

The possibility of using of neuronet models for automation of the gating systems development process is shown. The scheme of using of the neuronetprogramming in backlogs of choice of gating systems is offered.

А. Н. ЧИЧКО, Т. В. МАТЮШИНЕЦ, О. А. САЧЕК, В. А. ГАНЖА, БНТУ

УДК 669.27:519

О ПУТЯХ ПРИМЕНЕНИЯ МОДЕЛЕЙ НЕЙРОСЕТЕВОГО ПРОГРАММИРОВАНИЯ К РЕШЕНИЮ ЗАДАЧ КЛАССИФИКАЦИИ ОБЪЕКТОВ «ЛИТНИКОВАЯ СИСТЕМА–ОТЛИВКА»

Важнейший этап разработки технологии изготовления отливок в разовых и постоянных формах – выбор литниковой системы, которая является одним из основных технологических элементов, определяющих процессы заполнения форм. Важность этой задачи обусловлена огромной долей эмпиризма, который накоплен на каждом предприятии в результате изготовления отливок и может стать основой выбора литниковых систем. Известно, что от конфигурации литниковой системы и ее положения по отношению к отливке зависит расход металла и энергоносителей, которые, в конечном счете, определяют себестоимость литейной продукции. Повышенный расход металла и энергоносителей на литниковую систему приводит к снижению конкурентоспособности литейной продукции. К тому же известно, что от выбора литниковой системы для отливки зависят многие виды брака отливок, такие, как усадочная пористость, усадочные раковины, засор, недолив спаи. Уровень этих дефектов, в конечном счете, определяет экономические показатели производства отливок на литейном предприятии. Следует отметить, что работающие в условиях производства литниковые системы часто далеки от оптимальных как по массе, так и по условиям заполнения металлом формы, что существенно влияет на качество получаемой отливки и увеличивает ее себестоимость. Таким образом, от выбора литниковой системы зависит рентабельность работы предприятия.

Автоматизация выбора литниковой системы является одной из сложных и трудно формализуемых задач технологии из-за большого разнообразия отливок, которое обусловлено особенностью пространственных размеров, характеризующих геометрию отливки. Основная задача автоматизации процесса выбора литниковой системы – это

классификация отливок на основе конструкторско-технологических и геометрических характеристик. Выбор этих характеристик для каждой отливки является сложной математической задачей. В настоящее время отсутствует универсальная система признаков, характеризующих все возможные варианты отливок, позволяющая решать задачи классификации отливок. Одним из путей решения этой задачи является выбор оптимальных наборов конструкторско-технологических признаков для каждого класса отливок. Чем большее количество классов, тем меньше могут быть наборы конструкторско-технологических признаков, положенных в систему выбора литниковой системы.

В настоящее время теория, позволяющая распознавать отливки и литниковые системы по заданным наборам признаков, находится в стадии разработки и поэтому предлагаемые методы часто носят частный не универсальный характер и справедливы для определенных условий, т.е. разработка алгоритмов и методов, позволяющих классифицировать отливки различного назначения, является актуальной и от ее решения зависит качество технологических решений, принимаемых при разработке технологического процесса. Как следствие, на промышленных предприятиях практически отсутствуют программные средства, которые дают возможность, используя методы классификации, выбирать оптимальную литниковую систему.

Анализ современного состояния проблемы выбора литниковых систем для отливок показал, что эта проблема актуальна для многих литейных предприятий, особенно в условиях быстроменяющейся номенклатуры отливок.

Проблема выбора литниковых систем для заданной отливки может быть разделена на две

задачи. Первая — это выбор одной или нескольких литниковых систем для отливки, вторая — оценка и оптимизация литниковой системы. Поскольку решение первой задачи на основе методов автоматизации проблематично, то основное внимание уделяется экспертной оценке выбранной литниковой системы, но она может быть неудачным прототипом, что может быть проверено с использованием компьютерных методов моделирования, реализованных в таких программных продуктах, как ProCast (США), Magmasof (Германия), Полигон (Россия), ПроЛит (Беларусь). Основная функция этих программ состоит в оценке уже выбранных литниковых систем для отливки. Ограничения по времени решения задач выбора литниковой системы с помощью этих программ не позволяют решать данную задачу, перебирая множество различных вариантов литниковых систем. Однако они эффективны как экспертные системы при оптимизации уже выбранных литниковых систем. К сожалению, в настоящее время нет таких систем, которые на основе задания конфигурации отливки могли бы определить оптимальную литниковую систему. Поэтому на многих предприятиях по-прежнему проблема выбора и оптимизации литниковых систем для отливок решается на основе эмпирических формул или опытных данных. В литейном производстве установились определенные правила и руководства, по которым выбирают литниковую систему. Эти правила выработывались десятилетиями и изменялись в связи с изменяющимися условиями производства. До сих пор литейное производство в значительной степени зависит от опыта работников и их умения применять эти эмпирические формулы на практике. В настоящее время используемые на практике расчетные методы не позволяют оптимизировать издержки производства, связанные с разработкой технологической оснастки, особенно для сложных по пространственной конфигурации отливок. Поэтому технолог в значительной степени руководствуется методом прототипирования и собственного опыта, затрачивая много времени на оптимизацию и доводку литниковой системы. При этом доля бракованных отливок в литейных цехах по-прежнему остается высокой, что существенно влияет на рентабельность работы предприятия.

В дальнейшем эти программы позволяют еще на этапе проектирования виртуально оценить эффективность технологических решений производственного цикла, используя методы пространственной и послойной визуализации. При этом важнейшим является вопрос о разработке метода, позволяющего по геометрии отливки выбирать прототипы литниковых систем, которые служат базой для дальнейшей оптимизации. Один из таких методов в применении к системе «отливка-литниковая система» приведен на рис. 1, 2.

Из рисунков видно, что выбор литниковой системы соединяет в себе элементы нейросетевого программирования и методы компьютерного моделирования процессов заполнения форм. Выбор наилучших литниковых систем заключается в оценке близости данной отливки к отливкам, составляющим базу данных, объединенную посредством правил обучения. На основе выбранной литниковой системы можно проводить моделирование процесса заполнения форм и тем самым осуществлять экспертную оценку ее пригодности к изготовлению данной отливки. Следует отме-

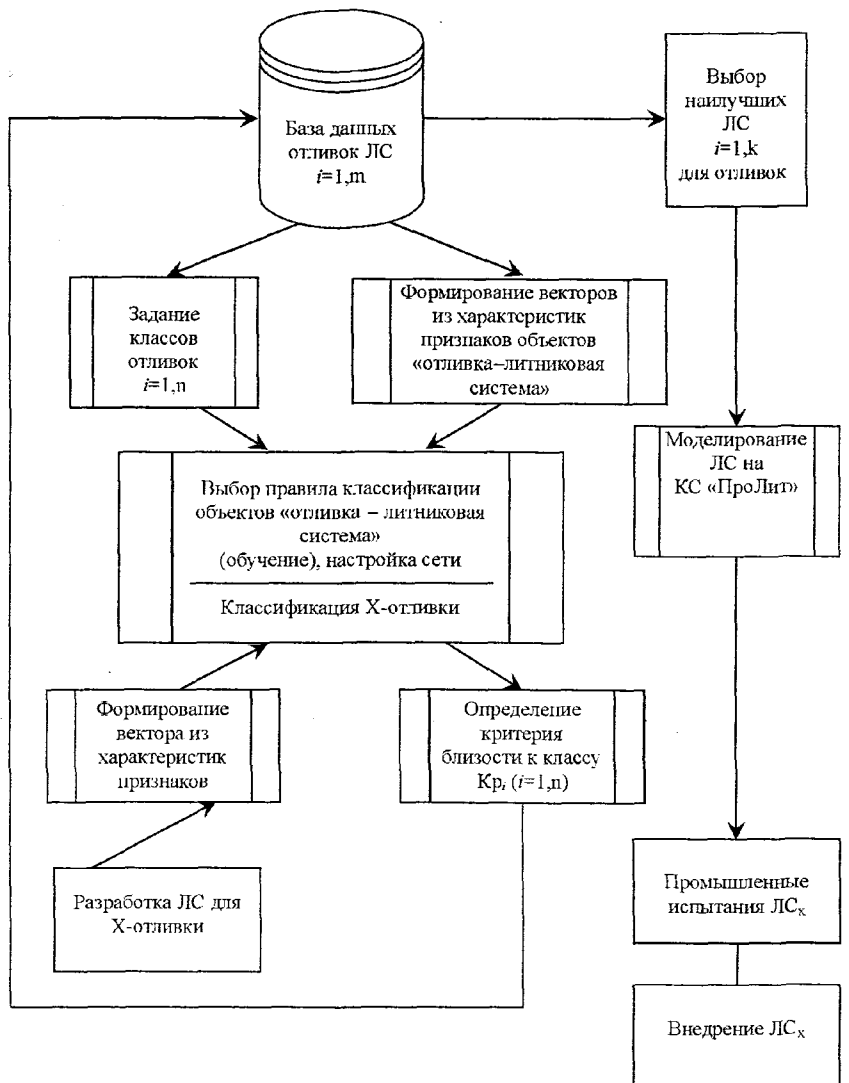


Рис. 1. Схема выбора литниковой системы на основе метода нейронных сетей

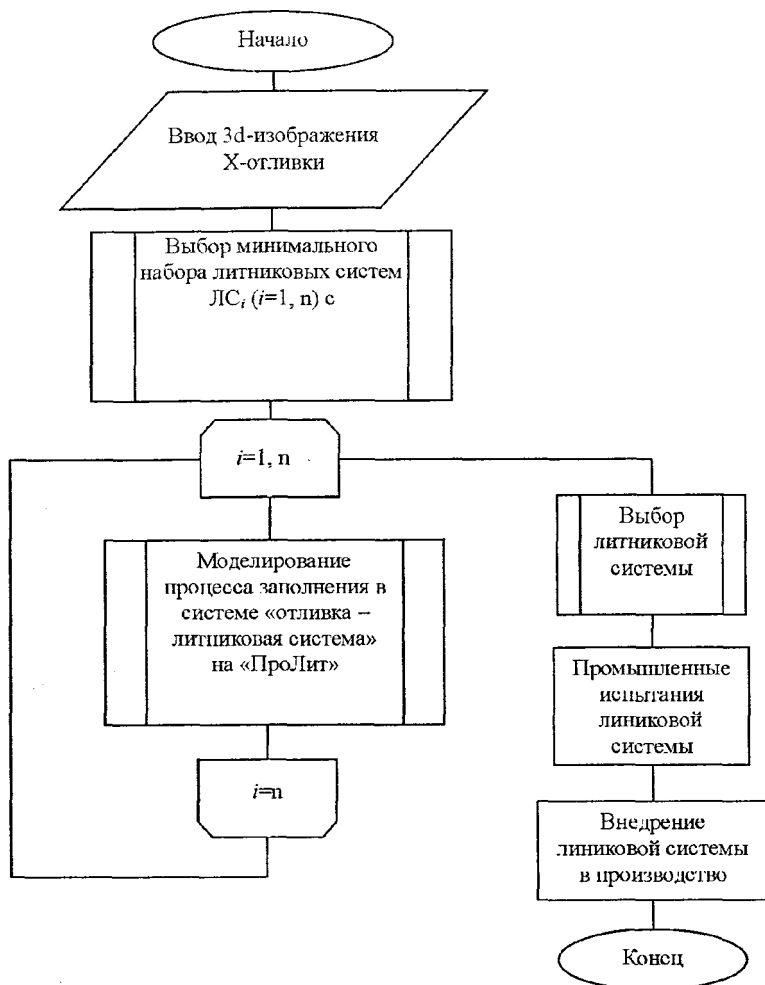


Рис. 2. Общая схема выбора и оптимизации литниковой системы для заданной отливки

тить, что математический аппарат нейросетевого программирования мало знаком литейщикам и конструкторам, но он хорошо зарекомендовал себя в других областях техники, где используется теория принятия решений.

Рассмотрим один из вариантов использования методов классификации объектов. В современной теории нейронных сетей существует множество алгоритмов, цель которых состоит в проведении так называемого «обучения», однако эффективность этих алгоритмов различна в зависимости от сложности решаемых задач. Задачи классификации отливок являются очень сложными из-за пространственной составляющей. Поэтому даже выбор метода или прототипа представляет сложную научно-техническую задачу.

Одной из основных функций инженера является проектирование изделий или технологических процессов их изготовления. Анализ и оценка каждой детали увеличивают время технологической подготовки производства и снижают ее

технологическую гибкость. Поэтому возникает необходимость в разбиении всех видов и типов деталей на группы по сходству. Признаками сходства могут служить конструктивные особенности деталей, от которых, в конечном счете, зависят технологичность и преемственность к автоматическому упорядочению.

Существует достаточное количество различных эвристических алгоритмов кластеризации, основанных на использовании мер близости между объектами [1, 2]. В этом случае алгоритм получения группировок объектов не отражается в явной форме. Преимущество использования нейронных сетей состоит в том, что процедура и результат нейросетевой кластеризации объектов просты в понимании, наглядны и выразительны. Они позволяют перейти от интуитивных методов анализа выборки технических объектов к использованию строгого математического алгоритма анализа всего набора обрабатываемых объектов.

Возможность использования искусственных нейронных сетей для решения задач классификации в машиностроении уже рассматривалась в [3]. В данной работе более подробно остановимся на особенностях обучения и архитектурах нейронных сетей для классификации технических объектов. Задача, решаемая с использованием искусственных нейронных сетей, включает в себя следующие

этапы (рис. 3):

- 1) выбор типа (архитектуры) сети;
- 2) подбор весов (обучение) сети;
- 3) применение сети.

На первом этапе необходимо определить число входов, выходов, слоев, передаточные функции; каким образом следует соединить нейроны между собой; что взять в качестве входов и выходов сети.

Эта задача на первый взгляд кажется трудоемкой, но на самом деле необязательно придумывать сеть «с нуля». Существует несколько десятков различных нейросетевых архитектур, причем




Рис. 3. Этапы нейросетевого решения задачи [4]

эффективность многих из них доказана математически. Наиболее популярные и изученные архитектуры – это многослойный персептрон, нейросеть с общей регрессией, сети Хебба и Кохонена и др. [1, 4–6].

На втором этапе следует «обучить» выбранную сеть, т.е. подобрать такие значения ее весов, чтобы сеть работала нужным образом. В используемых на практике нейросетях количество весов может составлять несколько десятков тысяч, поэтому обучение – действительно сложный процесс. Для большинства архитектур разработаны специальные алгоритмы обучения, которые позволяют подстраивать веса сети определенным образом.

Пусть у нас имеется некоторая база данных, содержащая примеры из разных классов, которые необходимо научить распознавать (набор изображений отливок, всего 50). Предъявляя изображение отливки «А» на вход нейросети, мы получаем от нее некоторый ответ, не обязательно верный. Нам известен верный (желаемый) ответ, поэтому мы сигнал с объекта «А» считаем максимальным.

Обычно в качестве желаемого выхода в задаче классификации берут набор (1, 0, 0, ...), где 1 стоит на выходе с меткой «А», а 0 – на всех остальных выходах. Вычисляя разность между желаемым ответом и реальным ответом сети, получаем 50 чисел (по количеству объектов) – вектор ошибки. Далее, применяя различные алгоритмы, по вектору ошибки вычисляем требуемые поправки для весов сети. Один и тот же объект мы можем предъявлять сети много раз.

После многократного предъявления примеров веса нейросети становятся постоянными, причем нейросеть дает правильный ответ на все (или почти все) примеры базы данных. В таком случае говорят, что «сеть обучена». В программных реализациях можно видеть, что в процессе обучения величина ошибки (сумма квадратов ошибок по всем выходам) постепенно уменьшается. Когда величина ошибки достигает нуля или оговоренного низкого уровня, обучение останавливают, а полученную сеть считают адаптированной (обученной) и готовой к применению на новых данных. Схематично процесс обучения представлен на рис. 4.

Разрабатывая методы, основанные на использовании нейронных сетей, как правило, возникает проблема выбора оптимальной архитектуры нейросети. Так как обла-

сти применения наиболее известных методов пересекаются, то для решения одной и той же задачи можно использовать совершенно разные типы нейронных сетей и при этом результаты могут оказаться одинаковыми. Ниже рассмотрен ряд основных видов нейронных сетей, успешно применяемых для решения задач классификации и кластеризации объектов (рис. 5) [4–6].

Простейшим устройством распознавания образов в нейроинформатике является одиночный нейрон-классификатор, превращающий входной вектор признаков в скалярный ответ, зависящий от комбинации входных переменных [4]. Возможности такой сети весьма ограничены. Для решения более сложных классификационных задач необходимо усложнить сеть, вводя дополнительные (скрытые) слои нейронов, производящих промежуточную переработку входных данных, таким образом, чтобы выходной нейрон-классификатор получал на свои входы уже линейно-разделимые множества. Такие структуры носят название многослойные персептроны (рис. 6).

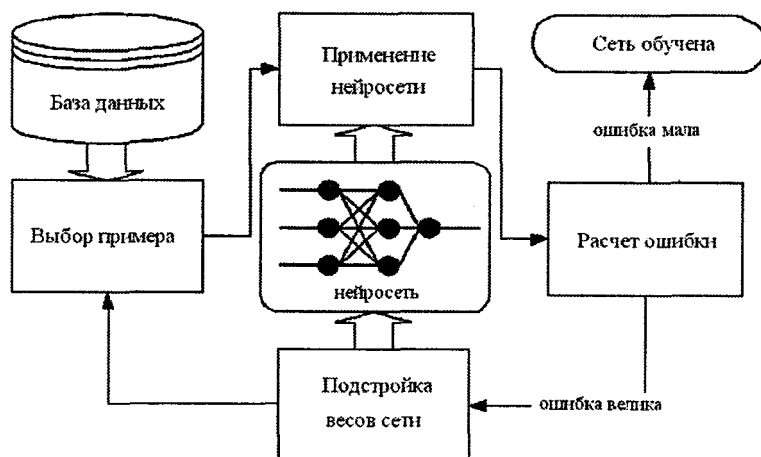


Рис. 4. Процесс обучения нейронной сети [5]

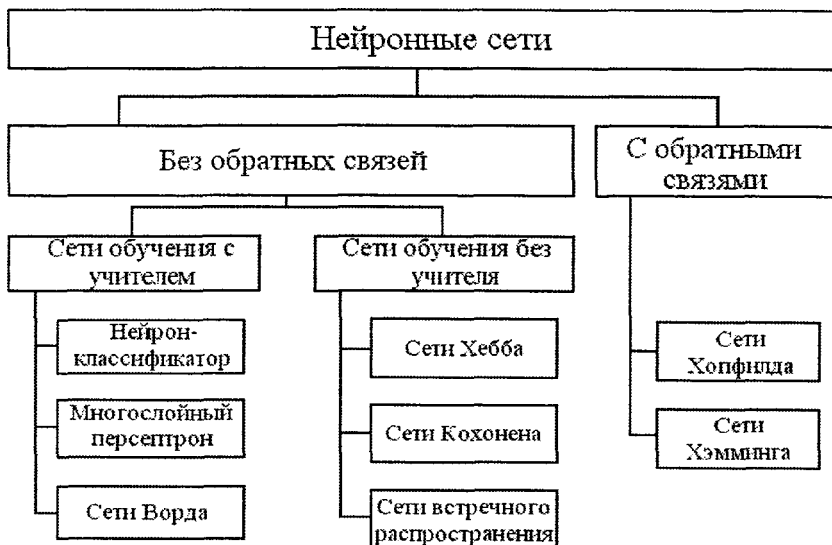


Рис. 5. Классификация нейронных сетей

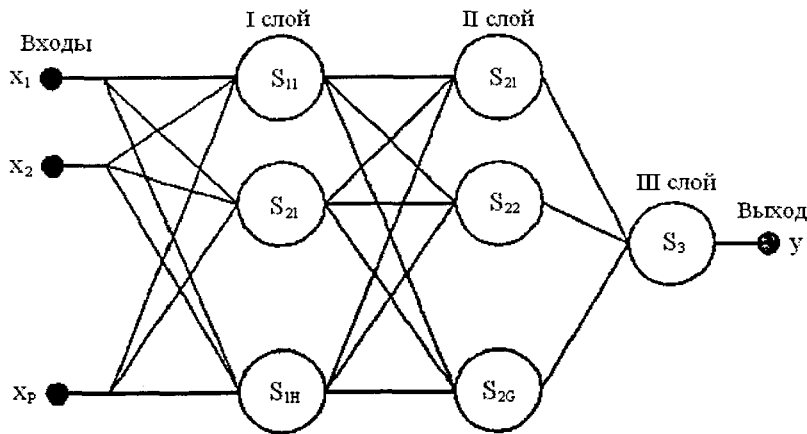


Рис. 6. Многослойный перцептрон [6]

В настоящее время для решения широкого спектра задач получили распространение нейронные сети с самоорганизацией на основе конкуренции [5]. Основу самоорганизации нейронных сетей составляет закономерность, показывающая, что сеть становится упорядоченной в результате самоорганизующих операций, независимо друг от друга проводящихся в различных ограниченных сегментах сети. В соответствии с поданными входными сигналами осуществляется активация нейронов, которые вследствие изменения значений весов адаптируются к поступающим обучающим данным. При этом происходит естественное распределение нейронов на различные группы. Отдельные нейроны или их группы взаимодействуют между собой и их связи становятся сильнее в ответ на возбуждение, подавляя своей активностью другие нейроны. Наряду с сотрудничеством нейронов внутри группы можно говорить и о конкуренции как между нейронами различных групп, так и между нейронами, входящими в состав одной группы.

Среди механизмов самоорганизации можно выделить два основных класса: самоорганизация, основанная на ассоциативном правиле Хебба и механизме конкуренции между нейронами на базе обобщенного правила Кохонена. Сети Кохонена — это одна из разновидностей нейронных сетей с самоорганизацией на основе конкуренции, для настройки которой используется алгоритм обучения без учителя. Задачей нейросети Кохонена является построение отображения набора крупных входных векторов на карту кластеров меньших размеров, причем таким образом, что близким кластерам на карте отвечают близкие друг другу входные векторы в исходном пространстве.

Сеть состоит из M нейронов, образующих, как правило, одно- или двумерную карту кластеров (рис. 7). Элементы входных сигналов $\{x_i\}$ подаются на входы всех нейронов сети. В процессе функционирования (самоорганизации) на выходе слоя Кохонена формируются кластеры — группа активных нейронов определенного размера, выход

которых отличен от нуля, отражающие отдельные характеристики входных векторов. Параллельно с такими сетями развивается так называемый нечеткий подход при построении нейронных сетей. Такие сети называются нечеткими нейронными сетями и их характерной особенностью является возможность использования нечетких правил вывода для расчета выходного сигнала. В нечеткой сети алгоритм самоорганизации приписывает вектор x к соответствующей группе данных, представляемых центром c_i , с использованием обучения конкурентного типа, как в сетях Кохонена. По сравнению с традиционными решениями они демонстрируют качества, связанные с их способностью гладкой аппроксимации пороговых функций.




Рис. 7. Сеть Кохонена [5]

Среди различных конфигураций искусственных нейронных сетей встречаются такие, классификации которых по принципу обучения затруднены. В таких сетях весовые коэффициенты синапсов рассчитываются только однажды перед началом работы сети на основе информации об обрабатываемых данных. Наиболее известными сетями, использующими этот алгоритм, являются сети Хопфилда.

Структурная схема сети Хопфилда приведена на рис. 8. Она состоит из единственного слоя нейронов, число которых является одновременно числом входов и выходов сети. Каждый нейрон связан синапсами со всеми остальными нейронами, а также имеет один входной синапс, через который осуществляется ввод сигнала. Выходные сигналы, как обычно, образуются на аксонах. Сеть должна уметь из произвольного неидеального сигнала, поданного на ее вход, выделить («вспомнить» по частичной информации) соответствующий образец (если такой есть) или «дать заклю-

чение» о том, что входные данные не соответствуют ни одному из образцов.

Выбирать нейронную сеть необходимо исходя из постановки задачи. Например, для простейшей задачи классификации объектов на два класса лучше всего подойдет нейрон-классификатор. Для более сложной классификации объектов на известное количество классов подойдет одна из разновидностей многослойного персептрона. Если классы известны заранее, но не известно по каким признакам следует производить классификацию, то в данном случае следует использовать сети обучения без учителя, например, сети Хейбба. В случае классификации объектов по неполной информации об объектах подойдут сети Хопфилда.

Для решения задач кластеризации наилучшим образом подходят нейронные сети с самоорганизацией на основе конкуренции, использующие алгоритм обучения без учителя. Идеология таких сетей совпадает с определением понятия кластеризации как разбиение множества объектов на неизвестные заранее классы. Использование самоорганизации не требует предопределения классов, а выделит необходимое их количество в процессе обучения и работы сети. Обучение без учителя позволит сети обучаться не только на начальном этапе при подготовке сети к работе, но и непосредственно в процессе работы. При появлении в процессе функционирования новых классов самоорганизующиеся сети не требуют переобучения, а способны сами перестроиться на основании новых значений.

Таким образом, решение задачи классификации и выбора литниковой системы можно проводить с использованием методов нейронных сетей. При классификации отливок нейронная сеть обучается по важнейшим их признакам, таким, как характеристики геометрии отливки, особенности охлаждения отливки и т.д. В процессе процесса обучения выделяются признаки, отличающие отливки друг от друга, которые и составляют информационную базу для принятия решений об отнесении отливок к соответствующим классам. Информация о каждой отливке представляется в виде вектора конструкторско-технологических признаков, как наиболее полно и достоверно отвечающее требованиям нейросетевого моделирования. Характеристики (признаки) отливки определяются посредством анализа ее твердо-




Рис. 8. Структурная схема сети Хопфилда [6]

тельной модели и чертежа на основе различных стандартов. Эти методы позволяют на основе эмпирической информации, в данном случае заводской и промышленно апробированной, выбирать литниковые системы, которые в дальнейшем оцениваются экспертными системами.

Таким образом, проблема автоматизированного выбора литниковых систем на основе задач классификации и кодирования объектов типа «отливка—литниковая система» является актуальной, так как от ее решения зависит уровень автоматизации технологической подготовки производства, а также уровень качества отливок и материальные затраты на их производство.

Литература

1. Горбань А.Н. Решение задач нейронными сетями. Нейроинформатика. Новосибирск: Наука, Сиб. издат. фирма РАН, 1998.
2. Ежов А.А., Шумский С.А. Нейрокомпьютинг и его применение в экономике и бизнесе. М.: МИФИ, 1998.
3. Матюшинец Т.В., Марков Л.В. О возможности использования метода нейронных сетей для автоматизированного проектирования кокильной оснастки // Литье и металлургия. 2006. №3. С. 125–129.
4. Уоссермен Ф. Нейрокомпьютерная техника: теория и практика / Пер. с англ. М.: Мир, 1992.
5. Осовский С. Нейронные сети для обработки информации / Пер. с польск. И.Д. Рудинского. М.: Финансы и статистика, 2002.
6. Горбань А.Н., Россиев Д.А. Нейронные сети на персональном компьютере. М.: Наука, 1996.