

АППРОКСИМАЦИЯ РЕАКЦИЙ СМАЗОЧНОГО СЛОЯ ПОДШИПНИКОВ СКОЛЬЖЕНИЯ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

© 2023

Ю. Н. Казаков

студент кафедры мехатроники, механики и робототехники;
Орловский государственный университет имени И.С. Тургенева;
KazakYurii@yandex.ru

И. Н. Стебаков

аспирант кафедры мехатроники, механики и робототехники;
Орловский государственный университет имени И.С. Тургенева;
chester50796@yandex.ru

Д. В. Шутин

кандидат технических наук, доцент кафедры мехатроники, механики и робототехники;
Орловский государственный университет имени И.С. Тургенева;
gover.ru@gmail.com

Л. А. Савин

доктор технических наук, профессор кафедры мехатроники, механики и робототехники;
Орловский государственный университет имени И.С. Тургенева;
savin3257@mail.ru

В статье проанализировано применение различных методов машинного обучения для решения задачи аппроксимации сил смазочного слоя подшипников скольжения в статической постановке. Исходные данные о значениях сил смазочного слоя для различных положений ротора получены при помощи модели роторно-опорной системы, основанной на численном решении уравнения Рейнольдса с учётом эффекта кавитации. На основе анализа точности аппроксимации решения искусственными нейронными сетями определены способы, позволяющие снизить объём вычислений для получения необходимого набора данных. После этого были построены аппроксимирующие модели с использованием ряда иных методов машинного обучения, проанализированы длительность обучения и получаемая точность предсказаний, сделаны выводы о наиболее эффективных подходах к построению таких моделей.

Подшипники жидкостного трения; машинное обучение; точность аппроксимации; искусственные нейронные сети

Цитирование: Казаков Ю.Н., Стебаков И.Н., Шутин Д.В., Савин Л.А. Аппроксимация реакций смазочного слоя подшипников скольжения методами машинного обучения // Вестник Самарского университета. Аэрокосмическая техника, технологии и машиностроение. 2023. Т. 22, № 3. С. 108-121. DOI: 10.18287/2541-7533-2023-22-3-108-121

Введение

В роторных машинах критическими узлами выступают опорные узлы, так как фокусируют в себе основные силовые и информационные потоки. Именно в них в первую очередь интегрируются как сенсорные системы, так и средства управления режимами работы машины. Повышение точности и надёжности таких систем требует применения моделей роторно-опорных узлов, учитывающих их нелинейные свойства. Такой подход применяется в задачах анализа [1; 2], проектирования [3; 4] и управления [5; 6] роторно-опорными системами. Расчёт силовых и энергетических параметров смазочного слоя как пассивных, так и активных опор жидкостного трения производится обычно решением уравнения Рейнольдса с использованием численных методов [7 – 9]. Такие расчёты требуют значительных вычислительных ресурсов для достижения приемлемой точности, однако вычислительные средства систем управления роторными машинами почти всегда имеют ограниченную производительность.

Снизить объём вычислений в задачах расчёта движений роторов позволяет широко применяемая линеаризация динамических параметров подшипников скольжения

[7; 10], однако такой подход не отражает нелинейных свойств смазочного слоя. Это делает его мало применимым в целом ряде условий, таких как значительная эксцентричность положения ротора, наличие явлений кавитации, а особенно при применении трибогенераторных опор с системами управления движением ротора [11; 12]. Поэтому возникает необходимость в более производительных моделях, демонстрирующих при этом достаточную точность. Одним из таких подходов является применение моделей на основе методов машинного обучения, формируемых с использованием данных экспериментов и/или физических моделей нелинейных объектов [5; 10; 13 – 15].

Для подшипников скольжения необходимость расчёта статических реакций смазочного слоя возникает, в частности, в задачах: 1) поиска равновесного положения ротора; 2) расчёта текущей несущей способности подшипника; 3) предсказания смещения ротора под действием различных нагрузок; 4) параметрического синтеза опорных узлов. В последнем случае также имеет большое значение минимизация объёма генерируемых исходных данных и времени обучения моделей для сокращения затрат времени на работу оптимизационных алгоритмов.

Данная работа освещает вопросы формирования необходимого набора данных для обучения аппроксимационных моделей сил смазочного слоя подшипников скольжения с требуемой точностью на основе методов машинного обучения, а также выбора самих таких методов. При этом учитывается характер соответствующих физических зависимостей, уделяется внимание вопросам затрат времени как на генерацию данных, так и на обучение моделей. В результате формулируются комплексные рекомендации по построению моделей статических реакций смазочного слоя подшипников скольжения с использованием методов машинного обучения.

1. Модели и методы

1.1 Модель подшипника

Базовым объектом для исследования является радиальный подшипник жидкостного трения, расчётная схема которого приведена на рис. 1.

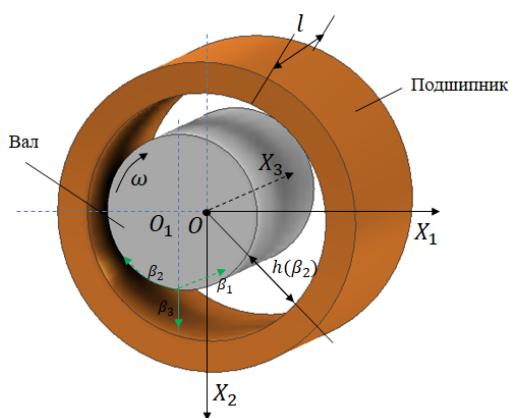


Рис. 1. Расчётная схема подшипника скольжения

На рис. 1 O, O_1 – геометрические центры подшипника и вала соответственно; X_i – координаты подшипника; $h(\beta_2)$ – зазор подшипника.

В качестве модели подшипника рассматривается течение вязкой несжимаемой жидкости в канале длиной l , образуемом двумя цилиндрами – валом и подшипником. Подшипник радиусом $R = r + h_0$, где r – радиус вала; h_0 – радиальный зазор, неподвижен. В свою очередь, вал вращается в подшипнике с постоянной частотой n и угловой

скоростью ω . Смазывающее вещество подаётся с одного торца подшипника под давлением p_0 . Поле скоростей двумерное и характеризуется вектором $\bar{V} = [V_1 \ V_2]$. Уравнения, описывающие движения среды, удобно представлять в цилиндрических координатах β_i , где $\beta_1, \beta_2, \beta_3$ – соответственно радиальная, угловая и осевая координаты. Цилиндрические координаты характеризуются коэффициентами Ламе: $H_1 = H_3 = 1, H_2 = \beta_1$. Распределение давления смазочного материала в подшипнике определяется на основе обобщённого уравнения Рейнольдса [5]:

$$h^3 \frac{\partial}{\partial \beta_1} \left(\beta_1 \frac{\partial p}{\partial \beta_1} \right) + \frac{1}{\beta_1} \frac{\partial}{\partial \beta_2} \left(h^3 \frac{\partial p}{\partial \beta_2} \right) = \mu u_1 6h + \mu u_2 6 \frac{\partial h}{\partial \beta_2} - 12 \mu u_3 \beta_1 \quad (1)$$

где $u_1 = 0$, $u_2 = \omega r + V_1 \cos\left(\frac{\beta_1^- \beta_2}{r}\right) - V_2 \sin\left(\frac{\beta_1^- \beta_2}{r}\right)$, $u_3 = V_1 \sin\left(\frac{\beta_1^- \beta_2}{r}\right) + V_2 \cos\left(\frac{\beta_1^- \beta_2}{r}\right)$ – компоненты вектора скоростей смазочной жидкости на поверхности вала, μ – вязкость смазочного материала, p – давление жидкости; h – значение зазора смазочного слоя.

Кавитация учитывалась на основе гипотезы Гумбеля [5; 16]. Уравнение (1) решается методом конечных разностей [5; 7]. Результатом решения является поле давления смазочного материала в подшипнике.

Реакции смазочного слоя рассчитываются интегрированием поля давления подшипника, для чего применяется метод численного интегрирования Симпсона:

$$\begin{aligned} R_1 &= - \int_{\beta_2^-}^{\beta_2^+} \int_{\beta_1^-}^{\beta_1^+} p \cos \varphi \beta_1 d\beta_1 \beta_1 d\beta_2, \\ R_2 &= - \int_{\beta_2^-}^{\beta_2^+} \int_{\beta_1^-}^{\beta_1^+} p \sin \varphi \beta_1 d\beta_1 \beta_1 d\beta_2, \end{aligned} \quad (2)$$

где φ – угол положения окрестности точки β_i на поверхности внутреннего цилиндра в координатах X_j .

Расчёты в данной работе проводились для образца подшипника длиной $l = 60$ мм, радиусом $R = 20$ мм, с зазором $h_0 = 120$ мкм, водой в качестве смазочного материала с вязкостью $\mu = 0,001$ Па·с при температуре $T = 20^\circ\text{C}$. Рабочая частота вращения вала $n = 3000$ об/мин .

1.2 Методы аппроксимации и оценка точности

Требования к точности модели для аппроксимации базируются на типовой точности применяемых в роторных системах первичных преобразователей положения ротора. В подавляющем большинстве случаев для этого применяются вихретоковые преобразователи перемещений [17; 18]. Типичная точность измерения положения ротора с их помощью обычно составляет 3 – 5% с учётом неравномерности магнитных свойств ротора [18], поэтому точность аппроксимации также не должна быть хуже 3 – 5%.

Для оценки точности аппроксимации применены две ключевые метрики, среднее (MEAN) и медианное (MED) значения ошибки:

$$MEAN = \frac{\sum_{i=1}^N e_i}{N}, \quad (3)$$

$$MED = \frac{e_{N/2} + e_{N/2}}{2}, \quad (4)$$

где N – количество точек в анализируемой выборке, e – ошибка аппроксимации.

Представленная в разделе 1.1 вычислительная модель на основе уравнения Рейнольдса была ранее верифицирована с использованием данных экспериментальных исследований [5; 13]. Это даёт основания использовать генерируемые с её помощью значения силовых параметров смазочного слоя в качестве эталонных при оценке точности моделей на основе методов машинного обучения.

В качестве базового метода аппроксимации сил смазочного слоя применены полносвязные искусственные нейронные сети (ИНС), поскольку они хорошо подходят для решения задач аппроксимации и классификации с небольшим количеством входных признаков [5; 15; 19]. В данном исследовании использовались ИНС с одним скрытым слоем и линейной функцией активации.

В качестве параметров, описывающих набор исходных данных, выбраны размеры сетки исходных данных о значениях сил смазочного слоя. Для построения сетки использована полярная система координат и равномерное распределение 12 точек по радиальной (т.е. по эксцентричеситету положения ротора) и 40 точек по окружной (т.е. по углу положения ротора в подшипнике) координатам. В ходе исследования определялась возможность снижения плотности сетки по каждой из координат для снижения затрат времени на генерацию исходных данных.

2. Результаты

2.1. Особенности исходного набора данных

Реакции смазочного слоя R_1 и R_2 имеют нелинейный вид и существенно возрастают в области высоких эксцентрикитетов положения ротора. Кроме того, результаты расчётов с использованием численных методов, таких как использованный метод конечных разностей, чувствительны к размерности расчётной сетки, особенно в области высоких эксцентрикитетов. На рис. 2 показаны варианты рассчитанных реакций смазочного слоя при меньшей (30×30) и большей (60×60) плотности расчетной сетки.

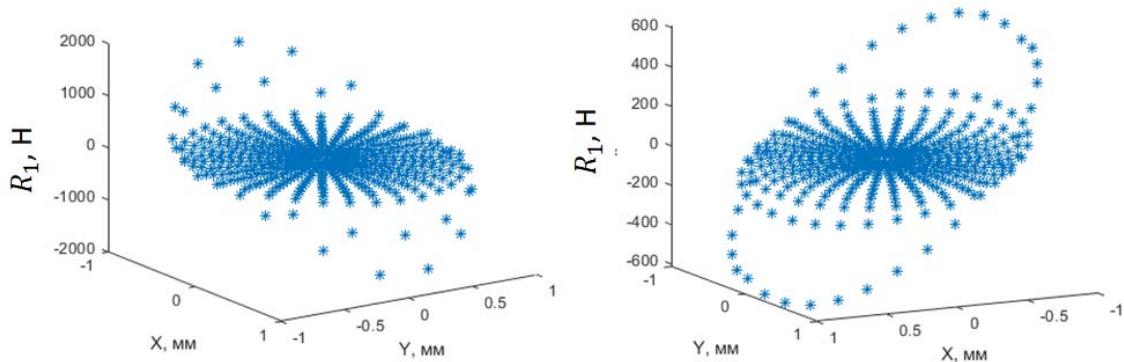


Рис. 2. Реакции смазочного слоя при изменениях эксцентричности положения ротора

Из рис. 2 видно, что сетка меньшей плотности даёт нестабильные значения реакций в области высоких эксцентрикитетов из-за расчётной ошибки при большом шаге конечно-разностной сетки. Данное явление наиболее выражено для диапазона эксцентрикитетов от 0,9 до 1. Уплотнение конечно-разностной сетки снижает вычислительную ошибку, однако при этом экспоненциально возрастают затраты машинного времени на вычисления. Поэтому для обеспечения приемлемой точности исходных данных и объёма необходимых для этого вычислений исходный набор данных о силах смазочного слоя генерировался и аппроксимировался раздельно для областей больших ($\geq 0,9$) и малых ($< 0,9$) эксцентрикитетов.

2.2. Базовый анализ точности аппроксимации с использованием искусственных нейронных сетей

2.2.1 Эксцентрикитеты до 0,9

Для выявления рациональных параметров набора данных и ИНС в области малых эксцентрикитетов был проведён ряд вычислительных экспериментов с оценкой точности решений по метрикам (3) и (4). В качестве варьируемых параметров использовались количество нейронов ИНС и количество точек сетки данных по эксцентрикитету. Для всех экспериментов количество точек сетки данных по окружной координате было зафиксировано на исходном значении 40. Оцениваемый диапазон эксцентрикитетов составил 0...0,9. Данные о точности решений приведены в табл. 1. Для тестирования точности обученных нейронных сетей использовался набор данных с количеством точек по углу 40 и диапазоном по эксцентрикитету 0,12...0,9 с количеством точек 12.

Таблица 1. Ошибка аппроксимации в зависимости от количества нейронов и количества точек по эксцентрикитету

Количество точек по эксцентрикитету	Метрика	Количество нейронов ИНС			
		10	20	50	100
4	MID	9,1	6,9	11,1	30,7
	MED	4,71	2,9	4,39	11,2
6	MID	5,74	2,78	2,59	5,63
	MED	3,18	1,73	1,34	2,12
8	MID	4,5	2,52	1,66	1,93
	MED	2,4	1,24	0,79	0,32
10	MID	4,31	3,61	2,75	2,34
	MED	2,64	2,23	1,76	0,63
12	MID	6,43	2	1,4	1,56
	MED	3,83	1,14	0,5	0,87

Из табл. 1 видно, что с увеличением количества точек по эксцентрикитету точность аппроксимации сети возрастает. Такая же тенденция наблюдается и при увеличении количества нейронов, однако начиная с 50 нейронов повышение точности прекращается. В табл. 1 наилучшие варианты выделены цветом. Лучшим вариантом можно считать ИНС с 50 нейронами, обученную на выборке данных с 12 точками по эксцентрикитету. Вместе с тем, точность решения при использовании 8 точек по эксцентрикитету лишь незначительно уступает лучшему варианту, что даёт основание снизить размерность сетки данных до соответствующего значения по радиальной координате. Детальные показатели точности для данного решения в графическом виде представлены на рис. 3.

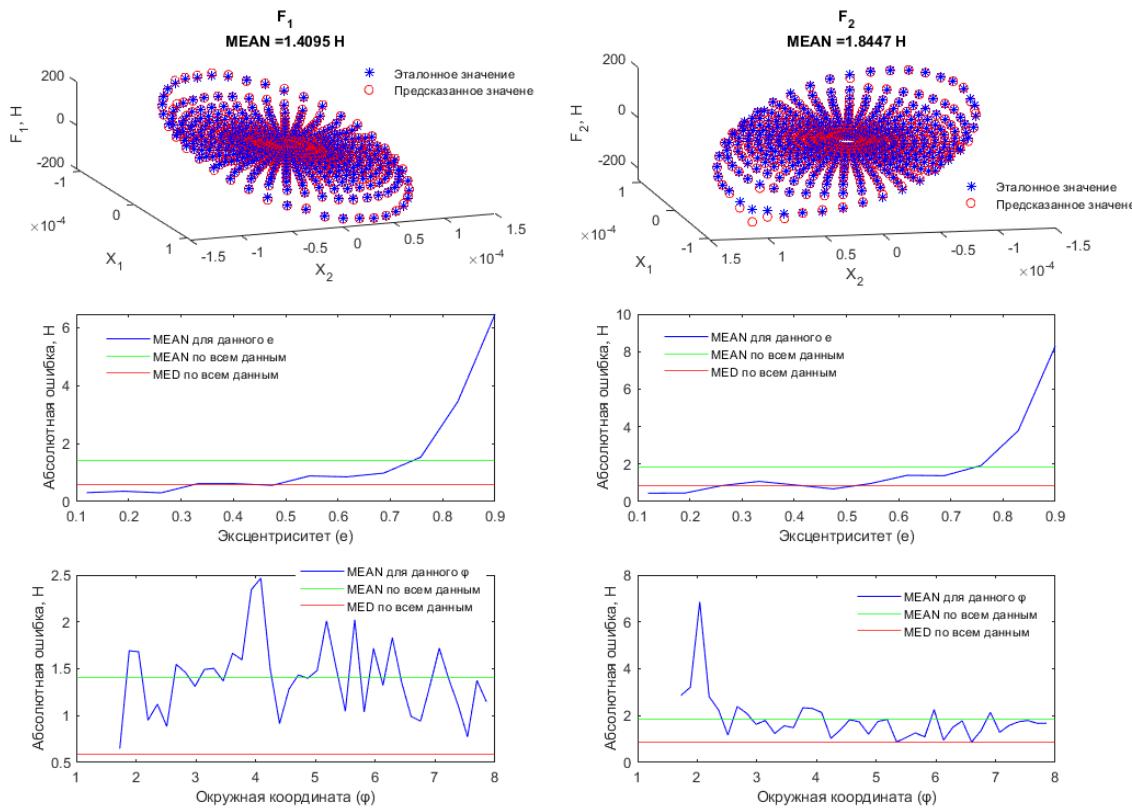


Рис. 3. Анализ точности аппроксимации в зоне малых эксцентрикитетов в зависимости от количества точек по радиальной координате

Метрики, представленные на рис. 3, показывают, что с увеличением эксцентрикитета ошибка предсказаний модели также увеличивается. Точность аппроксимации по углу изменяется без выраженной закономерности. Вместе с тем, практически во всём рассмотренном диапазоне точность решения укладывается в заданные границы и может рассматриваться как приемлемое.

Аналогичные расчёты были проведены для установления возможности снизить размерность сетки данных по окружной координате. Серия вычислений была проведена для сетки данных с фиксированным количеством в 12 точек по радиальной координате. Количество точек по окружной координате изменялось от 40 до 8. Тесты проводились на наборе данных: 60 точек по углу, 12 точек по эксцентрикитету в диапазоне 0...0,9. Результаты расчётов приведены в табл. 2.

Таблица 2. Ошибка аппроксимации в зависимости от количества нейронов и количества точек по окружной координате

Количество точек по углу	Метрика	Количество нейронов ИНС		
		20	50	100
40	MID	2	1,4	1,56
	MED	1,14	0,5	0,87
32	MID	4,1	1,89	2,14
	MED	2,39	0,84	0,38
24	MID	3,57	1,58	3,39
	MED	2,29	0,4	0,51
16	MID	2,98	4,29	6,4
	MED	1,13	1,56	2,2
8	MID	15,85	11,49	74,95
	MED	2,1	3,36	43,91

Из табл. 2 видно, что с увеличением количества точек по окружной координате точность аппроксимации возрастает. Однако точность для вариантов с 24 и 32 точками лишь незначительно уступает показателям лучшей модели. Это позволяет принять в качестве варианта, удовлетворяющего заданным критериям, размер сетки данных 8×24 в радиальном и окружном направлениях и использовать для аппроксимации данных полносвязную ИНС с 50 нейронами в скрытом слое. Показатели точности для данного решения в графическом виде представлены на рис. 4.

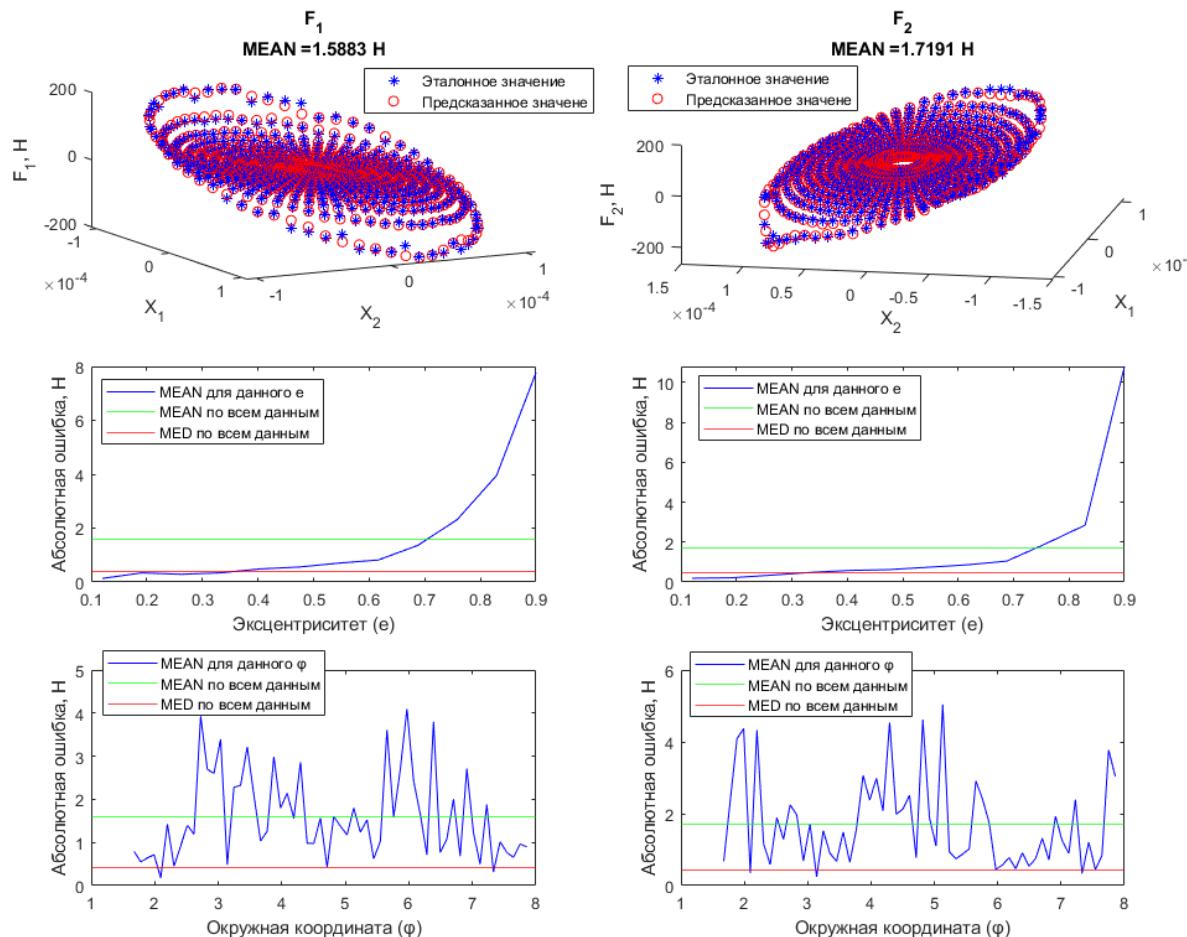


Рис. 4. Анализ точности аппроксимации в зоне малых эксцентрикитетов
в зависимости от количества точек по окружной координате

Эти метрики показывают, что с увеличением эксцентрикитета ошибка аппроксимации увеличивается. Ошибка аппроксимации с уменьшением числа точек по окружной координате до 24 увеличивается незначительно, однако дальнейшее уменьшение значительно увеличивает ошибку. Также из рис. 4 видно, что ошибка аппроксимации по углу имеет большой разброс между соседними показаниями.

2.2.2 Эксцентрикитеты до 0,9 и до 0,97

При типичных параметрах шероховатости рабочих поверхностей подшипников жидкостного трения система переходит к смешанному трению, когда достигается эксцентрикитет 0,97...0,98 и более [20]. Начинаяющиеся при этом трибологические процессы не учитываются в применяемой гидродинамической модели трения. Поэтому для данной расчётной области верхняя граница рассматриваемого эксцентрикитета была установлена на уровне 0,97.

Оценка точности аппроксимации с использованием ИНС проводилась по методике аналогичной применённой для области малых эксцентрикитетов. Был проведён ряд вычислительных экспериментов по обучению ИНС с 50 нейронами в скрытом слое. Диапазон изменения эксцентрикитета составил от 0,9 до 0,97. В свою очередь количество точек по углу и по эксцентрикитету варьировалось в большую и меньшую сторону относительно лучших значений, полученных для области малых эксцентрикитетов. Результаты расчётов представлены в табл. 3. Проверка точности аппроксимации проводилась на наборе данных с диапазоном эксцентрикитетов 0,904...0,97, количество точек составило 20, количество точек по углу составило 80.

Из табл. 3 видно, что с увеличением количества точек по окружной координате точность аппроксимации возрастает, как и в случае увеличения точек по эксцентрикитету. Однако, как отмечалось, уплотнение расчётной сетки приводит к значительному увеличению затрат времени на генерацию данных.

Другой характерной особенностью результатов является то, что количество точек по окружной координате гораздо сильнее сказывается на точности решений, чем по радиальной. Наилучшие результаты точности в табл. 3 выделены цветом. С учётом точности и времени на генерацию необходимых данных в качестве рационального размера сетки в области высоких эксцентрикитетов выбран размер 12×60 . Показатели точности для данного решения в графическом виде представлены на рис. 5.

Метрики, представленные на рис. 5, как и в предыдущих случаях, показывают увеличение ошибки с увеличением эксцентрикитета. Вместе с тем, на более высоких эксцентрикитетах рост ошибки выражен сильнее. По окружной показатели точности изменяются нестабильно, а по абсолютному значению существенно превышают заданный порог в 3 – 5%.

Таблица 3. Ошибка аппроксимации искусственной нейронной сети на больших эксцентрикитетах

Количество точек по углу	Метрика	Количество точек по эксцентрикитету		
		8	12	16
60	MID	14,1	12,9	10,19
	MED	10,8	8,8	6,89
50	MID	24,4	22,45	19,18
	MED	14	17,51	12,5
40	MID	35,45	47,67	33
	MED	12,5	16	13,9
30	MID	84,76	61,49	52,63
	MED	53,82	41,67	27,55
20	MID	210,13	348,5	589
	MED	148,21	255,3	335

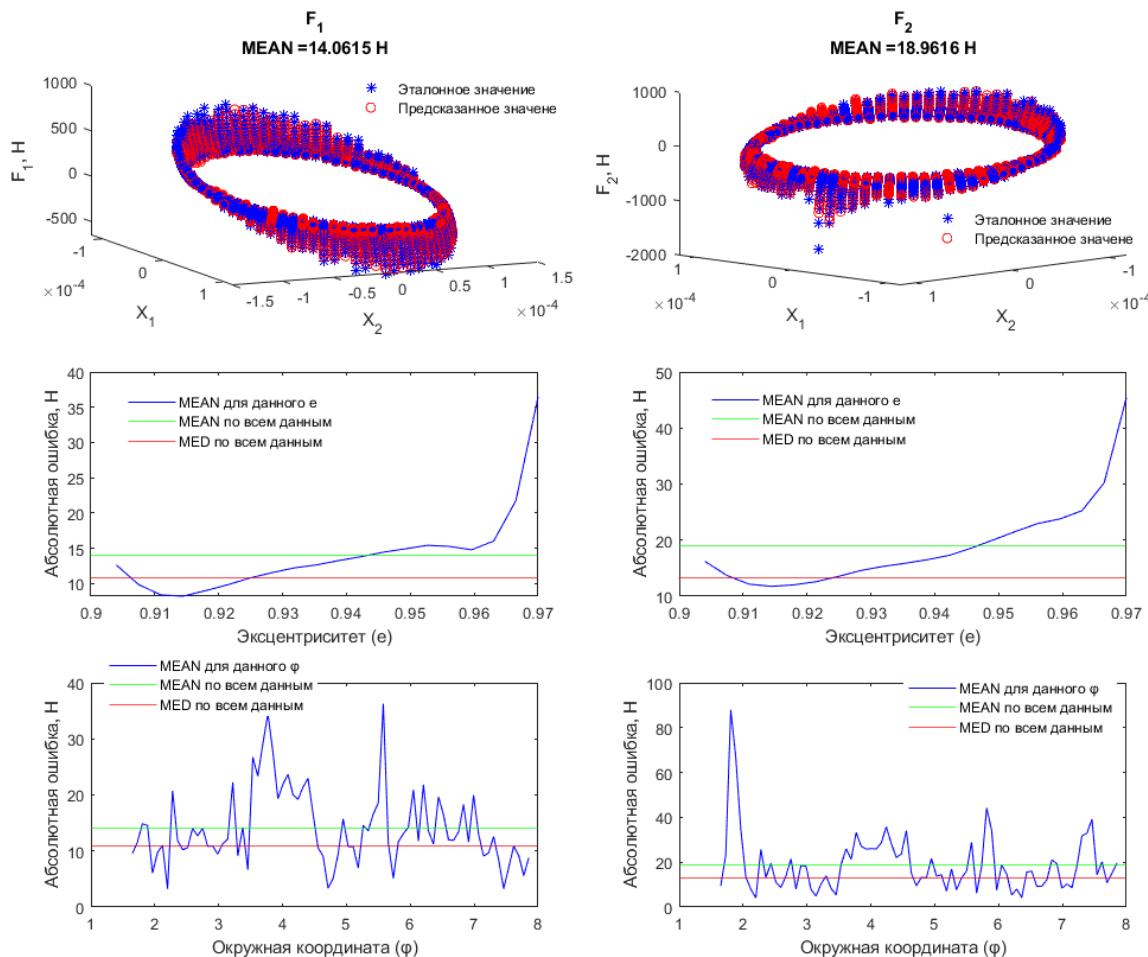


Рис. 5. Анализ точности аппроксимации в зоне больших эксцентрикитетов

Анализируя результаты раздела 2.2, можно сделать вывод, что точность аппроксимации статических реакций подшипников жидкостного трения на основе ИНС имеет тенденцию к существенному снижению с ростом эксцентричности положения вала. При этом уплотнение расчётной сетки в области высоких эксцентрикитетов не даёт значительного улучшения точности получаемых решений в этих диапазонах. Рассчитанные показатели точности следует принимать во внимание при создании и применении соответствующих моделей.

2.3. Сравнение методов машинного обучения

Помимо полносвязных ИНС для решения рассматриваемой задачи аппроксимации было также протестировано несколько других наиболее распространенных методов машинного обучения: метод линейной регрессии в стандартной модификации, а также с L1 регуляризацией; метод опорных векторов (SVR) в стандартной модификации и с множественным ядром; метод ближайших соседей (KNN); метод «случайного леса» (Random Forest); метод градиентного усиления (Gradient Boosting).

Для обучения соответствующих моделей использовался набор данных в конфигурации, определённой как наилучшая на предыдущем этапе исследования (сетка 8×24 для малых и 12×60 для больших эксцентрикитетов). Для рассмотренных методов оценивалось значение ошибки по каждой из составляющих силы (R_1 и R_2), а также замерялось необходимое для обучения модели время. Полученные показатели точности представлены в графическом виде на рис. 6, а в числовом, включая затраты времени на обучение, в табл. 4.

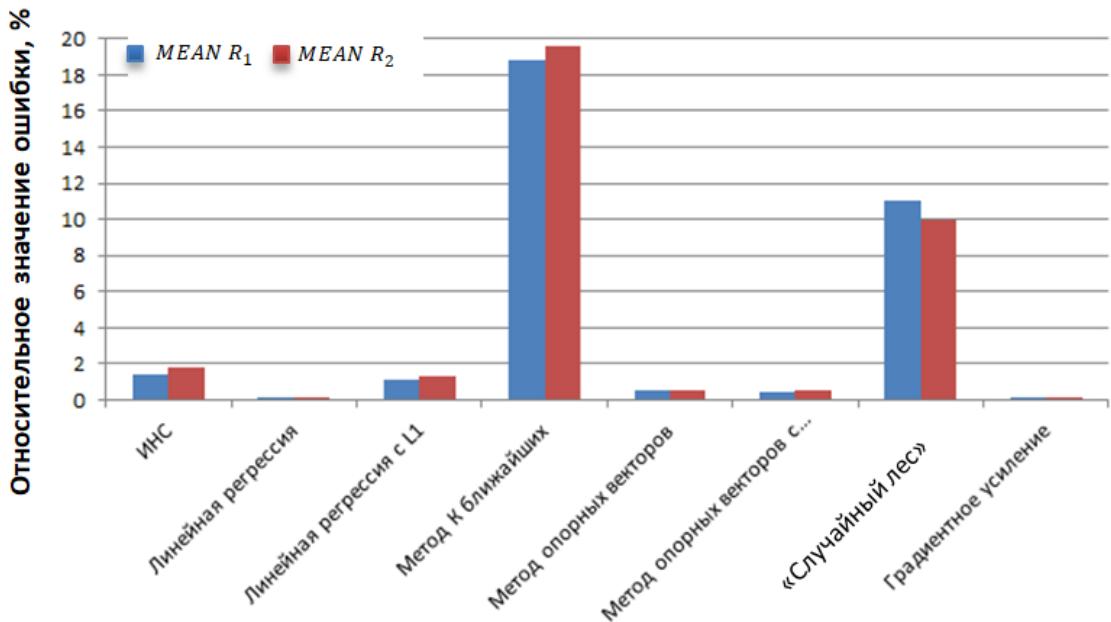


Рис. 6. Сравнение точности аппроксимации протестированных методов машинного обучения

Таблица 4. Сравнение точности аппроксимации протестированных методов машинного обучения

Параметр	ИНС	Линейная регрессия	Линейная регрессия с L1	Метод К ближайших	Метод опорных векторов	Метод опорных векторов с множественным ядром	«Случайный лес»	Градиентное усиление
MEAN R ₁ (H)	1,4	0,0195	1,1	18,8	0,518	0,477	11	0,009
MEAN R ₂ (H)	1,8	0,0428	1,29	19,6	0,51	0,517	9,98	0,008
Время обучения (с)	1	0,27	8,73	494,45	8,83	434,07	3444,93	408,42

По точности полученных решений протестированные методы машинного обучения можно разделить на две категории. Методы ближайших соседей (KNN) и «случайного леса» (Random Forest) показали ошибку, существенно превышающую заданные пороговые значения 3 – 5%, в то время как все прочие методы показали результаты, удовлетворяющие такому критерию.

Кроме того, показавшие худшую точность аппроксимации методы также показывают и наибольшее время обучения, на один или несколько порядков превышающие лучшие показатели по этому параметру. Метод опорных векторов с множественным ядром и градиентного усиления, при удовлетворительной точности, также требуют существенно большего времени на обучение.

По совокупности точности решений и скорости обучения наилучшими для задачи аппроксимации статических реакций смазочного слоя подшипников жидкостного трения можно считать полносвязные ИНС и различные варианты линейной регрессии, а также стандартную модификацию метода опорных векторов. В каждом конкретном случае корректировать выбор метода можно по данным табл. 4 либо, при необходимости более детального анализа точности, согласно общей методике, представленной в разделе 2.2.

Заключение

В работе представлен анализ возможности аппроксимации статических реакций смазочного слоя подшипников жидкостного трения методами машинного обучения. Исследование позволило определить параметры методов и исходного набора данных, при которых для значительного диапазона возможных эксцентриков вала достигается точность решений в пределах 5% по сравнению с результатами моделей на основе традиционных численных методов. По результатам исследования можно сформулировать следующие выводы.

1. Точность аппроксимации зависит как от параметра исходного набора данных, так и от гиперпараметров используемых методов машинного обучения. При этом существует общая тенденция снижения точности решений в области более высоких эксцентриков, где сильнее выражена нелинейность реакций подшипника.

2. Уменьшение времени на генерацию исходных данных без существенной потери точности аппроксимации достигается снижением плотности расчётных сеток. Примлемая точность в пределах 5% достигается при применении сетки данных для обучения 8×12 в области малых и средних эксцентриков ($<0,8\dots0,9$), и 12×60 – при более высоких. Конечно-разностную сетку для генерации исходных данных рекомендуется также выбирать меньшей плотности для малых средних и низких эксцентриков ($<0,8\dots0,9$) и большей – для более высоких.

3. Наряду с методами линейной регрессии и опорных векторов полносвязные ИНС наилучшим образом подходят для решения рассмотренной задачи. При этом более оптимальной является структура ИНС с 50 нейронами в скрытом слое. Иные рассмотренные методы машинного обучения показали недостаточную точность или время, затрачиваемое на обучение модели.

Исследование выполнено за счёт гранта Российского научного фонда № 22-19-00789, <https://rscf.ru/project/22-19-00789/>.

Библиографический список

1. Tala-Ighil N., Fillon M. A numerical investigation of both thermal and texturing surface effects on the journal bearings static characteristics // Tribology International. 2015. V. 90. P. 228-239. DOI: 10.1016/J.TRIBOINT.2015.02.032
2. Gropper D., Harvey T.J., Wang L. Numerical analysis and optimization of surface textures for a tilting pad thrust bearing // Tribology International. 2018. V. 124. P. 134-144. DOI: 10.1016/J.TRIBOINT.2018.03.034
3. Kumar V., Sharma S.C., Jain S.C. On the restrictor design parameter of hybrid journal bearing for optimum rotordynamic coefficients // Tribology International. 2006. V. 39, Iss. 4. P. 356-368. DOI: 10.1016/J.TRIBOINT.2005.03.015
4. Cui S., Zhang C., Fillon M., Gu L. Optimization performance of plain journal bearings with partial wall slip // Tribology International. 2020. V. 145. DOI: 10.1016/J.TRIBOINT.2019.106137
5. Kazakov Yu.N., Kornaev A.V., Shutin D.V., Li Sh., Savin L.A. Active fluid-film bearing with deep Q-network agent-based control system // Journal of Tribology. 2022. V. 144, Iss. 8. DOI: 10.1115/1.4053776
6. Breńkacz L., Witanowski L., Drosińska-Komor M., Szewczuk-Krypa N. Research and applications of active bearings: A state-of-the-art review // Mechanical Systems and Signal Processing. 2021. V. 151. DOI: 10.1016/J.YMSSP.2020.107423

7. Kornaev A.V., Kornaeva E.P., Savin L.A., Kazakov Yu.N., Fetisov A., Rodichev A.Yu., Mayorov S.V. Enhanced hydrodynamic lubrication of lightly loaded fluid-film bearings due to the viscosity wedge effect // *Tribology International*. 2021. V. 160. DOI: 10.1016/J.TRIBOINT.2021.107027
8. Peixoto T.F., Cavalca K.L. Thrust bearing coupling effects on the lateral dynamics of turbochargers // *Tribology International*. 2020. V. 145. DOI: 10.1016/j.triboint.2020.106166
9. Momoniat E. A Reynolds equation modelling Coriolis force effects on chemical mechanical polishing // *International Journal of Non-Linear Mechanics*. 2017. V. 92. P. 111-117. DOI: 10.1016/j.ijnonlinmec.2017.04.003
10. Iseli E., Schiffmann J. Prediction of the reaction forces of spiral-groove gas journal bearings by artificial neural network regression models // *Journal of Computational Science*. 2021. V. 48. DOI: 10.1016/J.JOCS.2020.101256
11. Chasalevris A., Dohnal F. Vibration quenching in a large scale rotor-bearing system using journal bearings with variable geometry // *Journal of Sound and Vibration*. 2014. V. 333, Iss. 7. P. 2087-2099. DOI: 10.1016/j.jsv.2013.11.034
12. Santos I.F. Controllable sliding bearings and controllable lubrication principles-an overview // *Lubricants*. 2018. V. 6, Iss. 1. DOI: 10.3390/LUBRICANTS6010016
13. Li S., Babin A., Shutin D., Kazakov Yu., Liu Y., Chen Zh., Savin L. Active hybrid journal bearings with lubrication control: Towards machine learning // *Tribology International*. 2022. V. 175. DOI: 10.1016/J.TRIBOINT.2022.107805
14. Almqvist A. Fundamentals of physics-informed neural networks applied to solve the reynolds boundary value problem // *Lubricants*. 2021. V. 9, Iss. 8. DOI: 10.3390/LUBRICANTS9080082
15. Kornaev A.V., Kornaev N.V., Kornaeva E.P., Savin L.A. Application of artificial neural networks to calculation of oil film reaction forces and dynamics of rotors on journal bearings // *International Journal of Rotating Machinery*. 2017. V. 2017. DOI: 10.1155/2017/9196701
16. Hori Y. *Hydrodynamic lubrication*. Tokyo: Springer-Verlag, 2006. 231 p. DOI: 10.1007/4-431-27901-6
17. Hu B., Zhou C., Wang H., Chen S. Nonlinear tribo-dynamic model and experimental verification of a spur gear drive under loss-of-lubrication condition // *Mechanical Systems and Signal Processing*. 2021. V. 153. DOI: 10.1016/J.YMSSP.2020.107509
18. Liu W., Zhao X., Zhang T., Feng K. Investigation on the rotordynamic performance of hybrid bump-metal mesh foil bearings rotor system // *Mechanical Systems and Signal Processing*. 2021. V. 147. DOI: 10.1016/J.YMSSP.2020.107076
19. Kornaeva E.P., Kornaev A.V., Kazakov Yu.N., Polyakov R.N. Application of artificial neural networks to diagnostics of fluid-film bearing lubrication // *IOP Conference Series: Materials Science and Engineering*. 2020. V. 734, Iss. 1. DOI: 10.1088/1757-899X/734/1/012154
20. Хебда М., Чинчинадзе А.В. *Справочник по триботехнике: в 3 т. Т. 2. Смазочные материалы, техника смазки, опоры скольжения и качения*. М.: Машиностроение, 1990. 411 с.

APPROXIMATION OF FORCES OF FLUID FILM BEARING LUBRICATING LAYER USING MACHINE LEARNING METHODS

© 2023

Yu. N. Kazakov

Student of the Department of Mechatronics, Mechanics and Robotics;
Orel State University named after I.S. Turgenev, Orel, Russian Federation;
KazakYurii@yandex.ru

I. N. Stebakov

Postgraduate Student of the Department of Mechatronics, Mechanics
and Robotics;
Orel State University named after I.S. Turgenev, Orel, Russian Federation;
chester50796@yandex.ru

D. V. Shutin

Candidate of Science (Engineering), Associate Professor, Department
of Mechatronics, Mechanics and Robotics;
Orel State University named after I.S. Turgenev, Orel, Russian Federation;
rover.ru@gmail.com

L. A. Savin

Doctor of Science (Engineering), Professor, Department of Mechatronics,
Mechanics and Robotics;
Orel State University named after I.S. Turgenev, Orel, Russian Federation;
savin3257@mail.ru

The article analyzes the application of various machine learning methods for solving the problem of approximating the forces of fluid film bearing lubricating layer in static formulation. The initial data on the values of lubricating layer forces for different shaft positions were obtained using a model of a rotor-bearing system based on the numerical solution of the Reynolds equation, with account for the cavitation effect. Methods for reducing the amount of calculation required to obtain the necessary data set are determined on the basis of analyzing solution approximation accuracy with artificial neural networks. After that, approximation models were constructed using a number of other machine learning methods, and the accuracy of predictions as well as the duration of the training process were analyzed. Finally, conclusions were drawn about the most effective approaches to building such models.

Fluid film bearings; machine learning; approximation accuracy; artificial neural networks

Citation: Kazakov Yu.N., Stebakov I.N., Shutin D.V., Savin L.A. Approximation of forces of fluid film bearing lubricating layer using machine learning methods. *Vestnik of Samara University. Aerospace and Mechanical Engineering*. 2023. V. 22, no. 3. P. 108-121. DOI: 10.18287/2541-7533-2023-22-3-108-121

References

1. Tala-Ighil N., Fillon M. A numerical investigation of both thermal and texturing surface effects on the journal bearings static characteristics. *Tribology International*. 2015. V. 90. P. 228-239. DOI: 10.1016/J.TRIBOINT.2015.02.032
2. Gropper D., Harvey T.J., Wang L. Numerical analysis and optimization of surface textures for a tilting pad thrust bearing. *Tribology International*. 2018. V. 124. P. 134-144. DOI: 10.1016/J.TRIBOINT.2018.03.034
3. Kumar V., Sharma S.C., Jain S.C. On the restrictor design parameter of hybrid journal bearing for optimum rotordynamic coefficients. *Tribology International*. 2006. V. 39, Iss. 4. P. 356-368. DOI: 10.1016/J.TRIBOINT.2005.03.015
4. Cui S., Zhang C., Fillon M., Gu L. Optimization performance of plain journal bearings with partial wall slip. *Tribology International*. 2020. V. 145. DOI: 10.1016/J.TRIBOINT.2019.106137
5. Kazakov Yu.N., Kornaev A.V., Shutin D.V., Li Sh., Savin L.A. Active fluid-film bearing with deep Q-network agent-based control system. *Journal of Tribology*. 2022. V. 144, Iss. 8. DOI: 10.1115/1.4053776

6. Breńkacz L., Witanowski L., Drosińska-Komor M., Szewczuk-Krypa N. Research and applications of active bearings: A state-of-the-art review. *Mechanical Systems and Signal Processing*. 2021. V. 151. DOI: 10.1016/J.YMSSP.2020.107423
7. Kornaev A.V., Kornaeva E.P., Savin L.A., Kazakov Yu.N., Fetisov A., Rodichev A.Yu., Mayorov S.V. Enhanced hydrodynamic lubrication of lightly loaded fluid-film bearings due to the viscosity wedge effect. *Tribology International*. 2021. V. 160. DOI: 10.1016/J.TRIBOINT.2021.107027
8. Peixoto T.F., Cavalca K.L. Thrust bearing coupling effects on the lateral dynamics of turbochargers. *Tribology International*. 2020. V. 145. DOI: 10.1016/j.triboint.2020.106166
9. Momoniat E. A Reynolds equation modelling Coriolis force effects on chemical mechanical polishing. *International Journal of Non-Linear Mechanics*. 2017. V. 92. P. 111-117. DOI: 10.1016/j.ijnonlinmec.2017.04.003
10. Iseli E., Schiffmann J. Prediction of the reaction forces of spiral-groove gas journal bearings by artificial neural network regression models. *Journal of Computational Science*. 2021. V. 48. DOI: 10.1016/J.JOCS.2020.101256
11. Chasalevris A., Dohnal F. Vibration quenching in a large scale rotor-bearing system using journal bearings with variable geometry. *Journal of Sound and Vibration*. 2014. V. 333, Iss. 7. P. 2087-2099. DOI: 10.1016/j.jsv.2013.11.034
12. Santos I.F. Controllable sliding bearings and controllable lubrication principles-an overview. *Lubricants*. 2018. V. 6, Iss. 1. DOI: 10.3390/LUBRICANTS6010016
13. Li S., Babin A., Shutin D., Kazakov Yu., Liu Y., Chen Zh., Savin L. Active hybrid journal bearings with lubrication control: Towards machine learning. *Tribology International*. 2022. V. 175. DOI: 10.1016/J.TRIBOINT.2022.107805
14. Almqvist A. Fundamentals of physics-informed neural networks applied to solve the reynolds boundary value problem. *Lubricants*. 2021. V. 9, Iss. 8. DOI: 10.3390/LUBRICANTS9080082
15. Kornaev A.V., Kornaev N.V., Kornaeva E.P., Savin L.A. Application of artificial neural networks to calculation of oil film reaction forces and dynamics of rotors on journal bearings. *International Journal of Rotating Machinery*. 2017. V. 2017. DOI: 10.1155/2017/9196701
16. Hori Y. Hydrodynamic lubrication. Tokyo: Springer-Verlag, 2006. 231 p. DOI: 10.1007/4-431-27901-6
17. Hu B., Zhou C., Wang H., Chen S. Nonlinear tribo-dynamic model and experimental verification of a spur gear drive under loss-of-lubrication condition. *Mechanical Systems and Signal Processing*. 2021. V. 153. DOI: 10.1016/J.YMSSP.2020.107509
18. Liu W., Zhao X., Zhang T., Feng K. Investigation on the rotordynamic performance of hybrid bump-metal mesh foil bearings rotor system. *Mechanical Systems and Signal Processing*. 2021. V. 147. DOI: 10.1016/J.YMSSP.2020.107076
19. Kornaeva E.P., Kornaev A.V., Kazakov Yu.N., Polyakov R.N. Application of artificial neural networks to diagnostics of fluid-film bearing lubrication. *IOP Conference Series: Materials Science and Engineering*. 2020. V. 734, Iss. 1. DOI: 10.1088/1757-899X/734/1/012154
20. Khebda M., Chinchinadze A.V. *Spravochnik po tribotekhnike: v 3 t. T. 2. Smazochnye materialy, tekhnika smazki, opory skol'zheniya i kacheniya* [Handbook on tribological engineering. V. 2. Lubricants, lubrication techniques, sliding and rolling bearings]. Moscow: Mashinostroenie Publ., 1990. 411 p.