

СОВЕРШЕНСТВОВАНИЕ СИСТЕМЫ ПРИЕМОЧНОГО ВЫБОРОЧНОГО КОНТРОЛЯ КАЧЕСТВА ДЕТАЛЕЙ С ПРИМЕНЕНИЕМ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ

Волков И.А. (ИТМО)

Научный руководитель – кандидат технических наук, доцент Андреев Ю.С.
(ИТМО)

Введение. В приборостроительном производстве, особенно при изготовлении деталей на станках с ЧПУ, статистический приемочный контроль по альтернативному признаку остается ключевым инструментом подтверждения качества партий продукции [1]. В Российской Федерации нормативная база такого контроля регламентируется ГОСТ Р 50779.52-95 [2], предусматривающим выбор планов контроля на основе нормативного уровня несоответствий и заданных рисков поставщика и потребителя.

Однако классический подход предполагает априорную оценку ожидаемого уровня дефектности партии. На практике эта оценка часто формируется экспертно либо на основе ограниченной ретроспективной информации, что не учитывает сложные производственные взаимосвязи: параметры обработки, состояние оборудования, квалификацию оператора, загрузку смены и др. [3]. В условиях цифровизации производства и накопления больших массивов данных возникает возможность перехода от экспертной оценки дефектности к прогнозу уровня дефектности, основанному на обработке исторических данных с помощью алгоритмов машинного обучения (Machine Learning, ML) [4].

Цель настоящего исследования – разработка методики интеграции ML-модели в процедуру выбора параметров плана выборочного контроля (n , A_c) с сохранением нормативных ограничений по рискам сторон.

Основная часть. Предлагаемая методика основана на трех этапах.

1. Прогнозирование уровня дефектности партии. На основе производственных данных (параметры обработки, время цикла, межоперационные отклонения, информация об операторе и станке) обучается ML-модель классификации, прогнозирующая интервал ожидаемой дефектности партии. Модель формирует принадлежность партии к одной из групп дефектности, соответствующих интервалам ожидаемого уровня несоответствий (по ГОСТ Р 50779.52-95).

2. Трансляция прогноза в параметры плана контроля. Полученный номер группы дефектности используется как входной параметр для выбора допустимого плана контроля по таблицам стандарта ГОСТ Р 50779.52-95. Далее автоматически рассчитываются объем выборки n и приемочное число A_c на основе гипергеометрического распределения. Таким образом, ML-модель не заменяет нормативную методику, а уточняет исходные данные для ее применения.

3. Обеспечение нормативных рисков. Ключевым условием является соблюдение ограничений риска потребителя (β_0) и риска поставщика (α_0).

Переход к прогнозной оценке уровня дефектности позволяет динамически изменять параметры плана контроля: при низком прогнозируемом уровне дефектности возможно уменьшение объема выборки при сохранении допустимого риска, а при повышенном прогнозе дефектности объем выборки увеличивается, что повышает вероятность недопуска несоответствующей партии.

В отличие от традиционного статического выбора плана, предлагаемый механизм реализует адаптивный приемочный контроль, где параметры контроля зависят от цифрового профиля партии.

Экономический эффект достигается за счет:

- сокращения трудоемкости операций технического контроля при стабильных процессах;
- снижения вероятности поставки дефектной продукции;
- уменьшения совокупных потерь от брака и повторных проверок.

Важно подчеркнуть, что алгоритм машинного обучения функционирует в контуре поддержки принятия решений и не нарушает нормативной согласованности процедур контроля поставщика и потребителя.

Выводы. Предложенная методика позволяет получить следующие результаты:

1. Интеграция алгоритмов машинного обучения в систему приемочного контроля позволяет перейти от экспертной оценки дефектности к количественно обоснованному прогнозу.
2. Результаты ML-модели могут использоваться для автоматизированного выбора параметров плана контроля без изменения нормативной базы и с соблюдением рисков сторон.
3. Предложенная методика формирует адаптивную модель приемочного контроля, сочетающую требования стандарта ГОСТ Р 50779.52-95 и инструменты интеллектуального анализа данных.
4. Практическая реализация методики обеспечивает снижение объема выборочного контроля при стабильных процессах и повышение вероятности выявления несоответствующих партий при росте производственных рисков.

Таким образом, применение алгоритмов машинного обучения в процедурах статистического приемочного контроля является перспективным направлением цифровой трансформации системы управления качеством в высокотехнологичном приборостроительном производстве.

Список использованных источников:

1. Щеголева С.А. Методы выборочного приемочного контроля. // Учебное пособие для вузов. Инженерная школа ДВФУ. 2014.
2. ГОСТ Р 50779.52-95. Статистические методы. Приемочный контроль качества по альтернативному признаку. М.: Изд-во стандартов, 1999. 234 с.
3. Wang, C.-C., Chang, Y.-S. Dynamic Acceptance Sampling Strategy Based on Product Quality Performance Using Examples from IC Test Factory. // Mathematics 2023, № 11, 2872.
4. von Hahn, T., Mechefske, C.K. Machine Learning in CNC Machining: Best Practices. // Machines, 2022, №10, 1233.