

Корректировка скорости процесса резания на основе анализа акустической эмиссии и нейросетевого обобщения экспериментальных данных

Rate adjustment of cutting through the analysis of acoustic emission and neuronet generalization of experimental data

Статья посвящена повышению эффективности металлообработки с помощью нейросетевых адаптивных систем, обеспечивающих автоматизированную коррекцию режимов резания при изменении технологических параметров.

This work is dedicated to the increase of metal-working efficiency with the help of neuron network adaptive systems. The neuron network adaptive systems provide the automated correction of cutting modes during change of master schedules

Ключевые слова: акустическая эмиссия, волновой критерий, нейроконтроллер, нейроэмулятор, RBF-сеть, алгоритм обратного распространения.

Keywords: acoustic emission, the wave criterion neurokontroller, neuroemulyator, RBF-network back-propagation algorithm.

Как показали исследования [1], амплитуда A (максимальное значение сигнала акустической эмиссии АЭ в течение выбранного интервала времени) и интенсивность \dot{N} (отношение числа импульсов АЭ к интервалу времени наблюдения) адекватно реагируют на изменения технологических условий протекания процесса резания. В [1] предложена экспресс-методика определения оптимальных скоростей резания. Исследуемая заготовка обрабатывается на нескольких скоростях V , регистрируются значения амплитуды A и интенсивности \dot{N} , рассчитываются значения волнового критерия

$$W = \frac{A \cdot \dot{N}}{V} \quad (1)$$

и строится график $W = f(V)$. Характерные точки на этой кривой (перегибы) будут соответствовать оптимальным скоростям обработки $V_{\text{опт}}$, то есть предельным скоростям, не вызывающим резкого возрастания интенсивности износа инструмента. Оптимальная скорость обеспечивает максимальный путь резания до критерия затупления [1].

Выполняя обработку инструментом, имеющим различную степень износа, получим семейство кривых (рис. 1). Аналогичное семейство кривых получим при обработке с различной глубиной резания или при обработке материалов различной твердости.

Возникает вопрос, каким образом, используя данные экспериментов и имея некоторый ограниченный набор кривых $W = f(V)$ для различных материалов или износа инструмента, корректировать процесс ре-

зания по скорости в процессе обработки в зависимости от значений волнового критерия? Предлагается следующее решение с использованием нейроконтроллера.

Пусть имеется некоторое семейство кривых $W = f(V)$, которые отличаются друг от друга, например, материалом обрабатываемой заготовки (рис. 1). Зададимся некоторой начальной скоростью $V_{\text{нач}}$, значение которой является заведомо низким и не приведет к интенсивному износу инструмента при любом обрабатываемом материале. С такой скоростью будем начинать обработку новой заготовки. Точки пересечения прямой линии, проведенной из $V_{\text{нач}}$ перпендикулярно оси абсцисс, с кривыми $W_1(V), \dots, W_n(V)$ дадут нам соответствующие зна-




Рис. 1. Семейство кривых $W = f(V)$




Рис. 2. Нахождение отношения $(\Delta W / \Delta V)_i$

чения $W_1(V_{нач.}), \dots, W_n(V_{нач.})$. При этом каждой кривой $W_1(V), \dots, W_n(V)$ соответствуют оптимальные скорости резания $V_{опт.1}, \dots, V_{опт.n}$, а также значения $W_1(V_{опт.1}), \dots, W_n(V_{опт.n})$. Таким образом, для известных кривых $W_1(V), \dots, W_n(V)$ и $V_{нач.}$ можем составить следующую таблицу (табл.1), где $(\frac{\Delta W}{\Delta V})_i = \frac{W(V_{опт.i}) - W(V_{нач.i})}{V_{опт.i} - V_{нач.i}}$ (рис. 2):

1. Обучающая выборка для нейроконтроллера

$\frac{\Delta W}{\Delta V}$	$(\frac{\Delta W}{\Delta V})_1$	$(\frac{\Delta W}{\Delta V})_2$	$(\frac{\Delta W}{\Delta V})_3$...	$(\frac{\Delta W}{\Delta V})_n$
$V_{опт.}$	$V_{опт.1}$	$V_{опт.2}$	$V_{опт.3}$...	$V_{опт.n}$

Значения, приведенные в табл. 1, фактически являются обучающей выборкой для нейронной сети, используемой в качестве нейроконтроллера (НК).

Следует отметить, что, чем больше проделано предварительных экспериментов, т.е. чем больше

кривых $W_i(V)$ найдено, тем больше объем обучающей выборки и соответственно, тем качественнее будет произведено обучение нейронной сети. При этом, имея даже очень большой набор экспериментальных кривых, он остается ограниченным, т.к. нельзя предусмотреть все возможные комбинации различных возмущающих факторов, воздействующих на объект управления. Поэтому необходимо обобщение результатов эксперимента, чем и объясняется использование нейроконтроллера.

В качестве НК предлагается RBF-сеть, преимуществом которой является высокая скорость обучения и относительная компактность [2]. С помощью НК контролируется величина, представляющая собой отношение изменения энергетического критерия к изменению скорости резания $\frac{\Delta W}{\Delta V}$. На выходе НК будем

получать величину скорости резания V , обеспечивающую наилучшее приближение текущего значения $\frac{\Delta W}{\Delta V}$ к значению уставки. Величина уставки r определяется исходя из экспериментальных данных по графикам (рис. 1). Берется кривая, у которой при $V > V_{опт.}$ начинается наименее крутой подъем кривой по сравнению с остальными кривыми в том же диапазоне скоростей, т.е.:

$$r = \min\left\{\left(\frac{\Delta W}{\Delta V}\right)_i\right\}, V_i > V_{опт.i}, i = \overline{1, n}.$$

Обучение нейроконтроллера производится с помощью конкурентного обучения и алгоритма обратного распространения ошибки. Для определения функции объекта управления используется вторая сеть – нейромультипликатор (НЭ), представляющий собой сеть прямого распространения. Таким образом, структура системы управления принимает вид, показанный на рис. 3.

Обучение НЭ производится с помощью алгоритма обратного распространения ошибки. Под обучением НЭ подразумевается обучение копии НЭ. Обучение копии непрерывно повторяется; повторное

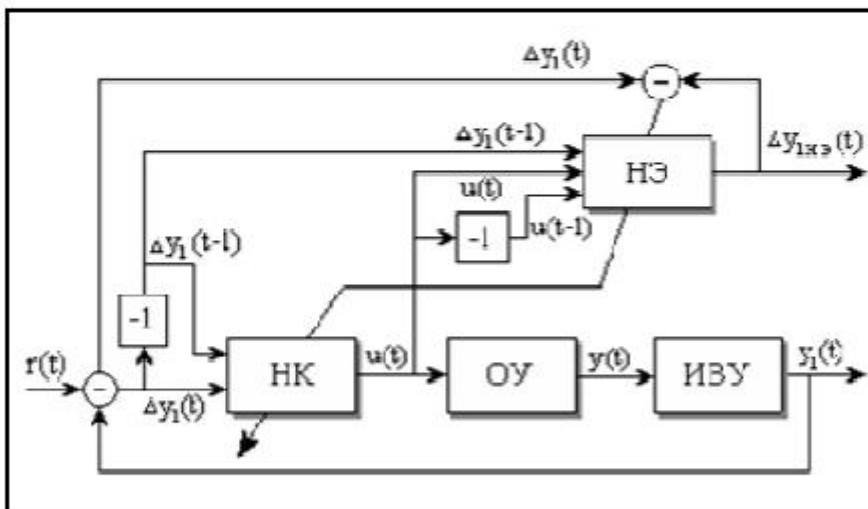


Рис. 3. Структура системы управления: ОУ – объект управления – процесс резания; ИВУ – измерительно-вычислительное устройство, определяющее величину $y_1(t) = \Delta W / \Delta V$; $y(t)$ – текущие значения $A, \dot{N}, V_{рез}$; $r(t)$ – уставка; $\Delta y_1(t) = y_1(t) - r(t)$; $u(t)$ – сигнал управления с НК, а именно, оптимальная скорость резания; $u(t-1), \Delta y_1(t-1)$ – соответствующие задержанные на один такт сигналы, которые вводятся в систему для улучшения качества управления




Рис. 4. Нейроконтроллер и нейроэмулятор как одна многослойная сеть

обучение производится каждый раз заново, т.е. все весовые коэффициенты снова задаются случайным образом.

Если качество управления ухудшилось, т.е. ошибка управления стала выше заданной, то параметры нейроэмулятора (его весовые коэффициенты, найденные при последнем обучении), фиксируются и используются для переобучения нейроконтроллера.

При обучении НК обе сети (НК и НЭ) рассматриваются как одна многослойная сеть (рис. 4). На рис. 4 видны также и внутренние структуры сетей.

Обучение нейросетевых компонент проводилось в пакете NeuroSolutions 4.1. Экспериментальные исследования по обучению сетей показали, что можно получить время обучения нейроконтроллера в пределах 1 сек.

Программный продукт NeuroSolutions – среда для создания искусственных нейронных сетей в виде динамических библиотек, предоставляющая графический интерфейс для моделирования различных искусственных нейронных сетей, которые могут быть сохранены в динамическую библиотеку (файл *.dll). Это позволяет реализовать систему адаптивного управления в виде COM – компонента с последующим встраиванием его в систему ЧПУ.

Библиографический список

1. Подураев В.Н. Базаров А.А., Горелов В.А. Технологическая диагностика резания методом акустической эмиссии. – М.: Машиностроение, 1988. – 56 с.
2. Головкин В.А. Нейронные сети: обучение, организация и применение. Кн. 4/ Нейрокомпьютеры и их применение – М.: ИПРЖР, 2001. – 256 с.: ил.
3. Григорьев С.Н. Развитие отечественного станкостроения - фундамент модернизации машиностроительного про-

изводства. // Автоматизация в промышленности. 2012. №5. С.4-7.

4. Григорьев С.Н., Андреев А.Г., Мартинов Г.М. Перспективы развития кроссплатформенных компьютерных систем числового программного управления высокотехнологичного оборудования // Автоматизация в промышленности. 2011. №5. С. 3-8.

5. Мартинов Г.М. Тенденции развития современных систем управления технологическим оборудованием // Ремонт, восстановление, модернизация. 2010. № 1. С. 2-3.

6. Мартинов Г. М. Академическая версия системы ЧПУ WinPCNC // Инструмент, технология, оборудование. 2007. №8. С. 62-64.

7. Мартинов Г. М., Мартинова Л. И. - Современные тенденции в области числового программного управления станочными комплексами // СТИН. 2010. №7. С. 7-10.

8. Мартинова Л.И., Григорьев А.С., Соколов С.В. Диагностика и прогноз износа режущего инструмента в процессе обработки на станках с ЧПУ // Автоматизация в промышленности. 2010. №5. С. 46-50.

9. Сергеев В.Н., Букейханов Н.Р., Никишечкин А.П., Чмырь И.М., Воробьев П.Б. Ресурсосберегающие интегрированные технические системы на основе процесса газового азотирования // Экология и промышленность России. 2011. № 12. С. 8-9.

10. Григорьев С.Н. Научно-технические проблемы построения современных технологических систем с числовым программным управлением // Мехатроника, автоматизация, управление. 2011. № 4. С. 19-26.

11. Мартинов Г.М., Мартинова Л.И., Козак Н.В., Нехметдинов Р.А., Пушков Р.Л. Принципы построения распределенной системы ЧПУ технологическими машинами с использованием открытой модульной архитектуры // Справочник. Инженерный журнал. 2011. №12. С. 45-51.

12. Григорьев С.Н., Гурин В.Д., Козочкин М.П., Кузовкин В.А., Мартинов Г.М., Сабиров Ф.С., Синопальников В.А., Филатов В.В. Диагностика автоматизированного производства. - М.: Машиностроение, 2011. – 600 с.

Никишечкин Анатолий Петрович – канд. техн. наук, доцент кафедры компьютерных систем управления МГТУ «СТАНКИН».

Тел.: (499) 972-94-40. E-mail: anatolij-petrovich@yandex.ru

Nikishechkin Anatolij Petrovich – Candidate of Science in engineering, associate professor of sub-department "Computer Architecture Control Systems" of MSTU "STANKIN".

Тел.: (499) 972-94-40. E-mail: anatolij-petrovich@yandex.ru