

УДК 621.002

СИСТЕМА ДИАГНОСТИКИ КАЧЕСТВА МЕХАНООБРАБОТКИ НА ОСНОВЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

В.В. Медведев, В.С. Медведев

ДонНТУ, г. Донецк; ДГМА, г. Краматорск, Украина

У статті викладені питання діагностики якості поверхневого шару в масштабі реального часу. Основа методики полягає у зв'язку комплексних сигналів від діагностичних датчиків з комплексними характеристиками якості поверхні деталей складної конфігурації.

Постановка задачі. На передових підприємствах машинобудування щороку зростає частка обладнання з числовим програмним управлінням – станків з ЧПУ і оброблюваних центрів. Їх впровадження спрямоване на подальше підвищення якості випущеної продукції і передбачає перехід до частково або повністю безлюдної технології. Однак, цьому перешкоджає, в певній мірі, відсутність системи забезпечення якості випущених деталей безпосередньо в час обробки на металорежущому обладнанні з ЧПУ.

Основна складність побудови таких систем полягає в пред'являемому до них високим вимогам до гнучкості, точності і надійності. Дані властивості найкращим чином можна реалізувати інтелектуальними системами, здатними не тільки забезпечити високу гнучкість і можливість функціонувати в умовах сильних шумів реального виробництва, але й навчатися безпосередньо в час виконання технологічної операції.

Состояние вопроса. При контролі стану інструмента класичними методами, контролюють параметри оброблюваної деталі, вид стружки і показники процесу обробки [1-3]. Контроль виконується в процесі різання, тривалість періоду обробки деталі при цьому не зростає, так як відмова інструмента може бути виявлено за час, визначений інерційністю вимірювача і обробкою інформації. До критеріїв зносу відносять різке зростання розмірного зносу, збільшення сили і вібрації вище допустимих меж і т.д. Вказаних системах існує один загальний недолік – незрозумілі можливості алгоритмів обробки отриманої інформації. Для розв'язання даної проблеми вказані системи потрібно реалізувати на нейронній мережі. Для цього необхідно аналогові фільтри замінити цифровими спектральними перетворювачами, а інтенсиметри – нейронними аналізаторами.

Основная часть. С помощью математического аппарата нейронных сетей стало возможно получать адекватность частот от технологических параметров в каждом эксперименте. Если графики адекватности частот при противоположно крайних значениях технологических параметров идентичны, то нет необходимости проведения экспериментов с промежуточными значениями. Во многих случаях ниже описанная методика позволяет за один раз вычислить адекватность частот для всего диапазона изменения технологического параметра.

Основа методики заключается в свойстве нейронной сети находить настройку своей структуры по учебным данным, а затем адекватно реагировать на дальнейшие входные сигналы. Так, если на вход сети подать сигнал датчиков станка, а на выходе обучающие данные – технологические режимы станка, найденные в процессе эксперимента, то нейронная сеть начнёт обучение. Система изменяет настройки нейронов и веса между ними таким образом, что при подачи входных данных сигналы выходов будут равны соответствующим обучающим данным. Полное обучение произойдёт при условиях существования зависимости между входными и выходными данными, а так же приемлемой структуре самой сети, которую нужно подобрать экспериментально. Изучая полученные после обучения настройки структуры сети можно получить эмпирические зависимости выходных сигналов от входных а главное, насколько сильно каждый входной канал повлиял в процессе эксперимента на выходной канал.

Обучение происходит следующим образом. На входные каналы подают диагностические сигналы от датчиков, а на выходные каналы – соответствующие технологические параметры. Для подготовки сигналов датчиков предусмотрен отдельный блок, показанный на рисунке 1, а. Во время обучения производится настройка структуры сети, вида нейронов и веса связей между ними. В режиме обучения выходы нейросети работают как входы обучающих данных. Эти данные измеряют сторонними методами на полученной детали.

После обучения выходные каналы работают по своему прямому назначению – выполняют диагностику технологических параметров, как показано на рисунке 1, б. То есть канал измерения требуемых параметров отключается. В таком виде они могут устанавливаться непосредственно на оборудование в цехах.

Иногда в работу нейросети добавляют ещё один режим – режим тестирования. Схема тестирования сходна со схемой на рисунке 1, а. Но в отличие от обучения, в этом режиме не производится никаких изменений в сети, а только вычисляется ошибка между расчётными и реальными параметрами. Данные исследования, как и обучение нейросети, производятся в лабораторных условиях.

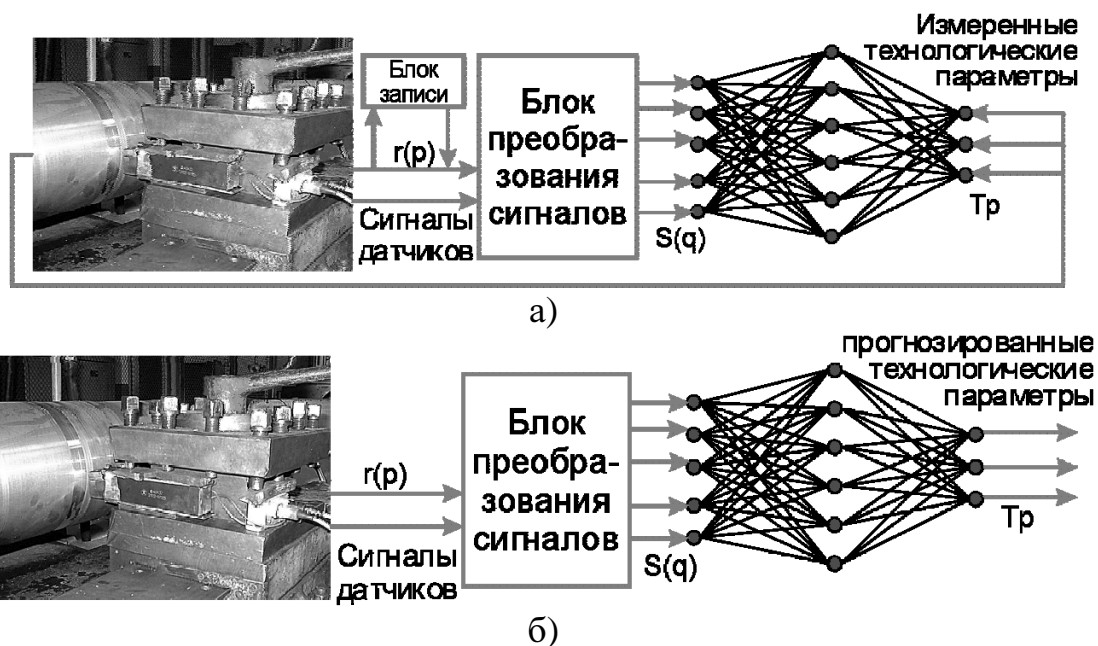


Рис. 1. Установка для исследования стабилизации качества поверхностного слоя при механообработке:

- а – схема в режиме обучения;
- б – схема в режиме работы.

В условиях производства, если требуется дообучение нейросети конкретным производственным ситуациям, канал измеренных технологических параметров должен быть реализован на самом оборудовании. Если дообучение не требуется, то можно поставлять в производство не саму нейросеть, как показано на рисунке 1, б, а только её вербализацию, реализованную математическими формулами или аппаратно. Это позволит синтезировать аналоговые и цифровые диагностические системы, которые будут контролировать сложнейшие комплексные параметры и иметь высокую защищенность от помех.

Имея столь мощный инструмент можно переориентироваться в выборе датчиков, находящихся на станке. Ранее стремились в основном измерить силы резания, как наиболее изученные и адекватные режимам резания сигналы. Данная система предполагается устанавливаться на уже действующих станках, поэтому требуется минимальное вмешательство в конструкцию. Наиболее информативным сигналом не требующим для его регистрации значительных вмешательств являются электромагнитные излучения зоны резания, звуковые излучения, акустическая эмиссия, в некоторых случаях ЭДС резания.

Математическая реализация системы. Предположим, что в системе находится D датчиков. Тогда сигналы от них являются временными рядами $s_i(q)$, где q – интервалы времени работы станка или

обрабатывающего центра, а $l=1..D$ – номера датчиков. В некоторых случаях над сигналами могут проводить нормализацию с заранее рассчитанными и **неизменными** в процессе всей работы коэффициентами:

$$sn_l(q) = an_l \cdot s_l(q) + bn_l, \quad (1)$$

$$an_l = \frac{2}{\max(s_l) - \min(s_l)}, \quad bn_l = 1 - an_l \cdot \max(s_l).$$

Нормализованные временные ряды подвергаются быстрому преобразованию Фурье. Оно строится на алгоритме, в центре которого имеется функция [166]:

$$S_l(q) = \sum_{p=0}^{M_y-1} sn_l(p) \cdot W_N^{pq},$$

где $W_N = e^{\frac{-j2\pi}{N}}$ – материнская функция быстрого преобразования.

Для упрощения расчётов входной вектор представляется комплексным числом [5]:

$$sn_l(p) = x(p) + jy(p),$$

где x, y – матрица координат входного сигнала.

Отдельные компоненты преобразования Фурье образуют вектор F . Этот вектор также определяет структуру образа технологической системы, но в другом пространстве параметров. Компоненты этого описания позволяют легко преобразовывать данные, независимо от их положения, масштаба, угла поворота, а также выбранной начальной точки и общего их количества.

Полученные матрицы спектра диагностического сигнала обычно имеют большое количество столбцов Mx . Для уменьшения их размерности выделяют, например, только пиковые частоты разницы интерполяцией L -й степени и спектральной кривой:

$$M_l(k) = \max_k \left[S_l(q_0) + \sum_{i=0}^L \left[\frac{\Delta^i S_l(q_0)}{i! \cdot \Delta q_0^i} \cdot \prod_{j=0}^{i-1} (q - q_j) \right] - S_l(q) \right],$$

где L – степень многочлена;

$a_{i,l}, q_l$ – коэффициенты интерполяции l -го датчика;

$k=1..Mxt$;

Mxt – требуемое количество столбцов после алгоритма уменьшения размерности.

Для реализации алгоритма, предложенного автором, сначала из спектров входных сигналов выбираются все возможные максимумы:

$$Z_l(k) = \max_k [S_l(q)]$$

А затем отбрасываются те решения, которые не удовлетворяют условию

$$Z_l(k - r_l \dots k + r_l) < Z_l(k) + \left[r_l - \sqrt{r_l^2 - (k - r_l \dots k + r_l)^2} \right],$$

где r_l – радиус касательной окружности;

$k - r_l \dots k + r_l$ – интервал, в пределах которого окружность может коснуться пиков в положении на k -м пике.

Радиус касательной окружности обычно выбирается в ходе экспериментов. Его максимальный размер ограничивается минимальным количеством пиков Mxt после уменьшения размерности. А минимальный – минимальным расстоянием между вершинами пиков:

$$\frac{\sum_{ki=2}^k |Z_l(ki - 1) - Z_l(ki)|}{k - 1} < r_l < [if \{max(k) \geq Mxt\}]$$

Если на обрабатываемом центре установлено более одного датчика ($D > 1$), то перед подачей полученных данных матрицы объединяют по горизонтали. Важным условием возможности такого объединения является одинаковость их частотного разрешения r_j :

$$X(k) = [Z_1(k) \dots Z_D(k)].$$

Обработка с помощью искусственной нейронной сети является заключительным этапом. Если принять за основу структуру сети с упорядоченными слоями, то преобразование информации в ней можно записать в виде:

$$Ot_1 = \frac{X(k) + av}{dv}; \quad Ot_j = f_j \left(\sum_{i=1}^{U_{j-1}} Ot_{j-1} \cdot d_i + b_{i,j} \right);$$

$$Q = \frac{Ot_K + au}{bu}, \quad (2)$$

где $j = 1 \dots K$ – номер слоя сети;

Ot_j – совокупность входных сигналов в j -м слое;

$f_j(*)$ – функция отклика нейрона в j -м слое (активационная функция);

U_j – количество нейронов в j -м слое;

av, dv, d, au, bu – коэффициенты сети, определяемые в ходе обучения нейросети;

$b_{i,j}$ – сдвиг в i -м нейроне j -го слоя;

Q – совокупность показателей качества получаемой поверхности, реальных режимов резания и прогноза состояния режущего инструмента.

Реализуя формулы в интервале от (1) до (2) непосредственно на технологическом оборудовании, получаем зависимость диагностических сигналов от показателей качества получаемой поверхности, реальных режимов резания и прогноза состояния режущего инструмента. Как видно, данный математический алгоритм легко может быть реализован на базе современных стоек ЧПУ. А если применять алгоритмы уменьшения размерности спектральной матрицы только отбросом неинформативных частотных промежутков, то возможна его реализация на базе аналоговой электронной техники.

Результатом обработки диагностических данных по формулам (1) – (2) является временная матрица Q , в которой по строкам отложено время, а по столбцам – показатели качества. Для принятия решения об изменении режима работы оборудования матрицу Q построчно сравнивают со строкой требований качества по чертежу Q_{re} .

Выводы. Таким образом качество поверхностного слоя, так и совокупность диагностических сигналов являются комплексными показателями. Модели, работающие с двумя-тремя переменными этих комплексных показателей, не могут обеспечить достаточную точность. Поэтому для работы с ними требуются комплексные модели. Такие модели могут быть выполнены на основе математического аппарата «искусственные нейронные сети».

Система стабилизации качества на основе нейросетей имеет ряд преимуществ перед уже использующимися алгоритмами. Кроме преимуществ системности, появляются возможность работы практически с любыми диагностическими каналами, высокая гибкость и режим дообучения непосредственно на технологическом оборудовании.

Литература

1. Захаркин Н.В. Системный подход к выбору технологий повышения качества рабочих поверхностей изделий/ Н.В.Захаркин, В.Б.Тарельник, Я.И.Чибиряк // Механика и машиностроение. – 2003. – №1 – С. 216-220.
2. Кибальченко А.В. Контроль состояния режущего инструмента. М.: ВНИИТЭМР, 1986, 44с., 13ил.
3. An investigation of tool wear and the vibration spectrum in milling. / Wear, 91, №2, 1983. – p. 219-234
4. Ковалевский С.В., Медведев В.В. О построении систем распознавания состояния обработанной поверхности на основе нейронных сетей. //Сборник докладов международной конференции “Нейрокомпьютеры и их применение”, Москва, Россия, 2000 г.
5. Осовский С. Теория искусственных нейронных сетей. – М.: Финансы и статистика, 2001. – 340 с.

30.04.08