

УДК 004.032.26

В.Б. Гитис

Донбасская государственная машиностроительная академия, г. Краматорск, Украина
vbg@krm.net.ua

Сопряжение информационных потоков нейросетевой системы нормирования времени механообработки деталей

В статье рассмотрены информационные потоки, циркулирующие в системе нормирования времени механической обработки деталей на основе нейронных сетей. Приведены формулы и алгоритм предварительной обработки исходных данных для подачи их на входы нейронных сетей, а также формулы интерпретатора ответа для перевода выходов нейронной сети в формат норм времени.

Введение

В современных условиях хозяйствования затраты на труд превращаются во все более значительную часть общих расходов. Поэтому для предприятий важно обеспечить максимально эффективное использование трудовых ресурсов. Способность выполнить эту задачу зависит от того, насколько точно будут рассчитаны и контролируются затраты на труд. Роль норм как основы организации производства и повышения эффективности использования живого труда с расширением рыночных отношений будет возрастать.

Затраты времени на производство продукции оказывают решающее влияние на себестоимость и, как следствие, на конкурентоспособность продукции [1]. При этом основное место в большинстве отраслей машиностроения занимает обработка металлов снятием стружки на металлорежущих станках различных типов. Так, в серийном и единичном производстве удельный вес механической обработки составляет 60 – 90 %.

В то же время расчет длительности механической обработки представляет собой трудоемкую и продолжительную процедуру, поскольку установление технических норм времени является завершающим этапом разработки технологического процесса. Поэтому перед предприятиями, имеющими широкую, часто меняющуюся номенклатуру производимой продукции, стоит проблема быстрого и точного нормирования времени изготовления новых изделий. Такая ситуация характерна прежде всего для предприятий тяжелого машиностроения, и проблема нормирования здесь особо актуальна.

Постановка задачи

Для совершенствования процесса установления норм времени механической обработки деталей в работах [2-4] было предложено рассматривать детали как объекты, описываемые набором признаков, определяющих трудоемкость их изготовления. Тогда в общем виде процедуру нормирования будет описывать следующая математическая модель:

$$\begin{cases} T_i = f_i(\bar{X}_i) \\ T_o = f_o(\bar{X}_o) \\ T_o = \sum_{i=1}^n T_i \\ \bar{X}_o^{\min} \leq \bar{X}_o \leq \bar{X}_o^{\max}, \end{cases}$$

где $i = 1 \dots n$ – номер технологической операции;

n – число технологических операций;

T_i – норма времени на выполнение i -й технологической операции;

T_o – общая норма времени на изготовление детали;

f_i – функция, описывающая зависимость нормы времени на выполнение i -й технологической операции от характеристик детали;

f_o – функция, описывающая зависимость общей нормы времени на изготовление детали от ее характеристик;

\bar{X}_o – вектор характеристик детали;

\bar{X}_i – векторы характеристик детали, влияющих на величину T_i ;

\bar{X}_o^{\min} и \bar{X}_o^{\max} – соответственно векторы минимальных и максимальных значений вектора \bar{X}_o .

Компоненты векторов \bar{X}_i выбираются из числа компонент вектора \bar{X}_o . Значения \bar{X}_o^{\min} и \bar{X}_o^{\max} задают границы области проектирования и могут быть определены либо как минимальное и максимальное значения соответствующей характеристики среди всех деталей группы, либо задаваться исходя из характеристик деталей, для которых предполагается выполнять нормирование.

Реализация математической модели нормирования была выполнена путем построения нейросетевой системы технического нормирования времени механической обработки деталей. Система состоит из $n + 1$ нейронных модулей, представляющих собой прямонаправленные персептроны с одним скрытым слоем с сигмоидальными функциями активации нейронов скрытого слоя. Каждый нейронный модуль осуществляет нормирование длительности одной из n технологических операций, а также определение длительности общего времени обработки.

На входы модулей подаются характеристики деталей в соответствии с математической моделью нормирования. На выходе модулей формируются сигналы, соответствующие нормам времени (T). При отсутствии какого-либо вида технологической операции, на соответствующем выходе формируется ноль. Количество входов фиксировано, поэтому если какая-либо характеристика детали отсутствует, то на соответствующий вход подается ноль.

Цель работы

В работах, описывающих построение нейросетевой системы нормирования времени механической обработки деталей, не был отражен вопрос сопряжения информационных потоков, приходящих в систему извне, циркулирующих в системе и выдаваемых пользователю. Поэтому необходимо построить модули, осуществляющие перевод реальных данных в нейросетевой формат и обратно.

Результаты исследований

Система нормирования времени используется по схеме, представленной на рис. 1.

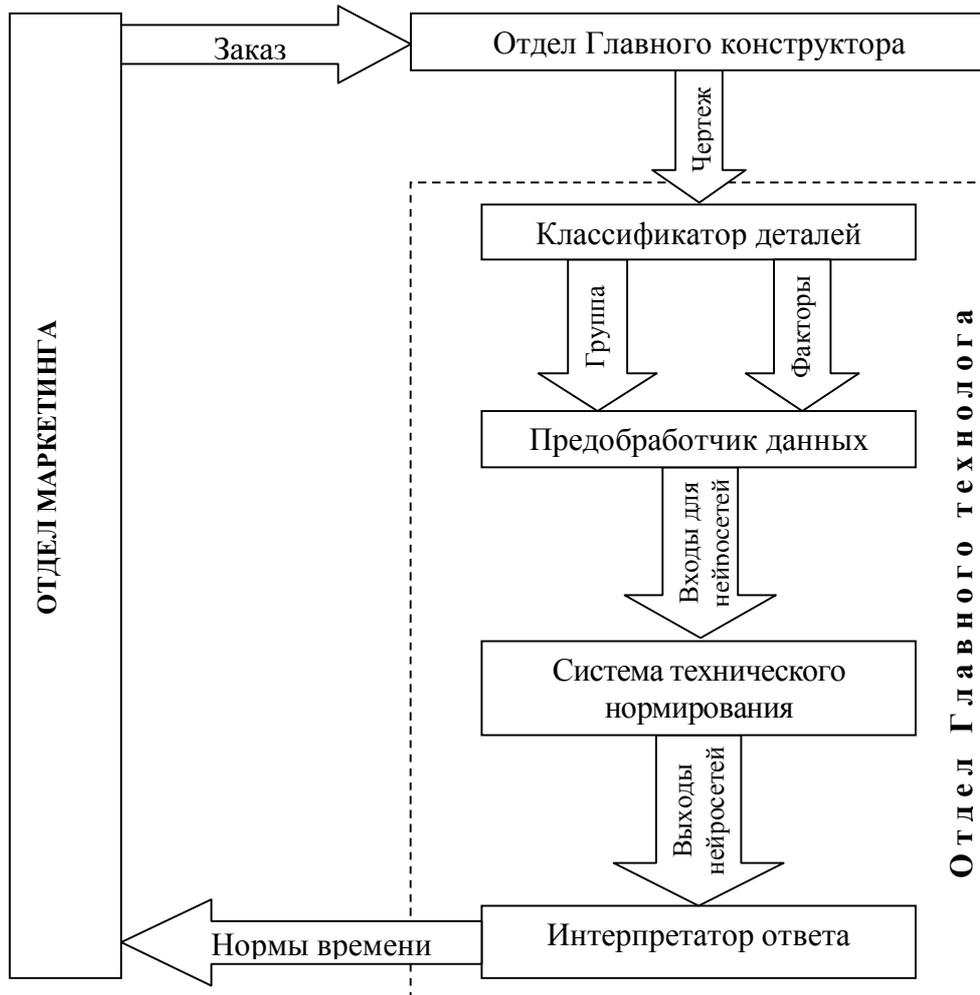


Рисунок 1 – Схема определения трудоемкости механообработки при технико-коммерческой проработке заказов

Из отдела маркетинга поступает требование технико-коммерческой проработки заказа в отдел главного конструктора, который передает комплект чертежей деталей в отдел главного технолога для определения трудоемкости механической обработки. В соответствии с принятой системой классификации идентифицируется группа, к которой принадлежит деталь, и в соответствии с номером группы выбирается нейросетевая система, обученная нормированию в этой группе.

Факторы, описывающие деталь, подаются на входы системы через предобработчик данных, который переводит исходные данные в нейросетевой формат. Таким образом, предобработчик данных является модулем сопряжения между пользователем, формирующим исходную информацию, и нейросетевой системой нормирования.

Поскольку компоненты входных векторов имеют различные единицы измерения и диапазоны вариации, необходимо выполнить операцию масштабирования для того, чтобы представить все элементы входного сигнала числами одного типа из одного диапазона.

Подача на вход нейронной сети немасштабированных данных затрудняет обучение сети и приводит к ошибкам в ее работе, так как:

1) работа весовых коэффициентов сети в различных масштабах усложняет начальную инициализацию весов;

2) весовые коэффициенты нейронов в зависимости от величины дисперсии примут очень большие или очень малые значения, что увеличит время обучения и снизит точность прогнозов;

3) нейроны входного слоя или окажутся в постоянном насыщении из-за большого усредненного значения совокупности входных данных и малой дисперсии, или будут заторможены из-за малого среднего значения выборки [5].

Также необходимо масштабирование эталонных выходных сигналов, потому что обычно диапазон выходных значений нейронов лежит в ограниченном интервале и нейронная сеть в принципе не сможет выдать ответ в реальном масштабе данных.

Поскольку нейронные сети анализируют не абсолютные значения входных сигналов, а их изменения, то для повышения различимости сигналов, кроме масштабирования при предварительной обработке данных, следует выполнять сдвиг входных данных. Сдвиг обеспечивается при идентификации границ диапазона изменения признака и рассмотрении их в качестве границ входного диапазона.

Операции сдвига и масштабирования вместе представляют собой нормализацию входных данных. Числовые сигналы необходимо масштабировать и сдвигать так, чтобы весь диапазон исходных значений попадал в нормализованный диапазон входных сигналов. Обычно в зависимости от вида активационных функций нейронов исходные сигналы нормализуются в единичный гиперкуб или в гиперкуб с координатами углов, отличными от единицы по координатной оси, соответствующей масштабируемому признаку. Однако, поскольку в системе нормирования отсутствуют жесткие ограничения на диапазон значений входного признака, может быть выполнена нормализация, дающая нулевое среднее и единичную дисперсию нормализованной величине, по следующей формуле:

$$x'_i = \frac{\left(nx_i - \sum_{i=1}^n x_i \right) \sqrt{n(n-1)}}{n \sqrt{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2}}, \quad (1)$$

где n – количество примеров в исходных данных, x_i – входной сигнал.

Получение нулевых средних для входных сигналов сети ускоряет градиентное обучение, поскольку снижает отношение максимального и минимального ненулевого собственных чисел матрицы вторых производных целевой функции по параметрам сети [6], [7].

Для обучения нейронных модулей также необходимо выполнить нормализацию эталонных ответов (норм времени). Поскольку диапазон выходных сигналов нейромодулей находится в интервале $(-N_n; N_n)$, где N_n – число нейронов скрытого слоя, нормализацию эталонных ответов необходимо осуществлять с помощью минимаксного преобразования, которое для нейросетевой системы нормирования будет иметь следующий вид:

$$T'' = \frac{2N_n(T - T_{\min})}{T_{\max} - T_{\min}} - N_n, \quad (2)$$

где T – норма времени на технологическую операцию;

T_{\min} и T_{\max} – соответственно минимальное и максимальное значение нормы времени на технологическую операцию в исходном множестве данных.

Поскольку исходные данные содержат как входные признаки, так и эталонные ответы, то для настройки сети можно использовать принцип контролируемого обучения (обучения с учителем). Для реализации этой стратегии необходимо исходные данные разделить на обучающую выборку и тестовую.

Так как интерполяция в общем случае осуществляется точнее, чем экстраполяция, то для повышения точности прогнозов сетей обучающую выборку следует формировать из реперных (опорных) примеров, характеризующих особенности функции, которую должна будет реализовывать обученная нейронная сеть. К таким примерам относятся все примеры, у которых значение хотя бы одного компонента лежит на границе диапазона изменения этого компонента.

Помимо нормализации и отбора примеров для обучающего множества, в предварительную обработку данных входят рандомизация данных и анализ обучающего множества на противоречивость. Рандомизация предполагает расположение примеров в случайном порядке внутри обучающего множества для ликвидации шума, появляющегося при упорядочивании примеров, когда их порядок не соответствует закономерностям, характерным для описываемого объекта. Непротиворечивость обучающей выборки означает, что для двух одинаковых входных векторов должен существовать только один выходной вектор. Противоречивые примеры могут появляться вследствие погрешностей в исходных данных. Поэтому такие примеры следует исключать из обработки.

Таким образом, в режиме обучения работа преобразовщика осуществляется по алгоритму, блок-схема которого приведена на рис. 2.

В приведенной блок-схеме N_p – число примеров в исходном множестве данных (число чертежей деталей). В режиме обучения, как и в режиме эксплуатации, нормализация входных сигналов осуществляется по формуле (1).

Интерпретатор ответа преобразовывает выходные сигналы нейросети в нормы времени по формуле

$$T^n = \frac{(T^c + N_n)(T_{\max} - T_{\min})}{2N_n} + T_{\min}, \quad (3)$$

где T^c – выходной сигнал нейросети.

При проектировании структуры технологического процесса нужно знать перечень технологических операций, необходимых для обработки детали. Как было отмечено, при отсутствии какой-либо технологической операции на выходе соответствующего нейронного модуля должен быть сформирован нулевой сигнал. Однако из-за возникновения погрешностей работы нейронных сетей, выходной сигнал может незначительно отличаться от нуля, что может быть интерпретировано как наличие технологической операции. Поэтому интерпретатор также выполняет фильтрацию шума по формуле

$$T = \begin{cases} T, & T \geq T'_{\min} \delta_{\max} \\ 0, & T < T'_{\min} \delta_{\max} \end{cases}, \quad (4)$$

где T'_{\min} – минимальное отличное от нуля значение нормы времени для данной технологической операции в обучающей выборке;

δ_{\max} – заданная максимально допустимая относительная погрешность расчета нормы времени.

Таким образом, и в режиме эксплуатации, и в режиме обучения работа интерпретатора ответа осуществляется по формулам (3) и (4).



Рисунок 2 – Блок-схема алгоритма работы преобработчика в режиме обучения

Выводы

1. В статье предлагается использование нейросетевой системы технического нормирования времени механической обработки при технико-коммерческой проработке заказов в структуре отдела главного технолога.
2. Выведены формулы и построен алгоритм работы преобразовщика данных для сопряжения входного информационного потока и системы нормирования времени.
3. Выведены формулы интерпретатора ответа, позволяющие конвертировать выходные сигналы системы в формат норм времени, а также осуществлять фильтрацию шума.

Литература

1. Проектирование технологических процессов механической обработки в машиностроении: Учеб. пособие для машиностроительных специальностей вузов / Под ред. В.В. Бабука. – Минск: Вышейш. школа, 1987. – 255 с.
2. Гитис В.Б., Ковалевский С.В. Применение нейросетевых технологий для нормирования времени механообработки в машиностроении // VIII Всероссийская конф. «Нейрокомпьютеры и их применение». Сб. докл. – М.: ИПРЖР. – 2002. – С. 569-572.
3. Гитис В.Б. Техническое нормирование на основе нейросетевых технологий // Надёжность инструмента и оптимизация технологических систем. – Краматорск: ДГМА. – 2002. – № 12. – С. 113-118.
4. Гитис В.Б. Методика построения нейросетевых моделей типовых деталей // Искусственный интеллект. – 2004. – № 4. – С. 539-544.
5. Заенцев И.В. Нейронные сети: основные модели. – Воронеж: ВГУ, 1999. – 157 с.
6. LeCun Y., Kanter L., Solla S. A. Second order properties of error surfaces: learning time and generalisation // Advances in Neural Information Processing Systems. Morgan-Kaufmann. – 1991. – № 3. – P. 918-924.
7. LeCun Y., Bottou L., Orr G. B., Müller K. R. Efficient BackProp // Neural Networks: Tricks of the trade. Springer Lecture Notes in Comp. – 1998. – P. 5-50.

В.Б. Гитис

Сполучення інформаційних потоків нейросітьової системи нормування часу механообробки деталей

У статті розглянуті інформаційні потоки, які циркулюють у системі нормування часу механічної обробки деталей на основі нейронних сітей. Приведено формули й алгоритм попередньої обробки вихідних даних для подачі їх на входи нейронних сітей, а також формули інтерпретатора відповіді для переводу виходів нейронної сіті у формат норм часу.

V.B. Gitis

Time Regulation of Neuronet System Informational Streams Coupling at Detail Mechanical Processing

In this paper information flows circulating in the system of normalization detail machining time in a base of neural networks are considered. Some formulas and algorithm of the initial data preliminary processing for its representation to inputs of neural networks together with the formula of answer interpreter for neural network Output feed into format of norm time.

Статья поступила в редакцию 08.07.2005.