

СИСТЕМЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

УДК 681.142.3

И.В. Бондаренко, С.П. Навойцев, В.Н. Наумов, Ю.И. Синещук

НЕЙРОСЕТЕВАЯ МОДЕЛЬ КЛАССИФИКАЦИИ СИТУАЦИЙ

Бондаренко Илья Витальевич, кандидат технических наук, окончил факультет автоматизированных систем управления Военно-морского института радиоэлектроники им. А.С. Попова. Старший преподаватель Военного учебно-научного центра (ВУНЦ) ВМФ «Военно-морская академия им. Н.Г. Кузнецова». Имеет статьи по применению нейросетевых моделей в военной сфере. [e-mail: bondarenko@bk.ru].

Навойцев Сергей Петрович, кандидат технических наук, старший научный сотрудник, лауреат Государственной премии РФ, окончил факультет математического обеспечения АСУ Высшего военно-морского училища радиоэлектроники им. А.С. Попова (ВВМУРЭ). Специализируется в области информационных технологий АСУ специального назначения. Заместитель главного конструктора ФНПЦ ОАО «НПО «Марс». [e-mail: navojcev@yandex.ru].

Наумов Владимир Николаевич, доктор военных наук, профессор, заслуженный деятель науки РФ, окончил факультет электронной вычислительной техники ВВМУРЭ. Профессор ВУНЦ ВМФ «Военно-морская академия им. Н.Г. Кузнецова». Имеет многочисленные публикации в области автоматизации процессов управления корабельными средствами и системами. [e-mail: naumov122@list.ru].

Синещук Юрий Иванович, доктор технических наук, профессор, заслуженный работник высшей школы РФ, окончил факультет боевых информационных управляющих систем ВВМУРЭ. Профессор ВУНЦ ВМФ «Военно-морская академия им. Н.Г. Кузнецова». Специализируется в области моделирования свойств устойчивости функционирования сложных систем. [e-mail: sinegal@rambler.ru].

Аннотация

В статье приводится нейросетевая модель классификации ситуаций, возникающих при отражении атак противокорабельных ракет (ПКР). Описаны функции принадлежности входных и выходных переменных. Выявлены необходимые способы фаззификации переменных.

Ключевые слова: противовоздушная оборона, противокорабельные ракеты, нейронная сеть, классификация ситуаций.

Ilya Vitalyevich Bondarenko, Candidate of Engineering; graduated from the Faculty of C2 Systems of the Naval Radio-Electronics Academy named after A. Popov; senior lecturer at the Military Training and Research Centre 'Naval Academy named after N. Kuznetsov'; author of articles in the field of use of neuronet models in military fields. e-mail: bondarenko@bk.ru.

Sergey Petrovich Navoytsev, Candidate of Engineering, senior staff scientist; laureate of the State Prize of the Russian Federation; graduated from the Faculty of Software of the Naval Radio-Electronics Academy named after A. Popov; specializes in the field of information technologies of special-purpose C2 systems; deputy chief designer at FRPC OJSC 'RPA 'Mars'. e-mail: navojcev@yandex.ru.

Vladimir Nikolaevich Naumov, Doctor of Military Sciences, Professor; honoured worker in the science of the Russian Federation; graduated from the Faculty of Computers of the Naval Radio-Electronics Academy named after A. Popov; Professor at the Military Training and Research Centre 'Naval Academy named after N. Kuznetsov'; author of numerous publications in the field of automation of control processes of ship's facilities and systems. e-mail: naumov122@list.ru.

Yury Ivanovich Sineshchuk, Doctor of Engineering, Professor; honoured worker of the Higher School of the Russian Federation; graduated from the Faculty of Combat-Management Systems of the Naval Radio-Electronics Academy named after A. Popov; Professor at the Military Training and Research Centre 'Naval Academy named after N. Kuznetsov'; specializes in the field of modeling of the features of the operation stability of complex systems. e-mail: sinegal@rambler.ru.

Abstract

The article cites a neuronet model to categorize situations which occur during the repulsion of anti-ship missiles. It also describes the membership functions of input and output variables. The authors brought to light required methods of variable phasing.

Key words: anti-aircraft defense, anti-ship missiles, neural network, situation categorization.

ВВЕДЕНИЕ


Сложность организации решения задач противовоздушной обороны (ПВО) в автоматизированных системах надводных кораблей обусловлена их большой размерностью, наличием разнообразных информационных потоков, нечеткостью, противоречивостью, неполнотой поступающей информации и другим. В настоящее время реализация в корабельных автоматизированных системах задач ПВО осложняется рядом существенных обстоятельств, к которым относятся:

- невозможность учета большого количества взаимосвязанных факторов;
- сложность формализации протекающих процессов;


- трудность согласования различных по характеристикам источников информации;
- нехватка оперативно добываемой объективной и субъективной исходной и промежуточной информации;
- сложность формализации и дальнейшего использования накопленных знаний, используемых лицом, принимающим решение (ЛПР), при решении задач ПВО;
- отсутствие методов анализа тактической и оперативно-тактической ситуаций в условиях недостатка, неопределенности и нечеткости информации;
- сложность разработки математических моделей процессов.

При этом, в целом, применение средств автоматизации в процессах сбора и обработки данных показывает, что:


а) $T_e = 9$ с



б) $T_e = 10$ с



в) $T_e = 12$ с



г) $T_e = 15$ с




Рис. 1. Зависимости рабочего времени и времени управления от скорости ПКР для разного времени воздействия

- существующие системы специального программного обеспечения не выполняют полномасштабной оперативной обработки информации, в результате чего ЛПР использует только около 15% всей поступающей информации;

- отсутствуют технологии выявления скрытых знаний из накапливаемых данных с целью их использования при принятии решения;

- необходимость учета эмпирического опыта при решении задач ПВО влечет за собой совершенствование организации их решения на базе новых информационных технологий, например нейросетевых алгоритмов обработки информации.

Несмотря на многообразие источников информации, эффективность их использования при решении задач отражения атак ПКР в существующих системах остается недостаточной. При этом время воздействия используемых при обороне зенитных огневых средств (ЗОС) достаточно велико. Учитывая, что время управления T_y определяется разницей между полным рабочим временем T_p и временем воздействия T_e : $T_y = T_p - T_e$, зависимость временных параметров ПВО от скорости используемых противником ракет представлена на рисунке 1. Следует сказать, что при увеличении скорости ракеты уменьшается имеющееся рабочее время, и, как результат, время на принятие решения резко сокращается. В ряде случаев, например, при скорости выше 800 м/с и при времени воздействия 15 с управление вообще не может быть реализовано (рис. 1 г).

При этом надо понимать, что влияние радиоэлектронных помех и фактор малоразмерных целей еще более усугубляют ситуацию.

В этих условиях актуальной становится задача адаптации структуры программных комплексов к реальной тактической ситуации.

МОДЕЛЬ КЛАССИФИКАЦИИ ТАКТИЧЕСКОЙ СИТУАЦИИ

Предлагаемая нейросетевая модель классификации позволяет на основе накопленных в процессе обучения знаний распознавать тактическую ситуацию и выработать варианты организации решения указанных задач.

Возможный набор входной информации, используемой в модели, представлен в таблице 1.

Различные наборы программных модулей позволяют получить различные варианты архитектуры программного комплекса ПВО, обладающие различными функциональными возможностями и временными параметрами реализации в соответствии с отождествленной ситуацией. Состав его программных компонентов определяется текущей тактической ситуацией. Данные компоненты могут быть сопоставлены этапам цикла управления и режимам (табл. 2), в которых они могут выполняться.

Несмотря на кажущуюся простоту, число комбинаций вариантов архитектуры достигает 27. С каждым этапом цикла управления и его режимом также связаны набор и приоритеты решения задач, определяемые исходной обстановкой. С учетом этого число возможных вариантов комбинаций архитектур возрастает. Возникает проблема выбора варианта архитектуры, которая представляет

Таблица 1

Входные переменные		
Лингвистическая переменная	Обозначение	Значения переменной
Дистанция до цели	X1	A11 – цели в зоне самообороны; A12 – цели в опасной близости; A13 – цели далеко
Количество отметок воздушных целей	X2	A21 – одиночная цель; A22 – групповая цель
Число и мощность излучений в диапазоне	X3	A31 – молчание; A32 – низкая; A33 – средняя; A34 – интенсивная
Скорость цели	X4	A41 – низкая; A42 – среднескоростная; A43 – скоростная; A44 – высокоскоростная
Курсовой параметр цели	X5	A51 – неопасный; A52 – средний; A53 – угрожающий; A54 – опасный
Высота цели	X6	A61 – низколетящая; A62 – средняя; A63 – высотная
Наличие помех	X7	A71 – нет; A72 – есть

Таблица 2

Выходные переменные		
Этапы цикла управления	Обозначение	Режимы выполнения
Отображение обстановки	Y1	B11 – фоновый режим; B12 – формулярный режим; B13 – графический режим
Подготовка предложений по боевому использованию средств ПВО	Y2	B21 – автоматический режим; B22 – циклический режим с утверждением; B23 – возможное участие оператора в формировании решения
Формирование и передача команд управления средствам ПВО корабля	Y3	B31 – автоматический режим; B32 – циклический режим; B23 – возможен полуавтоматический режим


собой задачу классификации ситуации. С учетом приведенных в таблице 1 данных при однозначном определении значения каждой переменной число классов ситуаций равно 2304. Таким образом, задача классификации может быть рассмотрена как задача поиска в матрице размерностью 2304x27.

Размерность такой задачи, с одной стороны, велика, а с другой – каждая лингвистическая переменная, приведенная в таблице 1, задается нечетким множеством.


Поэтому в общем случае мощность множества ситуаций бесконечна.

Для решения задачи классификации используем нейронные сети, входными и выходными переменными которых являются значения функций принадлежности нечетких множеств. Построение модели предполагает определение функции принадлежности значений лингвистических переменных, представленных в таблицах 1 и 2. На рисунке 2 приведены графики функций принадлежности для указанных переменных.

а) дистанция до цели (X_1)




б) тип цели (X_2)




в) число и мощность излучения (X_3)




г) скорость цели (X_4)




д) курсовой параметр (X_5)




е) высота цели (X_6)



ж) наличие помех (X_7)



з) режим отображения обстановки (Y_1)



и) режим подготовки предложений по использованию ЗОС (Y_2)



к) режим формирования и передачи команд управления (Y_3)




Рис. 2. Функции принадлежности входных и выходных переменных

Предлагаемая модель описывается нейронной сетью, основанной на многослойном перцептроне, позволяющей реализовать представленные выше функции принадлежности и состоящей из пяти слоев, 10 нейронов, 7 нейронов-сумматоров и 3 дефаззификаторов (рис. 3).

Каждый нейрон в нейронной сети осуществляет преобразование входных сигналов в выходной и связан с другими нейронами [1]. Входные нейроны формируют так называемый интерфейс нейронной сети, состоящий из потоков входных данных. Нейронная сеть, показанная на рисунке, имеет два слоя нейронов. Один из них принимает входные сигналы, а второй – генерирует выходные сигналы. Информация вводится в нейронную сеть через входной слой. Все слои нейронной сети обрабатывают эти сигналы до тех пор, пока они не достигнут выходного слоя. Помимо этого используются вспомогательные слои для фаззификации, суммирования и дефаззификации

переменных. Эти операции выполняются в соответствии с формулами 1, 2.

$$\mu(x) = \frac{1}{1 + \left(\frac{x-b}{c}\right)^2}, \quad (1)$$

где $\mu(x)$ – функция принадлежности входных переменных;

x – входное значение;

b – координата максимума функции принадлежности;

c – коэффициент «пологости» функции принадлежности.

$$Y_k = \frac{1}{2} \left(\min(y | \mu(y) = \max \mu(Z)) + \max(y | \mu(y) = \max \mu(Z)) \right), \quad (2)$$

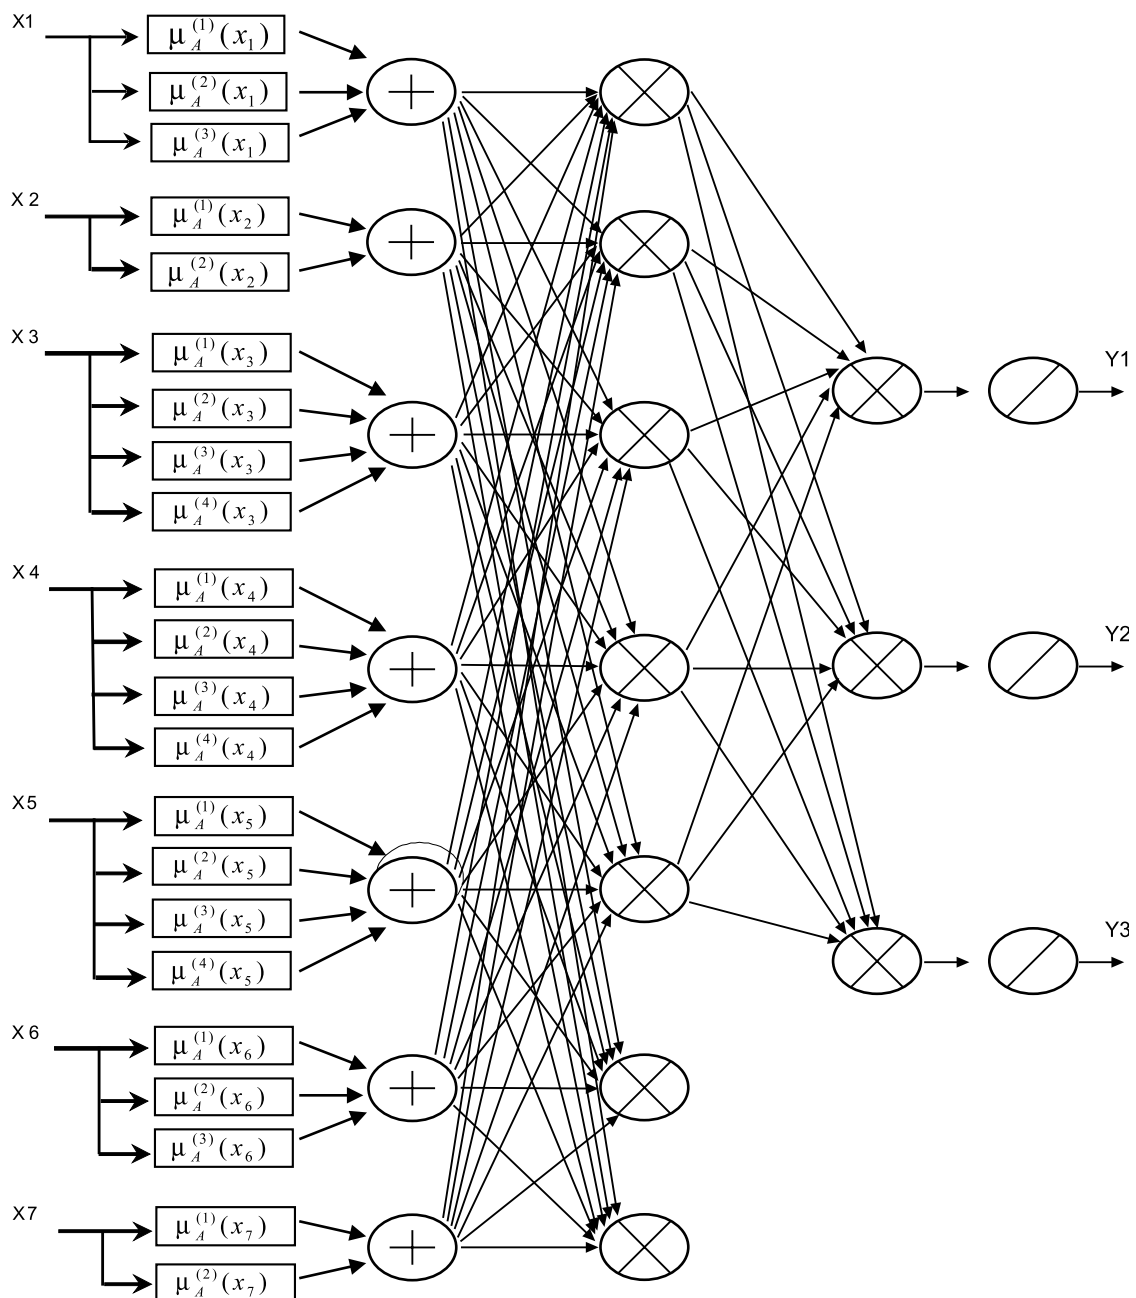


Рис. 3. Нейронная сеть, отображающая заданные функции принадлежности

где Y_k – функция дефаззификации выходного значения;
 $\mu(Z)$ – функция принадлежности выходной переменной, определенной способом «центра максимумов»;
 $\mu(y)$ – функции принадлежности выходных переменных.

Задача нейронной сети – преобразование информации требуемым образом, исходя из складывающейся ситуации.

Для использования предложенной сети при решении задач классификации данная сеть предварительно обучается, настраиваются весовые коэффициенты нейронов и функции принадлежности входных и выходных переменных. При обучении используются идеальные (эталонные) значения пар входы-выходы, например, экспертные правила продукции, которые оценивают поведение нейронной сети. Для обучения используется обучающий алгоритм (рис. 4).

Ненастроенная нейронная сеть не способна отображать желаемое поведение [2]. Обучающий алгоритм модифицирует отдельные нейроны сети и веса ее связей таким образом, чтобы поведение сети соответствовало желаемому поведению. Так, в частности вычисляются входной и выходной сигналы и погрешность нейронной сети:

$$u_j = \sum_{i=1}^m v_i w_{ij}, \quad v_j = \frac{1}{1 + e^{-ku_j}},$$

$$Q = \frac{1}{2} \sum_{j=1}^{N_k} (v_i - v_j), \quad (3)$$

где u_j – входной сигнал нейрона ij ;
 m – число слоев в нейронной сети;
 v_i – входной сигнал;
 v_j – выходной сигнал;
 k – нормализующий параметр;
 Q – погрешность нейронной сети;
 w_{ij} – весовой коэффициент нейрона ij ;
 N_k – количество выходов.

После завершения обучения каждый нейрон в сети имеет свой весовой коэффициент.

Сравнительная оценка способов фаззификации выходных переменных позволила выявить, что при фаззификации методом центра максимумов степень соответствия выходного значения эталонному достигает более высокого значения.

Таким образом, предложенная в работе нейросетевая модель представляет собой систему, жизненный цикл которой состоит из двух фаз: обучения и, непосредственно, работы сети. Обучение считается законченным, когда сеть правильно выполняет преобразование на тестовых примерах и дальнейшее обучение не вызывает значительного изменения настраиваемых весовых коэффициентов [3]. Далее сеть выполняет преобразование ранее неизвестных ей данных на основе сформированной в процессе обучения модели объекта. Сеть успешно работает до тех пор, пока существенно не изменится реальная модель отображаемого процесса (например, в случае возникновения си-

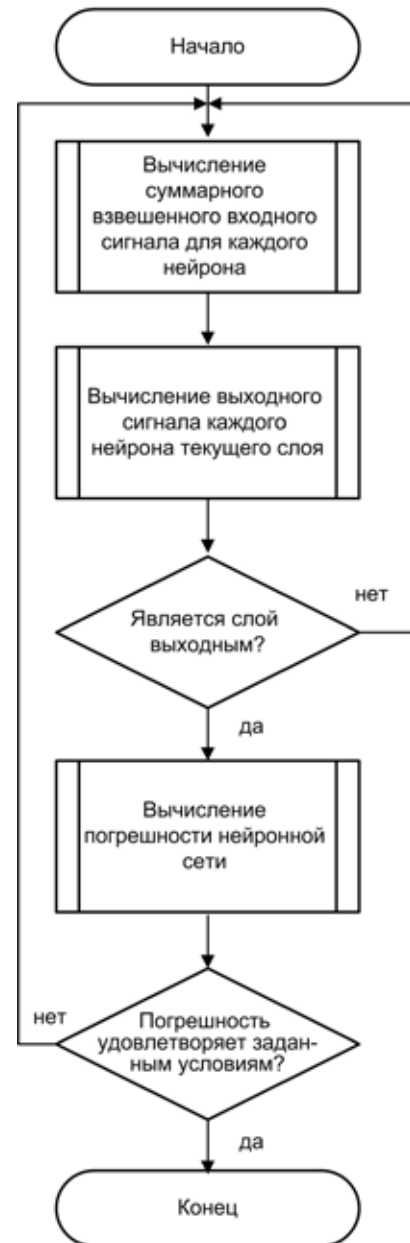


Рис. 4. Алгоритмизированная процедура обучения нейронной сети

туации, информация о которой никогда не предъявлялась сети при обучении: появление новых образцов вооружения, способов применения, средств ПВО и т. д.). В этом случае сеть может быть дообучена с учетом новой информации. При этом предыдущая информация не теряется, а агрегируется с вновь поступившей. От того, насколько качественно будет выполнен этап обучения, зависит способность сети решать поставленные перед ней задачи во время эксплуатации.

Наибольшие преимущества применения предлагаемых средств достигаются на подготовительных этапах разработки, отличительной чертой которых является значительный уровень неопределенности вследствие неполноты, внутренней противоречивости данных, неоднозначности и размытости технического задания, содержащего приближенные оценки характеристик объекта в виде числовых диапазонов, а также словесное описание

целей, ограничений и условий качественного характера [4]. Отсутствие аналитических зависимостей, уравнений, связывающих данные и критерии, и, как следствие, расплывчатость представлений о взаимодействии, изменчивый динамический характер причинно-следственных связей также обуславливают необходимость построения нечеткой базы знаний.

Заключение

Представленная нейросетевая модель позволяет провести адаптацию архитектуры программного обеспечения систем обработки к текущей тактической ситуации. Применение предложенных средств позволяет повысить эффективность организации решения задач ПВО в условиях нечеткости, противоречивости, неполноты поступающей

информации, наличия разнообразных информационных потоков большой размерности и ограниченных временных ресурсов.

СПИСОК ЛИТЕРАТУРЫ

1. Ярушкина Н.Г. Основы теории нечетких и гибридных систем. – М. : Финансы и статистика, 2004.
2. Ротштейн А.П. Интеллектуальные технологии идентификации. – М. : Мир, 1999.
3. Назаров А.В., Лоскутов А.И. Нейросетевые алгоритмы прогнозирования и оптимизации систем. – СПб. : Наука и Техника, 2003.
4. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика. – 2-е изд. – М. : Горячая линия–Телеком, 2002.