

УДК 004.8.032.26; 623.004

А.Л. ЛЯХОВ, С.П. АЛЕШИН

*Полтавский национальный технический университет им. Юрия Кондратюка, Украина***ТЕХНИЧЕСКАЯ ДИАГНОСТИКА БОРТОВЫХ РАДИОЛОКАЦИОННЫХ СИСТЕМ В СРЕДЕ STATISTIKA NEURAL NETWORK**

Работа посвящена проблеме автоматизации поиска неисправностей в бортовых радиолокационных системах на основе технологий искусственного интеллекта. Предложена методика построения нейросетевой модели метода последовательных приближений при поиске неисправностей. В качестве среды формирования моделей базовых процессов выбран стандартный нейрокит Statistika Neural Network. Построены модели кластерного анализа входных данных и двухуровневого классификатора состояний объекта. Предлагаемая методика позволяет автоматизировать процесс поиска неисправностей РЛС и снизить время на принятие решений по их восстановлению.

Ключевые слова: радиолокационная система, поиск неисправностей, кластерный анализ, классификация, нейронная сеть.

Введение

При эксплуатации радиолокационных систем (РЛС) приходится встречаться с отказами или изменением параметров ниже допустимых пределов. Наиболее сложной и трудоемкой процедурой при восстановлении требуемых характеристик является процесс отыскания неисправностей. Практика эксплуатации показывает, что время на установление причины той или иной неисправности занимает (60-80)% общего времени ремонта [1]. Это связано с тем, что по внешнему признаку неисправности, как правило, нельзя однозначно указать на неисправные элементы, узлы, блоки. Например, внешний признак неисправности РЛС: отсутствие отметки эхо – сигналов на индикаторах – может проявляться в результате отказа в: передающей системе; антенно-волноводной (фидерной) системе; приемной системе; системе индикации; системе синхронизации; системе электропитания.

Следовательно, решение об установлении неисправного элемента принимается в условиях некоторой априорной неопределенности. Для ее преодоления персонал проводит ряд дополнительных замеров, испытаний, замен. В основе этого процесса лежит метод последовательных приближений [1]. Практика применения этого метода (на примере многолетней эксплуатации изделия 2С6) при достаточной квалификации обслуживающего персонала, показала высокую эффективность. Однако, существенным недостатком следует считать, относительно длительный (до нескольких часов) период диагностирования изделия и зависимость результата от квалификации персонала. Анализ возможных путей

сокращения времени диагностики и снижения зависимости от человеческого фактора позволяет предположить целесообразность автоматизации этого процесса на основе применения интеллектуальных технологий, в частности, моделирования процесса принятия решений применением искусственных нейронных сетей в среде Statistika Neural Networks. Публикации исследований в этой области, отражают определенные успехи в автоматизации процесса поиска неисправностей в радиолокационных системах и, как следствие, в сокращении сроков их устранения. Эти результаты достигнуты применением автоматизированных систем встроенного контроля с применением специализированных цифровых вычислительных систем (ЦВС). Однако и в этом случае проблема решена лишь частично. Так, например, в изделии 2С6 [1] не все системы охвачены автоматизированным встроенным контролем (антенно-волноводная система, высокочастотная часть приемной системы, силовые приводы и др.). Это обстоятельство требует дополнительных промежуточных замеров штатной контрольно-измерительной аппаратурой, что, в свою очередь, предполагает составление тракта прохождения сигналов и команд, а значит и дополнительных затрат времени. Это снижает эффективность системы встроенного контроля и позволяет выделить не решенную ранее часть общей проблемы, которой и посвящена данная статья, – обоснованию возможности полной автоматизации процесса принятия решений при отыскании неисправностей в радиолокационных системах на основе нейросетевых обучающихся моделей распознавания в среде стандартных нейроэмуляторов. В пользу подобного подхода говорит тот

факт, что эксплуатация радиолокационных систем осуществляется годами (а в примере с 2С6 – десятилетиями). За это время накопился значительный массив данных описаний неисправностей, что в контексте теории распознавания образов, представляет репрезентативное множество алфавита классов и соответствующее ему представительное множество словаря признаков. Инструментом формирования знаний из массива данных в подобной ситуации целесообразно использовать нейросреду стандартных нейроконструкторов. Для решения данной задачи воспользуемся нейросетевой средой модуля Statistika Neural Networks и на его основе построим диагностическую модель принятия решений. Массив данных предыстории позволяет описать состояние классов неисправностей как образов на языке их информативных признаков и получить массив обучающих примеров. Нейросетевая модель в этом случае, может быть использована для формирования, разделяющей классы, гиперповерхности в виде модифицированного пространства синаптических коэффициентов на множестве практических примеров.

Таким образом, есть объективная основа решения проблемы автоматизации процесса диагностирования радиолокационной системы путем постановки и решения задачи распознавания образов в многомерном пространстве признаков в среде нейроэмуляторов.

Постановка задачи

Имеется объект – радиолокационная система 2С6, состояние которой описывается вектором признаков заданной размерности. Физическое содержание признаков выражается в значениях параметров по системам изделия.

1. Передающая система: наличие зондирующего импульса на экране индикатора; значение тока магнетрона; наличие и величина импульса запуска; значение напряжений питания подмодулятора, модулятора, высоковольтного выпрямителя, тиристорного регулятора и др.

2. Антенно-волноводная система: величина напряжения управления на переключателях АН-ТЕННА-ЭКВИВАЛЕНТ, ПОИСК-ПЕЛЕНГ, факт подсветки кнопок-табло АВТОМАТ, ПЕЛЕНГ, СБРОС при их нажатии, параметры напряжений системы стабилизации и управления антенной и др.

3. Приемная система: наличие контрольного сигнала, величина токов смесителей, уровень шумов в каналах КАН1,КАН2, значение напряжений ЭХО11,ЭХО12, напряжения клистрона в точках 4Б-7Б и др.

4. Система индикации: наличие разверток ин-

дикаторов СИ1,СИ2, стробных меток и линий визира, параметры разверток дальности, угла места, значения напряжений в каналах формирования разверток и др.

5. Система синхронизации: величина контрольных импульсов, значение питающих напряжений, факт свечения контрольных индикаторов и др.

6. Система электропитания: наличие напряжений на контрольных гнездах, свечение контрольных индикаторов, определенная последовательность появления напряжений при включении и др.

Таким образом, имеется массив данных предыстории эксплуатации изделия 2С6 в виде описания неисправностей и перечня указанных признаков, им соответствующих, с числом примеров несколько сотен. Цель исследования состоит в решении задачи распознавания неисправных элементов и построении нейросетевой модели распознающего автомата в среде стандартных нейроэмуляторов StatSoft. В основе исследования лежит метод конструирования классификатора путем интерактивного диалога с нейросредой при комплексном использовании экспертных данных и интеллектуальных опций нейропакета.

Для нахождения адекватного отображения пространства входных факторов на пространство состояний требуется классифицировать состояние объекта исследования, то есть построить модель распознающего автомата, сравнивающего текущий входной вектор с массивом векторов предыстории той же размерности. Для моделирования этого процесса применим технологию Statsoft в формате модуля Statistika Neural Network и обеспечим условия адекватности модели реальным процессам в рамках требований задачи.

Построение нейросетевой модели

В контексте обобщенной математической модели (сущность распознавания неисправного элемента) состоит в непрерывной или дискретной оценке текущего состояния объекта, измерении наблюдаемых переменных, сравнении текущего состояния с образами состояний из массива предыстории и выборе номера класса, набор признаков которого в заданном метрическом пространстве, наиболее близок текущему набору. Для поиска закономерностей в данных вид функции связи признаков и состояний целесообразно искать в неявном виде, используя обучающие правила на множестве примеров предыстории. Обучив сеть получим зависимость между значениями признаков и номерами классов. Подав на вход обученной сети исследуемую выборку, на выходе получим номер

класса (конкретную неисправность: блок, узел, панель). Первый шаг – формирование алфавита классов. Это группы одноименных показателей (классы), характеризующие ту или иную неисправность исследуемого объекта. Это трудоемкий процесс и требует определенного времени на ввод прецедентов. Но это делается только один раз и результат сохраняется в базе данных в файле с определенным именем файла. Алфавит классов ограничивается числом блоков и панелей в блоке, так как это минимальный заменяемый сегмент согласно правил ремонта изделия 2С6. Так как каждому классу соответствует свой набор показателей, то процедура классификации объекта сводится к анализу пространства признаков текущего состояния и сравнения результатов анализа с описаниями выбранных классов. Процесс классификации заключается в подаче на вход обученной сети вектора признаков и фиксации зарегистрированного сетью класса. Установленный номер класса характеризует тот или иной неисправный элемент. Однако, предварительно необходимо сформировать обучающее множество путем кластеризации входных данных.

Кластерный анализ входных данных

Необходимо построить алгоритм группировки вектора исходных данных на заданное число кластеров. Пусть исходные данные располагают числом примеров (наблюдений) 500 в 60-мерном пространстве признаков (Var 1 – Var 60).

Для решения этой задачи в первую очередь обоснуем метрику сравнения образов, то есть в пространстве входных признаков выберем меру сходства между ними. Воспользуемся традиционной евклидовой метрикой, которая выражается как корень из суммы квадратов по координатным разностям. В нашем случае каждая координата – это один из 60 признаков входного вектора и в общем случае это двоичное число фиксированной разрядности. В решаемой задаче признаки могут представляться числом (величина тока смесителя, напряжение оторазжательного клапана и т.д.) и могут быть категориальными (наличие контрольного сигнала, импульса запуска и т.д.). Это означает, что абсолютные величины входных признаков измеряются в разных шкалах и имеют разные диапазоны изменений, то есть вклад в евклидову метрику будет зависеть от типа измерительной шкалы признака, что может привести к потере информации о воздействии некоторых факторов. Обеспечить инвариантность меры сходства от типа шкалы поможет процедура стандартизации входных переменных, результатом которой является при-

ведение всех переменных к единой шкале. Реализация этой функции в среде StatSoft осуществима в контекстном меню раздела Fill / Standardize Block опцией Standardize Columns. Количество кластеров, учитывая особенности предметной области исследуемого объекта, равно 6. В основе этого разделения лежит итеративная процедура метода K-средних, которая начинается с задания начальных условий, т.е. числа кластеров и их центров. Реализация кластеризации данных начинается из главного меню Statistics опцией Cluster Analysis. В диалоговом окне Clusterin method выбираем K-means clustering и иницилируем сеть (OK). Вызываем стартовую панель этого модуля командой Statistics из основного меню и во вкладке Quick данного диалогового окна в разделе Problem type выберем задачу Classification. Командой Variables вызываем диалоговое окно Select input, output и записываем все переменные по списку (Var 1 – Var 28). В разделе Selekt analysis выбираем опцию Intelligent Problem Solver, что необходимо для установки параметров сети по умолчанию и фиксации сложности и топологии сети. В диалоговом окне IPS Training In Proqress выбираем сеть. Анализ осуществляем по десяти строкам информационного поля диалогового окна. В разделе Profile фиксируем топологию сети (SNN – Kohonen 24:24 – 48:1) На вкладке Advanced в разделе Clusterds выберем Cases, а в поле Number of Clusters введем цифру 2 – число классов (кластеров). Сохраним результаты анализа при помощи вкладки Advandet выбором опции Save clustering and distances для сохранения результатов кластеризации и расстояния. В таблице результатов скопируем переменную Cluster и добавим ее в исходный файл данных. В строках данной переменной содержатся номера классов, к которым были отнесены в итоге многомерные образы. Кластеризация проведена, классы описаны на языке выбранных признаков и готовы к использованию на втором этапе как обучающие выборки соответствующего класса.

Для удобства построим двухуровневую модель. На первом - нейронная сеть устанавливает неисправную систему (приемная, передающая и т.д.), а на втором – неисправный узел или панель в самой системе. Соответственно, потребуется обучать две сети и для каждой описание классов будет свое. Процедура кластеризации проводится отдельно для каждого из двух уровней.

Построение классификатора 1

Построим нейросетевую модель, которая по произвольному входному вектору заданной размерности (совокупности – x чисел), определяла

бы класс, к которому принадлежит исследуемый образ. Другими словами, необходимо реализовать процедуру отнесения каждого предъявленного сети множества из словаря признаков (Var 1 – Var 60) определенному классу из алфавита. Решим эту задачу в нейросреде StatSoft с помощью модуля Neural Networks. Вызываем стартовую панель этого модуля командой Statistics из основного меню и во вкладке Quick данного диалогового окна в разделе Problem type выберем задачу Classification. Командой Variables вызываем диалоговое окно Select input, output и записываем все переменные по списку (Var 1 – Var 60). Обучающее множество импортируем из файла результатов кластерного анализа. В разделе Selekt analysis выбираем опцию Intelligent Problem Solver, а в окне настройки этой процедуры на вкладке Quick установим в разделе Networks tested укажем количество тестируемых сетей, например, 10. Все остальные параметры остаются неизменными. В диалоговом окне IPS Training In Progress по информации о времени исполнения алгоритма, значениям ошибок на обучающем, контрольном и тестовом множествах, путем сравнения их между собой, выбираем сеть. Анализ осуществляем по строкам информационного поля диалогового окна. В разделе Profile фиксируем топологию сети (SNN – MLP 24:24 – 56 – 1:1). Это важно знать при экспертном выборе компромиса между ошибками, производительностью и временем обучения. Под производительностью в задачах классификации понимается доля правильно классифицируемых наблюдений по отношению к общему числу наблюдений. Для практического применения часто используются значения производительности в диапазоне (0,9 – 0,97). Далее вызываем вкладку Descriptive Statistics с таблицей статистик классификации. Столбцы этой таблицы представляют собой наблюдаемые классы, а строки – предсказанные классы. В идеале в этой таблице диагональные элементы должны быть отличны от нуля, а все остальные – нулевые. Это значит, что процент неправильно классифицированных наблюдений равен нулю, а производительность сети равна 1.

Чтобы определить к какому классу относится многомерное наблюдение, во вкладке Advanced применим опцию User defined case для инициализации рабочего режима классификации входных образов. Для этого в окне Quick на вкладке User defined case prediction задаем входные значения, запустив режим сети User defined input и иницилируем Predictions.

В результате сеть выдает номер класса, которому принадлежит совокупность признаков (входной вектор), описывающих исследуемое состояние субъекта.

Построение классификатора 2

Аналогично проводим построение модели второго уровня, повторяя те же процедуры. Отличие заключается в том, что кластерный анализ проводится для 45 классов – по максимальному числу узлов в системах первого уровня классификации. Построим нейросетевую модель, которая по произвольному входному вектору заданной размерности (совокупности 60 – x чисел), определяла бы класс, к которому принадлежит исследуемый образ и реализуем процедуру отнесения каждого предъявленного сети множества из словаря признаков (Var 1 – Var 60) определенному классу из алфавита. Обучающее множество импортируем из файла результатов кластерного анализа для для второго уровня классификации. Решим эту задачу по алгоритму классификатора 1. В разделе Profile фиксируем топологию сети (SNN – MLP 60:60 – 27 – 1:1).

А далее отмечаем, к какому классу относится многомерное наблюдение, во вкладке Advanced применим опцию User defined case для инициализации рабочего режима классификации входных образов. Для этого в окне Quick на вкладке User defined case prediction задаем входные значения, запустив режим сети User defined input и иницилируем Predictions. В результате сеть выдает номер класса, которому принадлежит совокупность признаков (входной вектор), описывающих исследуемое состояние субъекта.

Таким образом, последовательно поставлены и решены две задачи: сформировано обучающие множество признаков для двух классов и для двух уровней диагностики; реализована процедура диагностики на двух уровнях. Последовательное применение этих процедур позволяет получить искомую нейросетевую модель диагностики радиолокационной системы:

(SNN – Kohonen 24:24 – 48:1) →

→ (SNN – MLP 24:24 – 56 – 1:1) →

→ (SNN – Kohonen 24:24 – 48:1) →

→ (SNN – MLP 60:60 – 27 – 1:1).

Заключение

1. Научная новизна предлагаемого решения состоит в обосновании возможности автоматизации отыскания неисправностей в изделии 2С6 на основе информационных моделей в среде Statsoft в формате модуля Statistika Neural Network.

2. Практическая значимость результатов данного исследования заключается в сокращении времени поиска неисправностей и снижении степени

человеческого фактора при принятии решений.

3. Перспективным является продолжение исследований в направлении адаптации полученных результатов для зашумленного вектора входных данных и с пропусками информативных параметров. Это позволит установить границы применимости полученного алгоритмического и программного инструментария в условиях высокой неопределенности.

Литература

1. Аleshин С.П. *Общая методика отыскания неисправностей в изделии 2С6* / С.П. Аleshин, М.Н. Коп-

нин, В.А. Пожарницкий [и др.] // *Основы эксплуатации и ремонта изделия 2С6. – Учебное пособие. – ПВЗРККУ. – Полтава, 1990. – С. 100-127.*

2. Хайкин С. *Нейронные сети: полный курс, 2-е издание. Пер. с англ. / С. Хайкин. – М.: Издательский дом «Вильямс», 2006. – 1104с.*

3. Морозов А.А. *Новые информационные технологии в системах принятия решений / А.А. Морозов // Управляющие системы и машины. – 1993. – № 3. – С. 13-32.*

4. Ляхов А.Л. *Проблема моделирования сложных социотехнических систем / А.Л. Ляхов, С.П. Аleshин // Системы поддержки принятия решений. Теория и практика. – ИПММС НАНУ, К., 2009. – С.31-34.*

Поступила в редакцию 3.02.2010

Рецензент: д-р техн. наук, проф., заведующий кафедрой экономической кибернетики Р.Г. Савенко, Полтавский национальный технический университет, Украина.

ТЕХНІЧНА ДІАГНОСТИКА БОРТОВИХ РАДІОЛОКАЦІЙНИХ СИСТЕМ В СЕРЕДОВИЩІ STATISTIKA NEURAL NETWORK

О.Л. Ляхов, С.П. Альошин

Робота присвячена проблемі автоматизації пошуку несправностей в бортових радіолокаційних системах на основі технологій штучного інтелекту. Запропоновано методику побудови нейромережевої моделі методу послідовних наближень при пошуку несправностей. В якості середовища формування моделей базових процесів обраний стандартний нейропакет Statistika Neural Network. Побудовано моделі кластерного аналізу вхідних даних і дворівневого класифікатора станів об'єкта. Запропонована методика дозволяє автоматизувати процес пошуку несправностей РЛС і знизити час на ухвалення рішень по їх відновленню.

Ключові слова: радіолокаційна система, пошук несправностей, кластерний аналіз, класифікація, нейронна мережа.

TECHNICAL DIAGNOSTICS OF BOARD RADAR SYSTEMS IN THE MEDIUM STATISTIKA NEURAL NETWORK

O.L. Lyakhov, S.P. Aleshin

The work is devoted to the automation troubleshooting airborne radar systems based on artificial intelligence techniques. The technique of constructing neural network model of the method of successive approximations by troubleshooting is proposed. An environment of basic processes formation models was selected standard package Statistika Neural Network. A model of cluster analysis of input data and two-level classification of states of the object was developed. The proposed method allows to automates the process of troubleshooting the radar and to reduce the time to make decisions on their recovery.

Keywords: radar system, troubleshooting, cluster analysis, classification, neural network.

Ляхов Александр Логвинович – д-р техн. наук, проф., заведующий кафедрой компьютерных и информационных технологий и систем, Полтавский национальный технический университет им. Юрия Кондратюка, Украина, e-mail: LAL@pntu.edu.ua.

Аleshин Сергей Павлович - канд. техн. наук, доц., ст. научн. сотр., Полтавский национальный технический университет им. Юрия Кондратюка, Украина, e-mail: aleshsp@ukr.net.