

ДИАГНОСТИКА НЕИСПРАВНОСТЕЙ АВИАЦИОННЫХ ДВИГАТЕЛЕЙ¹

В настоящее время, когда авиакатастрофы стали проблемой мирового масштаба, особую актуальность приобрела проблема раннего выявления неисправностей авиационных двигателей. Традиционно диагностика неисправностей авиадвигателей производится с применением моделей, основанных на физических закономерностях, а также путем статистической обработки данных полетного мониторинга. Специалисты, занимающиеся этой проблемой, устанавливают датчики, измеряющие параметры работы авиадвигателей во время полетов. Файл данных полетного мониторинга обычно содержит такие параметры как: номер полета, дату полета, общую наработку двигателя, температуру и давление воздуха на входе в двигатель, температуру и давление газа за турбиной, температуру лопаток, уровень и температуру масла в маслблоке, число Маха и т.д. Количество полетных параметров может достигать сотни и более единиц.

После выполнения определенного количества полетов (порядка двухсот), двигатель снимается с самолета и подвергается стендовой разборке, во время которой выявляются и устраняются его дефекты. Характерными дефектами авиадвигателей являются: трещина на сопловом агрегате, забоины, разрушение дефлектора, стружка в масле и т.д., всего порядка тридцати видов.

Задача инженера-диагноста состоит в том, чтобы, используя данные полетного мониторинга, выявить дефекты двигателя до его выхода из строя или до профилактической разборки. Как уже отмечалось, традиционно эта задача решается путем применения методов, основанных на физических закономерностях: каждый дефект вызывает определенные отклонения тех или иных параметров работы двигателя, поэтому, анализируя их характер изменения, можно сделать предположения о появлении дефектов, вызывающих эти изменения. Понятно, что ввиду значительных объемов информации и сложности существующих взаимосвязей между дефектами и измеренными параметрами, задача анализа данных полетного мониторинга и выявления дефектов авиадвигателей является далеко не тривиальной и во многих случаях решается ненадежно и некачественно.

Настоящим проектом предлагается эту задачу решать с помощью нейросетевого моделирования [1], например, используя многослойный персептрон с сигмоидными активационными функциями. Прежде всего отметим, что во входном векторе персептрона X следует предусмотреть места всем параметрам полетного мониторинга, на значения которых оказывает влияние появление выявляемых дефектов. Возможные дефекты авиадвигателя можно закодировать в выходном векторе Y , например, с помощью нулей и единиц. Вектора желаемых выходов D_q составляются по результатам стендовых разборок двигателей.

Кроме того, разумно предположить, что при первых вылетах нового или вновь отремонтированного самолета, его двигатель полностью исправен и дефектов нет, тогда как на последних вылетах двигатель уже имел те самые дефекты, которые выявились при его разборке. Поэтому, из всего множества параметров полетного мониторинга ценность для обучения нейросети имеет несколько первых и несколько последних полетов самолета. Таким образом, для каждого двигателя, побывавшего на разборке, можно сформировать несколько пар обучающих векторов X_q и D_q ($q=1, \dots, Q$).

Если количество обучающих примеров Q будет достаточным, то можно ожидать, что правильно спроектированный многослойный персептрон обучится надежно ставить диагнозы неисправностей авиационных двигателей, в том числе и тех, которые в обучающем множестве примеров не участвовали. А если таким персептроном оборудовать бортовой компьютер самолета, то он будет сообщать о появлении дефектов двигателя в реальном времени, т.е., как только сложится опасная конфигурация вектора входных парамет-

ров – результатов измерений, оперативно снимаемых во время полета самолета. Естественно, что прежде чем попасть в кабину пилотов, сигналы персептрона должны обрабатываться бортовым компьютером, вырабатывающим инструкции об адекватных действиях экипажа.

При формировании множества примеров нами использовались данные полетного мониторинга и стендовых исследований турбореактивных авиационных двигателей. При обработке данных была введена следующая рабочая гипотеза: предполагалось, что первые шесть полетов в каждом файле полетного мониторинга выполнены при исправном двигателе, а последние шесть полетов – при неисправном двигателе. Множество примеров предметной области мы разделили на две части: обучающее (пять исправных и пять неисправных двигателей) и тестирующее (один исправный и один неисправный двигатель). Каждой неисправности поставили в соответствие один выходной нейрон. Условились, что значение каждого выходного нейрона равно нулю или единице: “0” – если нет неисправности и “1” – если неисправность есть.

В экспериментах участвовали пять двигателей, снятых с полетов, причем при стендовой разборке у них обнаружены дефекты приведенные в табл.1.

Таблица 1.
Неисправности двигателей

№ двигателя	Неисправности двигателя
1	Стружка в масле
2	Дефекты гор.части
3	Забоины КВД
4	Разрушение 5ст КВД
5	Трещина на 1РЛ ТВД

Согласно принятым гипотезам, персептрон должен иметь пять выходных нейронов: желаемый выход первого нейрона D_1 , соответствующего неисправности «Стружка в масле», равен единице для первого снятого двигателя, и равен нулю для всех остальных. Выход второго нейрона D_2 , соответствующего неисправности «Дефекты гор.части», равен единице для второго снятого двигателя и равен нулю для всех остальных и т.д.

На вход персептрона подаются параметры полетного мониторинга, количество которых равно 26, т.е. персептрон содержит 26 нейронов входного слоя.

Согласно принятым гипотезам, на каждый двигатель приходится десять обучающих примеров: пять входных векторов, для которых двигатель еще был исправен, и пять входных векторов, для которых двигатель неисправен. Таким образом, обучающее множество содержит всего 50 примеров. Кроме того, для каждого двигателя имеется по два тестирующих входных вектора, соответствующих исправному и неисправному состояниям.

Проектирование персептрона, оптимизацию количества нейронов внутренних слоев, проводили конструктивным методом, а обучение – методом обратного распространения ошибки. В табл. 2 приведены результаты тестирования обученной нейросети. В первом столбце помещены номера авиадвигателей, причем тестовые примеры для исправных двигателей чередуются с неисправными. Во 2-м – 6-м столбцах приведены значения желаемых выходных сигналов персептрона D_i , а в 7-м – 11-м столбцах – результаты прогноза сети – фактические выходные сигналы Y_i .

Как видно из таблицы, нейросеть правильно прогнозирует неисправности авиадвигателей, хотя разница между желаемыми и фактическими сигналами персептрона доходит до 35%, что говорит о низкой степени его уверенности.

Таблица 2
Результаты тестирования персептрона

№ двигателя	D_1	D_2	D_3	D_4	D_5	Y_1	Y_2	Y_3	Y_4	Y_5
1 (исправный)	0	0	0	0	0	0,1548	0,2881	0,3764	0,1845	-0,002
1(неиспрвыный)	1	0	0	0	0	1,3506	-0,096	-0,534	-0,517	0,39

2 (исправный)	0	0	0	0	0	-0,191	-0,014	0,0909	0,1075	0,1033
2(неиспрвыный)	0	1	0	0	0	0,0026	0,789	0,3145	0,3337	-0,234
3 (исправный)	0	0	0	0	0	-0,201	-0,008	-0,091	0,1080	0,1251
3(неиспрвыный)	0	0	1	0	0	0,155	0,288	0,976	0,2895	-0,002
4 (исправный)	0	0	0	0	0	0,1759	0,2012	0,1840	0,0963	0,0278
4(неиспрвыный)	0	0	0	1	0	0,1648	0,2943	0,3800	1,1224	0,0116
5 (исправный)	0	0	0	0	0	-0,186	-0,017	0,0897	0,1064	0,1007
5(неиспрвыный)	0	0	0	0	1	-0,058	-0,031	-0,028	-0,025	0,8955

Для повышения степени уверенности нейропрогноза нами был предложен и применен прием, заключающийся в выявлении и исключении из числа входных параметров тех, значения которых слабо меняются в процессе мониторинга двигателя. Визуальное выявление повторяющихся и слабо меняющихся параметров затруднено большими объемами информации. Поэтому эту задачу решили с помощью той же нейрости, повернутой на 90°. После такого поворота столбцы данных полетного мониторинга становятся строками и каждое значение конкретного параметра становится входом нейросети. Сеть обучается так, что ее единственный выходной нейрон выдает нулевой сигнал, если параметр изменяется слабо, и единичный – в противном случае.

Нейросетевой анализ данных полетного мониторинга позволил выявить и отбраковать 15 слабо изменяющихся параметров и уменьшить, таким образом, число входных нейронов персептрона до 11. В результате, качество прогноза редуцированной нейросети существенно улучшилось, что видно из табл. 3, содержащей результаты тестирования сети на тех же примерах, что и до редуцирования. Отклонения расчетных выходных сигналов от требуемых теперь не превышает 7%.

Таблица 3
Результаты тестирования редуцированного персептрона

№ двигателя	D_1	D_2	D_3	D_4	D_5	Y_1	Y_2	Y_3	Y_4	Y_5
1(исправный)	0	0	0	0	0	0,0374	-0,2311	-0,2821	0,0347	-0,102
1(неиспрвыный)	1	0	0	0	0	1,0176	-0,0162	-0,2281	-0,057	0,0937
2(исправный)	0	0	0	0	0	0,0363	0,1117	0,2582	0,017	0,1127
2(неиспрвыный)	0	1	0	0	0	-0,0881	1,0658	0,3195	-0,3201	-0,410
3(исправный)	0	0	0	0	0	-0,0774	-0,3273	0,2920	0,2756	0,0998
3(неиспрвыный)	0	0	1	0	0	0,156	0,002	0,9745	0,1759	-0,029
4(исправный)	0	0	0	0	0	0,0699	0,1363	0,1521	0,0892	0,1187
4(неиспрвыный)	0	0	0	1	0	0,0726	0,01391	0,3800	0,9839	0,0711
5(исправный)	0	0	0	0	0	0,01432	-0,7101	0,0019	0,09135	0,5781
5(неиспрвыный)	0	0	0	0	1	0,2857	-0,0977	0,1632	0,4614	0,9957

Напомним, что обучение и тестирование нейросети проводилось на данных мониторинга первых и последних вылетах самолета. В сеть закладывалась информация о том, что на первых вылетах двигатель самолета был полностью исправен, тогда как на последних вылетах двигатель уже имел те неисправности, которые были обнаружены при его стендовой разборке. Вопрос о том, на каком вылете появилась та или иная неисправность, представляет практический интерес. Поэтому нейросети было предложено сделать заключение о наличии неисправностей, анализируя полетные параметры, снятые в каждый вылет на протяжении всего срока использования двигателя. Результат такого прогноза для некоторых видов неисправностей представлен графически на рис. 1 и рис. 2. Как видно из рисунков, нейросеть обнаруживает появление неисправностей двигателей задолго до их стендовых разборок.




Рис.1. Прогноз нейросети о наличии неисправности «Дефекты гор.части» на каждый вылет.

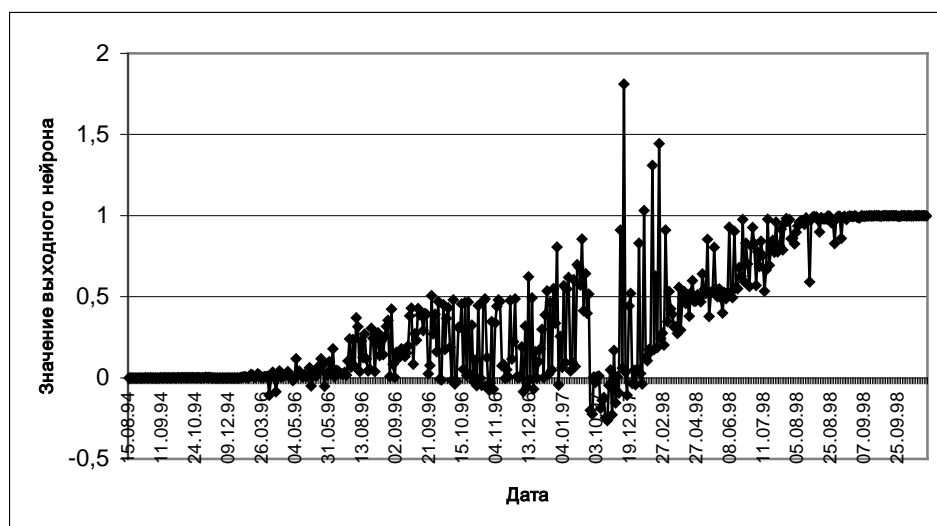


Рис.2. Прогноз нейросети о наличии неисправности «Стружка в масле» на каждый вылет.

Укажем на еще одно преимущество нейросетевой диагностики перед традиционными диагностическими методиками, основанными на явных знаниях. Специалисты, занимающиеся традиционными методами диагностики, пытаются учесть как можно больше взаимосвязей между значениями измеряемых полетных параметров и появлениями тех или иных дефектов двигателя. В сложных технических устройствах количество таких взаимосвязей настолько велико, а характер взаимодействий настолько сложен, что построить полную математическую модель, полностью адекватную моделируемому устройству, на современном этапе развития точных наук представляется весьма затруднительным. Кроме того, в сложных технических устройствах существуют и такие взаимосвязи, о которых специалисты просто не знают. Существуют также взаимосвязи, о которых специалисты догадываются, но объяснить их физическую природу не могут. Например известно, что дефект «стружка в масле» не влияет ни на один из измеряемых датчиками параметров работы авиадвигателя, вследствие чего, не существует традиционных методик, способных выявлять этот дефект. Как видно из приведенных нами результатов, нейросеть появление стружки в масле легко обнаруживает. Дело тут, по-видимому в том, что, не

оказывая заметного влияния на каждый отдельно взятый параметр двигателя, появление стружки в масле все-таки влияет на общую конфигурацию входного вектора, что и вызывает соответствующую реакцию нейронной сети.

Выводы: 1. Применение нейросетевых технологий позволяет с достаточной высокой степенью надежности выявлять появление дефектов авиационных двигателей, причем задолго до их стендовых разборок.

2. Нейросетями успешно выявляются такие дефекты, которые традиционными методами диагностики выявлены быть не могут.

3. В дальнейшем перспективным представляется оборудование нейросетью бортового компьютера самолета. В этом случае появится возможность сообщать экипажу о появлении дефектов двигателя в реальном режиме времени, т.е., как только сложится опасная конфигурация вектора входных параметров – результатов измерений, оперативно снимаемых во время полета самолета. Естественно, что прежде чем попасть в кабину пилотов, сигналы нейросети должны проходить обработку с целью формирования инструкций для адекватных действий экипажа.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Конев С.В., Сичинава З.И. Ясницкий Л.Н. Применение нейросетевых технологий для диагностики неисправностей авиационных двигателей. Вестник Пермского университета. Математика. Информатика. Механика. Вып.2. Пермь: Изд. Пермского ун-та, 2005. с.43-47.
2. Конев С.В., Сичинава З.И. Халлиулин В.Ф. Ясницкий Л.Н. Возможности применения нейросетевых технологий для прогнозирования неисправностей авиационных двигателей. Аэрокосмическая техника и высокие технологии – 2005. Материалы VIII Всероссийской научно-технической конференции – Пермь: ПГТУ, 2005. – 174 с.

ⁱ Данный проект выполнялся инициативной группой студентов и сотрудников Пермского государственного университета в содружестве с АО «Авиадвигатель» в 2002-2005 гг., однако, ввиду отсутствия финансирования и заинтересованности со стороны заказчиков, работы над проектом были прекращены.