

ОПТИМИЗАЦИЯ ПРЕДСТАВЛЕННЫХ СЕТЯМИ ПЕТРИ СИСТЕМ С ПОМОЩЬЮ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Сочнев А.Н.¹

(Сибирский федеральный университет, Красноярск)

Данная 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.

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

Исходя из этого, разработка новых методов оптимизации систем, представленных 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. (рис. 1).




Рис. 1. План расположения оборудования гибкого производственного комплекса

Для составления плана - графика производственного процесса задается номенклатура деталей, производимых УИ ГПК. Предусматривается обработка деталей тридцати типов. Время обработки представлено в единицах (тактах), равных 0,01 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 комплексе. Готовые изделия также направляются в ячейки склада. Приоритет всех изделий установлен одинаковым.

Для составления суточного плана - графика необходимо определить все параметры основного и вспомогательного производственных процессов (таблица 1).

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

Группа Т: изделия № 1, 2, 4, 6, 7, 9, 10, 11, 12, 16, 9, 20, 21, 23, 24, 26, 27, 28, 29, 30


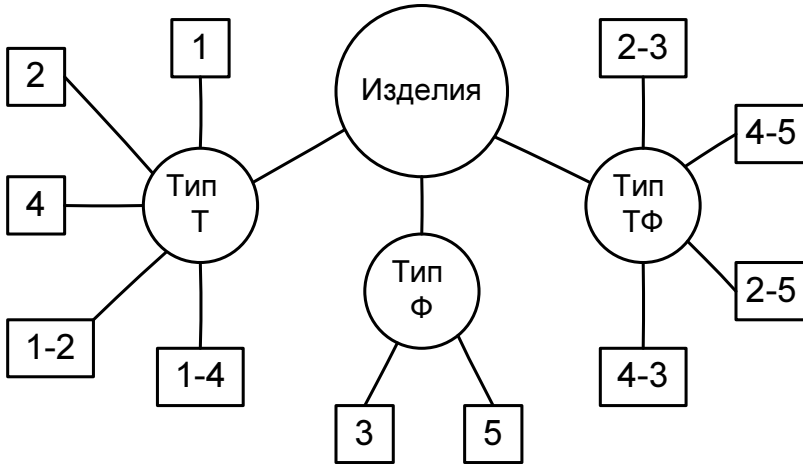
Группа Ф: изделия № 15, 17

Группа ТФ: изделия № 3,5,8,13,14,18,22,25


Таблица 1. Перечень продукции моделируемой производственной системы

№	Наименование изделия	Время токарной обработки 1, мин	Время токарной обработки 2, мин	Время фрезерной обработки, мин	Требуемый объем выпуска	Объем партии	Общее время операций, мин
1.	Болт 1	2,56	0	0	6	6	15,36
2.	Болт 2	2,8	0	0	8	4	22,4
3.	Вал 1	8,4	6,5	0	2	2	36,6
4.	Вал 2	6,3	0	0	18	6	113,4
5.	Вал 3	2,2	1,3	3,1	6	6	39,6
6.	Вал 4	6,96	9,8	0	4	1	67,04
7.	Ввертыш	7,8	4	0	8	4	94,4
8.	Матрица	3,4	0	14	12	4	208,8
...
24	Шайба 1	2,4	0	0	8	4	19,2
25	Палец 1	4,6	0	8	6	1	75,6
26	Шайба 2	3	0	0	4	1	12
27	Фланец 1	6,7	0	0	1	1	6,7
28	Шпилька 2	11,4	8	0	12	6	232,8
29	Гайка 1	8,4	0	0	16	8	134,4
30	Гайка 2	7,6	0	0	12	6	91,2

В рассматриваемой системе можно выделить возможные траектории перемещения изделий (рис. 2). Эти траектории определяются технологом с учетом свойств станков и технологических процессов изделий.



- обработка на станке № n



- последовательная обработка на станках n и m

Рис. 2. 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.

Группа Т1: 1,2,4,9,10,12,16,20,21,23,24,26,27,29,30

Группа Т2: 6,7,11,19,28

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 однотипных объектов (изделий). По указанным причинам для формирования имитационной модели выбраны раскрашенные сети [1].

Структура модели формируется на основе структуры технологических маршрутов, представленной ранее. Выделяются три позиции (p_0, p_{10}, p_{14}), в которые помещаются маркеры, соответствующие изделиям тип 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: p_2 - токарный станок 16К20Ф3 (№1), p_{17} - токарный станок 16К20Ф3 (№2), p_{15} - обрабатывающий центр 2254ВМФ4 (№3), p_{19} - токарный станок HAAS TL-1 (№4), p_{18} - фрезерный станок HAAS ТМ-1 (№5). В позициях сети p_9, p_{13} и p_{27} скапливаются готовые изделия типа Т, Ф и ТФ соответственно. Остальные позиции модели представ-

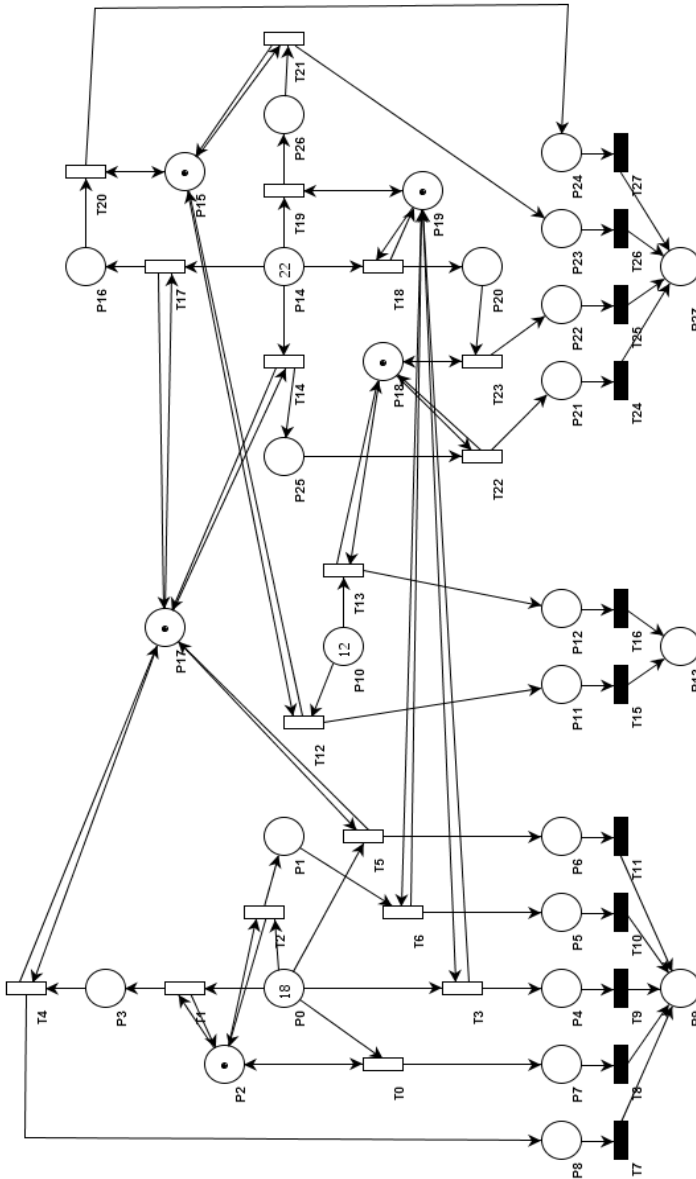


Рис.3. Имитационная модель производственного процесса

Сеть, представленная на рис. 3, 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. 4).




Рис. 4. Структура подсети обработки

При необходимости реализации системы группового диспетчерского управления производством модель может быть детализирована до уровня каждого технологического перехода и операции (рис. 5).

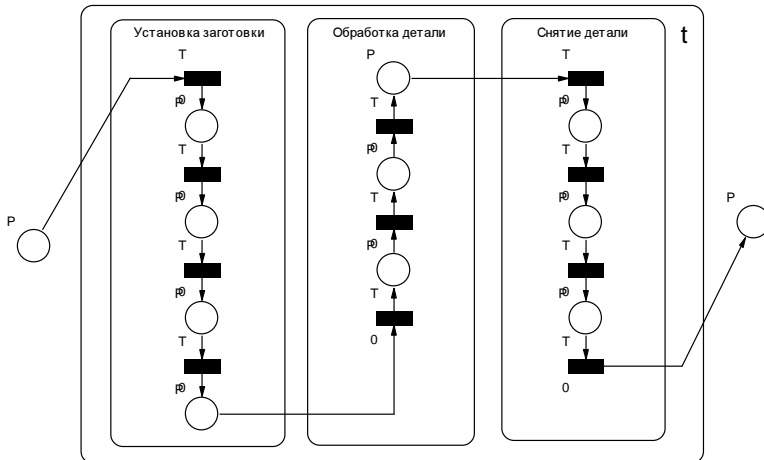


Рис. 5. Структура подсети обработки (детализированная)

3. 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 (ИНС), которая позволит принимать решения о выборе активируемых переходов сети. Правила работы нейронной сети предполагается заложить на этапе обучения перед имитацией сети Петри.

Эмпирически доказано, 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 ИНС 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

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

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 -ой единицы оборудования;

$T_{jПЕР}$ и $T_{jЛП}$ - суммарное время соответственно переналадок и простоя j -ой единицы оборудования;

$L_{ij} = (q_{ij}, t_{ij})$ - операция с номером i ($i = 1, \dots, m_j$), которая выполняется над j -ой деталью ($j = 1, \dots, n$);

m_j - число операций, которое необходимо выполнить над j -ой 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

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

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

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

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 λ_i для каждого критерия.

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

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

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

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

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 – максимизация 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 входных векторов. Учитывая это обстоятельство, выбирается такой тип нейронной сети, который предусматривает обучение с учителем.

4. Формирование структуры искусственной нейронной сети.

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

Нейросеть содержит входной слой, выходной и один скрытый слой (рис. 7). Скрытый слой существенно улучшает свойства нейронной сети [3, 4, 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 должно составлять от N до $3N$. Экспериментально было подобрано $K = 16$. При данном значении обеспечивается высокая скорость обучения, а также обобщающие свойства нейросе-

ти не превышают точность классификации состояний. Функция активации нейрона для каждого нейрона сигмоидальная (логистическая). Количество нейронов в выходном слое равно количеству переходов сети Петри, которые управляются нейросетью. Рассматриваемая модель содержит одиннадцать управляемых переходов, поэтому количество нейронов выходного слоя $M=11$. Управляемые переходы сети: $t_0, t_1, t_2, t_3, t_5, t_{12}, t_{13}, t_{14}, t_{17}, t_{18}, t_{19}$.

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.

```
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
%создание и тестирование нейросети
net = newff([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, производится обучение (рис. 6) и создаются структурные модели нейронной сети в пакете Simulink (рис. 7, 8, 9). 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 ИНС 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

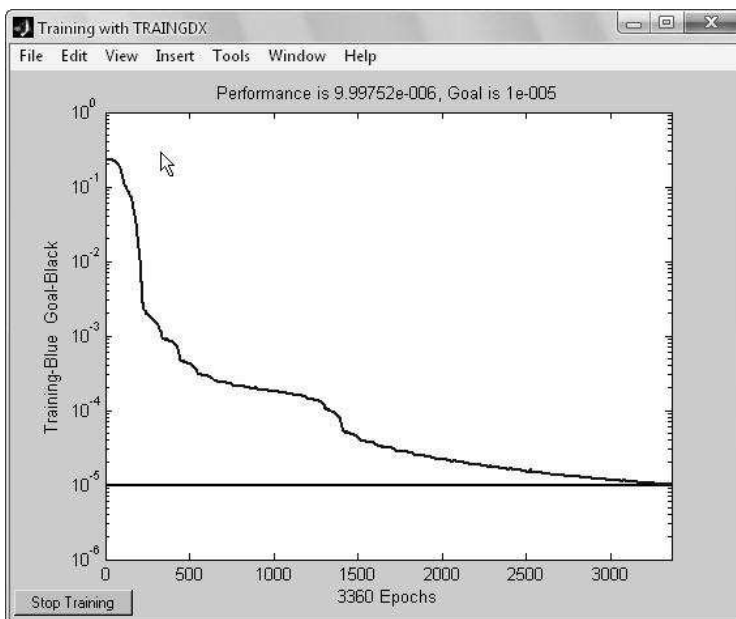


Рис.6. Процесс обучения нейронной сети


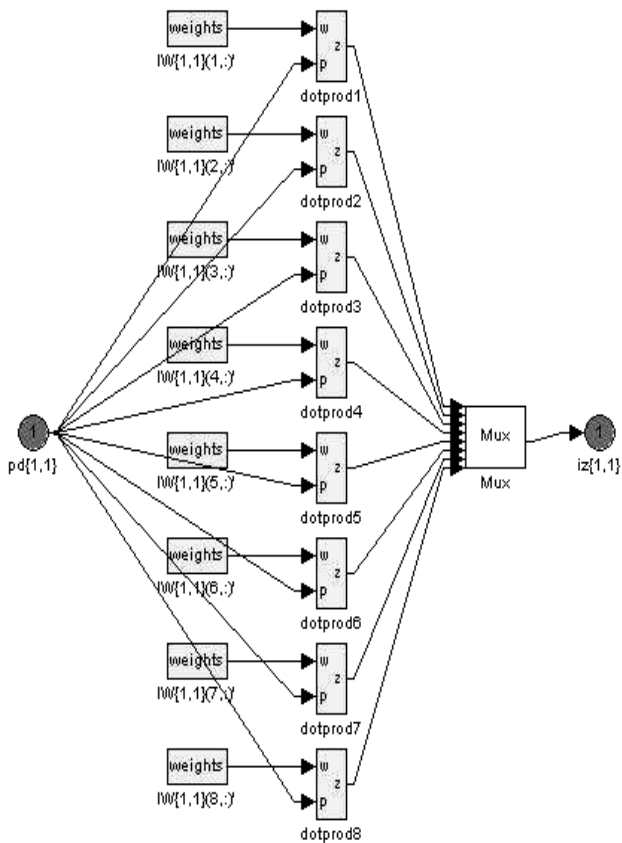


Рис. 7. Структура нейронной сети



*Рис. 8. Структура входного слоя
нейронной сети*

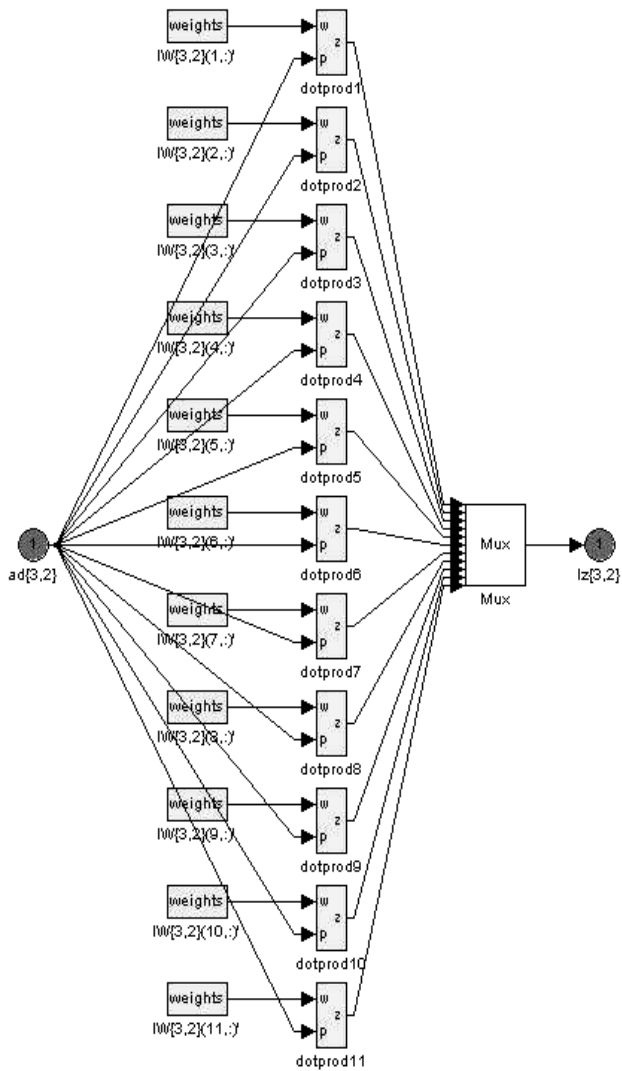


Рис. 9. Структура выходного слоя нейронной сети

5. Исследование предложенного метода

эффективности

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. 10) 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.

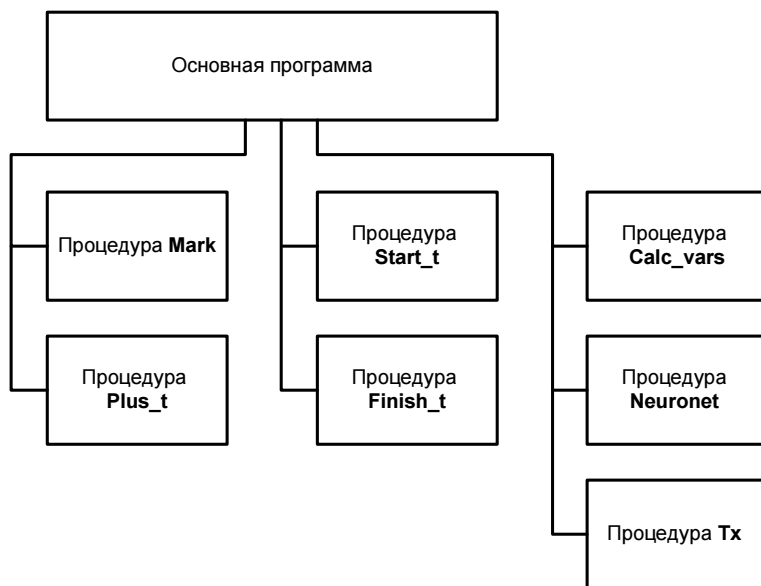


Рис. 10. Модульная структура разработанной программы

Таблица 2. Процедуры программы

Название процедуры	Выполняемые функции
mark	Распечатка маркировки
plus_t	Пересчет времени
start_t	Запуск переходов
finish_t	Завершение выполнения переходов
calc_vars	Вычисление входных параметров нейросети
neuronet	Запуск нейросети
tx	Выбор активируемого перехода сети Петри

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

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

Если поставить цель некоторого ускорения работы приведенного алгоритма, то можно ограничиться неполным перебором элементов выходного вектора нейросети. При этом можно прогнозировать некоторое ухудшение значения критерия оптимальности. В таблице 3 приведены результаты экспериментов с различным количеством повторения выбора активируемых переходов (стадий решения) для контрольного примера. Анализ результатов позволяет сделать вывод, что влияние нейронной сети выражается в выравнивании загрузки всех единиц оборуду-

дования с сопутствующим сокращением времени производственного процесса (рис. 11).

Таблица 3. Результаты моделирования исходного варианта работы системы

	Исходный вариант	Вариант №1	Вариант №2	Вариант №3
Общее время процесса	747.6	604.8	551.85	519.72
Коэффициенты загрузки:				
Станок №1	0.387908	0.319664	0.319712	0.307306
Станок №2	0.277154	0.27476	0.264774	0.274716
Станок №3	0.216168	0.256162	0.249886	0.32892
Станок №4	0.28118	0.29384	0.289924	0.287202
Станок №5	0.232316	0.294158	0.34652	0.301278
Количество стадий решения	0	1	9	11
Средний коэффициент загрузки	0.278945	0.287717	0.294163	0.299884
Дисперсия коэффициента загрузки	0.004499	0.000566	0.001559	0.000424




Рис. 11. Загрузка оборудования производственной системы

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 4, рис. 12).

Таблица 4. Результаты моделирования модифицированного варианта работы

	Исходный вариант	Оптимизированный вариант
Общее время процесса	706.4	657.6
Коэффициенты загрузки:		
Станок №1	0.47466	0.458333
Станок №2	0.466874	0.463656
Станок №3	0.303511	0.346411
Станок №4	0.470413	0.467914
Станок №5	0.298839	0.300639
Количество стадий решения	0	4
Средний коэффициент загрузки	0.402859	0.407391
Дисперсия коэффициента загрузки	0.008627	0.006135




Рис. 12. Загрузка оборудования производственной системы (второй вариант)

Получены результаты схожие с предыдущим вариантом работы системы. Нейросеть стремится выровнять загрузку токарного оборудования: станков 16K20Ф3 №1, №2 и HAAS TL-1.

6. Заключение

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

1. Существует структурная прямая взаимосвязь критерия оптимальности и факторов, оказывающих на него влияние;
2. Возможность реализации сложных правил выбора переходов, зависящих от множества факторов и возможно меняющихся во времени;
3. Возможность выбора периода перенастройки параметров (переобучения) нейросети.

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. Использование иных типов нейросетей для оптимизации.

Литература

1. МАКАРОВ, И. М. Робототехника и гибкие автоматизированные производства. В 9-ти кн. Кн. 5. Моделирование робототехнических систем и гибких автоматизированных производств: учеб. пособие для вузов / И. М. Макаров, В. З. Рахманкулов, В. М. Назаретов и др.; Под ред. И. М. Макарова. - М.: Высш. шк., 1986. - 175 с.
2. ЕМЕЛЬЯНОВ, В. В. *Оперативное управление в ГПС* / В. Ф. Горнев, В. В. Емельянов, М. В. Овсянников. - М.: Машиностроение, 1990. - 256 с.
3. ОСОВСКИЙ С. *Нейронные сети для обработки информации* / Пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2004. – 344 с.: ил.
4. БОДЯНСКИЙ, Е.В. *Нейро-фаззи сети Петри в задачах моделирования сложных систем* / Бодянский Е.В., Куче-

ренко Е.И., Михалев А.И. - Днепропетровск.: Системные технологии, 2005. – 311 с.

5. КРУГЛОВ, В. В. *Искусственные нейронные сети. Теория и практика* / Круглов В. В., Борисов В. В. - М.: Горячая линия – Телеком, 2001. – 382 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: This article describes the method of optimization systems presented models based on Petri nets. As expected the optimizer application training in accordance with the chosen criterion of optimality of an artificial neural network. Is an example of using the proposed control method simulation of Petri net.

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