

## **ОПТИМИЗАЦИЯ РЕМОНТНЫХ ПРОГРАММ ЭНЕРГЕТИЧЕСКОГО ОБОРУДОВАНИЯ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА**

**Бородин В.А.<sup>1</sup>, Андриюшин А.В.<sup>2</sup>, Проталинский О.М.<sup>2</sup>, Ханова А.А.<sup>1</sup>**

<sup>1</sup>*Астраханский государственный технический университет,  
Россия, г. Астрахань, ул. Татищева д.16*

<sup>2</sup>*Московский энергетический институт, Россия, г. Москва, ул. Красноказарменная д.14  
vitkt@yandex.ru, andriushinav@mpei.ru, protalinskiy@gmail.com, akhanova@mail.ru*

*Аннотация: В статье рассмотрена проблема планирования ремонтной программы на крупных энергетических предприятиях, предложена многоэкспертная система поддержки принятия решений. Рассмотрены два основных подхода для получения знаний, построена модель классификации. Предложены различные подходы взаимодействия базы знаний и исторических данных. Разработан алгоритм взаимодействия между базой продукционных правил и системой предиктивного анализа, проведён эксперимент на классической задаче классификации.*

Ключевые слова: многоэкспертные системы, предиктивный анализ, машинное обучение, энергетика, ремонтная программа.

В настоящее время энергетика является одной из самых высокоёмких отраслей промышленности. Отказы оборудования в этой отрасли приводят к серьёзным экономическим потерям и отрицательным социальным последствиям. Важную роль в снижении этого фактора играют системы управления производственными активами энергетических предприятий [1]. Основной целью функционирования таких систем является обеспечение заданного уровня надёжности или производственных рисков при удовлетворении экономических требований. Одной из основных мер сокращения риска отказов оборудования является оптимальное планирование и реализация ремонтных программ. Высокая стоимость оборудования и широкое распространение энергетических технологий приводит к существенному сокращению затрат, что даёт значительный экономический эффект. Техническим последствием оптимизации ремонтных программ является обеспечение заданной надёжности, социальным – уменьшение рутинного труда и повышения квалификации персонала. При планировании ремонтных программ источником нормативной информации являются технологические карты, представляющие организационно-технологический документ, содержащий данные о затратах на проведение работ с целью ликвидации дефектов оборудования: количество материалов, необходимость использования машин и механизмов, квалификацию и объёмы трудовых ресурсов [2].

Соответствие дефекта оборудования технологическим картам зависит от признаков оборудования, места установки и других параметров. Для принятия решения разработчикам ремонтной программы необходимо знать соответствие между признаками объекта планирования и технологическими картами. Для крупных энергетических предприятий неавтоматизированный процесс создания ремонтных программ является малоэффективным: требует реализации большого количества правил работы с организационно-технологическими документами и во многом зависит от квалификации и опыта разработчика. Эти причины делают актуальным создание системы поддержки принятия решений (СППР) для составления ремонтной программы энергетического оборудования. Целью такой системы является повышение эффективности процесса планирования, за счет оптимизации ремонтных программ и удовлетворения экономических и технических показателей.

В качестве прототипа предлагается использовать многоэкспертную систему [3], включающую в себя продукционную базу знаний, построенную на основе знания и опыта экспертов, и статистическую обработку накапливаемой информации, на основе предиктивного анализа. Сочетание этих компонентов позволяет учесть возможную неполноту и некорректность экспертных правил, как результат влияния человеческого фактора, и недостаток исторических данных, собранных во время эксплуатации оборудования. Таким образом, задачу определения способа сопоставления технологических карт обнаруженным дефектам предлагается решать на основе предыдущих сопоставлений: накопленные в результате эксплуатации исторические данные, и экспертных знаний.

Достаточный набор статистических данных позволяет достичь высокой точности решения, обучение классификаторов производится существенно быстрее, чем формализация продукционных правил экспертами. При этом качество классификаторов сильно зависит от объёма выборки и достаточного количества признаков – отсутствие данных приведет к серьёзному снижению точности классификации. Накопление достаточного объёма выборки исторических данных может занимать достаточно продолжительное время. Экспертная информация не требует продолжительного сбора и может быть основана на нормативных и внутрикорпоративных документах, а также на знаниях и опыте эксперта. База продукционных правил требует постоянной актуализации, в то же время статистическая выборка более гибка: переобучение может осуществляться при накоплении нового набора данных. Реализацию статистического подхода предлагается осуществить с использованием предиктивного анализа на основе машинного обучения, а экспертной информации в виде базы продукционных правил на основе известных методов обработки экспертных знаний.

Задача сопоставления технологических карт дефектам может быть описана в виде концептуальной модели:

),

где  $Dfs \subseteq \{Df_1, Df_2 \dots Df_m\}$  – подмножество дефектов, выявленных у единицы оборудования, принадлежит множеству типовых дефектов;  $\{Tc_n\}$  – подмножество технологических карт для устранения данных дефектов;  $\{Attr_n\}$  – аргументы функции, соответствующие значимым для сопоставления атрибутам. Каждый аргумент принадлежит своему множеству допустимых значений:  $Eqt \in \{E\}$  } – тип оборудования принадлежит множеству типов

оборудования. В качестве атрибутов используются характеристики оборудования или дефекта: географические координаты расположения оборудования, время обнаружения дефекта и другие.

Сформулированная выше задача сопоставления технологических карт может быть представлена как задача классификации с пересекающимися классами (multi-label classification), для решения которой используют подход «один против всех» (one-vs-rest). При таком подходе для каждого класса создаётся свой бинарный классификатор. Идентификации математической модели осуществлялась на основе данных о плановых показателях ремонтной программы одного из филиалов «МРСК Северного Кавказа». Данные включали в себя информацию о единице оборудования, наборе дефектов в заказе и назначенных технологических картах. В первом эксперименте использованы только наборы дефектов и технологических карт. Множества дефектов и технологических карт упорядочены, а заказы представлены в виде логической матрицы. Данные заказов на ремонт разбиты на тестовую и обучающую выборки. Для проверки возможности автоматического обучения протестировано несколько классификаторов – деревья принятия решений, байесовский классификатор, многослойный персептрон (число скрытых слоёв – 50). Для каждой технологической карты создан классификатор, обученный на заказах для определения необходимости использования технологической карты при данном наборе дефектов. По результатам классификации вычислены метрики – доля верно классифицированных объектов, точность, полнота, F-мера. Для обобщения результатов всех классификаторов выбрана концепция микро-усреднения.

Все классификаторы показали высокий процент правильно классифицированных объектов – около 80-90%. Значение остальных метрик оказалось низким. Добавление информации о типе оборудования незначительно улучшило результаты. При подробном анализе найден 441 заказ, для которых одинаковый набор дефектов приводит к разным наборам технологических карт. Исторических данных, зарегистрированных системой учёта, оказалось недостаточно для эффективного решения задачи. Помимо проблемы с конфликтующими результатами прослеживается зависимость качества классификации технологической карты от количества заказов, в которые она входит. Для решения проблемы предложена концепция объединения двух подходов – машинного обучения и базы продукционных правил. Объединение дополняет подходы – с одной стороны, в случае недостатка статистических данных система может пользоваться экспертными знаниями, с другой – неточности в правилах могут быть исправлены машинным обучением. В разработанной системе поддержки принятия решений взаимодействие базы знаний и машинного обучения регламентируется ещё одной экспертной системой (метаправила). В соответствии с ними при обнаружении конфликтующих сэмплов или недостатке исторических данных, используется информация из базы продукционных правил, при отсутствии знаний в базе используются классификаторы.

Если существует достаточное количество статистики для работы классификаторов и база правил обладает большим объёмом знаний, результат её работы представляется как результат классификатора. В машинном обучении известен ряд алгоритмов (комитет машин), объединяющих результаты нескольких классификаторов. Они делятся на статические и динамические. К статическим алгоритмам относят ансамблевые методы и бустинг. Ансамблевые методы предполагают независимое обучение классификаторов и последующее объединение результатов. Результаты могут быть усреднены, выбраны голосованием. В разработанной системе поддержки принятия решений база знаний объединена с классификаторами взвешенным голосованием.

Знания классификаторов, возникшие в результате обучения, можно импортировать в базу продукционных правил. Деревья принятия решений хранят информацию в виде дерева логических правил и имеют объяснительную способность. В случае ручного режима импорта пользователю предлагается набор правил. Он может переносить их из дерева принятия решений в базу знаний. Использование метода затрудняет то, что данные в деревьях принятия решений не всегда имеют понятный пользователю вид, так как вычислены с помощью статистики. Данный подход реализован в системе поддержки принятия решений как аналитический инструмент – пользователь может просматривать обученные деревья принятия решений и изменять правила экспертной системы в соответствии с ними. Реализована проверка соответствия продукционных правил и результатов классификации. В этом случае весь набор исторических данных проходит через правила базы знаний экспертной системы. Пользователь информируется о несовпадении результатов, после чего он может вносить корректировки в правила либо пометать исторические данные как неактуальные.

В виду отсутствия базы знаний для набора данных заказов принято решение проверить модель на известной задаче классификации. Одна из классических задач – ирисы Фишера. Это набор данных для задачи классификации, 50 экземпляров из трёх видов ириса. Для каждого экземпляра измерились

четыре характеристики. Входные данные разбиты на обучающий и тестовый наборы. Для имитации конфликтующих данных при обучении классификаторов использованы только первые два признака. В данных присутствуют сэмплы, где при одинаковых длине и ширине наружной доли околоцветника результатом являются разные виды ириса. Конфликтующие данные исключены из обучающей и тестовой выборки, учитываются в метриках как верно рассчитанные (имитация передачи конфликтующих данных в экспертную систему). Важным вопросом является имитация базы продукционных правил. Наиболее близкий к продукционной модели классификатор – дерево принятия решений. Для воссоздания неполных, но точных данных, дерево обучено на всех четырёх признаках. Для трети сэмплов обучающей выборки решения от дерева не принимались (имитация отсутствия правил для части данных). Весами классификаторов являлись значения доли верно классифицированных объектов, для «базы знаний» вес принимался за единицу. Эксперимент повторён 100 раз, результаты усреднены.

Вместе с конфликтующими сэмплами байесовский классификатор и многослойный персептрон показали около 76% и 70% верно классифицированных объектов. Исключение сэмплов из выборки повысило значение метрики до 82% и 81%. Доля верно классифицированных объектов дерева принятия решений, используемого для имитации базы знаний, составила 95%, с учётом исключения трети выборки 69%. Значение метрики для всей системы – 88%.

Исследование показало высокую эффективность объединения методов машинного обучения и базы продукционных правил. В дальнейшем функционал системы может быть расширен другими способами взаимодействия – автоматическим импортом правил из деревьев принятия решений в базу знаний или более эффективным алгоритмом объединения результатов.

## **Литература**

1. Проталинский О.М., Проталинский И.О., Кладов О.Н. Система оптимального управления производственными активами энергетических предприятий // Автоматизация и ИТ в энергетике. 2017. №4 (93).
2. Яцура А.И. Система технического обслуживания и ремонта энергетического оборудования. Справочник. М.: НЦ ЭНАС, 2006.
3. Аведьян Э.Д., Ле Тхи Чанг Линь Процедуры оптимального голосования в многоэкспертных бинарных системах // Труды МФТИ. 2017. №4 (36).