

и 0,15 г/л кобальта. Эти концентрации достаточны для селективного выделения цветных металлов с применением известных технологических приемов.

Предполагается, что после выделения из раствора цветных металлов оставшейся раствор, содержащий в основном ионы двухвалентного железа (до 20 г/л) в виде сульфата, направляется на биорегенерацию с применением используемых железоокисляющих хемолитотрофных бактерий. Бактерии в процессе биорегенерации окисляют ионы двухвалентного железа до трехвалентного. После биорегенерации раствор предлагается использовать для повторного химического выщелачивания шлака, полученного при производстве медно-никелевого штейна.

Таким образом, предлагаемый процесс выщелачивания цветных металлов из шлака сульфатом трехвалентного железа, полученным с помощью железоокисляющих хемолитотрофных бактерий, позволит не только получить из него цветные металлы, но и создать технологию с замкнутым циклом технологических потоков. При этом шлак после удаления из него цветных металлов может использоваться в качестве сырья для других отраслей промышленности, в частности для производства стройматериалов.

Литература

1. Gorai B., Jana R., Premchand K. Characteristics and utilization of copper slag – a review. Resour. Conserv. Recycl. 2003. V. 39. P. 299–313.
2. Yang Z., Rui-lin M., Wang-dong N., Hui W. Selective leaching of base metals from copper smelter slag. Hydrometallurgy. 2010. V.103. P. 25–29.
3. Banza A.N., Gock E., Kongolo K. Base metals recovery from copper smelter slag by oxidizing leaching and solvent extraction. Hydrometallurgy. 2002. V. 67. P.63–69.
4. Anand S., Rao K.S., Jena P.K. Pressure leaching of copper converter slag using dilute sulphuric acid for the extraction of cobalt, nickel and copper values. Hydrometallurgy. 1983. V.10. P. 305–312.
5. Carranza F., Romero R., Mazuelos A., Iglesias N., Forcat O. Biorecovery of copper from converter slags: Slags characterization and exploratory ferric leaching tests. Hydrometallurgy. 2009. V. 97. P.39–45.
6. Altundogan H.S., Boyrazli M., Tumen F. A study on the sulfuric acid leaching of copper converter slag in the presence of dichromate. Miner. Eng. 2004. V. 17. P. 465–467.
7. Gbor P.K., Ahmed I.B., Jia C.Q. Behavior of Co and Ni during aqueous sulphur dioxide leaching of nickel smelter slag. Hydrometallurgy. 2000. V. 57. P. 13–22.
8. Arslan C., Arslan F. Recovery of copper, cobalt, and zinc from copper smelter and converter slags. 2002. Hydrometallurgy. V. 67. P.1–7.

Методика распознавания летательных аппаратов и радиолокационных ловушек в контуре управления системы контроля воздушного пространства на основе нейросетевой технологии

к.т.н. Бобин А.В.¹, Азаров В.А.², Булгаков С.А.², Савин Д.А.²

¹Университет машиностроения

²НИУ ВШЭ

alvbobin@gmail.com

Аннотация. В работе предлагается методика построения автоматических распознавателей летательных аппаратов по набору радиолокационных измерений на основе каскада многослойных нейронных сетей прямого распространения. Демонстрируется практическое применение данной методики при распознавании летательных аппаратов трех типов.

Ключевые слова: распознавание динамических объектов, распознавание образов, нейросетевая обработка информации, многослойные нейронные сети.

Работа выполнена при финансовой поддержке РФФИ (грант № 12-01-31322 mol_a)

Проблема классификации динамического объекта (ДО), состояние которого меняется с течением времени, встречается во многих предметных областях и является сложной и трудноразрешимой [1, 3, 5]. Единого подхода к построению систем классификации таких объектов, пригодного для любых ситуаций и задач, в настоящее время не разработано [4–6]. Таким образом, задача синтеза разнообразных методик построения автоматических классификаторов ДО является важной и актуальной [6].

Подобная задача возникает в контуре управления системы контроля воздушного пространства (СКП) [7]. СКП создается с целью отслеживания перемещений летательных аппаратов (ЛА) в заданной области воздушного пространства в интересах управления воздушным движением гражданской авиации или в интересах противовоздушной обороны. При обслуживании большого числа ЛА с помощью ограниченных ресурсов СКП важную роль играет своевременная и достоверная информация о типах обслуживаемых ЛА, об их технических возможностях и режимах работы [7]. В частности, большой интерес представляет информация о применении летательным аппаратом радиолокационных ловушек (РЛ).

Основным источником информации для пунктов управления СКП, принимающих решения по распределению ресурсов системы между обслуживающими ЛА, являются наземные или воздушные радиолокационные станции (РЛС).

В данной статье предлагается методика построения компонента системы управления СКП – блока распознавания типа ЛА – на основе каскада многослойных нейронных сетей прямого распространения. Предлагаемая система классификации состоит из отдельных нейросетевых блоков, причем каждый блок характеризуется простой функциональной задачей, а обучение блоков выполняется в определенной последовательности с использованием как результатов непосредственных наблюдений РЛС, так и результатов обучения других блоков.

Постановка задачи

Пусть РЛС осуществляет наблюдение за одним ЛА неизвестного типа, который вошел в ее зону действия. В каждый момент дискретного времени РЛС выдает траекторную информацию о движении неизвестного ЛА. Предполагается, что данные, получаемые от РЛС, содержат ошибки измерений, причем ошибки в разные моменты времени независимы.

Требуется построить систему классификации, работающую в контуре управления СКП, которая по получаемой от РЛС информации в темпе поступления входных данных будет определять типа неизвестного ЛА. Число распознаваемых типов заранее известно и фиксировано. ЛА других типов должны идентифицироваться системой как неопознанные.

Информационной основой для построения подобной системы принятия решений является набор характерных траекторий движения ЛА распознаваемых типов, полученных в разных условиях применения и достаточно полно отражающих динамические свойства рассматриваемых ЛА. Реализации траекторий ЛА, используемые для настройки системы классификации, могут быть получены на стендах полунатурного моделирования, в условиях полигонных испытаний и на математических моделях.

В связи со сложностью формализации процесса принятия решения в условиях разнообразия воздушных ситуаций, неполноты и возможной противоречивости исходных данных целесообразно использование адаптивных алгоритмов, в частности, аппарата искусственных нейронных сетей.

Структура нейросетевого распознавателя

Система F распознавания ЛА состоит из двух блоков (рисунок 1), которые работают последовательно. Классификатор F_1 осуществляет локальную во времени классификацию

ЛА на основе текущего значения входного вектора S_i . Решения классификатора F_1 принимаются независимо в каждый момент времени. Для учета предыстории принятых в отношении данного ЛА решений служит классификатор F_2 .

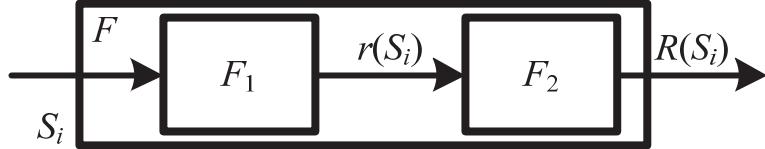


Рисунок 1. Структура системы классификации

Классификатор F_1 состоит из нескольких блоков (рисунок 2). Рассмотрим N нейросетевых блоков $G_j, j = 1, 2, \dots, N$, которые далее составят основу для нейросетевого классификатора F_1 . Каждый блок G_j , предназначен для классификации входного вектора S_i по принципу «тип j против всех». Каждый блок G_j обучается воспроизводить следующий желаемый выход:

$$\begin{aligned} g_j(S_i) &= 1, \text{ если вектор } S_i \text{ соответствует ЛА типа } j, \\ g_j(S_i) &= 0, \text{ в других случаях.} \end{aligned}$$

Нейросетевые блоки $G_j, j = 1, 2, \dots, N$, выполняют локальную по типу и по времени классификацию ЛА (рисунок 2). В связи с неточностью вычисленных по данным РЛС компонентов входного вектора S_i , а также с возможностью расположения вектора S_i вблизи границы классов классификаторы G_j могут не дать однозначного вывода о принадлежности вектора S_i определенному типу ЛА. Для устранения этой возможной неопределенности используется дополнительный нейросетевой классификатор G , который принимает на вход значения $g_j(S_i), j = 1, 2, \dots, N$, и обучается воспроизведению значения, равного номеру типа ЛА:

$$g(S_i) = \varphi(g_1(S_i), g_2(S_i), \dots, g_N(S_i)) = j, \text{ если вектор } S_i \text{ соответствует типу } j.$$

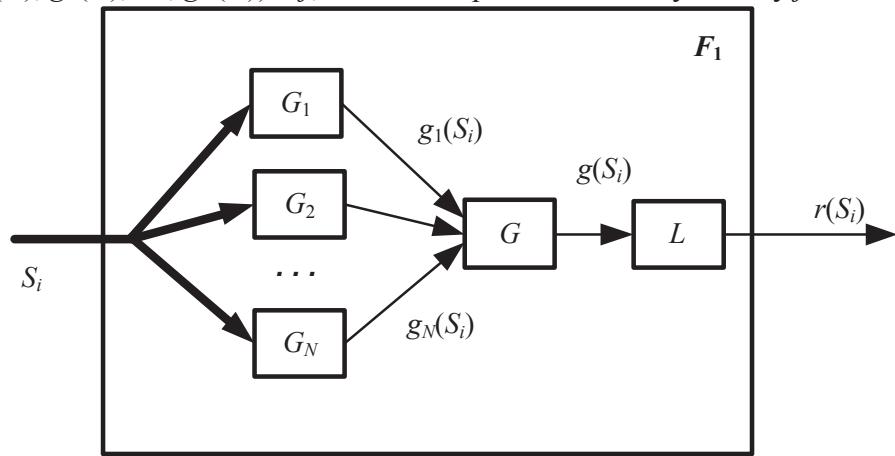


Рисунок 2. Структура блока локальной классификации

Если для некоторого значения j выполняется неравенство

$$|g(S_i) - j| \leq \delta,$$

где δ – заданный параметр, $\delta \in (0, 1)$, то принимается решение о принадлежности цели с текущим входным вектором S_i типу j : $r(S_i) = j$. Если ни для одного значения $j = 1, 2, \dots, N$ данное неравенство не выполняется, классификатор принимает решение в пользу неизвестного типа ЛА: $r(S_i) = 0$. Все эти неравенства проверяются в выходном блоке L классификатора F_1 (рисунок 2).

Классификатор F_1 вырабатывает предварительное решение о типе наблюдаемого ЛА. Финальное решение формируется с использованием расчетных данных о достоверности решения классификатора F_1 . Локальные решения, вырабатываемые классификатором F_1 , в раз-

ные моменты времени принимаются независимо друг от друга, без учета предыстории и накопления информации. Этот недостаток устранен далее введением дополнительного блока классификации F_2 , который обеспечивает инерционность принятия решений.

Учет предыстории локальных решений

Рассмотрим временной интервал заданной длины, включающий M измерений перед текущим моментом принятия решения о типе ЛА, т.е. «скользящее окно» ширины M . В каждый момент времени на этом интервале локальным классификатором F_1 принято предварительное решение. Среди возможных решений F_1 могут быть и решения «неопознанный ЛА».

В блоке F_2 происходит осреднение в «скользящем окне» ширины M локальных решений $r(S_i)$, полученных в предшествующие моменты времени. Для этого в блоке F_2 (рисунок 3) содержится N накопителей. При поступлении новых данных переключатель K выбирает нужный накопитель с номером $r(S_i)$ и добавляет в него текущее значение 1, в остальные накопители добавляется значение 0.

Осреднение локальных решений по каждому типу производится в каждом накопителе Q_i , $i = 0, \dots, N$, согласно выражению

$$q_i^* = \frac{1}{M+1} \sum_{j=k-M}^k q_i(t_j),$$

где M – ширина «скользящего окна» (размер накопителя Q_i);

$q_i(t_j)$ – значение локального решения в пользу этого типа, поступившее в момент t_j ;

t_k – текущий момент времени.

Таким образом, на выходе блоков Q_i , $i = 0, \dots, N$, получается вектор из осредненных локальных решений $(q_0^*, q_1^*, \dots, q_N^*)$. Этот вектор подается на логический блок L , который аналогичен одноименному блоку локального классификатора.

Полученное после работы блока L окончательное решение $R(S_i)$ является результатом работы системы классификации. Применение выходного классификатора F_2 обеспечивает накопление информации о предыстории принятых решений, отсутствие «скачков» и повышение точности решения о типе ЛА.

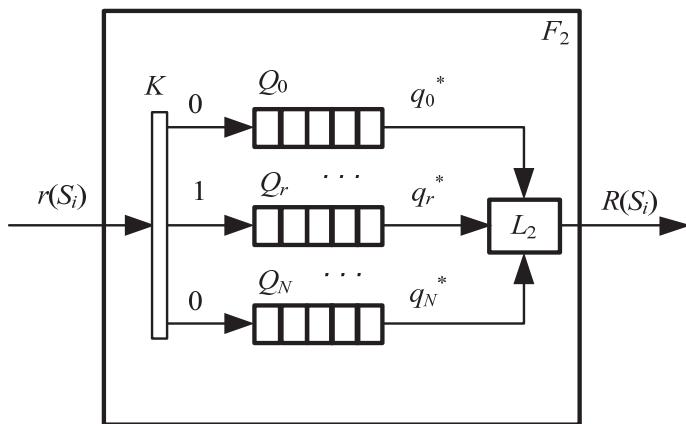


Рисунок 3. Структура блока учета динамики локальных решений

Рекомендуется ширину «скользящего окна» на начальном этапе классификации выбрать небольшой и постепенно увеличивать до заданного максимального значения. Это позволит активно перестраивать решение в условиях, когда информации недостаточно для принятия уверенного решения.

Алгоритм обучения системы классификации

Для обучения системы классификации предлагается следующий алгоритм. На первом шаге обучения системы производится настройка локальных по времени и по типу классифи-

каторов G_i , $i = 1, \dots, N$. Для этого формируется обучающая выборка T_1 , включающая представителей всех распознаваемых типов ЛА. Каждый элемент обучающей выборки – вектор S_i , описывающий мгновенное состояние конкретного ЛА.

На втором шаге обучения производится тестирование качества обучения классификаторов G_i , $i = 1, \dots, N$, на новой независимой тестовой выборке T_2 . Фактические выходы классификаторов G_i , полученные в результате тестирования, представляют собой обучающую выборку для выходного локального классификатора G .

На третьем шаге алгоритма формируется независимая от T_1 и T_2 выборка T_3 , которая предъявляется классификаторам G_i и косвенно – классификатору G . Получившиеся в результате тестирования классификатора G фактические выходные значения служат информационной основой для настройки пороговых значений в логическом блоке L локального классификатора F_1 .

На четвертом шаге обучения системы формируется независимая выборка T_4 , которая служит для настройки пороговых значений в логическом блоке L классификатора F_2 .

Обучение каждого нейросетевого модуля производится по алгоритму обратного распространения ошибки. В ходе исследований установлено, что наиболее быстрое и качественное обучение достигается с помощью алгоритма Левенберга–Марквардта.

Показатели качества классификации

Отдельные нейронные сети, входящие в состав предложенной системы классификации, осуществляют за один такт обработку одного обучающего примера, который соответствуетциальному траекторному измерению. Такую классификацию будем называть поточечной. Наиболее естественные показатели качества поточечной классификации приведены в таблице 1.

Таблица 1

Показатели качества поточечной классификации

Формула	Описание
$\mu = \frac{K}{N}$	Доля правильно распознанных примеров выборки по отношению к ее общему объему; N – общее число примеров выборке; K – число правильно распознанных примеров.
$\eta_{ij} = \frac{n_{ij}}{n_i}$	Доля примеров типа i , отнесенных к типу j ; n_i – количество примеров типа i ; n_{ij} – количество примеров из числа n_i , отнесенных к типу j .
$\theta_{ij} = \frac{m_{ij}}{m_i}$	Доля примеров, отнесенных к типу i , которые на самом деле относятся к типу j ; m_i – количество примеров, отнесенных к типу i ; m_{ij} – количество примеров из числа m_i , которые на самом деле относятся к типу j .

Для конечного пользователя системы классификации большой интерес представляют показатели, оценивающие качество распознавания типа всей траектории интегрально на некотором участке наблюдения.

Для этого предлагается делать «временной срез» на каком-нибудь фиксированном измерении и относить траекторию к типу i , если среди последних P измерений H измерений относилось к типу i . Если ни для одного типа данный критерий не выполняется, то предлагается считать траекторию неопознанной. Оценивать качество классификации по всей выборке данных предлагается с помощью интегрального показателя

$$\rho_i = K_T^i / N_T^i,$$

где N_T^i – общее число траекторий типа i , K_T^i – число траекторий типа i , которые были рас-

познаны правильно в соответствии с указанным критерием.

Результаты модельных экспериментов

Изложенная выше методика распознавания типа ЛА проверена математическим моделированием. В качестве исходных данных для моделирования взяты типовые траектории движения трех видов ЛА. Все рассмотренные при проведении экспериментальных исследований траектории сгенерированы с помощью математических моделей, адекватно представляющих реальные динамические характеристики ЛА.

В общей сложности сгенерировано по 100 траекторий для каждого типа ЛА. Полученные с помощью математических моделей траектории будем называть эталонными. На основе каждой эталонной траектории построено по 10 вариантов реализаций. При подготовке выборок данных учитывались характеристики РЛС по точности и дальности обнаружения и сопровождения ЛА. В модельные траекторные данные были введены аддитивные ошибки, соответствующие погрешностям измерений реальной РЛС. Общее число модельных измерений вдоль всех сгенерированных траекторий составило около 70 000.

Результаты тестирования классификатора F_1 на независимой тестовой выборке приведены в таблице 2. В строках таблицы указаны принятые локальным классификатором решения для разных типов ЛА, указанных в первом столбце. В ячейках таблицы приведены значения показателя η_{ij} . Как следует из таблицы 2, доля правильно распознанных ЛА превышает 80 %. Лучше всего распознаются ЛА типа 1, при этом ошибка в пользу ЛА типа 3 и «Неопознан» невелика (в сумме менее процента). Ошибки при распознавании ЛА типа 2 и ЛА типа 3 в пользу друг друга несколько выше. Полученные результаты свидетельствуют не только об удовлетворительной точности, но и высокой обобщающей способности обученного локального классификатора F_1 .

Таблица 2

Результаты тестирования блока F_1 на независимой выборке

		Принятое классификатором решение			
		Тип 1	Тип 2	Тип 3	Неопознан
Фактический тип ЛА	Тип 1	0,9534	0,0367	0,0037	0,0062
	Тип 2	0,0213	0,8860	0,0600	0,0327
	Тип 3	0,0212	0,1140	0,8184	0,0464

Моделирование показало, что на ограниченных временных отрезках траектории ЛА разных типов могут быть сходны и трудно различимы. В таких ситуациях наблюдается частая смена решений локального классификатора F_1 . На рисунке 4 показаны решения, которые принимал локальный классификатор F_1 по мере приближения ЛА типа 3 к наблюдающей за ним РЛС. На горизонтальной оси отмечены номера наблюдений за ЛА от момента его обнаружения, на вертикальной оси указан номер типа, к которому классификатор F_1 отнес этот ЛА в текущем наблюдении. На графике показано 64 решения, последовательно принятых локальным классификатором. Из них 10 решений приняты в пользу неопознанного ЛА, 13 решений – в пользу ЛА типа 2 и одно решение – в пользу ЛА типа 1. На графике хорошо видно, что на средних дальностях (наблюдения 18-52) локальный классификатор начинает принимать противоречивые решения в пользу ЛА типов 2 и 3. Более того, начиная с 53-го наблюдения, классификатор F_1 практически стабильно начинает ошибочно относить ЛА к типу 2.

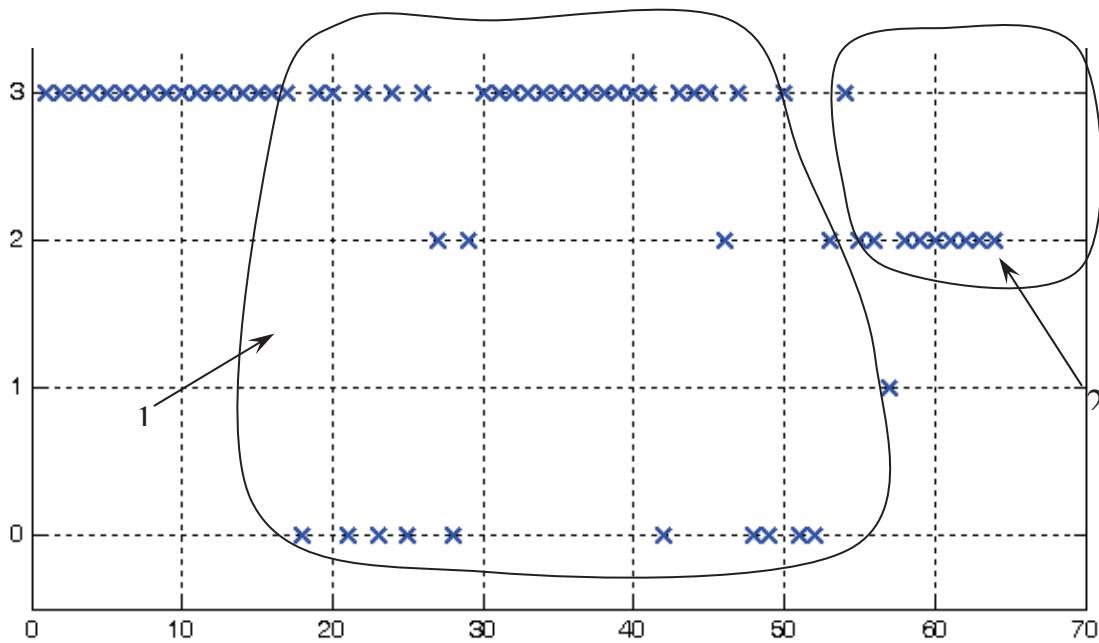


Рисунок 4. Последовательность решений, принятых блоком F_1 по ЛА типа 3:
1 – участок, где классификатор принимает верные решения на фоне локальных ошибок, 2 – участок, где классификатор стабильно принимает неправильные решения

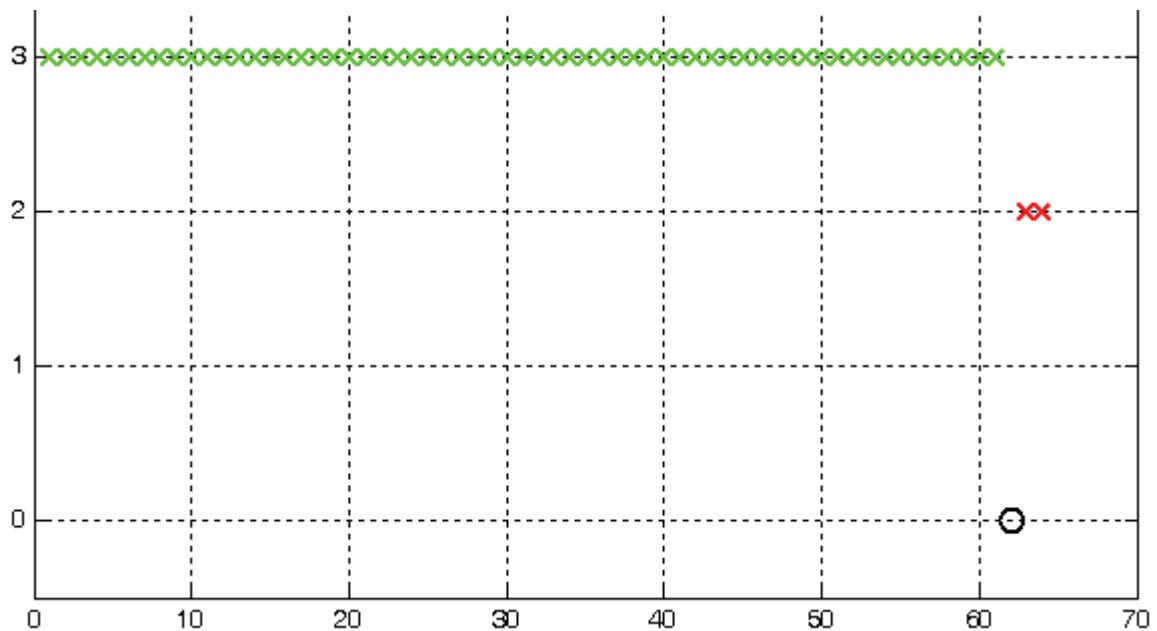


Рисунок 5. Демонстрация устранения локальных ошибок блоком F_2

Для преодоления возникающей неопределенности используется классификатор F_2 со «скользящим окном» длины 10. На рисунке 5 изображены решения о типе ЛА, принятые по тем же исходным данным интегральным классификатором F_2 . Изображенный на рисунке график наглядно демонстрирует эффект от использования интегрального классификатора. Практически на всей траектории движения ЛА классификатор F_2 стабильно принимает правильное решение о его типе. Лишь на трех самых последних наблюдениях ЛА сначала воспринимается как неопознанный (наблюдение 62), а затем принимается ошибочное решение (наблюдения 63-64) о его принадлежности к типу 2. Для данной конкретной траектории интегральный классификатор F_2 полностью подавляет колебания величины $r(S_i)$ на средних

дальностях, которые возникают в локальном классификаторе F_1 (рисунок 4), и существенно уменьшает область, где принимаются неправильные решения.

Заключение

В работе предлагается методика построения автоматических классификаторов динамических объектов на основе каскада многослойных нейронных сетей прямого распространения. Демонстрируется применение этой технологии при разработке классификатора летательных аппаратов, и приводятся числовые показатели распознавания трех типов ЛА.

Литература

1. Bishop, Chris. M. Neural Networks for Pattern Recognition. –Oxford: University Press, 2005.
2. Ту Дж., Гонсалес Р. Принципы распознавания образов. – М.: Мир, 1978.
3. Фукунага К. Введение в статистическую теорию распознавания образов. –М.: Наука, 1979.
4. Потапов А.С. Распознавание образов и машинное восприятие. –Изд. Политехника, 2007.
5. Хайкин, Саймон. Нейронные сети: полный курс.: Пер. с англ. – М.: «Вильямс», 2006.
6. Осовский С.. Нейронные сети для обработки информации. –М.: Финансы и статистика, 2004.
7. Бакуев П.А. Радиолокационные системы. – М.: Радиотехника, 2004.

Теплофизические зависимости при гранулировании в жидком азоте дисперсных частиц диаметром от 1 до 5 мм

к.т.н. проф. Белуков С.В., Кименс П.Ю.

Университет машиностроения

8(499)267-07-14

Аннотация. В работе рассмотрены разные математические модели для решения задачи криогранулирования жидких капель вещества в криоагенте. Получены расчетные данные и построены характерные зависимости процесса.

Ключевые слова: криогранулирование, криоагент, замораживание, теплопроводность, теплообмен.

Криогенный процесс – термодинамический процесс, частично или полностью протекающий при криогенных температурах.

Источником криогенной температуры служит жидкий азот (77 К). В процессе замораживания рабочее тело находится при криогенных температурах в газообразном и конденсированном состоянии.

Попадая в среду жидкого азота вещество, имеющее первоначально температуру окружающей среды, охлаждается, а затем замерзает, претерпевая фазовый переход из жидкого состояния в твердое. При высокой скорости протекания процесса криогранулирования происходит образование гранул мелкой кристаллической структуры, а, следовательно, в итоге получаем материалы с меньшим числом повреждений [1, 2].

При конструировании криогранулятора для приведения системы к лучшим параметрам и повышения эффективности работы устройства необходимо знать продолжительность основных процессов. Один из главных процессов в криогранулировании процесс замораживания жидкой капли вещества в среде криоагента играет решающую роль.

Задача определения времени, за которое гранула промерзает, попадая в жидкий азот, представляет собой задачу Стефана, так как присутствует фазовое превращение.

В рассматриваемом примере имеем нестационарную теплопроводность, которая меняется по координате и по времени в процессе распространения теплоты в веществе. Данный режим имеет место только для тепловых процессов, которые не успевают выйти на стаци-