

# ОПТИМИЗАЦИОННЫЕ АЛГОРИТМЫ ВЫДЕЛЕНИЯ ИНФОРМАТИВНЫХ ПРИЗНАКОВ ДЛЯ ПРОГНОЗИРОВАНИЯ ТЕХНИЧЕСКОГО СОСТОЯНИЯ ЭЛЕКТРОМЕХАНИЧЕСКИХ СИСТЕМ ЛЕТАТЕЛЬНЫХ АППАРАТОВ<sup>1</sup>

Вересников Г.С., Скрябин А.В., Голев А.В.

*Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия*  
veresnikov@mail.ru, skryabinalexey@gmail.com, oiw23@mail.ru

*Аннотация. В статье предлагаются оптимизационные алгоритмы выделения информативных признаков для прогнозирования технического состояния электромеханических систем с применением методов спектрального анализа и анализа временных рядов. Приводятся результаты исследования разработанных алгоритмов на данных, полученных использованием математической модели электромеханического привода беспилотного летательного аппарата.*

*Ключевые слова: диагностика, прогнозирование, спектральный анализ, быстрое преобразование Фурье, оптимизационные модели, отбор признаков.*

## Введение

Актуальность прогнозирования технического состояния электромеханических систем (ЭС) обусловлена необходимостью обеспечения безопасности и эффективности эксплуатации сложных технических объектов. Особо важное значение эта проблема имеет при реализации концепции «полностью электрического самолета», в рамках которой ЭС находят широкое применение в системах управления полетом. Также в настоящее время ЭС широко применяются в промышленности, беспилотной авиации, космической технике, наземном и водном транспорте. Возможность получения прогноза, отражающего упреждающую информацию о возникновении и параметрах развития деградаций, приводящих к неисправностям в ЭС с учетом различных режимов функционирования и значимых факторов воздействия, позволяет принимать своевременные решения по предотвращению нештатных ситуаций, вызывающих нарушение работоспособности контролируемого объекта. В связи с этим построение систем ранней диагностики ЭС с использованием методов ретроспективного анализа имеет высокую практическую значимость.

В мировой научной литературе значительное внимание уделяется применению методов машинного обучения для диагностики ЭС. При оценке технического состояния ЭС используются нейронные сети [1, 2], деревья решений [3], логистическая регрессия [4], метод опорных векторов [5], k-ближайших соседей [6] и т.д. Методы машинного обучения позволяют найти в эмпирических данных неочевидные нелинейные закономерности, которые могут применяться для разделения множеств значений контролируемых параметров ЭС на классы, соответствующие обобщенным техническим состояниям контролируемого объекта. Эти закономерности формализуются в классификационных моделях, которые принимают на входе набор признаков, сформированных на основе значений контролируемых параметров (сигналов ЭС), и выдают на выходе метку класса, определяющую оценку технического состояния ЭС.

Для решения проблемы «проклятия размерности» и повышения качества классификационных моделей применяются методы извлечения и отбора признаков [7]. В частности, применение этих методов позволяет снизить количество входных параметров (признаков), повысить точность, устойчивость к шуму классификационных моделей.

Прогнозирование технического состояния ЭС на основе ретроспективных данных обычно базируется на методах анализа временных рядов, с использованием которых выполняется экстраполяция значений признаков, используемых в классификационных моделях [8, 9]. При этом на этапах извлечения и отбора признаков проблема построения прогнозных моделей обычно не рассматривается. В статье предлагаются алгоритмы, которые предназначены для поиска диапазонов интегрирования спектра стационарного сигнала, обеспечивающих максимальные показатели качества моделей прогнозирования технического состояния ЭС. В первом разделе статьи рассматриваются оптимизационные модели, на которых основаны эти алгоритмы, приводится формальное описание и рассматриваются вопросы программной реализации. Во втором разделе приводятся результаты расчетных исследований, в которых разработанные алгоритмы применяются в целях выделения

<sup>1</sup> Исследование выполнено частично за счет гранта Российского научного фонда (проект № 23-19-00464)

информативных признаков для прогнозирования деградаций электромеханического привода (ЭМП), связанных с изменением сухого трения ( $M_{CF}$ ) и люфта ( $BL$ ).

## 1. Оптимизационные модели

Пусть на основе измерений каждого контролируемого параметра с заданной периодичностью формируются множества  $M_1, \dots, M_D$  стационарных временных последовательностей, характеризующие изменение технического состояния ЭС во времени. Здесь  $D$  – количество сформированных множеств временных последовательностей. В целях упрощения будем считать мощность множеств (циклов отработки)  $M_1, \dots, M_D$  одинаковой.

Для каждой стационарной временной последовательности, входящей в множество  $M_i, i=1, \dots, D$ , строится амплитудный спектр с использованием быстрого преобразования Фурье. В результате формируется упорядоченная по времени последовательность множеств  $S_1, \dots, S_D$ , состоящих из амплитудных спектров. Далее множества  $S_1, \dots, S_D$  используются для формирования множеств  $S'_1(\bar{x}), \dots, S'_D(\bar{x})$ , состоящих из обобщенных характеристик, вычисленных на основе амплитуд спектров с номерами отсчетов, попадающими в диапазоны, задаваемые вектором  $\bar{x}$ . Нечетные и четные элементы вектора  $\bar{x}$  содержат номера отсчетов, определяющие соответственно левые и правые границы диапазонов спектра. Количество диапазонов, задаваемых вектором  $\bar{x}$ , выбирается экспертом экспериментально. Значения элементов вектора  $\bar{x}$  определяются при выполнении оптимизационных расчетов. В работе для вычисления обобщенных характеристик используется интегрирование спектра – суммирование амплитуд на информативных частотах. Проблема выбора алгоритма расчета обобщенных характеристик является предметом отдельных исследований, поэтому в статье не рассматривается.

Предлагается применять 2 подхода к обработке множеств  $S'_1(\bar{x}), \dots, S'_D(\bar{x})$ :

- множества  $S'_1(\bar{x}), \dots, S'_D(\bar{x})$  без изменения используются для оценки коэффициентов статистической регрессионной модели – построения модели тренда.
- множества  $S'_1(\bar{x}), \dots, S'_D(\bar{x})$  преобразуются статистическими методами для снижения количества входящих в них элементов, а затем используются для оценки коэффициентов статистической регрессионной модели.

Практика показывает, что предварительная обработка множеств  $S'_1(\bar{x}), \dots, S'_D(\bar{x})$  нередко обеспечивает повышение качества моделей тренда, т.к. позволяет исключить из анализа «выбросы» – данные, значительно выделяющиеся из генеральной выборки. В каждом множестве после статистической обработки может остаться по 1 элементу и тогда множества  $S'_1(\bar{x}), \dots, S'_D(\bar{x})$  преобразуются во временной ряд (например, в результате вычисления числовых характеристик случайных величин, рассчитанных на основе значений из этих множеств).

Разработаны обобщенные оптимизационные модели 1-3, в которых используются критерии оптимизации и ограничения, учитывающие выраженность и адекватность тенденций изменения признаков для прогнозирования технического состояния ЭС. Эти критерии и ограничения вычисляются на основе множеств  $S'_1(\bar{x}), \dots, S'_D(\bar{x})$  и моделей трендов, построенных на их основе.

Применение модели 1 позволяет найти диапазоны интегрирования спектра, обеспечивающие построение на основе  $S'_1(\bar{x}), \dots, S'_D(\bar{x})$  «выраженного» восходящего тренда, характеризующегося высоким уровнем адекватности соответствующей ему статистической регрессионной модели.

Модель 1. Многокритериальная оптимизационная модель для выделения информативных признаков.

$$\left\{ \begin{array}{l} \max_{\bar{x}, f \in O\{f\}, \bar{p} \in O\{\bar{p}\}} E(\bar{x}, f, \bar{p}), \\ \max_{\bar{x}, f \in O\{f\}, \bar{p} \in O\{\bar{p}\}} \{Q_1(\bar{x}, f, \bar{p}), \dots, Q_n(\bar{x}, f, \bar{p})\}, \\ d(\bar{x}) < d', \end{array} \right.$$

где  $\bar{x}$  – вектор оптимизируемых целочисленных параметров, содержащий границы диапазонов для вычисления обобщенных характеристик спектра;  $f$  – вектор категориальных значений, определяющих вид функции, используемой для построения статистических регрессионных моделей тренда;  $d(\bar{x})$  – общее или максимальное количество спектральных отсчетов, входящих в диапазоны, задаваемые вектором  $\bar{x}$ ;  $d'$  – пороговое значение для  $d(\bar{x})$ ;  $Q_1, \dots, Q_n$  – критерии, отражающие адекватность моделей тренда;  $\bar{p}$  – параметры алгоритма вычисления обобщенных характеристик на основе амплитуд спектров;  $O\{\bullet\}$  – область допустимых значений параметра/вектора  $\bullet$  (для вектора область допустимых значений представляется декартовым произведением множеств значений элементов этого вектора).

В качестве оптимизационных критериев модели 1, отражающих выраженность восходящей тенденции, задаваемой моделью тренда, например, могут использоваться:

- угол наклона линейного тренда, нормированного на максимальный элемент;
- нормированное расстояние между последним и первым значением тренда (соответствуют краям диапазона от 1 до  $D$ ) относительно максимального значения.

В качестве оптимизационных критериев модели 1, отражающих адекватность моделей тренда, могут применяться коэффициент детерминации  $R^2$ , средняя абсолютная процентная ошибка MAPE, симметричная MAPE, средняя абсолютная масштабированная ошибка MASE, средняя абсолютная масштабированная (относительно среднего уровня ряда) ошибка SMAE, относительная MAE – rMAE, средняя процентная ошибка MPE, корень из средней квадратичной ошибки RMSE, относительный rRMSE [10]. В этой статье рассматривается только коэффициент детерминации  $R^2$ , т.к. анализ эффективности использования перечисленных коэффициентов в предложенных оптимизационных моделях 1-3 является предметом отдельных исследований.

Так же список показателей  $Q_1, \dots, Q_n$  может учитывать возможность применения моделей автопрогнозирования после детрендрования временного ряда. Например, пусть для уточнения прогноза, полученного по модели тренда, используется модель ARMA( $p, q$ ), имеющая следующий вид [11]:

$$S'_t = \sum_{i=1}^p a_i S'_{t-i} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j},$$

где  $\varepsilon_t$  - гауссовский белый шум;  $a_i, \theta_j$  – оцениваемые параметры модели.

Тогда автоматизированный выбор порядка авторегрессии  $p$  и скользящего среднего  $q$  модели ARMA в рамках оптимизационных расчетов может обеспечиваться применением информационных критериев Акаике, Шварца и Хеннана-Куинна, а в качестве критериев оптимизации использоваться коэффициенты асимметрии Skewness, эксцесса Kurtosis, коэффициент Jarque-Bera и показатели точности на внутренней и внешней выборках.

Для модели 1 характерны высокие вычислительные затраты на выполнение оптимизационных расчетов, которые можно снизить посредством перевода критериев оптимизации в ограничения, получив модели 2 и 3.

Модель 2. Однокритериальная оптимизационная модель (критерий оптимизации – выраженность тренда):

$$\begin{cases} \max_{\bar{x}, f \in O\{\bar{f}\}, \bar{p} \in O\{\bar{p}\}} E(\bar{x}, f, \bar{p}), \\ Q_1(\bar{x}, f, \bar{p}) < Q'_1, \dots, Q_n(\bar{x}, f, \bar{p}) < Q'_n, \\ d(\bar{x}) < d', \end{cases}$$

где  $Q'_1, \dots, Q'_n$  – заданные пороговые значения для  $Q_1(\bar{x}, f, \bar{p}), \dots, Q_n(\bar{x}, f, \bar{p})$ .

Модель 3. Однокритериальная оптимизационная модель (критерий оптимизации – адекватность модели тренда):

$$\begin{cases} \max_{\bar{x}, f \in O\{\bar{f}\}, \bar{p} \in O\{\bar{p}\}} \{Q_1(\bar{x}, f, \bar{p}), \dots, Q_n(\bar{x}, f, \bar{p})\}, \\ E(\bar{x}, f, \bar{p}) < E', \\ d(\bar{x}) < d', \end{cases}$$

где  $E'$  – заданное пороговое значение для  $E(\bar{x}, f, \bar{p})$ .

С использованием моделей 1-3 и генетических алгоритмов, реализованных в матлаб, разработаны оптимизационные алгоритмы выделения информативных признаков для прогнозирования технического состояния ЭС. Результаты расчетных исследований этих алгоритмов приводятся в разделе 2.

## 2. Результаты расчетных исследований

Разработанные алгоритмы исследованы и верифицированы на данных, полученных с использованием моделирования отработки входных периодических треугольных сигналов ЭМП. Для моделирования деградаций ЭМП момент сухого трения последовательно изменяется от 0,25 до 1,7 с шагом 0,05, люфт изменяется от 0,05 до 1,5 с шагом 0,05. При зафиксированных значениях момента сухого трения и люфта с добавлением случайной компоненты для каждого контролируемого параметра сформированы стационарные временные последовательности  $1, \dots, D$  ( $D=30$ ), которые являются входной информацией для алгоритмов выделения информативных признаков. Эти стационарные

временные последовательности составляют множества  $M_1, \dots, M_D$ , которые требуются для применения моделей и алгоритмов, описанных в разделе 1.

В качестве контролируемых параметров ЭМП в исследовании рассматривались: положение ротора электродвигателя (ЭД), приведенное к выходному валу (град), положение выходного вала (град), напряжение ЭД (В), сила тока ЭД (А), потребляемая мощность ЭД (Вт), угловая скорость ротора ЭД (об/мин), момент ротора ЭД (мНм), мощность на валу ЭД (Вт), угловая скорость на выходном валу (град/с). Для каждого из этих параметров при отдельных деградациях ЭМП по  $M_{CF}$  и VL были построены Парето-фронты с использованием оптимизационных алгоритмов, основанных на модели 1.

Приведем графики Парето-фронтов для параметров «положение выходного вала» и «потребляемая мощность ЭД» при деградации по  $M_{CF}$ , как наиболее показательные.




Рис. 1. Парето-фронт, полученный с использованием модели 1 для параметра «Положение выходного вала» (деградация по  $M_{CF}$ )




Рис. 2. Парето-фронт, полученный с использованием модели 1 для параметра «Потребляемая мощность ЭД» (деградация по  $M_{CF}$ )

На рис. 3-4 для контролируемых параметров «Положение выходного вала» и «Потребляемая мощность ЭД» представлены динамика изменения суммы амплитуд (Data), тренд (Fit), доверительные интервалы (Confidence bounds), которые были построены на последней итерации выполнения оптимизационных расчетов по модели 1 при деградации ЭМП по  $M_{CF}$ . Каждому из этих рисунков соответствуют одна точка (решение) Парето-фронта, приведенного на рис. 1-2. Для сравнения

приводятся решения, обеспечивающие максимальный угол наклона тренда. Это связано с тем, что некоторые точки Парето-фронта с максимальным значением коэффициента детерминации  $R^2$  соответствуют 0-му углу наклона и поэтому соответствующие им модели тренда не могут использоваться для прогнозирования технического состояния ЭМП.

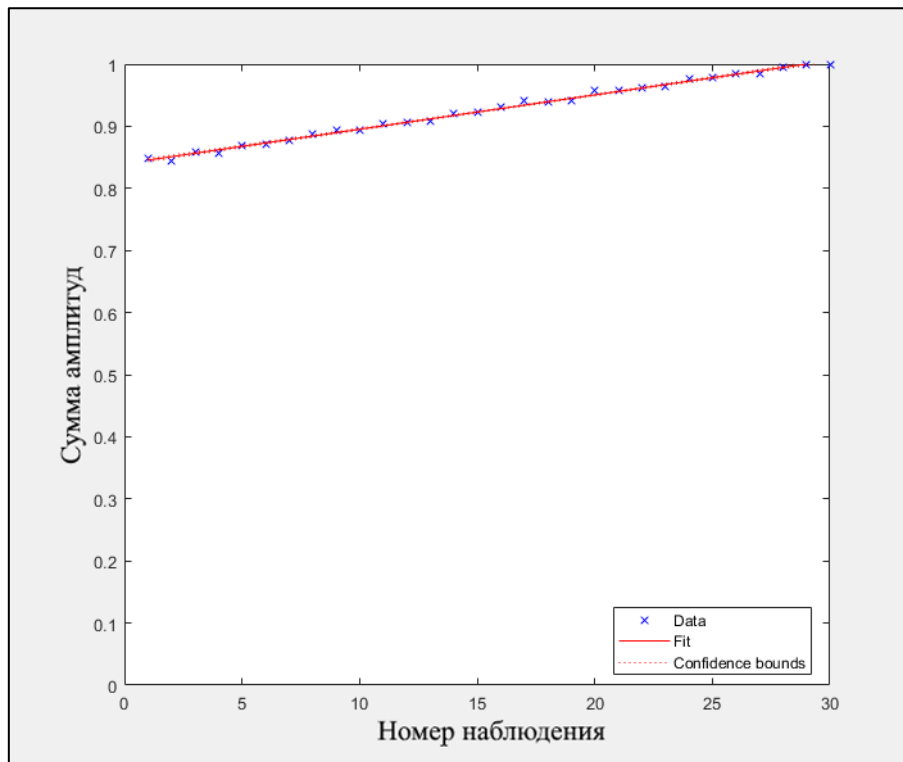


Рис. 3. Тренд для диапазона интегрирования спектра [47; 47] и  $R^2 = 0,99506$  («Положение выходного вала», деградация по  $M_{CF}$ )




Рис. 4. Тренд для диапазона интегрирования спектра [138; 138] и  $R^2 = 0.86725$ , («Потребляемая мощность ЭД», деградация по  $M_{CF}$ )

На рис. 3-4 видно, что полученные модели трендов могут использоваться при прогнозировании технического состояния ЭМП при деградации по  $M_{CF}$ .

На рис. 5-6 для параметров «напряжение ЭД» и «потребляемая мощность ЭД» представлены Парето-фронты, которые являются результатом применения алгоритма выделения информативных признаков, основанного на модели 1, при деградации ЭМП по  $BL$ .




Рис. 5. Парето-фронт, полученный с использованием модели 1 для параметра «Напряжение ЭД» (деградация по  $BL$ )




Рис. 6. Парето-фронт, полученный с использованием модели 1 для параметра «Потребляемая мощность ЭД» (деградация по  $BL$ )

Сравнение полученных Парето-фронтов показывает, что максимальные коэффициенты детерминации  $R^2$  значительно отличаются. Для параметра «Напряжение ЭД» характерны высокие углы наклона нормированного тренда и адекватность его модели. При этом для параметра «Потребляемая мощность ЭД» адекватность модели тренда можно считать низкой при высокой выраженности тренда.

На рис. 7-8 для контролируемых параметров «Напряжение ЭД» и «Потребляемая мощность ЭД» представлены динамика изменения суммы амплитуд (Data), тренд (Fit), доверительные интервалы (Confidence bounds).

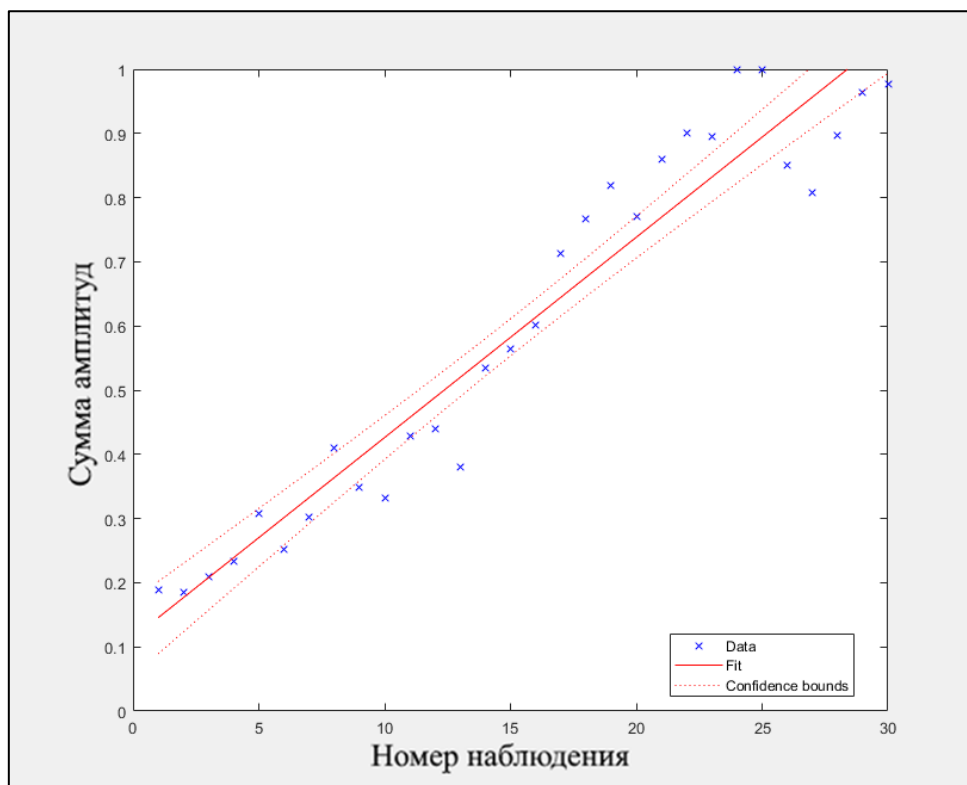


Рис. 7. Тренд для диапазона интегрирования спектра [100; 100] и  $R^2 = 0,92923$  (Напряжение ЭД, деградация по BL)

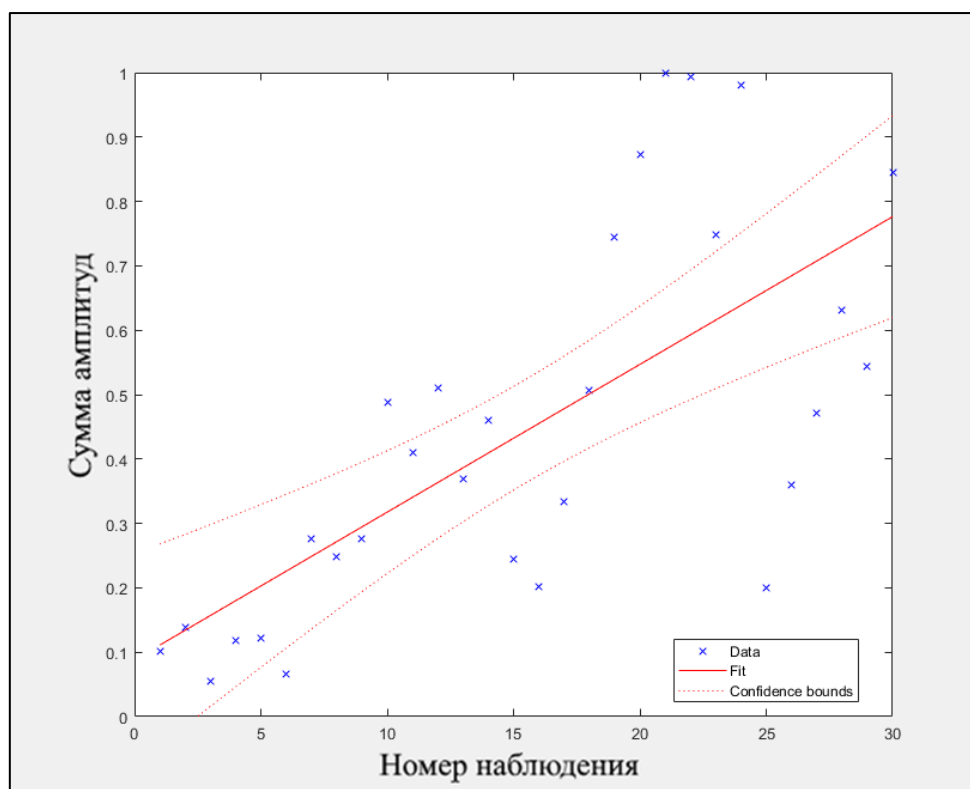


Рис. 8. Тренд для диапазона интегрирования спектра [137; 137] и  $R^2 = 0,47746$  (Потребляемая мощность ЭД, деградация по BL)

На рис. 7-8 видно, что уменьшение коэффициента детерминации ведет к снижению качества моделей прогнозирования. Соответственно модель тренда на рис. 7 можно использовать при прогнозировании технического состояния ЭМП при деградации по BL, а модель тренда на рис. 8

нельзя. Если множество Парето-решений позволяет, то рекомендуется выбирать компромиссное решение между углом наклона нормированного тренда и значением коэффициента детерминации.

Увеличение количества диапазонов интегрирования позволяет добиться смещения Парето-фронта в область «лучших» значений целевых функций. Пример представлен на рис. 9.




Рис. 9. Парето-фронт, полученный с использованием модели 1, для параметра «Угловая скорость на выходном валу» (деградация по BL), линия 1 – 1 диапазон интегрирования, линия 2 – 2 диапазона интегрирования

Таким образом, расчетные исследования показали, что применение предложенных оптимизационных моделей позволяет решать задачу формирования множества признаков, которые могут использоваться при прогнозировании технического состояния ЭС.

### 3. Заключение

Разработаны оптимизационные алгоритмы, позволяющие выделить информативные признаки для прогнозирования технического состояния ЭС. Эти алгоритмы могут применяться как в исследовательских целях при анализе одного случая деградации ЭС, так и в целях предобработки данных при построении классификационных моделей, предназначенных для реализации в системе ранней диагностики ЭС. Результаты расчетных исследований на примере диагностики технического состояния ЭМП, связанных с изменением люфта и сухого трения, показывают адекватность и перспективность дальнейшего развития разработанных алгоритмов. Дальнейшие исследования предлагается направить на повышение эффективности разработанных алгоритмов посредством поиска критериев оптимизации, позволяющих повысить точность и устойчивость к шуму прогнозных моделей.

### Литература

1. Arellano-Espitia F., Delgado-Prieto M., Martínez-Viol V., Saucedo-Dorantes J.J., Osornio-Rios R.A. Deep-Learning-Based Methodology for Fault Diagnosis in Electromechanical Systems // Sensors. – 2020. – Vol. 20, Issue 14. – P. 3949.
2. Arellano-Espitia F., Delgado-Prieto M., Martínez-Viol V., Fernández-Sobrino Á., Osornio-Rios R.A. Anomaly Detection in Electromechanical Systems by means of Deep-Autoencoder // Proceedings of the 26th International Conference on Emerging Technologies and Factory Automation (ETFA). – 2021. – IEEE, Vasteras, Sweden. – P. 21466790.
3. Azevedo B.C.F., Bressan G.M., Agulhari C.M., Santos H.L., Endo W. Three-Phase Induction Motors Faults Classification using Audio Signals and Decision Trees // Applied Mathematics & Information Sciences. – 2019. – Vol. 13, № 5. – P. 847–858.
4. Bodla M.K., Malik S.M., Rasheed M.T., Numan M., Ali M.Z., Brima J.B. Logistic regression and feature extraction based fault diagnosis of main bearing of wind turbines // Proceedings of the 11th Conference on Industrial Electronics and Applications. – 2016. – IEEE, Hefei, China. – P. 1628–1633.



5. *Shui Y., Ming G., Hai Q., Jay L., Yangsheng X.* Intelligent diagnosis in electromechanical operation systems // Proceedings of the IEEE International Conference on Robotics and Automation. – 2004. – Vol. 3. – P. 2267–2272.
6. *Borja C.A., Tisado K.J., Ostia C.* Fault Diagnosis of a Brushless DC Motor Using K-Nearest Neighbor Classification Technique with Discrete Wavelet Transform Feature Extraction // Proceedings of the 14th International Conference on Computer and Automation Engineering (ICCAE). – 2022. – IEEE, Brisbane, Australia. – P. 21760713.
7. *Hui-Man W., Xingjian C., Hui-Hin T., Jiecong L., Shixiong Z., Shankai Y., Xiangtao L., Ka-Chun W.* Feature Selection and Feature Extraction: Highlights // Proceedings of the 5th International Conference on Intelligent Systems, Metaheuristics & Swarm Intelligence. – 2021. – Victoria Seychelles. – P. 49-53.
8. *Grzesica D., Wiecek P.* Advanced Forecasting Methods Based on Spectral Analysis // Procedia Engineering. – 2016. – Vol. 161. – P. 253–258.
9. *Li W.Q., Zhang C.* Application of Combination Forecasting Model in Aircraft Failure Rate Forecasting // Computational Intelligence and Neuroscience. – 2022. – Vol. 2022. – P. 36172319.
10. *Shcherbakov M., Brebels A., Shcherbakova N.L., Tyukov A., Janovsky T.A., Kamaev V.A.* A survey of forecast error measures // World Applied Sciences Journal. – 2013. – Vol. 24. – P. 171–176.
11. *Kozitsin V., Katser I., Lakontsev D.* Online Forecasting and Anomaly Detection Based on the ARIMA Model // Applied Sciences. – 2021. – Vol. 11, № 7. – P. 3194.