

УДК 681.3.07:658.001.57

С. С. ФЕДИН, канд. техн. наук

Киевский национальный университет технологий и дизайна, г. Киев

АДАПТИВНАЯ НЕЙРОСЕТЕВАЯ МОДЕЛЬ ПРОГНОЗИРОВАНИЯ И УПРАВЛЕНИЯ КАЧЕСТВОМ МНОГОЭТАПНЫХ ТЕХНОЛОГИЧЕСКИХ ПРОЦЕССОВ

В статье разработана адаптивная модель рекурсивной нейронной сети для оперативного прогнозирования и управления качеством сложного многоэтапного технологического процесса. Показано, что суперпозиция моделей нейронных сетей отдельных этапов технологического процесса позволяет создать гибкую модель управления сквозной технологией изготовления изделий.

У статті розроблено адаптивну модель рекурсивної нейронної мережі для оперативного прогнозування та управління якістю складного багатоетапного технологічного процесу. Показано, що суперпозиція моделей нейронних мереж окремих етапів технологічного процесу дозволяє створити гнучку модель управління наскрізною технологією виготовлення виробів.

Введение

Для эффективного управления качеством сложных многоэтапных технологических процессов (ТП) производства продукции машиностроения необходимо детальное изучение явлений, протекающих непосредственно на каждом этапе или стадии ТП, с целью установления зависимости между факторами технологии производства и характеристиками свойств изготавливаемой продукции. В работах И.И. Пляскина [1], В.Г. Горского [2], Л.А. Кузнецова [3] показано, что в большинстве случаев для описания зависимости между совокупностью свойств продукции и факторами ТП применяют линейные по параметрам регрессионные модели.

В работе [4] показано, что для управления качеством на отдельном этапе ТП в условиях зашумленной входной информации одним из наиболее эффективных методов является применение адаптивных нейросетевых моделей – двухслойных перцептронов с алгоритмом обучения обратного распространения ошибки. В работе [5] рассмотрено использование двухслойных перцептронов для моделирования взаимосвязи свойств изготавливаемой продукции и параметров технологии.

Следует отметить, что большинство сложных ТП состоят из нескольких отдельных производств, а конечная продукция получается из полуфабрикатов (сырья и заготовок) путем их последовательной, поэтапной обработки. Так последовательность сложного многоэтапного технологического процесса механической обработки деталей может включать процессы: чернового обтачивания; получистового обтачивания; тонкого обтачивания; предварительного шлифования; чистого шлифования; алмазного выглаживания. На этих этапах могут протекать процессы, различные по своей природе и разделенные некоторыми временными периодами, а совокупность таких технологических этапов представляет собой сквозную технологию, характеризующуюся зашумленной информацией о параметрах ТП.

Управление качеством на каждом этапе ТП можно осуществлять на основе адаптивных нейронных сетей (НС). При этом, если для описания каждого технологического этапа можно воспользоваться двухслойной НС, то суперпозиция нейросетевых моделей отдельных этапов позволит создать адаптивную нейросетевую модель сквозной технологии.

Целью статьи является разработка адаптивной нейросетевой модели оперативного прогнозирования и управления сложным многоэтапным ТП на основе взаимосвязи между факторами ТП и характеристиками качества изготавливаемой продукции.

Основная часть

Формализация задачи управления качеством технологических процессов методом нейросетевого моделирования

Для решения задачи управления качеством ТП рассмотрим применение двухслойных нейронных сетей (НС) типа feedforward, позволяющих моделировать взаимосвязи между свойствами продукции и факторами ТП. НС типа feedforward представляет собой совокупность простых процессорных элементов – нейронов, организованных слоями. Нейроны в одном слое получают информацию от нейронов из предыдущего слоя и посылают результат нейронам следующего слоя. Между слоями НС имеются связи, которые подвергаются корректировке в процессе обучения нейросетевой модели. Обучение заключается в усилении одних связей и ослаблении других таким образом, чтобы при появлении одного и того же примера из обучающего множества модель НС на каждой эпохе обучения НС получает более корректный ответ по отношению к выбранному критерию обучения.

С математической точки зрения НС типа feedforward можно рассматривать в виде сетей Маркова, которые находят широкое применение для решения задач прогнозирования, управления и оценки надежности технических объектов и технологических систем [6]. Для сетей Маркова вероятность перейти в какое-либо состояние S_{i+1} в момент времени t_{k+1} при условии, что в момент t_k система находится в состоянии S_i , зависит только от состояния S_i и не зависит от того, в каких состояниях система находилась в моменты t_{k-1} , t_{k-2} [7]. Приведенные в таблице 1 аналогии между сетями Маркова и НС позволяют рекомендовать последние в качестве специализированных марковских моделей для решения задач прогнозирования качества и управления сложными многоэтапными ТП.

Таблица 1

Аналогии между нейронными сетями и марковскими моделями

Нейронная сеть	Марковская модель
Нейрон	Состояние процесса
Функция активации нейрона	Дифференциальное уравнение, описывающее динамику изменения вероятности нахождения в данном состоянии
Веса соединений	Интенсивности потоков событий
Порог активации	-
Входы и выходы нейронов	Вероятности нахождения в различных состояниях процесса
Свободные параметры – это веса связей и порог активации	Свободные параметры – это интенсивности потоков событий (коэффициенты дифференциальных уравнений, описывающих эволюцию технологической системы)
Обучающее множество	Наблюдаемая гистограмма частот попадания в различные состояния процесса в заданные моменты времени
При обучении минимизируется ошибка прогноза в заданной метрике	При обучении минимизируется статистика, асимптотически описываемая χ^2 распределением и определяющая различия между наблюдаемой и прогнозируемой гистограммами

Необходимо отметить, что несмотря на ряд аналогий между НС и марковскими моделями, в специфике применения сетей Маркова и прямослойных НС имеется ряд различий:

– НС прямой передачи обучаются для применения в качестве идентификатора классов, детектора новых явлений или прогнозирования, а главным назначением сетей Маркова является поиск коэффициентов модели, по которым реализуется прогноз вероятностей нахождения ТП в определенном состоянии;

– диаграммы сетей Маркова обычно *a priori* определяются постановкой задачи, а структура НС обычно не фиксируется заранее и гибко подстраивается к заданной постановке задачи.

Задача управления качеством многоэтапного ТП состоит в том, чтобы для каждого свойства продукции построить такое отображение $\varphi: X \rightarrow y$, при котором значение оценки $\hat{y}(X_i)$, получаемое на основе модели было бы наиболее близко к значению моделируемого

свойства продукции $y(X_i)$, полученной при реализации технологии X_i [8]. В общем случае модели управления качеством ТП имеют вид: $y = \varphi(X)$, где y – одно из свойств продукции, φ – сложная функция многих переменных, а X – вектор технологических параметров. При определении вида функции φ используется массив накопленной статистической информации $W = \{X | Y\} \in R^{p(n+m)}$, содержащий наборы значений технологических параметров $X = \{x_1, x_2, \dots, x_n\}$ и значения свойств $Y = \{y_1, y_2, \dots, y_m\}$ продукции, полученной при реализации определенной технологии.

Примем, что x_1, \dots, x_n – факторы ТП, y_1, \dots, y_m – свойства продукции, $t_{i,j}$, $a_{i,j}$, и $w_{i,k,j}$, $i=1, 2, j=1, \dots, r_i, k=1, \dots, r_{i-1}$ – параметры нейросетевой модели. r_0, r_1, r_2 – количество входных сигналов сети и количество нейронов в первом и втором слоях соответственно ($r_0=n, r_2=m$). $S_{i,j}$, $j=1, \dots, r_i, i=1, 2$ – идентификаторы выходов адаптивных сумматоров каждого нейрона, а $P_{i,j}$, $j=1, \dots, r_1$ – идентификаторы выходных значений нейронов скрытого слоя. Практическую реализацию такого типа моделей НС можно эффективно осуществить в различных системах моделирования искусственных НС: BrainMaker Pro, Statistica Neral Networks, Deductor Studio и др.

Разработка модели нейронной сети для одновременного прогнозирования комплекса свойств изготавливаемой продукции

Сформируем топологию модели НС по следующим правилам:

– моделируется однородная двухслойная НС с логистической функцией активации

нейронов, т.е. $y(s) = \frac{1}{1 + e^{-as}}$;

– число входов модели определяется количеством технологических факторов, все входные сигналы подаются всем нейронам первого скрытого слоя;

– число выходов модели соответствует числу контролируемых свойств получаемой продукции;

– выходными сигналами модели являются сигналы нейронов выходного (второго) слоя, поэтому количество нейронов в этом слое равно числу показателей качества продукции.

– количество нейронов в первом – скрытом слое рассчитывается с учетом зависимостей (1, 2) и граничных условий (3).

Для создания двухслойной модели НС, т. е. содержащей один скрытый слой определим количество нейронов по формуле (1) [9]:

$$N = \frac{N_w}{N_x + N_y}, \quad (1)$$

где N_x – размерность входного сигнала, N_y – размерность выходного сигнала;

N_w – необходимое число синаптических весовых коэффициентов нейронной сети.

Для определения значения N_w целесообразно использовать формулу (2), являющуюся следствием теорем Арнольда – Колмогорова – Хехт-Нильсена [9]:

$$\frac{N_y Q}{1 + \log_2 Q} \leq N_w \leq N_y \left(\frac{Q}{N_x} + 1 \right) (N_x + N_y + 1) + N_y, \quad (2)$$

где Q – число примеров обучающей выборки нейронной сети.

На качество процесса обучения нейронной сети значительно влияет объем обучающей выборки, т. е. количество примеров, отображающих связь между факторами ТП и свойствами изготавливаемой продукции. Определим это число в виде нестрогого неравенства и получим диапазон количества скрытых нейронов сети (3):

$$6(N_x + N + N_y) \leq Q \leq 10(N_x + N + N_y), \quad (3)$$

где N – количество скрытых нейронов.

Вследствие этого минимальное Q_{\min} и максимальное Q_{\max} количество фактов можно рассчитать по формулам (4) и (5):

$$Q_{\min} = 6(N_x + N + N_y), \quad (4)$$

$$Q_{\max} = 10(N_x + N + N_y). \quad (5)$$

Таким образом, можно определить диапазон скрытых нейронов, т.е. их возможное минимальное N_{\min} и максимальное N_{\max} количество (6, 7):

$$N_{\min} = \frac{Q}{10} - N_x - N_y, \quad (6)$$

$$N_{\max} = \frac{Q}{6} - N_x - N_y. \quad (7)$$

Необходимо отметить, что в тех случаях, когда применение приведенных отношений (1–7) не позволяет разработать модель НС, обладающую высокими обобщающими способностями, рекомендуется использовать формулу (8) для определения числа скрытых нейронов [9]:

$$N = \frac{(N_x + N_y)}{2} \quad (8)$$

При вычислении числа скрытых нейронов полученное значение, в большинстве случаев, не является целым. В этом случае для повышения обобщающих свойств нейронной сети необходимо округлять это значение в меньшую сторону.

На этапе обучения параметры модели, а именно коэффициенты синаптических связей $w_{i,k,j}$, пороговые значения $t_{i,j}$ и параметры функции активации $a_{i,j}$ иницируются случайными числами в диапазоне (0; 1). Оценка оптимальных значений этих параметров определяется в процессе обучения модели. В основу обучения положено использование массива обучающих данных W' . Для проверки качества обучения используется массив W'' данных тестирующего множества. Критерий обучения имеет вид (9):

$$\sum_{i=1}^p \sum_{j=1}^m (y_{ji} - \hat{y}_{ji})^2, \quad (9)$$

где p – мощность обучающей совокупности (объем выборки);

\hat{y}_{ji} – действительное значение j -го выхода модели для i -го набора экспериментальных данных; y_{ji} – желаемое значение j -го выхода модели для i -го набора экспериментальных данных. Обучение такой сети можно осуществлять по алгоритму обратного распространения ошибки [8, 10].

Необходимо отметить, что в производственном цикле процесс формирования каждого свойства продукции осуществляется во взаимодействии с другими процессами и часто оказывает значительное влияние на их протекание и на конечные значения остальных показателей качества продукции в зависимости от времени. Взаимное влияние протекающих процессов на каждом этапе сложного ТП с учетом фактора времени позволяет учитывать двухслойная рекуррентная нейросетевая модель, в которой нейроны скрытого слоя обрабатывают входную информацию и на ее основе формируют новый массив информации для передачи его на следующий слой (рис. 1). Эта информация участвует в расчете значений каждого выхода модели. Каждый формальный нейрон (или некоторая их совокупность) моделирует один из процессов, протекающих в ходе технологического цикла. Таким образом, значения каждого выхода модели определяются совокупностью результатов этих процессов и параметрами соответствующего формального нейрона выходного слоя.

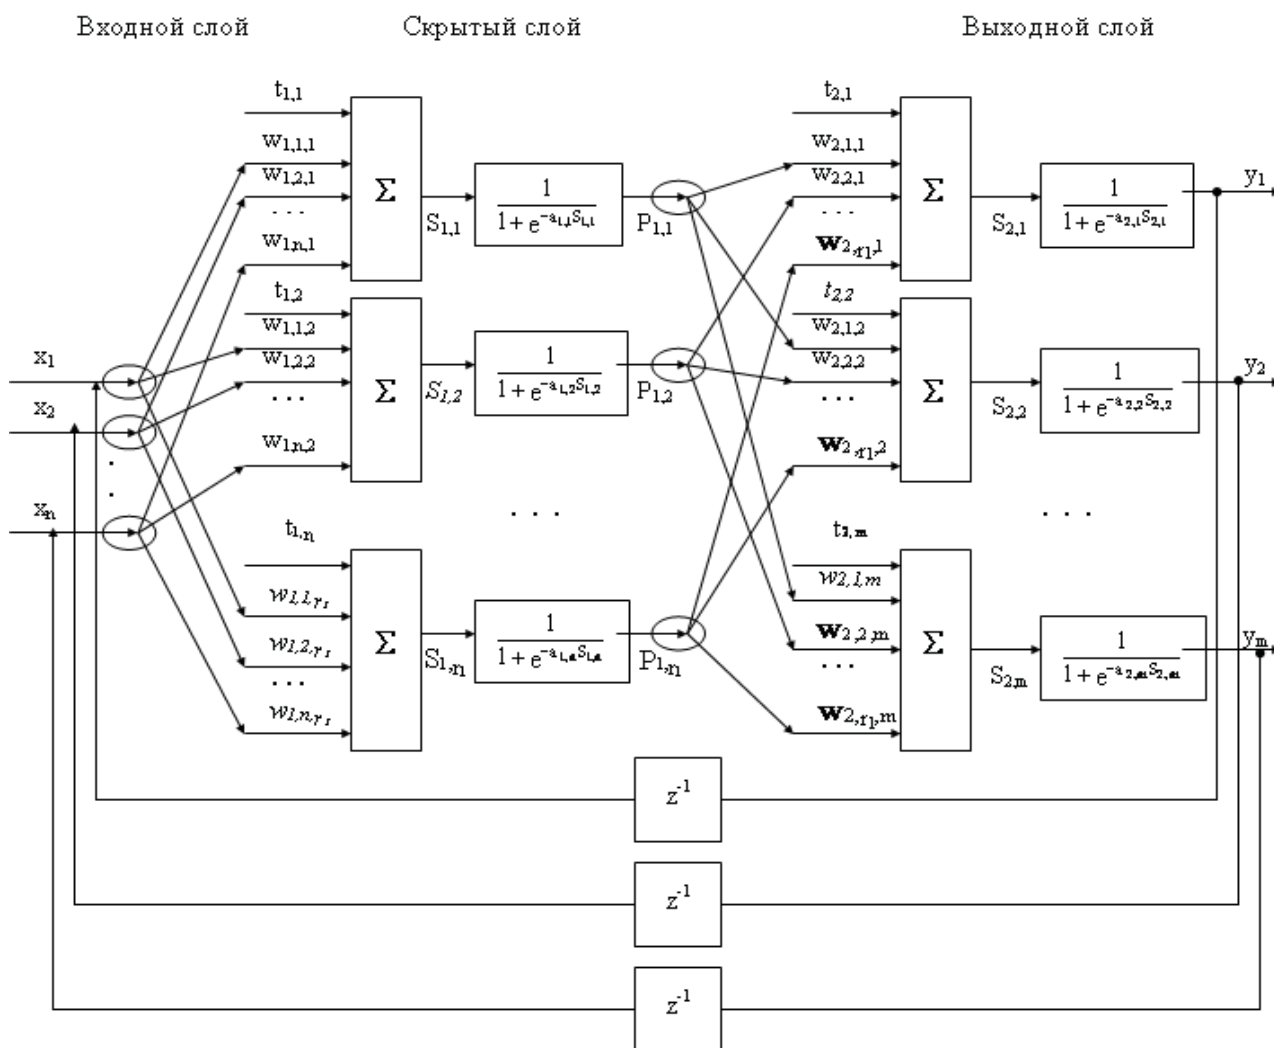


Рис. 1. Модель нейросетевого управления n технологическими параметрами при изготовлении изделий, характеризующихся m контролируруемыми свойствами

Представленная на рис. 1 модель характеризуется замкнутым контуром опережающего отражения действительности и характеризует влияние применяемой в ходе производства

технологии на конечные свойства изготавливаемой продукции, а функционирование модели осуществляется в три этапа по следующим правилам.

На первом этапе функционируют нейроны первого слоя (10, 11):

$$S_{1,i} = \sum_{j=1}^n w_{1,j,i} x_j + t_{1,i}, \quad i = 1, \dots, r_1, \quad (10)$$

$$P_{1,i} = \frac{1}{1 + e^{-a_{1,i} S_{1,i}}}, \quad i = 1, \dots, r_1. \quad (11)$$

На втором этапе рассчитываются значения выходов нейронов выходного слоя (12, 13):

$$S_{2,i} = \sum_{j=1}^n w_{2,j,i} x_j + t_{2,i}, \quad i = 1, \dots, m, \quad (12)$$

$$y_i = \frac{1}{1 + e^{-a_{2,i} S_{2,i}}}, \quad i = 1, \dots, m. \quad (13)$$

На третьем этапе с использованием оператора задержки (z^{-1}) выполняется рекурсия, что позволяет НС запоминать ретроспективную информацию и осуществлять идентификацию параметров ТП.

Таким образом, созданная математическая рекуррентная модель может быть применена для управления ТП, так как отражает взаимосвязи между факторами ТП и характеристиками качества продукции и позволяет одновременно прогнозировать значения нескольких свойств продукции.

Нейросетевое управление сквозной технологией изготовления продукции

В модели НС, построенной на основе принципов сквозной технологии, непосредственное влияние на свойства продукции k -го этапа оказывают соответствующие технологические режимы, свойства продукции предыдущего ($k-1$) – го этапа, а также свойства материалов, обрабатываемых на k - м этапе производственного цикла. Создание такой модели возможно только после формализации вербального описания сквозного технологического процесса [8]. Для разработки универсальной модели управления сквозной технологией изготовления продукции рассмотрим схему K -этапного технологического процесса (рис. 2).

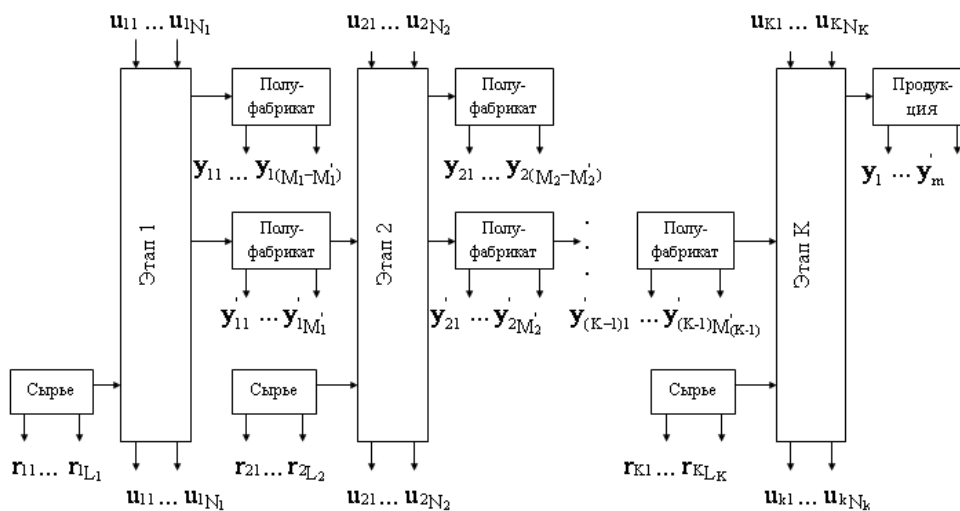


Рис. 2. Схема K -этапного технологического процесса

Пусть сквозной технологический процесс механической обработки деталей состоит из K этапов. На каждом i -м этапе контролируется и измеряется N_i технологических параметров. Таким образом, множество реальных технологических значений параметров

$T^{(i)} = \{\tau_{1i}, \tau_{2i}, \dots, \tau_{N_i}\}$ и множество измеренных значений технологических параметров $U^{(i)} = \{u_{1i}, u_{2i}, \dots, u_{iN_i}\}$ i -го этапа имеют N_i составляющих. На каждом этапе производятся полуфабрикаты (обрабатываемые заготовки деталей), M_i свойств которых контролируются: $Y^{(i)} = \{y_{1i}, y_{2i}, \dots, y_{iN_i}\}$. Часть полуфабрикатов, полученных на i -м этапе, проходят дальнейшую обработку на $(i+1)$ -м этапе производства. Количество свойств этой части продукции i -го этапа обозначим через M'_i ($M'_i \leq M_i$), $Y^{(i)} = \{y'_{1i}, y'_{2i}, \dots, y'_{iM'_i}\}$, где $y'_{ij} \in Y^{(i)}$, $j = 1, \dots, M'_i$. Кроме того, на некоторых этапах используется дополнительное сырье, которое имеет L_i измеряемых характеристик $V^{(i)} = \{v_{1i}, v_{2i}, \dots, v_{iL_i}\}$. Таким образом, факторы формирующие свойства продукции i -го этапа производственного цикла делятся на три группы:

– свойства заготовок, произведенных на $(i-1)$ -м этапе:

$$P^{(i)} = \{p_{1i}, p_{2i}, \dots, p'_{iM_{(i-1)}}\}, p_{ij} = y'_{iM_{(i-1)}}, j = 1, \dots, M'_{i-1};$$

– свойства материалов, используемых на i -м этапе производственного цикла

$$V^{(i)} = \{v_{1i}, v_{2i}, \dots, v_{iL_i}\};$$

– технологические параметры, определяющие режим производства на i -м технологическом этапе, $U^{(i)} = \{u_{1i}, u_{2i}, \dots, u_{iN_i}\}$.

Множество $X^{(i)}$, описывающее технологию, реализованную на i -м этапе, имеет вид: $X^{(i)} = \{P^{(i)}, V^{(i)}, U^{(i)}\} = \{x_1(i), x_2(i), \dots, x_{n_i}(i)\}$, $n_i = M'_i$. Подобным образом обозначим и множество свойств получаемых заготовок (полуфабрикатов): $Y^{(i)} = \{y_1(i), y_2(i), \dots, y_{n_i}(i)\}$, $i = 1, \dots, M_i$. Технологическая информация о сквозном процессе производства представляет собой совокупность свойств материалов (сырья), используемых на каждом этапе производственного цикла, и параметров технологических режимов, реализованных на этих этапах (14):

$$X = \{V^{(1)}, U^{(1)}, V^{(2)}, U^{(2)}, \dots, V^{(k)}, U^{(k)}\} = \{x_1, x_2, \dots, x_n\}, \quad (14)$$

$$\text{где } n = \sum_{k=1}^K (N_k + N_k).$$

Продукция, получаемая в результате реализации технологии X , имеет m характеристик: $Y = \{y_1, y_2, \dots, y_m\}$, где $m = M_k$. Для каждой единицы продукции такая информация различна, но структура векторов V , U , и Y постоянна. Поэтому эту информацию можно представить в виде матрицы (15):

$$W = \begin{pmatrix} X_1, Y_1 \\ \dots \\ X_p, Y_p \end{pmatrix}, \quad (15)$$

где X_i – вектор значений технологических параметров при изготовлении i -й единицы продукции, а Y_i – вектор значений свойств i -й единицы продукции.

Создание модели сквозного ТП на основе НС позволит прогнозировать значения свойств полуфабрикатов (заготовок), выпускаемых на каждом технологическом этапе, а также значения свойств готовой продукции. При этом, модели технологических этапов могут обучаться в отдельности, а затем интегрироваться в одну и таким способом формализовать сквозную многоэтапную технологию.

На рис. 3 представлена универсальная нейросетевая модель многоэтапного технологического процесса.

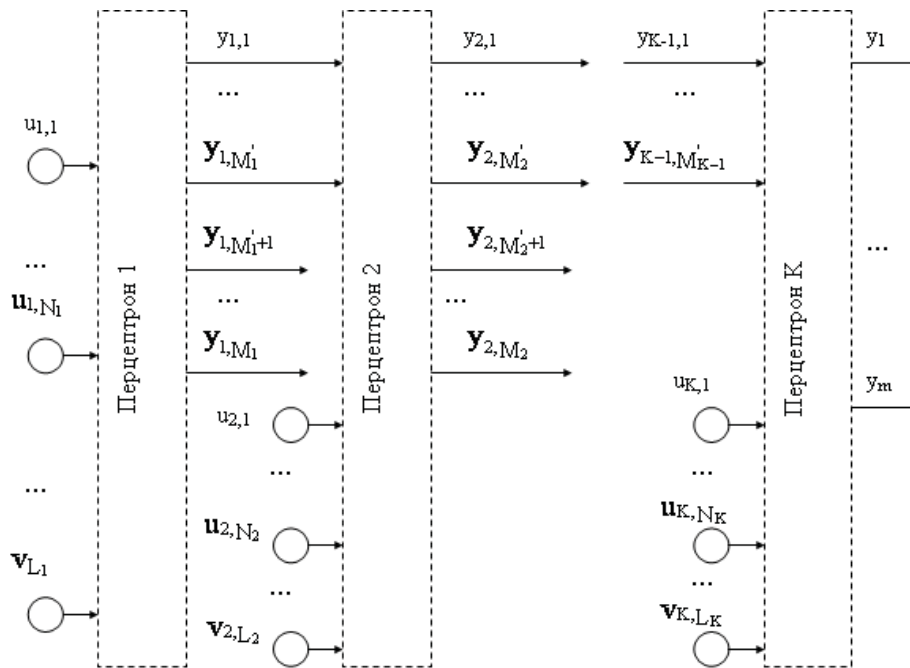


Рис. 3. Нейросетевая модель K - этапного технологического процесса

Фактически модель представляет суперпозицию двухслойных моделей (10 – 13) отдельных этапов технологического процесса изготовления продукции.

Предлагаемый подход к проектированию топологии нейронной сети, описывает многоэтапный технологический процесс механической обработки деталей на основе четырех правил:

- каждому этапу технологического цикла в нейросетевой модели соответствует однородный двухслойный перцептрон с логистической функцией активации, в которой выходы нейронов первого слоя передаются всем нейронам второго слоя;

- количество нейронов выходного слоя i -го перцептрона соответствуют количеству контролируемых свойств заготовок, изготавливаемых на i -м этапе технологического цикла. Количество нейронов в выходном слое i -го перцептрона равно M_i . В выходном слое нейросетевой модели количество нейронов выбирается равным количеству показателей качества, характеризующих m свойств выпускаемой продукции;

- выходы M'_i нейронов i -го перцептрона, соответствующие M'_i контролируемым свойствам заготовок, изготавливаемых на i -м этапе технологического процесса и проходящих дальнейшую обработку на $(i+1)$ -м этапе, подаются на входы всем нейронам первого слоя $(i+1)$ -го перцептрона, которые называются внутренними. Остальные $(M_i - M'_i)$ выходов являются выходами нейросетевой модели;

- на входы нейронов первого слоя i -го перцептрона подаются сигналы, соответствующие свойствам полуфабрикатов, используемым на i -м этапе технологического процесса, а также сигналы, соответствующие параметрам технологических режимов i -го этапа, которые называются внешними. В соответствии с введенными обозначениями у i -го перцептрона будет $(L_i + N_i)$ внешних входов, а общее количество входов i -го перцептрона составит $(L_i + N_i + M'_{i-1})$. Нейросетевая модель сформированная по данным правилам имеет

$2K$ слоев, $m = \sum_{i=1}^{K-1} (M_i - M'_i)$ выходов и $n = \sum_{i=1}^K (L_i + N_i)$ входов, представляющих совокупность внешних входов моделей НС каждого этапа ТП.

Выводы

1. Разработана гибкая адаптивная модель НС прогнозирования и управления качеством сложных многоэтапных ТП, отличающаяся от стандартных моделей адекватным описанием сквозной технологии производства и свойством рекурсии, что позволяет корректно прогнозировать значения выходных сигналов скрытого слоя нейронов – параметров промежуточных этапов технологического процесса, а также значения выходных сигналов выходного слоя модели – показателей качества продукции.

2. Показано, что разработанную модель НС можно рассматривать в качестве специализированной марковской модели прогнозирования и управления состояниями ТП.

3. Предложены аналитические зависимости для определения количества скрытых нейронов модели НС, предназначенной для управления качеством сложного многоэтапного ТП изготовления изделий.

Список литературы

1. Пляскин И. И. Оптимизация технических решений в машиностроении. – М.: Машиностроение, 1982. – 176 с.
2. Горский В. Г., Адлер Ю. П., Талалай А. М. Планирование промышленных экспериментов. М.: Металлургия, 1978. – 112 с.
3. Кузнецов Л.А. Введение в САПР производства проката. - М.: Металлургия, 1991. – 112 с.
4. Федин С. С., Трищ Р. М. Управление качеством с использованием методов нейронных сетей//Системні методи керування, технологія та організація виробництва, ремонту і експлуатації автомобілів, К.: НТУ, ТАУ, 2003, – вип.15. – С. 228–230
5. Кузнецов Л. А., Домашнев П. А. Нейросетевая модель многоэтапного технологического процесса // Сб. научн. тр. междунар. конф. СССУ/НТCS'2003. – Воронеж, 2003. – С. 191–196.
6. ГОСТ Р 51901.15-2005. Менеджмент риска. Применение марковских методов. Введен 01.02.2006. – М.: Федеральное агентство по техническому регулированию и метрологии России, 2005. – 16 с.
7. Кемени Дж., Снелл Дж. Конечные цепи Маркова.– М.: Наука, 1970. – 272 с.
8. Кузнецов Л. А., Домашнев П. А. Нейросетевые модели для описания сложных технологических процессов // Проблемы управления. – 2004. – № 1. – С. 20–27.
9. Ясницкий Л. Н. Введение в искусственный интеллект. – М.: Академия, – 2005.– 176 с.
10. Федин С. С., Трищ Р. М. Обеспечение качества типовых деталей машиностроения методом нейросетевой классификации статистических законов распределения // Восточно-Европейский журнал передовых технологий. – 2006. – № 3/2 (21). – С. 93–100.

ADAPTIVE NEYROSETEVAYA MODEL OF PROGNOSTICATION AND QUALITY OF MULTISTAGE TECHNOLOGICAL PROCESSES MANAGEMENT

S. S. FEDIN, Cand. Tech. Sci.

In the article the adaptive model of recursion neuron network is developed for operative prognostication and quality of a difficult multistage technological process management. It is rotined that superpoziciya of models of neuron networks of the separate stages of technological process allows to create a flexible case through technology of making of wares frame.

Поступила в редакцию 27.02.2010