм обучения глубокой сети доверия позволяет обучить модель на меньшем количестве данных, что является актуальным при применении моделей машинного обучения при решении задач, где возможно получение датасета большого объема. Кроме того, DBN эффективно обучаются на данных сложной структуры.

Показано, что вероятностные параметры профиля шероховатости имеют большую точность в сравнении с основными параметрами и позволяют получить больше информации о профиле поверхности при исследовании качества поверхностного слоя детали.

Список литературы

1. Хусу, А. П. Шероховатость поверхностей (теоретико-вероятностный подход) / А. П. Хусу, Ю. Р. Витенберг, В. А. Пальмов. – М. : Наука, 1975. – 343 с.
2. Синькевич, Ю. В. Вероятностно-статистическая оценка шероховатости поверхности электроимпульсно полированных деталей /

Ю. В. Синькевич, А. А. Гриневич, И. Н. Янковский // Вестник Белорусского национального технического университета. – 2011. – № 5. – С. 9-18.

3. Абрамов, А. Д. Исследование шероховатости поверхности бомбинированных роликов на основе анализа их автокорреляционных функций / Абрамов А.Д., Носов Н.В., Хаустов В.И. // Вестник СГАУ. Серия «Авиационная и ракетно-космическая техника». – 2009. – №3(19). С. 45-53.

4. Elangovan, M. Machine learning approach to the prediction of surface roughness using statistical features of vibration signal acquired in turning.// Procedia Computer Science. – 2015. – № 50. – pp. 282-288.

5. Wan-Ju Lin. Evaluation of deep learning neural networks for surface roughness prediction using vibration signal analysis// Applied Sciences. – 2019. – № 9. – 17 p.

6. Горбатов, И. В. Определение геометрической точности и шероховатости поверхности малогабаритных деталей круглого и квадратного сечения, получаемых в зависимости от расположения в рабочем пространстве принтера по технологии селективного лазерного плавления из стали марки 12X18H10T / И. В. Горбатов [и др.] // Вестник Концерна ВКО «Алмаз – Антей». – 2019. – С. 59-67.

7. Сапрыкин, А. А. Разделение технологических режимов лазерного спекания при формировании единичного спеченного слоя из металлического порошка / А. А. Сапрыкин, Н. А. Сапрыкина, Е. А. Ибрагимов //Аддитивные технологии: настоящее и будущее. Сборник докладов международной научной конференции, М. : ВИАМ – 2015. – С. 11.

8. Платформа для социальной журналистики, авторских публикаций [Электронный ресурс] : Deep Belief Networks – all you need to know. – Режим доступа: <https://medium.com/@icecreamlabs/deep-belief-networks-all-you-need-to-know-68aa9a71cc53>

9. Платформа для социальной журналистики, авторских публикаций [Электронный ресурс] : Deep Learning – Deep Belief Network (DBN). – Режим доступа: <https://medium.com/datadriveninvestor/deep-learning-deep-belief-network-dbn-ab715b5b8afc>