



Research Article

Received: December 02, 2022

Accepted: December 05, 2022

Published: December 10, 2022

ISSN 2658-5553

## Plane strain predictive estimation method

Khomutskaya, Olga Vladislavovna<sup>1\*</sup> Kopylov, Denis Aleksandrovich<sup>1</sup> Vantsov, Sergey Vasilevich<sup>1</sup> <sup>1</sup> Moscow Aviation Institute, Moscow, Russian Federation; [khomutskayaov@gmail.com](mailto:khomutskayaov@gmail.com) (K.O.V.);[kopylov-denis@inbox.ru](mailto:kopylov-denis@inbox.ru) (K.D.A.); [van2851@mail.ru](mailto:van2851@mail.ru) (V.S.V.)Correspondence: \* email [khomutskayaov@gmail.com](mailto:khomutskayaov@gmail.com); contact phone [+79154580330](tel:+79154580330)

### Keywords:

Plane deformation; Deformation; Circuit Boards; Artificial Intelligence; Prediction Method

### Abstract:

**The object of research** is a plane strain predictive estimation method. **Method.** Assessment of flat deformation was carried out on the example of flat deformation of printing blanks due to thermal and chemical influences, which the blanks are repeatedly exposed in the process of receiving boards. The study was conducted on twenty -five manufactured blanks for printed circuit boards. **Results.** The dependence of the deformation on the parameters of the printed circuit board is non-linear. It is determined that in order to identify the dependencies of deformation on the position of the reference points, the most effective is the algorithm for processing the primary data arrays according to the criteria Precision, Recall, F1. The proposed method makes it possible to increase the prediction of deformation of the multilayer structure of the board.

## 1 Introduction / Введение

Четвёртая промышленная революция позволила распространить и внедрить различные уровни автоматизации почти во все отрасли. Повсеместно появились IoT устройства, датчики, камеры, цифровые двойники, роботы и другие различные устройства, генерирующие большой объём данных. Обработка и извлечение информации и закономерностей из таких объёмных данных давно вышла за пределы человеческих возможностей, сейчас для таких задач повсеместно используются возможности искусственного интеллекта (ИИ). Различные области ИИ представлены в работе [1] и схематично на Рис.1.

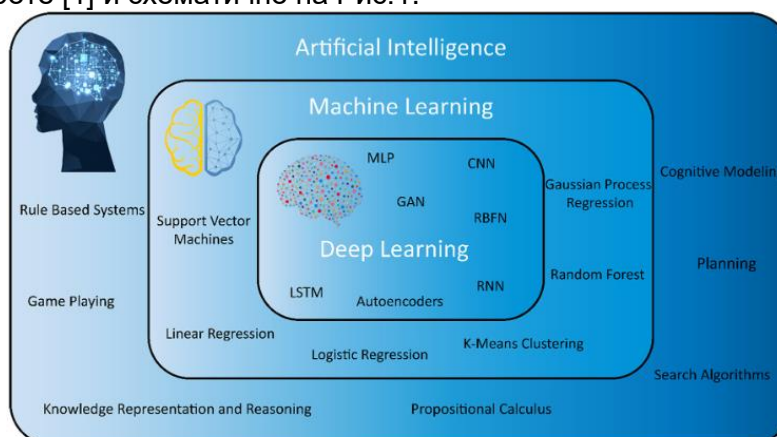


Рис. 1 — Области применения ИИ, машинного обучения и глубокого обучения  
Fig. 1 — Applications of AI, Machine Learning and Deep Learning

Khomutskaya, O.; Kopylov, D.; Vantsov, S.

Plane strain predictive estimation method;

2022; *AlfaBuild*; 25 Article No 2504. doi: 10.57728/ALF.25.4



Внедрение различных алгоритмов ИИ создаёт новый виток развития для Индустрии 4.0. Различные области промышленности исследуют возможности и ограничения применения ИИ в своих областях. Несмотря на присутствие множества свидетельств внедрения методов ИИ в различные отрасли, всё ещё присутствует большое количество сложностей и ошибок.

В работе [2] изучается возможность избегания ошибок, допущенных в ходе автоматизации таких отраслей, как автомобиле- и самолётостроение. В ходе исследования выделено шесть ключевых ошибок:

- Автоматизация требует, чтобы «люди были в курсе»;
- Операторы нуждаются в обучении автоматизации;
- Автоматизация требует резервного ручного варианта;
- Резервирование датчиков полезно в системах, критически важных для безопасности;
- Необходимо учитывать кибербезопасность;
- Этические решения и ответственный ИИ также должны учитываться.

По мнению авторов, учёт всех пунктов позволит в значительной степени улучшить эффект от внедрения автоматизации и избежать негативных последствий.

Помимо исследований ошибок и последствий, большая доля исследований посвящена оптимизации конкретных процессов в конкретных отраслях [3]-[5]. Таких как:

- Цепочки поставки в сфере электроэнергетики;
- Мониторинг процессов при помощи гибридной системы на основе зондов и ML в промышленности;
- Производство полупроводников.

Таким образом востребованность и необходимость применения ИИ методов очевидна, а результаты применения приносят значительные успехи. В источниках [6]-[11], рассматривающих составляющие Индустрии 4.0, зачастую акцент делается на технологиях и перспективах их применения, вроде повсеместного использования киберфизических систем, технологий «Интернета вещей» и технологий искусственного интеллекта, но при этом можно заметить отсутствие конкретных примеров цифровизации производственных процессов и процессов проектирования. В рамках данной статьи предлагается применить методы ИИ для предиктивного анализа сеточных структур на примере плоскостной деформации печатных плат (ПП).

Цифровизация производства и переход к управлению производством с помощью цифровых двойников [12]-[15] как в приборостроении, так и при проектировании высокотехнологичных транспортных средств [16] актуальна. Однако в них уделено недостаточное внимание связи проектирования изделия с его изготовлением.

Достаточно большой ряд проблем в технических приложениях связан с предварительной оценкой величины и направления деформации плоских объектов как во время их эксплуатации, так и в ходе их производства [17]-[18]. К таким задачам относятся, например, задачи плоской деформации изделий в результате действия остаточных напряжений и связанных с ними релаксационных явлений, а также деформации, связанные с тепловым влиянием на изделия в целом или его часть [19]-[21]. Предварительная оценка величины деформации приобретает свою актуальность в технологических процессах сборки легкодеформируемых изделий при условии малых погрешностей совмещения собираемых деталей. К таким процессам, в частности, может быть отнесена технологическая операции сборки многослойной печатной платы. Особенностью этих операций является наличие исходной, почти случайной, деформации отдельных слоёв платы, которая увеличивается во время сборки за счёт теплового и силового воздействий на собираемый комплект слоёв [22]. Характерность возникновения таких деформаций в ходе изготовления печатных плат связана также с физико-механическими особенностями материала собираемых и наличием на слоях поверхностных элементов, изменяющих случайный анизотропный характер деформации материала [23]-[30].

Предлагаемый способ предварительной оценки плоской деформации базируется на оценке изменения положения первоначально размещённых на поверхности плоского материала регулярных структур, в которых первоначально известными являются координаты каждого из их элементов [31]-[37].

Наиболее распространёнными из таких структур являются сетчатые. При этом очевидным является зависимость точности определения величины и направления деформации от шага сетки.



## 2 Materials and Methods / Материалы и методы

Способ прогностической оценки базируется на построении регрессионной модели изменения координат реперных точек сетки, представляющих собой точки пересечения взаимно перпендикулярных линий сетки. Исходными данными при построении модели являются разности координат между исходным положением реперных точек и их положением на первом шаге регрессии. В качестве шага регрессии можно рассматривать наблюдаемое изменение координат при любом как внешнем, так и внутреннем воздействии на плоский объект, приводящем к его деформации. Наблюдаемое смещение реперных точек может быть получено, в частности, путём анализа видеоизображений деформированной исходной плоской сетки. При этом точность прогностической оценки зависит от вида регрессионной модели.

Предлагаемый способ применим с наибольшей эффективностью при оценке деформации слоистых объектов, суммарная деформация которых зависит как от плоскостной деформации каждого из слоёв, так и их взаимного влияния. В этом случае целесообразно использовать многомерные пространственные сетки. Сложность заключается в решении проблемы наблюдаемости изменения координат пространственной сетки.

На первом этапе задача моделирования для многомерной сетки может быть сведена к моделированию каждого слоя в отдельности. В этом случае каждый слой представляет собой двумерную сетку с узлами на пересечении линий сетки.

В случае двумерного представления деформация сетки может быть описана с помощью пяти параметров для каждого узла:

$X_i$  — изначальная (без деформации) позиция по оси  $X$ ;

$Y_i$  — изначальная (без деформации) позиция по оси  $Y$ ;

$\Delta X_i$  — величина смещения по оси  $X$  после деформирующего воздействия;

$\Delta Y_i$  — величина смещения по оси  $Y$  после деформирующего воздействия;

$N_i$  — уникальное обозначения для узла.

Таким образом позиция  $i$ -ого узла после деформирующего воздействия может быть представлена следующим образом (1):

$$\begin{aligned} X_i &= X_i + \Delta X_i \\ Y_i &= Y_i + \Delta Y_i \end{aligned} \quad (1)$$


Для дальнейшей работы полученный массив данных подвергается предварительной обработке, которая включает в себя:

- этап ранжирования данных;
- этап исключения критических случайных значений;
- этап нормирования массива.

Этап ранжирования осуществляется традиционными способами.

Этап исключения критических случайных данных заключается в том, что из массива исходных данных должны быть удалены ошибочные данные, полученные в ходе работы программного обеспечения, обеспечивающего обработку видеоизображений смещения реперных точек образца. Для этого из массива удаляются дублирующие записи о состоянии одного и того же узла сетки, также удаляются выбросы значений смещения реперных точек, существенно превышающих среднее значение смещений. Последнее связано с тем, что точность определения положения реперной точки на основании анализа видеоизображения сетки не 100%, и существуют так называемые выбросы данных — это значения данных, которые сильно отличаются от большинства данных. Эти значения выходят за пределы общей тенденции, которая присутствует в данных.

Пример этому представлен на Рис. 2, где приведены распределения величины смещения.



**Рис. 2 — Пример возможного распределения величины смещения**  
**Fig. 2 — Example of a possible displacement distribution**

Для обработки данных на этом этапе может быть использован статистический метод «IQR» (межквартильный диапазон). Данный метод позволяет выделить данные, которые сильно отклоняются от остальных значений в наборе и удалить их, сводя таким образом случайные значения к минимуму.

Метод реализуется по следующему алгоритму:

1. Разделить массив данных на квартили;
2. Рассчитать IQR по следующей формуле:  $IQR = \text{Quartile3} - \text{Quartile1}$ ;
3. Рассчитать верхнюю и нижнюю границу диапазона средних нормальных значений:
  - Верхняя:  $Q3 + 1,5 * IQR$ ;
  - Нижняя:  $Q1 - 1,5 * IQR$ ;
4. Удалить все значения больше верхней границы и меньше нижней.

В статистике доказано, что такой подход позволяет учесть все данные между 2.7 стандартными отклонениями в распределении Гаусса. Центральная предельная теорема позволяет считать, что сумма достаточно большого количества слабо зависимых случайных величин, имеющих примерно одинаковые масштабы (ни одно из слагаемых не доминирует, не вносит в сумму определяющего вклада), имеет распределение, близкое к нормальному.

Этап нормирования массива используется для упрощения работы со стандартными алгоритмами обработки данных.

Нормирование производится при помощи «минимакс» метода. Данный алгоритм сжимает значений от 0 до 1, не изменяя свойства распределения данных.

Метод реализуется по следующему алгоритму:

1. Найти максимальное и минимальное значение в диапазоне масштабируемых данных;
2. Получить для каждого значения новую величину в диапазоне от 0 до 1, по следующей формуле (2):

$$x' = \frac{x_i - \min}{\max - \min} \quad (2)$$

Где:

$\min$  — минимальное значение в наборе данных масштабируемых данных;

$\max$  — максимальное значение в наборе масштабируемых данных;

$x'$  — очередное новое значения в диапазоне от 0 до 1;

$x_i$  — очередное значение, которое необходимо масштабировать

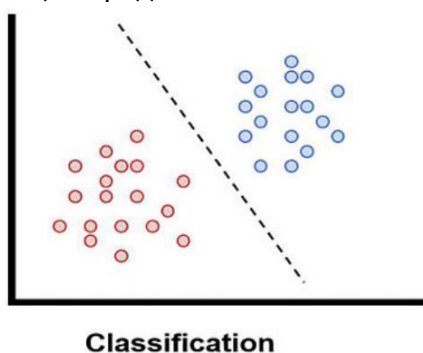
Результатом предварительной обработки является таблица данных смещения по осям реперных точек исходной сетки, пример которой приведён на Рис. 3.

	A	B	C	D	E	F	G	H
1	X1	Y1	X2	Y2	X1_norm	X2_norm	Y1_norm	Y2_norm
2	12,05441667	21,57941667	12,13908333	21,64291667	0,107584774	0,1082995	0,13781683	0,13816634
3	12,05441667	36,56541667	12,13908333	36,62891667	0,107584774	0,1082995	0,233524839	0,233835552
4	12,05441667	41,56075	12,11791667	41,56075	0,107584774	0,10811066	0,265427509	0,265319911
5	12,05441667	46,55608333	12,11791667	46,61958333	0,107584774	0,10811066	0,297330179	0,297615026
6	12,05441667	61,54208333	12,16025	61,58441667	0,107584774	0,108488339	0,393038189	0,393149112
7	12,05441667	76,57041667	12,07558333	76,52808333	0,107584774	0,107732981	0,48901656	0,488548071
8	12,05441667	81,56575	12,13908333	81,56575	0,107584774	0,1082995	0,520919229	0,52070806
9	12,05441667	86,56108333	12,13908333	86,56108333	0,107584774	0,1082995	0,552821899	0,552597977
10	12,05441667	96,55175	12,16025	96,53058333	0,107584774	0,108488339	0,616627239	0,616242146
11	12,05441667	101,5470833	12,13908333	101,5259167	0,107584774	0,1082995	0,648529909	0,648131883
12	12,05441667	116,5754167	12,07558333	116,4695833	0,107584774	0,107732981	0,74450828	0,743530843
13	12,05441667	121,57075	12,09675	121,5284167	0,107584774	0,10792182	0,77641095	0,775825958

**Рис. 3 — Пример применения предварительной обработки**  
**Fig. 3 — Example of pre-processing applications**

На основании этих данных решается задача кластеризации полученных данных, то есть поиска такого уравнения прямой (для двумерного случая), которое разделит плоскость существования данных на зоны, принадлежащие разным классам и отвечающим, соответственно, разным наборам определяющих признаков.

Применение алгоритмов кластеризации позволяет определить вид регрессионной модели. Пример вида результата кластеризации представлен на Рис. 4.



**Рис. 4 — Пример вида результата кластеризации**  
**Fig. 4 — Example of the clustering result view**

На базе полученных и предварительно обработанных данных построение регрессионной модели плоской деформации сводится к получению зависимости вида (3):

$$A_1x_1 + \dots + A_ix_i = y, \quad (3)$$

Где:

$y$  — величина деформации объекта;

$x_i$  — признаки, определяющие и влияющие на величину деформации;

$A_i$  — численные коэффициенты соответствующих признаков.

Численные значения коэффициентов определяются исходя из критерия минимального различия между исходным и прогнозируемым положениями реперных точек.

В рамках данной статьи эффективность предложенного способа прогностической оценки плоской деформации рассмотрена на примере плоской деформации заготовок печатных плат из-за термических и химических воздействий, которым заготовка многократно подвергается в процессе получения плат.

### 3 Results and discussion / Результаты и обсуждение

Для исследования были изготовлены 25 заготовок для печатных плат. Для этого использовался фольгированный стеклотекстолит (FR-4) толщиной 0.4 мм. Получение рисунка платы осуществлялось субтрактивным методом. В качестве реперных точек использовались центры отверстий, просверленных в узлах сетки (Рис. 5).

Проект печатной платы создан в САПР системе Altium Designer со следующими параметрами:


- размер заготовки — 166 x 124 мм;
- отверстия диаметром  $D = 1,0$  мм;

Khomutskaya, O.; Kopylov, D.; Vantsov, S.

Plane strain predictive estimation method;

2022; *AlfaBuild*; 25 Article No 2504. doi: 10.57728/ALF.25.4

- сетка 30 x 21 с шагом 5 мм.



**Рис. 5 — Проект платы в CAD системе Altium Designer**  
**Fig. 5 — Board Design in Altium Designer CAD System**

Для получения данных о заготовках и величине деформации (использовалось программа «Программное обеспечение для анализа деформации слоя многослойной печатной платы, Программа для ЭВМ» — далее «ПО для анализа деформации»). Для работы программы на вход необходимо подать эталонное изображение (изображение относительно которого рассчитывается величина деформации), в качестве эталонного изображения использовалось изображения проекта ПП из САПР. В результате работы программа формирует отчет для каждой анализируемой заготовки следующего формата:

File — номер файла сканирования;

Num — номер отверстия на плате;

X исх. — начальное положение по оси X для отверстия на проекте платы;

Y исх. — начальное положение по оси Y для отверстия на проекте платы;

X2 — положение отверстия на скане по оси X;

Y2 — положение отверстия на скане по оси Y;

Len — длина вектора смещения;

Delta X — смещение по оси X;

Delta Y — смещение по оси Y;

Tols, hcup, med\_pr — толщина платы, толщина слоя меди, площадь покрытия меди.

Для исследования данные о всех платах собраны в один файл и отброшены столбцы: Tols, hcup, med\_pr. Так как эти значения для всех плат одинаковы.

В результате работы программы сформирован массив данных, пример которого приведён на Рис. 6.

	A	B	C	D	E	F	G	H	I	J	K	L	
1	file	num	X1	Y1	X2	Y2	lenght	delta_X	delta_Y	tols	hcup	med_pr	
2		1	0	12.054416	21.579416	12.139083	21.664083	0.1197367	0.0846666	0.0846666	0.4000000	0.1500000	0.3
3		1	1	12.054416	36.565416	12.139083	36.650083	0.1197367	0.0846666	0.0846666	0.4000000	0.1500000	0.3
4		1	2	12.054416	41.56075	12.139083	41.603083	0.0946602	0.0846666	0.0423333	0.4000000	0.1500000	0.3
5		1	3	12.054416	46.556083	12.09675	46.640750	0.0946602	0.0423333	0.0846666	0.4000000	0.1500000	0.3
6		1	4	12.054416	61.542083	12.16025	61.584416	0.1139859	0.1058333	0.0423333	0.4000000	0.1500000	0.3
7		1	5	12.054416	76.570416	12.117916	76.54925	0.0669348	0.0634999	-0.0211666	0.4000000	0.1500000	0.3
8		1	6	12.054416	81.56575	12.139083	81.586916	0.0872724	0.0846666	0.0211666	0.4000000	0.1500000	0.3
9		1	7	12.054416	86.561083	12.16025	86.561083	0.1058333	0.1058333	0.0	0.4000000	0.1500000	0.3
10		1	8	12.054416	96.55175	12.16025	96.530583	0.1079292	0.1058333	-0.0211666	0.4000000	0.1500000	0.3
11		1	9	12.054416	101.54708	12.139083	101.56825	0.0872724	0.0846666	0.0211666	0.4000000	0.1500000	0.3
12		1	10	12.054416	116.57541	12.075583	116.49075	0.0872724	0.0211666	-0.0846666	0.4000000	0.1500000	0.3

Рис. 6 — Пример выходного файла  
Fig. 6 — Sample output file

Для последующего анализа данные предварительно очищены и нормализованы. Анализ проводился при помощи языка программирования Python и библиотек Numpy и Scikit-learn.

Для исследования возможностей прогнозирования величины деформации, на первом этапе в рамках данной статьи выбраны восемь классических алгоритмов классификации, с целью оценить существующую зависимость и выявить алгоритм, который справляется с задачей лучшего всего. Основной метрикой решения задачи классификации выбран показатель accuracy, который показывает долю правильных ответов алгоритма, то есть показывает, насколько точно алгоритм предсказывает значения класса для объектов.

Для проведения исследования данные о величине деформации разделены на три равные по количеству значений группы, разделение осуществлялось в ходе анализа результатов с использованием языка Python и библиотеки Numpy. Такое разделение выбрано как базовое для первичных исследований, в дальнейшем предполагается использовать другие методы (например: алгоритмы кластеризации).

Данные о величине смещения (Lenght) разделены на три группы по значению (меньше 0.3, меньше 0.5 и больше 0.5) (Рис. 7), затем к размеченным таким образом данным применялись базовые алгоритмы классификации, результаты применения обученных алгоритмов к тестовому набору данных сведены в Таблице 1.




Рис. 7 — Распределение групп в выборке  
Fig. 7 — Distribution of groups in the sample



Положительный результат применения базовых алгоритмов позволит перейти к решению задачи регрессии и сделать вывод, о том, что величина деформации имеет зависимость от положения на плате.

Для оценки использовались стандартные метрики классификации:

- Accuracy — показывает долю правильных ответов алгоритма;
- Precision — показывает долю объектов, названных классификатором положительными и при этом действительно являющимися положительными;
- Recall — показывает долю объектов положительного класса из всех объектов положительного класса нашёл алгоритм;
- F1-score — метрика, агрегирующая значения precision и recall.

Отобрано восемь наиболее популярных алгоритмов для решения задачи классификации, также приведённые алгоритмы имеют базовую реализацию во многих библиотеках для анализа данных, для эксперимента использовалась реализация из Python библиотеки Sklearn (version 1.1.1). Отличие алгоритмов заключается в исследуемых зависимостях, так Логистическая регрессия, K-nn, SVC, Adaboost относится к группе линейных алгоритмов, а оставшаяся часть к группе нелинейных алгоритмов.

Результаты обработки данных приведены в Таблице 1.

**Таблица 1. Результаты применения алгоритмов классификации**  
**Table 1. Results of classification algorithms**

Алгоритмы	Метрики	Class «малое смещение»	Class «среднее смещение»	Class «большое смещение»	Accuracy
Логистическая регрессия	precision	0,000	0,361	0,389	<b>0,374237</b>
	recall	0,000	0,556	0,524	
	f1-score	0,000	0,438	0,446	
K-nn	precision	0,653	0,504	0,781	<b>0,629426</b>
	recall	0,721	0,574	0,604	
	f1-score	0,686	0,537	0,681	
SVC	precision	0,568	0,424	0,591	<b>0,534799</b>
	recall	0,639	0,355	0,620	
	f1-score	0,602	0,386	0,605	
Дерево решений	precision	0,859	0,751	0,864	<b>0,822344</b>
	recall	0,873	0,771	0,829	
	f1-score	0,866	0,761	0,846	
Случайный лес	precision	0,867	0,755	0,874	<b>0,829670</b>
	recall	0,892	0,778	0,825	
	f1-score	0,879	0,766	0,849	
AdaBoost	precision	0,625	0,415	0,590	<b>0,534799</b>
	recall	0,554	0,446	0,606	
	f1-score	0,587	0,430	0,598	
QDA	precision	0,990	0,704	0,827	<b>0,818071</b>
	recall	0,807	0,829	0,817	
	f1-score	0,889	0,762	0,822	
MLP	precision	0,549	0,395	0,560	<b>0,517094</b>
	recall	0,622	0,274	0,665	
	f1-score	0,583	0,323	0,608	

Так как выборка заранее сбалансирована, то есть количество примеров для каждого класса примерно равно, то можно ориентироваться на accuracy, в ситуации не сбалансированной





выборки необходимо обращать внимание на другие метрики. Значения таблицы раскрашены по увеличению точности (зелёный — наилучшая точность, красная — худшая, жёлтый — средняя).

В результате применения восьми классических алгоритмов наилучшие результаты показали алгоритмы на основе деревьев решений и QDA (Quadratic Discriminant Analysis), данные алгоритмы являются нелинейными, из чего можно сделать вывод о нелинейности зависимости признаков и целевой переменной.

Для регрессионного анализа использовались несколько подходов с разным количеством входных признаков, а также разным целевым значением. На первом этапе алгоритмы регрессии применялись для данных, у которых было всего два признака:  $X_2$ ,  $Y_2$ , в качестве целевого значения выступала величина деформации. В качестве метрик использовалась среднеквадратичная ошибка (MSE) и коэффициент детерминации ( $R^2$ ). Для проводимых исследований входной набор данных по всем платам был поделён на обучающую и тестовую выборку в соотношении 80:20% (стандартное распределение данных для задач классификации). Данные эксперимента приведены в Таблице 2.

**Таблица 2. Результаты применения алгоритмов регрессии**  
**Table 2. Results of classification algorithms**

№ эксп	Используемый метод	Кол-во переменных на вход	Целевая переменная	MSE*	$R^2$ *
1	Линейная регрессия	2	length	0,0140	0,0100
	BayesianRidge	2	length	0,0140	0,0100
	Полиномиальная регрессия**	2	length	0,0110	0,2300
	Случайный лес	2	length	0,0140	0,0088
2	Линейная регрессия	4	length	0,0140	0,0230
	BayesianRidge	4	length	0,0140	0,0100
	Полиномиальная регрессия	4	length	0,0011	0,9200
	Случайный лес	4	length	0,0024	0,8300
3	Линейная регрессия	4	delta	0,0027	0,8700
	BayesianRidge	4	delta	0,0027	0,8700
	Полиномиальная регрессия	4	delta	0,0027	0,8700
	Случайный лес	4	delta	0,0024	0,8800
*MSE стремится к 0; $R^2$ стремится к 1 или -1(обратная зависимость)					
** Полиномиальная регрессия представлена многочленом 4-ой степени					

Для эксперимента №1 с 2 ( $X_2$ ,  $Y_2$ ) переменными предсказанием length по метрикам сильного различия практически нет, а их численное значение свидетельствует о не качественной модели регрессии. Значение MSE должно стремиться к 0, а значение  $R^2$  должно стремиться к 1.

Для эксперимента №2 в качестве признаков использовались четыре переменные:  $X_1$ ,  $X_2$ ,  $Y_1$ ,  $Y_2$ , целевое значение осталось тем же.

При таких входных данных результаты полиномиальной регрессии и регрессии случайного леса показывают результаты значительно лучше остальных алгоритмов, что ещё раз свидетельствует о нелинейности зависимости величины деформации от параметров ПП.

В последнем эксперименте №3 создавалось две модели регрессии, на вход подавалось четыре признака:  $X_1$ ,  $X_2$ ,  $Y_1$ ,  $Y_2$ , а в качестве целевого признака для одной модели использовался признак  $\Delta X$ , для другой  $\Delta Y$ , для подсчёта метрик из полученных значений  $\Delta X$  и  $\Delta Y$

Khomutskaya, O.; Kopylov, D.; Vantsov, S.

Plane strain predictive estimation method;

2022; AlfaBuild; 25 Article No 2504. doi: 10.57728/ALF.25.4



складывалось значение признака length и относительно этого значения производился расчёт метрик. Формула расчёта признака:  $length = (\Delta X^2 + \Delta Y^2)^{1/2}$ .

При таком подходе наблюдается значительное улучшение для всех моделей и при базовой реализации моделей однозначно лучшую выделить сложно. Из таких результатов можно сделать предположение, что смещение по каждой из осей является линейным и возможно применение разных моделей для двух составляющих деформации.

В ходе трёх экспериментов по применению алгоритмов регрессии получены различные по качеству результаты. Такие результаты связаны с разными подходами, так в первом эксперименте получена наихудшая точность, этот результат связан с недостатком информации, так как использовался не весь набор экспериментальных данных, в связи с этим искомая зависимость становилась не моделируема.

В результате второго и третьего эксперимента удалось построить регрессионную модель для плоскостной деформации с высокими метриками точности, но для второго эксперимента значение метрик для разных алгоритмов имеет значительный разброс, такого рода показатели связаны с тем, что используемые алгоритмы регрессии имеют разные модели в своей основе (линейные или полиномиальные), и для исследуемого процесса характерна полиномиальная зависимость.

Результаты третьего эксперимента позволяют сделать предположение, что смещения реперных точек на заготовке из стеклотекстолита для печатной платы по каждой из осей является линейным, что упрощает построение регрессионной модели.

В рамках дальнейших исследований планируется изучить возможность применения алгоритмов CV для прогнозирования зон или точек деформации (как пример сегментация изображения с зонами повышенной деформации), а также гибридной обработки изображений в связке с табличными данными деформации.

## 4 Conclusions / Выводы

Использование предложенного метода позволяет обеспечить значительное улучшение прогностических возможностей для всех видов регрессионных моделей.

Для анализа деформации заготовок для печатных плат использование алгоритмов классификации и регрессии позволяет сделать заключение о том, что существует строгая линейная зависимость между положением отверстия на плате и величиной деформации базового материала.

По результатам эксперимента выявлена нелинейная зависимость величины деформации от параметров печатной платы.

Определено, что для выявления зависимостей деформации от положения реперных точек наиболее эффективным является алгоритм обработки первичных массивов данных по критериям precision, recall, f1.

Предложенный способ дает возможность исследовать деформацию многослойных печатных плат, представляющих собой структуру из нескольких отдельных плоских слоев, соединяемых в ходе технологического процесса. Тем самым, полученные с использованием этого способа данные для каждого слоя отдельно позволяют повысить прогнозируемость деформации всей многослойной структуры платы в целом.

Применение предложенного подхода позволяет получать новую информацию о видах зависимостей вносимых ошибок после каждого этапа технологического процесса и использовать результаты прогнозирования деформации на этапе проектирования платы.

Предложенный способ является универсальным и может быть применен для анализа и построения регрессионной модели не только плоской, но и пространственной деформации.

## 5 Fundings / Финансирование

Работа выполнена в рамках гранта Президента Российской Федерации для государственной поддержки молодых российских учёных – кандидатов наук (МК-582.2022.4).

## References

1. Baduge, S.K., Thilakarathna, S., Perera, J.S., Arashpour, M., Sharafi, P., Teodosio, B., Shringi, Khomutskaya, O.; Kopylov, D.; Vantsov, S. Plane strain predictive estimation method; 2022; *AlfaBuild*; 25 Article No 2504. doi: 10.57728/ALF.25.4



- A., Mendis, P. Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications, *Automation in Construction*. URL <https://doi.org/10.1016/j.autcon.2022.104440> (date of application: 20.11.2022).
2. Savić, D. Digital Water Developments and Lessons Learned from Automation in the Car and Aircraft Industries, *Engineering*. URL: <https://doi.org/10.1016/j.eng.2021.05.013> (date of application: 20.11.2022).
  3. Richter, L., Lehna, M., Marchand, S., Scholz, C., Dreher, A., Klaiber, S., Lenk, S. Artificial Intelligence for Electricity Supply Chain automation, *Renewable and Sustainable Energy Reviews*. URL: <https://doi.org/10.1016/j.rser.2022.112459> (date of application: 20.11.2022).
  4. Bowler, A.L., Pound, M.P., Watson, N.J. A review of ultrasonic sensing and machine learning methods to monitor industrial processes, *Ultrasonics*. URL: <https://doi.org/10.1016/j.ultras.2022.106776> (date of application: 20.11.2022).
  5. Liu, D., Xu, L., Lin, X., Wei, X., Yu, W., Wang, Y., Wei, Z. Machine Learning for Semiconductors, *Chip*. URL: <https://doi.org/10.1016/j.chip.2022.100033> (date of application: 20.11.2022).
  6. Saurabh V., Prashant A., Santosh B. Industry 4.0 — A Glimpse. *Procedia Manufacturing*. 2018. 20. Pp. 233–238. DOI: [doi.org/10.1016/j.promfg.2018.02.034](https://doi.org/10.1016/j.promfg.2018.02.034)
  7. Schwab, K. The Fourth Industrial Revolution: what it means, how to respond. URL: <https://www.weforum.org/agenda/2016/01/the-fourth-industrial-revolution-what-it-means-and-how-to-respond> (date of application: 15.01.2022).
  8. What is Industry 4.0 — the Industrial Internet of Things (IIoT)?. URL: <https://www.epicor.com/en/resource-center/articles/what-is-industry-4-0/> (date of application: 25.02.2022).
  9. 4. Roblek, V., Meško, M., Krapež, A. A complexity view of Industry 4.0. *SAGE Open*. 2016. 6. DOI: [10.1177/2158244016653987](https://doi.org/10.1177/2158244016653987).
  10. Hozdić, E. Smart factory for industry 4.0: A review. *Journal of Modern Manufacturing Systems and Technology*. 2015. 7(1). Pp. 28–35
  11. Granados, G.E., Lacroix, L., Medjaher, K. Condition monitoring and prediction of solution quality during a copper electroplating process, *Journal of Intelligent Manufacturing*. 2020. 31. Pp. 285–300. DOI: [10.1007/s10845-018-1445-4](https://doi.org/10.1007/s10845-018-1445-4).
  12. Arucu, M. Industry 4.0 — holistic perspective: modelling and simulation applications in intelligent manufacturing systems, *Journal of Innovative Science and Engineering*. 2021. 5. Pp. 50–63. DOI: [10.38088/jise.816023](https://doi.org/10.38088/jise.816023).
  13. Cai, H., Jiang, L., Chao, K. Current and future of software services in smart manufacturing. *Service Oriented Computing and Applications*. 2020. 14. Pp 75–77. DOI: [10.1007/s11761-020-00293-y](https://doi.org/10.1007/s11761-020-00293-y)
  14. Vermesan, O. Artificial Intelligence for Digitising Industry — Applications. Informa UK Limited. 2022. 10. Pp. 12–17
  15. Levashkin, D., Ogini, P., Vasilyev F. Efficiency of Hybrid Cyclic Processing with the Use of Additive Technologies on CNC Machines for the Manufacture of Composite Aviation Parts due to the Reduction of Processing Errors. *Materials Science Forum*. 2019. 946. Pp. 959–965. DOI: [10.4028/www.scientific.net/MSF.946.959](https://doi.org/10.4028/www.scientific.net/MSF.946.959).
  16. Huaa, Y., Liu, X., Zhoua, S., Huang, Y., Ling, H., Yanga, S. Toward Sustainable Reuse of Retired Lithium-ion Batteries from Electric Vehicles. *Resources, Conservation and Recycling*. 2021. 168. DOI: [10.1016/j.resconrec.2020.105249](https://doi.org/10.1016/j.resconrec.2020.105249).
  17. Ripetskiy, A., Mirolyubova, T., Freylekhman, S. Analysis Of Factors That Determine The Possibility For Automation Of Smoothing Of Product Electronic Model, Obtained Through Topological Optimization For The Purpose Of Its Use In The Technological Preparation Of Additive Manufacturing. *Periodico Tche Quimica*. 2018. 15(1). Pp. 405–413.
  18. Vorunichev, D.S., Vorunicheva, K.Yu. Current capabilities of prototyping technologies for multilayer printed circuit boards on a 3D printer. *Russian Technological Journal*. 2021. 9. Pp. 1–15. DOI: [10.32362/2500-316X-2021-9-4-28-37](https://doi.org/10.32362/2500-316X-2021-9-4-28-37).
  19. Vantsov, S.V., Vasil'ev, F.V., Medvedev, A.M., Khomutskaya, O.V. Influence of Nonfunctional Contact Pads On Printed-Circuit Performance. *Russian Engineering Research*. 2020. 40(5). Pp. 442–445. DOI: [10.3103/S1068798X20050202](https://doi.org/10.3103/S1068798X20050202).
  20. Isaev, V., Korobkov, M., Vasilyev, F. The Influence of the PCB Design and the Process of their Manufacturing on the Possibility of a Defect-Free Production. *Przeglad Elektrotechniczny*. 2021. 97(3). Pp. 91–96. DOI: [10.15199/48.2021.03.18](https://doi.org/10.15199/48.2021.03.18).



21. Chvanova, M.S., Vasilyev, F.V., Isaev, V.V., Baranov, V.Yu. Modeling Publication Terminology Maps on Quality Assessment Problems of Printed Circuit Boards. IEEE International Conference "Quality Management, Transport and Information Security, Information Technologies". 2021. Pp. 267–273. DOI: 10.3390/mi13040634.
22. Minasyan, V.B., Ivanov, N.S., Malykh, E.A., Zanegin, Y.A., Douine, B. The Application of X-ray Micro-CT in the Study of HTS Tape Coils. *Inventions*. 2022. 7(3). DOI: 10.3390/inventions7030060.
23. Ming-ch'eng Adams, C.I., Baker, J.E., Kjellerup, B.V. Toxicological effects of polychlorinated biphenyls (PCBs) on freshwater turtles in the United States. *Chemosphere*. 2021. 154. Pp. 148–154 DOI: 10.1016/j.chemosphere.2016.03.102.
24. Guo, J., Guo, J., Xu, Z. Recycling of non-metallic fractions from waste printed circuit boards: A review. *Journal of Hazardous Materials*. 2020. 168(2–3). Pp. 567–590. DOI: 10.1016/j.jhazmat.2009.02.104
25. Li, T., Liang, B., Ye, Z., Zhang, L., Xu, S., Tu, T., Zhang, Y., Cai, Y., Zhang, B., Fang, L., Mao, X., Zhang, S., Wu, G., Yang, Q., Zhou, C., Cai, X., Ye, X. An integrated and conductive hydrogel-paper patch for simultaneous sensing of Chemical-Electrophysiological signals. *Biosensors and Bioelectronics*. 2022. 198, 10.1016/j.bios.2021.113855.
26. Tang, Q., Li, B., Yang, D., Ming, P., Zhang, C., Wang, Y. Review of hydrogen crossover through the polymer electrolyte membrane. *International Journal of Hydrogen Energy*. 2021. 46(42). Pp. 22040–22061. DOI: 10.1016/j.ijhydene.2021.04.050.
27. Vakilchap, F., Mousavi, S.M. Structural study and metal speciation assessments of waste PCBs and environmental implications: Outlooks for choosing efficient recycling routes. *Waste Management*. 2022. 151. Pp. 181–194. DOI: 10.1016/j.wasman.2022.07.036.
28. Ghimire, H., Ariya, P.A. E-wastes: bridging the knowledge gaps in global production budgets, composition, recycling and sustainability implications. *Sustain. Chem*. 2020. 1. Pp. 154–182. DOI: 10.3390/suschem1020012.
29. Wang, Q., Zhang, B., Yu, S., Xiong, J., Yao, Z., Hu, B., Yan, J. Waste-printed circuit board recycling: focusing on preparing polymer composites and geopolymers. *ACS Omega*. 2020. 5. Pp. 17850–17856. DOI: 10.1021/acsomega.0c01884.
30. Kakria, K., Thirumalini, S., Secco, M., Priya, T.S. A novel approach for the development of sustainable hybridized geopolymer mortar from waste printed circuit boards. *Resources, Conservatio and Recycling*. 2020. 163. DOI: 10.1016/j.resconrec.2020.105066.
31. Ortega-López, V., García-Llona, A., Revilla-Cuesta, V., Santamaría, A., San-José, J.T. Fiber-reinforcement and its effects on the mechanical properties of high-workability concretes manufactured with slag as aggregate and binder. *Journal of Building Engineering*. 2021. 43. DOI: 10.1016/j.job.2021.102548.
32. Revilla-Cuesta, V., Skaf, M., Santamaría, A., Hernández-Bagaces, J.J., Ortega-López, V. Temporal flowability evolution of slag-based self-compacting concrete with recycled concrete aggregate. *Journal of Cleaner Production*. 2021. 299. DOI: 10.1016/j.jclepro.2021.126890.
33. Kulikov, N., Khomutskaya, O., Vantsov, S. Tsifrovoy metod avtomatizirovannoi otsenki deformatsii pechatnoi platy. *Elektronika: Nauka, tekhnologiya, biznes*. 2018. 2(173). Pp. 186–191.
34. Adibhatla, V.A., Chih, H.C., Hsu, C.C., Cheng, J., Abbod, M.F. Applying deep learning to defect detection in printed circuit boards via a newest model of you-only-look-once. *Mathematical Biosciences and Engineering*. 2021. 18(4). Pp. 4411–4428. DOI: 10.3934/mbe.2021223.
35. Tao, Y., Bao, Y., Liu, Q., Liu, L., Zhu, J. Application of Deep-Learning Algorithm Driven Intelligent Raman Spectroscopy Methodology to Quality Control in the Manufacturing Process of Guanxinling Tablets. *Molecules*. 2022. 27. Pp. 1–23. DOI: 10.3390/molecules27206969.
36. Adibhatla, V.A., Chih, H.C., Hsu, C.C., Cheng, J., Abbod, M.F., Shieh, J.S. Defect Detection in Printed Circuit Boards Using You-Only-Look-Once Convolutional Neural Networks. *Electronics*. 2020. 9. Pp. 345–361. DOI: 10.3390/electronics9091547.
37. Ismail, A., Elpeltagy, M., Zaki, M.S., Eldahshan, K. A New Deep Learning-Based Methodology for Video Deepfake Detection Using XGBoost. *Sensors*. 2021. 21. Pp. 73–110. DOI: 10.3390/s21165413.