

ОПТИМИЗАЦИЯ ФУНКЦИОНИРОВАНИЯ ПРЕДСТАВЛЕННЫХ СЕТЯМИ ПЕТРИ СИСТЕМ С ПОМОЩЬЮ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Сочнев А. Н.¹

(Сибирский федеральный университет, Красноярск)

Статья содержит описание метода оптимизации систем, представленных моделями на основе сетей Петри. В качестве оптимизатора предполагается применение обученной в соответствии с выбранным критерием оптимальности искусственной нейронной сети. Приводится пример использования предлагаемого метода управления имитацией сети Петри.

Ключевые слова: сеть Петри, правила приоритета, искусственная нейронная сеть.

1. Введение

Организация управления сложными техническими системами предполагает, как правило, использование имитационных моделей, которые позволяют предварительно исследовать систему и выявить ее основные свойства. Использование сетевых моделей в системах управления с эталонной моделью ограничивается недостаточной гибкостью сетей Петри и их неспособностью учитывать быстро изменяющиеся условия внешней среды и требования к качеству процессов в системе. Типичный метод оптимизации – использование приоритетов операций не позволяет достаточно эффективно управлять имитацией сети. Исходя из этого, разработка новых методов оптимизации систем, пред-

¹ Алексей Николаевич Сочнев, кандидат технических наук, доцент (lesek@mail.ru).

ставленных сетями Петри, представляется актуальной научной и практической задачей.

2. Описание исследуемой производственной системы

В качестве объекта исследования рассматривается Учебно-исследовательский гибкий производственный комплекс (УИ ГПК), входящий в структуру Политехнического института ФГАОУ ВПО «Сибирский федеральный университет» и предназначенный для обучения студентов элементам *CAD/CAM*-технологий, методам автоматизированного управления и программирования устройств числового программного управления (ЧПУ) оборудования. В состав УИ ГПК входят: автоматизированный складской комплекс РСК-250, два токарно-винторезных станка 16К20Ф3 с системой ЧПУ 2Р22, токарный станок *Haas TL-1*, фрезерный станок *Haas TM-1* и обрабатывающий центр 2254ВМФ4.

Для дальнейшего исследования процессов в системе пронумеруем технологическое оборудование следующим образом:

- токарные станки 16К20Ф3 – №1 и №2;
- обрабатывающий центр 2254ВМФ4 – №3;
- токарный станок *HAAS TL-1* – №4;
- вертикальный фрезерный станок *HAAS TM-1* - №5.

В структуре учебно-исследовательского роботизированного технологического комплекса можно выделить две производственные ячейки, первая из которых содержит станки №1–3, вторая – станки №4, 5.

Для составления плана – графика производственного процесса задается номенклатура деталей, производимых УИ ГПК. Предусматривается обработка деталей тридцати типов. Время обработки представлено в единицах (тактах), равных 0,1 минуты. Задается также и необходимый объем производства каждого вида деталей. Одни детали требуют только токарной обработки, другие – токарной и фрезерной. Предполагается, что тара с заготовками присутствует в роботизированном складском ком-

плексе. Готовые изделия также направляются в ячейки склада. Приоритет всех изделий установлен одинаковым.

При формировании оптимального производственного процесса необходимо предварительно определить возможные траектории перемещения изделий внутри рассматриваемой производственной системы. Все изделия можно разделить на три вида: требующие токарной обработки (Т), требующие фрезерной обработки (Ф) и требующие последовательно токарной и фрезерной обработки (ТФ).

В рассматриваемой системе можно выделить возможные траектории перемещения изделий (рис. 1). Эти траектории определяются технологом с учетом свойств станков и технологических процессов изделий.

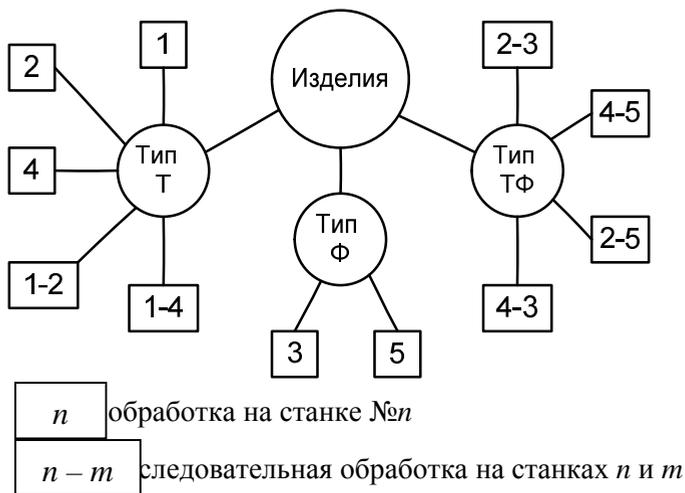


Рис. 1. Структура технологических маршрутов внутри УИ ГПК

Общее количество возможных технологических маршрутов в системе $5 + 2 + 4 = 11$.

В соответствии с технологическими процессами первую группу изделий (Т) условно разделим на две подгруппы: первая (Т1) содержит изделия, обрабатываемые с одной установкой, вторая (Т2) – изделия, требующие переустановку.

3. Формирование сетевой модели системы

Представленная выше структура технологических маршрутов является основой для формирования имитационной модели системы на основе сети Петри. Сети Петри являются удобным и достаточно универсальным средством представления дискретных систем. Это проявляется в частности в том, что они позволяют формировать модели с требуемой степенью детализации. Для задачи предварительного планирования производственного процесса степень детализации может быть меньше, чем при непосредственном согласованном управлении оборудованием в реальном времени. В рассматриваемом случае для распределения изделий по элементам системы можно операции обработки представить обобщенно, без выделения вспомогательных и транспортных операций.

Из всех классов сетей Петри для моделирования дискретного производства наилучшим образом подходят цветные (раскрашенные) сети Петри, поскольку они позволяют наглядно и компактно представить системы, в которых присутствует большое количество разнотипных объектов (изделий) [4].

Структура модели формируется на основе структуры технологических маршрутов, представленной ранее. Выделяются три позиции (P0, P10, P14), в которые помещаются маркеры, соответствующие изделиям типа Т, Ф и ТФ соответственно. Начальная маркировка соответствует требуемому объему производства каждого типа. Формируются позиции, представляющие доступность каждого агрегата производственной системы в отдельные моменты времени: P2 – токарный станок 16K20Ф3 (№1); P17 – токарный станок 16K20Ф3 (№2); P15 – обрабатывающий центр 2254ВМФ4 (№3); P19 – токарный станок *HAAS TL-1* (№4); P18 – фрезерный станок *HAAS TM-1* (№5). В позициях сети P9, P13 и P27 скапливаются готовые изделия типа Т, Ф и ТФ соответственно. Остальные позиции модели представляют движение объектов производства внутри системы (незавершенное производство).

Основная часть переходов сети разработанной модели представляет обобщенные операции производственного процес-

са. Переходы T7–T11, T15, T16, T24–T27 не имеют интерпретации в реальной системе и предназначены для организации накопления маркеров, приходящих по разным траекториям в сети в выходные позиции P9, P13 и P27.

Количество цветов в модели составляет $n + 1$, где n – количество изделий. Цвет $n + 1$ выбран для представления в модели доступности ресурсов, он отображает занятость станков. При необходимости можно ввести различимые маркеры и для каждой единицы оборудования.

Сеть, представленная на рис. 2, может являться иерархической и в общем случае содержит три уровня. Каждый из переходов, отображающий обработку, может быть представлен подсетью, содержащей три последовательно выполняющихся перехода, отображающие установку на станок и связанные с ней операции, собственно обработку изделия и удаление со станка готовой детали (рис. 3).

При необходимости реализации системы группового диспетчерского управления производством модель может быть детализирована до уровня каждого технологического перехода и операции (рис. 4).

4. Постановка задачи оптимизации

Оптимизация процессов в рассматриваемой системе содержит в своей основе перераспределение потоков заявок на обработку между отдельными производственными ячейками и агрегатами. Задача распределения изделий по отдельным структурным единицам является сложной, учитывающей многие факторы и условия, и в большинстве случаев решается человеком. В то же время в настоящее время существуют математические методы, позволяющие решать подобные задачи. В данной статье предлагается дополнить сеть Петри механизмом принятия решений на основе искусственной нейронной сети, которая позволит принимать решения о выборе активируемых переходов сети. Правила работы нейронной сети предполагается заложить на этапе обучения перед имитацией сети Петри.

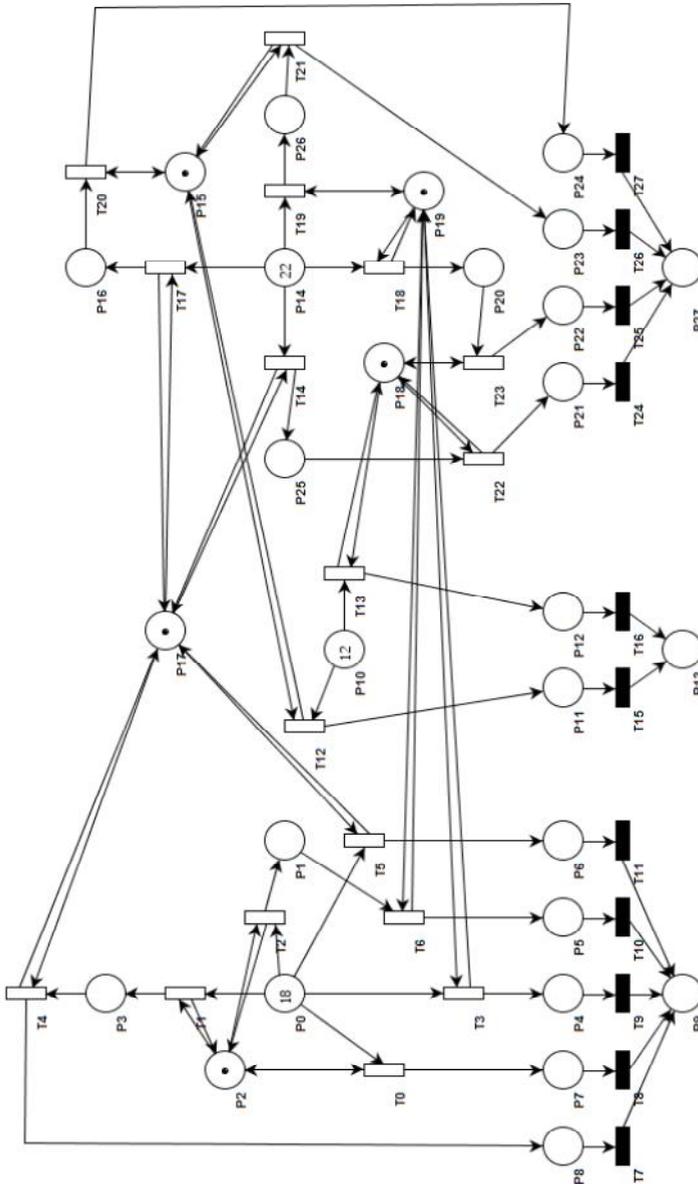


Рис.2. Имитационная модель производственного процесса

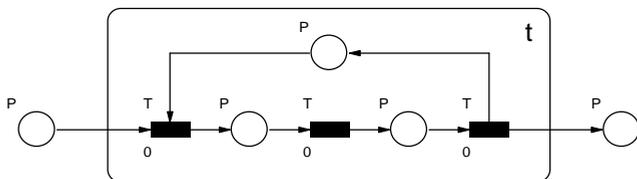


Рис. 3. Структура подсети обработки

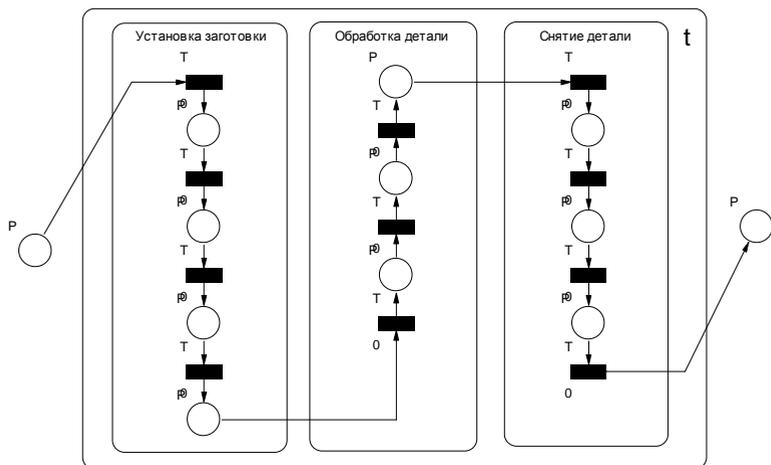


Рис. 4. Структура подсети обработки (детализированная)

Исследования показывают, что применение нейросетей в задачах классификации и распознавания дает очень хорошие результаты. Рассматриваемая задача по сути является аналогичной, так как нейросеть фактически должна классифицировать состояние (маркировку сети или другие переменные), предъявляемое на ее вход. Это позволяет прогнозировать хорошие результаты применения нейронной сети для данной задачи.

Оптимизация функционирования производственных систем может осуществляться по различным критериям. Наиболее часто используемыми критериями являются: максимизация объемов выпуска продукции, максимизация загрузки оборудования, минимизация времени производственного процесса и другие [2].

Выбор критерия эффективности осуществляется индивидуально для каждого конкретного производственного подразделения по результатам анализа его экономических, организационных и технических особенностей. Наиболее часто используют в качестве критерия эффективности минимизацию времени выпуска заданного объема продукции

$$(1) \quad T = \max_{j \in J} [T_{jB} + T_{jПЕР} + T_{jПР}] \rightarrow \min_{P \in \Omega_p},$$

где $\Omega_p = \{P : G = (L_{i_1}; L_{i_2}; \dots; L_{i_{m_j}}), t_{ij}^k = t_{ij}^0 + t_{ij}, t_{i_1 j_1}^0 \leq t_{i_2 j_2}^0, i = \overline{1, m_j}, j = \overline{1, n}\}$;

J – множество единиц оборудования; T_{jB} – суммарное время выполнения операций j -й единицы оборудования; $T_{jПЕР}$ и $T_{jПР}$ – суммарное время соответственно переналадок и простоя j -й единицы оборудования; $L_{ij} = (q_{ij}, t_{ij})$ – операция с номером i , $i = 1, \dots, m_j$, которая выполняется над j -й деталью, $j = 1, \dots, n$; m_j – число операций, которое необходимо выполнить над j -й деталью; q_{ij} – номер группы оборудования, настроенного на выполнение операции L_{ij} ; t_{ij} – номинальная продолжительность выполнения операций L_{ij} .

Иногда используют частные случаи указанного критерия, например:

– минимизация максимального времени простоя

$$(2) \quad T = \max_{j \in J} [T_{jПР}] \rightarrow \min_{P \in \Omega_p},$$

где $\Omega_p = \{P : G = (L_{i_1}; L_{i_2}; \dots; L_{i_{m_j}}), t_{ij}^k = t_{ij}^0 + t_{ij}, t_{i_1 j_1}^0 \leq t_{i_2 j_2}^0, i = \overline{1, m_j}, j = \overline{1, n}\}$,

– максимизация загрузки оборудования

$$(3) \quad K = \min_{j \in J} \left[\frac{T_{jB}}{T_{jB} + T_{jПЕР} + T_{jПР}} \right] \rightarrow \max_{P \in \Omega_p},$$

где $\Omega_p = \{P : G = (L_{i_1}; L_{i_2}; \dots; L_{i_{m_j}}), t_{ij}^k = t_{ij}^0 + t_{ij}, t_{i_1 j_1}^0 \leq t_{i_2 j_2}^0, i = \overline{1, m_j}, j = \overline{1, n}\}$;

$Y = Y'$; Y' – заданный объем выпускаемой продукции.

Часто в реальных производственных условиях целесообразно решать задачу календарного планирования с одновременным учетом нескольких критериев, т.е. как многокритериальную. Один из способов многокритериальной постановки задачи – составление компромиссного критерия. Пусть выбрано r

локальных критериев (F_1, F_2, \dots, F_r) , которые предполагается включить в компромиссный. Ими могут быть, например, перечисленные выше. Для каждого из локальных критериев решается задача оптимизации и вычисляется его экстремальное значение $F_i^* (i = \overline{1, r})$. На основе аналитического выражения каждого критерия записывается уравнение отклонений от оптимального значения

$$(4) \quad Q_i = F_i - F_i^*, i = \overline{1, r}.$$

Задаются также весовые коэффициенты I_i для каждого критерия.

Для построения компромиссного критерия используют различные выражения, например либо аддитивную функцию свертки

$$(5) \quad Q = \sum_{i=1}^r Q_i I_i \rightarrow \min,$$

либо функцию, обеспечивающую равномерность отклонения каждого критерия от экстремального значения (с учетом веса)

$$(6) \quad Q = \sum_{i=1}^r I_i \frac{Q_i}{F_i^*}.$$

Ограничения. Кроме очевидных ограничений по времени операций при решении задач календарного планирования приходится учитывать еще ряд других, например по структуре сети транспортных маршрутов или директивные сроки окончания обработки определенных деталей.

Для каждого критерия оптимальности нейросеть должна быть обучена индивидуально. Таким образом, в распоряжении диспетчера должна появиться библиотека искусственных нейронных сетей, из которой будет осуществляться выбор при планировании производства.

В рассматриваемой производственной системе задачу оптимизации будем решать как многокритериальную. Первый критерий – минимизация объема незавершенного производства в системе, второй – минимизация времени процесса за счет выравнивания загрузки станков.

Следует заметить, что использование нейросети позволяет отказаться от формирования компромиссного критерия. В этом случае достаточно того, чтобы предъявляемые на вход сети обучающие примеры учитывали оба критерия. Важность (весомость) каждого из критериев также должна быть учтена в значениях элементов входных векторов. Учитывая это обстоятельство, выбирается такой тип нейронной сети, который предусматривает обучение с учителем.

5. Формирование структуры искусственной нейронной сети

В настоящее время теория искусственных нейронных сетей достаточно развита. Для различных задач разработаны разные классы нейросетей. Соответственно, первая стадия – это выбор типа нейронной сети. В данном случае выберем наиболее распространенный тип – многослойный персептрон. Формирование структуры искусственной нейронной сети представляется труднореализуемой и итерационной задачей.

Нейронная сеть содержит входной слой, выходной и один скрытый слой. Скрытый слой существенно улучшает свойства нейронной сети [1, 3, 5]. Количество нейронов входного слоя соответствует числу учитываемых факторов. Для рассматриваемой системы входные нейроны воспринимают информацию о текущих значениях коэффициентов загрузки основного технологического оборудования и объеме незавершенного производства каждого типа изделий (Т, Ф и ТФ).

Система содержит пять металлообрабатывающих станков и три типа изделий, поэтому количество нейронов входного слоя в нейросети $N = 8$. Количество нейронов промежуточного слоя K рекомендуется выбирать от N до $3N$. Экспериментально было подобрано $K = 16$. При данном значении обеспечивается высокая скорость обучения, а также обобщающие свойства сети не ухудшают качество классификации состояний. Функция активации нейрона для каждого нейрона сигмоидальная (логистическая). Количество нейронов в выходном слое равно количеству переходов сети Петри, которые управляются нейросетью. Рас-

сматриваемая модель содержит одиннадцать управляемых переходов, поэтому количество нейронов выходного слоя $M = 11$. Управляемые переходы сети: T0, T1, T2, T3, T5, T12, T13, T14, T17, T18, T19.

Создание, обучение и исследование нейросетей осуществляется в пакете *Neural Network Toolbox*. Листинг программы *Matlab* представлен ниже.

Основные обозначения: p – обучающий вектор (p_1, p_2, \dots, p_5 – коэффициенты загрузки соответствующих единиц оборудования, p_6, p_7, p_8 – относительное количество заготовок типа Т, Ф и ТФ; t – вектор выходных состояний нейросети, соответствующих компонентам обучающего вектора; a – тестовый вектор; y – выходной вектор нейронной сети.

Элементы выходного вектора нейронной сети интерпретируются как приоритеты соответствующих управляемых переходов сети Петри.

```
p=[[0;0.1;0.5;0.2;0.8;0.2;0.1;0.7] [0.5;0;0.8;0.3;0.1;0.3;0.5;0.2]
[0.1;0.3;0.5;0.1;0.1;0.4;0.2;0.4] [0.2;0.4;0.3;0.6;0.2;0.8;0.1;0.1]
[0.8;0.8;0.2;0.7;0.5;0.4;0.3;0.3]
[0.1;0.2;0.1;0.4;0.2;0.6;0.1;0.3]];
```

p

```
t=[[1;1;1;0.7;0.7;0.7;1;0.5;0.5;0.2;0.2]
[0.3;0.3;0.3;1;1;1;0.4;0.5;0.5;0.8;0.8]
[0.9;0.9;0.9;0.6;0.6;0.6;0.2;1;1;1;1]
[1;1;1;0.8;0.8;0.8;0;0.6;0.6;0.3;0.3]
[0.4;0.4;0.4;0.3;0.3;0.3;1;0.9;0.9;0.7;0.7]
[1;1;1;0.8;0.8;0.8;0.2;0.6;0.6;0.7;0.7] ];
```

t

```
net = newff([0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1; 0 1],[8 16
11],{'logsig' 'logsig' 'logsig'},'traingdx');
net.trainParam.epochs = 10000;
net.trainParam.goal = 1e-5;
net=train(net,p,t);
a=[[0;0.8;0.5;0.8;0.8;0.2;0.1;0.7] [0.5;0;0.1;0.2;0.4;0.7;0.1;0.2]
[0.1;0.3;0.8;0.1;0.6;0.2;0.2;0.6]
[0.2;0.04;0.1;0.9;0.2;0.2;0.7;0.1]
```

```
[0.8;0.3;0.2;0.7;0.05;0.6;0.3;0.1]  
[0.2;0.2;0.1;0.2;0.2;0.2;0.6;0.2] ];  
y=sim(net,p); y  
y=sim(net,a); y  
gensim(net);
```

По завершению работы приведенной программы формируется структура сети создаются структурные модели нейронной сети в пакете *Simulink* (рис. 5) и производится её обучение (рис. 6). Точность обучения нейронной сети выбрана равной 10^{-5} . Она достигается за 3360 шагов.

Обучающие примеры сформированы таким образом, что маркеры должны направляться в те участки сети, в которых переходы наименее загружены. Второй фактор, применяемый для решения, – текущее количество заготовок каждого типа. В первую очередь выбираются маркеры, моделирующие заготовки изделий, которых больше чем других во входном накопителе.

Реакция нейронной сети на тестовый вектор соответствует ожидаемой (столбцы – номера векторов):

y = 0,2921	0,9992	0,7748	0,0814	0,9725	0,9894
0,2595	0,9980	0,2660	0,9827	0,9920	0,9875
0,2170	0,9982	0,3678	0,9509	0,9896	0,9939
0,6449	0,6291	0,6792	0,9744	0,8264	0,7590
0,6201	0,6247	0,7572	0,9957	0,7900	0,8820
0,6185	0,7011	0,5534	0,9684	0,7019	0,6454
0,9998	0,0787	0,9518	0,7418	0,0064	0,8944
0,6642	0,8318	0,9348	0,0399	0,8644	0,4828
0,5359	0,8641	0,9834	0,0580	0,7872	0,5504
0,1530	0,8439	0,9833	0,3712	0,7251	0,6110
0,5455	0,7763	0,9796	0,0270	0,5728	0,6028

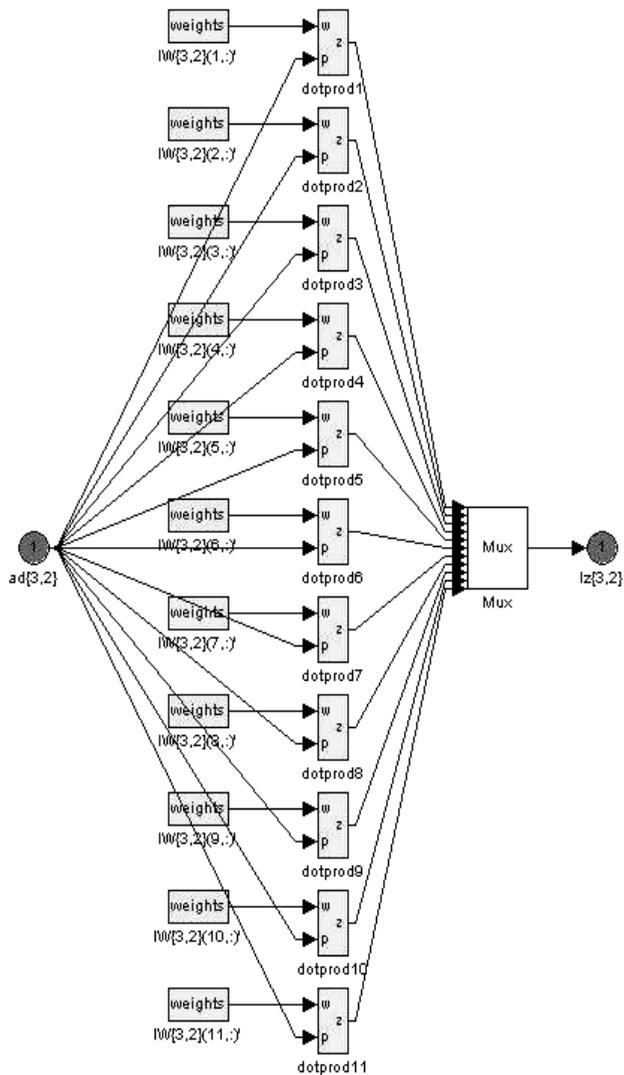


Рис. 5. Структура выходного слоя нейронной сети

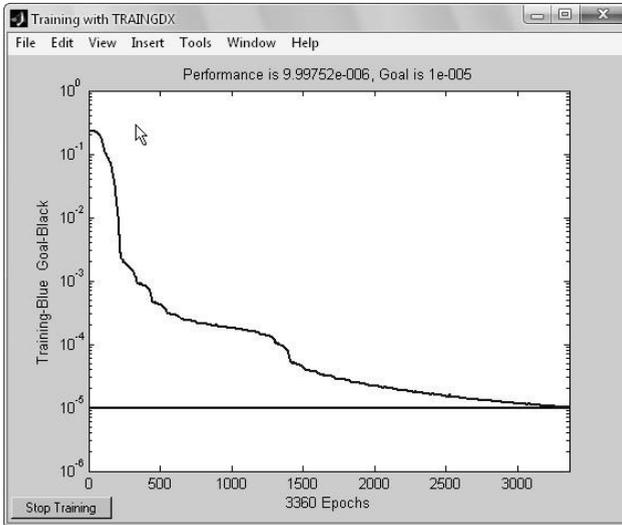


Рис.6. Процесс обучения нейронной сети

6. Исследование эффективности предложенного метода

Задача практической реализации совместного функционирования раскрашенной сети Петри и искусственной нейронной сети потребовала разработки программы на алгоритмическом языке программирования, поскольку известные программные продукты не позволяют ее решить. Программа сформирована на основе алгоритмического языка Паскаль, имеет модульную структуру (рис. 7) и разные режимы работы: с последовательным выбором активируемых переходов, со случайным выбором и режим активации, управляемый нейронной сетью. Программа позволяет оценить качество работы системы расчетом суммарного времени выполнения процесса, коэффициентов загрузки каждого перехода и загрузки каждого станка.

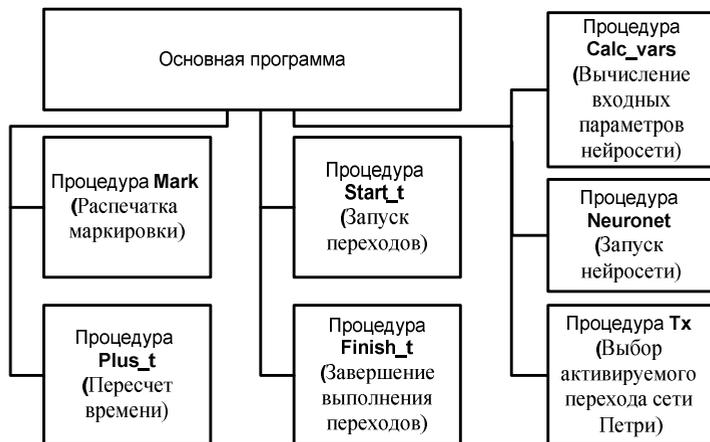


Рис. 7. Модульная структура разработанной программы

Исследование эффективности предлагаемого подхода выполнено путем сравнения режимов работы сети со случайным выбором активируемых переходов и выбором на основе решений нейросети. Выходной вектор нейросети анализируется следующим образом:

- 1) активируется такой переход t_j , для которого элемент вектора u_j максимален;
- 2) значение элемента u_j заменяется на ноль;
- 3) выбирается из оставшихся элементов вектора u максимальный элемент и активируется соответствующий переход;
- 4) процесс повторяется до тех пор, пока все элементы вектора u не станут нулевыми.

Если поставить цель некоторого ускорения работы приведенного алгоритма, то можно ограничиться неполным перебором элементов выходного вектора нейросети. В таблице 1 приведены результаты экспериментов для случая, когда из выходного вектора нейронной сети последовательно выбираются три наиболее предпочтительных перехода сети Петри. Всего в таблице представлены результаты имитационных экспериментов для трёх вариантов работы системы: вариант 1 – случайный выбор активируемых переходов; вариант 2 – выбор наименее

загруженных переходов; вариант 3 – выбор переходов нейронной сетью.

Таблица 1. Результаты моделирования

	Вариант №1	Вариант №2	Вариант №3
Общее время процесса (такты)	618,6	610,4	552
Коэффициенты загрузки:			
Станок №1	0,887165	0,885813	0,886051
Станок №2	0,877627	0,875655	0,880616
Станок №3	0,594083	0,646134	0,694746
Станок №4	0,884578	0,88401	0,881159
Станок №5	0,643065	0,605505	0,619384
Средний коэффициент загрузки	0,777303	0,779423	0,792391
Дисперсия коэффициента загрузки	0,021307	0,019882	0,015975

На рис. 8, 9 представлены показатели качества производственного процесса. Длительность производственного процесса сокращается примерно на 10%.

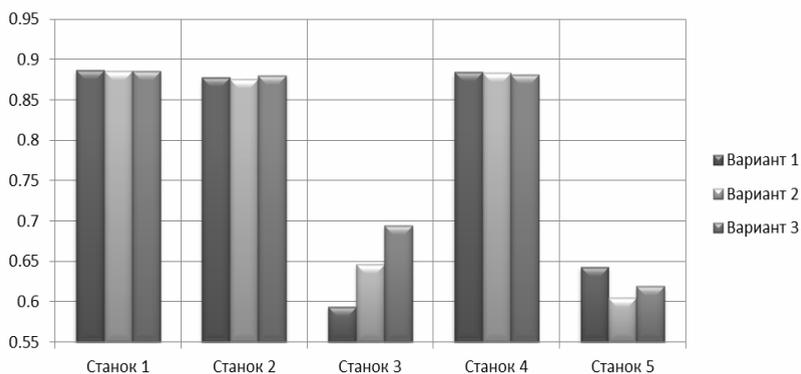


Рис. 8. Загрузка оборудования производственной системы

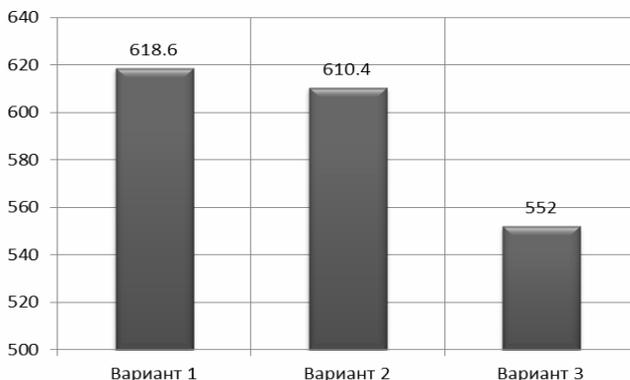


Рис. 9. Длительность производственного процесса (в минутах)

Исследуем эффективность предложенного метода управления сетью Петри. Для этого в структуре производственной программы существенно увеличим долю изделий токарного типа. Ниже приведены результаты моделирования для такого варианта работы системы (таблица 2, рис. 10, 11).

Получены результаты, схожие с предыдущим вариантом работы системы. Нейронная сеть стремится выровнять загрузку оборудования и уменьшает длительность производственного процесса.

Таблица 2. Результаты моделирования модифицированного варианта работы

	Вариант №1	Вариант №2	Вариант №3
Общее время процесса	1074,1	1073,3	1065,1
Коэффициенты загрузки:			
Станок №1	0,861838	0,864996	0,865271
Станок №2	0,856252	0,854561	0,863205
Станок №3	0,354622	0,367465	0,159985
Станок №4	0,859696	0,859312	0,861515
Станок №5	0,358812	0,344359	0,560041
Средний коэффициент загрузки	0,658244	0,658139	0,662003
Дисперсия коэффициента загрузки	0,075772	0,076198	0,096006

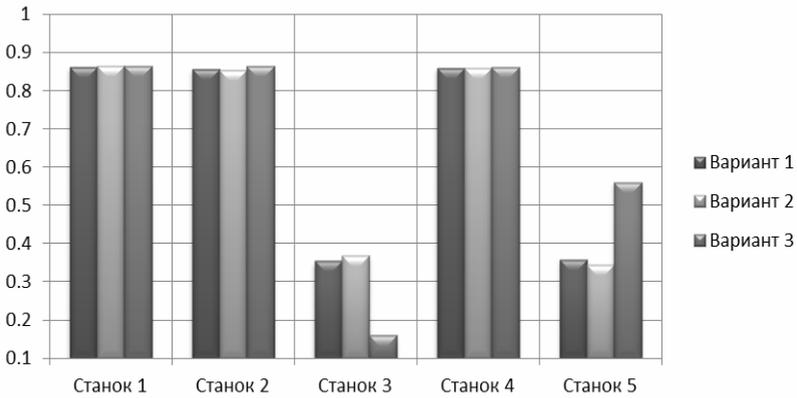


Рис. 10. Загрузка оборудования производственной системы (модифицированный вариант)

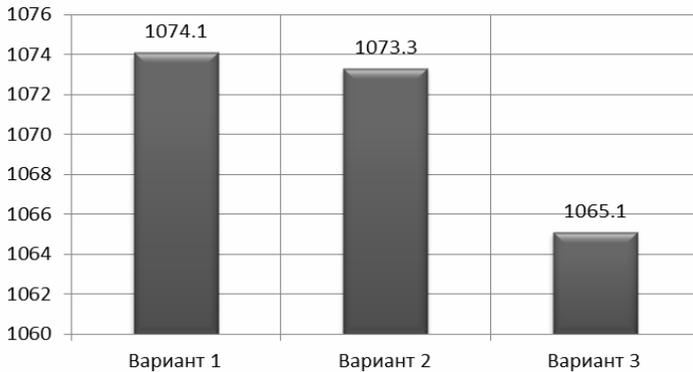


Рис. 11. Длительность производственного процесса (модифицированный вариант)

Для оценки эффективности предлагаемого подхода были также проведены эксперименты с различными наборами исходных данных: с увеличенной долей фрезерных изделий, а также с увеличенной долей токарно-фрезерных изделий. Нейронная сеть также улучшает показатели качества работы системы, и улучшение составляет от 1 до 3%. Это объясняется тем, что элемен-

ты обучающего вектора нейросети описывают наиболее вероятные распределения количества изделий разного типа, к которым относится исходный вариант.

7. Заключение

На основе анализа результатов работы можно отметить следующие основные преимущества предложенного метода оптимизации в отличие от оптимизации правилами приоритета.

1. Искусственная нейронная сеть выступает как элемент, запоминающий опыт эксперта при обучении с учителем. Учитывая особенности исследуемой системы, это является важным обстоятельством, поскольку при планировании производственного процесса на предприятии со временем накапливается опыт его оптимальной организации.
2. Возможность реализации сложных правил выбора переходов, зависящих от множества факторов и возможно меняющихся во времени. В производственных системах, как правило, требуется осуществлять многокритериальную оптимизацию. Использование нейронной сети позволяет отказаться от формирования общего критерия с определением весомости отдельных критериев.
3. Существует структурная прямая взаимосвязь критерия оптимальности и факторов, оказывающих на него влияние.
4. Возможность выбора периода перенастройки параметров (переобучения) нейронной сети.

Дальнейшие исследования по тематике статьи представляются актуальными по следующим вопросам.

1. Обучение нейросети в течение имитационного эксперимента на основе текущих значений показателей качества процесса.
2. Использования иных типов нейронных сетей для оптимизации.

Литература

1. БОДЯНСКИЙ Е.В., КУЧЕРЕНКО Е.И., МИХАЛЕВ А.И. *Нейро-фаззи сети Петри в задачах моделирования слож-*

- ных систем. – Днепропетровск: Системные технологии, 2005. – 311 с.
2. ГОРНЕВ В.Ф., ЕМЕЛЬЯНОВ В.В., ОВСЯННИКОВ М.В. *Оперативное управление в ГПС.* – М.: Машиностроение, 1990. – 256 с.
 3. КРУГЛОВ В.В., БОРИСОВ В.В. *Искусственные нейронные сети. Теория и практика.* – М.: Горячая линия – Телеком, 2001. – 382 с.
 4. МАКАРОВ И.М., РАХМАНКУЛОВ В.З., НАЗАРЕТОВ В.М. *Робототехника и гибкие автоматизированные производства. В 9-ти кн. Кн. 5. Моделирование робототехнических систем и гибких автоматизированных производств: учеб. пособие для втузов.* – М.: Высш. шк., 1986. – 175 с.
 5. ОСОВСКИЙ С. *Нейронные сети для обработки информации* / Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2004. – 344 с.

PETRI NETS PRESENTED SYSTEMS OPTIMIZATION USING ARTIFICIAL NEURAL NETWORKS

Alexey Sochnev, Siberian Federal University, senior lecturer at department «Robotics and Technical Cybernetics» (lesek@mail.ru)

Abstract: The method is suggested for optimization of systems modeled by Petri nets. The optimizer is based on the artificial neural network learned to adhere to the specific optimality criterion. An example is given of using the proposed method to control a Petri net simulation.

Keywords: Petri net, priority rules, artificial neural network.

*Статья представлена к публикации
членом редакционной коллегии О. П. Кузнецовым*