

УДК 004.94:004.67

Ю.Н. Внуков, В.И. Дубровин, Ю.С. Афонин, Т.В. Манило

Запорожский национальный технический университет, Украина
vdubrovin@gmail.com, yuriy.zp@gmail.com

Моделирование износа инструмента по результатам вейвлет-преобразования звукового сигнала

Исследуется проблема моделирования износа инструмента по звуковому сигналу. Как основной инструмент обработки звукового сигнала предлагается использовать пакетное вейвлет-преобразование. Для задачи моделирования износа были использованы многослойная нейронная сеть и нейро-нечеткая сеть. Исследуется оптимальная нейросетевая структура.

Введение

Одной из причин снижения точности при обработке на металлорежущих станках является изменение геометрических размеров обрабатываемой детали вследствие износа режущего инструмента. Необходимы контроль состояния и своевременная замена инструмента. Соответственно актуальной является проблема создания системы оперативной диагностики состояния режущего инструмента с устойчивым методом обработки сигнала для получения полезной информации о процессе станочной обработки. Это особенно важно при выполнении операций обработки, требующих высокой точности.

Звуковая информация о процессе обработки на станке может быть использована для контроля состояния режущего инструмента. Звуковой сигнал может быть использован в целях анализа различных операций механообработки. Использование технологий контроля процесса станочной обработки по звуковому сигналу дает большие возможности в обеспечении высокого качества изделия и минимизации его стоимости. Звуковой сигнал может быть использован для наблюдения за характеристиками процесса, обнаружения дефектов и определения конечного качества изделия.

В работе в качестве инструмента обработки звукового сигнала выбран метод пакетного вейвлет-преобразования, а для моделирования износа по результатам вейвлет-преобразования – искусственная нейронная сеть и нейро-нечеткая сеть, которые успешно применяются в задачах диагностики и контроля [1], [2].

Обработка звукового сигнала с использованием вейвлет-преобразования

Для нахождения характеристик звукового сигнала, несущих полезную информацию об исследуемом процессе, необходимо выполнить обработку звукового сигнала.

По своей природе звуковой сигнал является нестационарным. В качестве математического инструмента обработки полученного звукового сигнала целесообразно использовать методы вейвлет-преобразования (ВП), так как данный математический аппарат хорошо приспособлен для изучения структуры нестационарных сигналов [3-9].

Вейвлет-преобразование может быть использовано для разложения сигнала на различные составляющие в различных частотных диапазонах и временной области. В результате скалярного произведения сигнала и функции семейства вейвлетов получаем коэффициенты вейвлет-преобразования по выражениям (1) и (2) [4], [5]:

$$c_{j,k} = \frac{1}{\sqrt{2^j}} \sum_{t=0}^L s(t) \phi\left(\frac{t-2^j k}{2^j}\right), \quad (1)$$

$$d_{j,k} = \frac{1}{\sqrt{2^j}} \sum_{t=0}^L s(t) \psi\left(\frac{t-2^j k}{2^j}\right), \quad (2)$$

где $c_{j,k}$, $d_{j,k}$ – коэффициенты аппроксимации и детализации соответственно, j – параметр масштаба или уровень разложения, k – параметр сдвига, $s(t)$ – исходный сигнал, t – номер отсчета сигнала, L – длина сигнала, ϕ – масштабирующая функция, ψ – вейвлет-функция.

Коэффициенты $c_{j,k}$ представляют собой грубое приближение исходного сигнала, а коэффициенты $d_{j,k}$ выражают его локальные особенности, поэтому их соответственно называют коэффициентами аппроксимации и детализации.

Функции ϕ и ψ служат высокочастотными и низкочастотными фильтрами соответственно [6].

Уравнения (3) и (4) являются быстрыми алгоритмами вычислений коэффициентов и называются быстрым ВП (БВП) [7], [8]:

$$c_{j+1,k} = \sum_n h_n c_{j,2k+n}, \quad (3)$$

$$d_{j+1,k} = \sum_n g_n c_{j,2k+n}, \quad (4)$$

где h_n , g_n – соответственно вейвлет-последовательность и масштабирующая последовательность для заданного уровня, определяются особенностями функций ϕ и ψ , n – количество коэффициентов последовательности h и g .

В качестве коэффициентов $c_{j,k}$ при нулевом значении масштаба принимаются временные отсчеты сигнала (5):

$$c_{0,k} = s(k). \quad (5)$$

Исходный сигнал подается на фильтры низких и высоких частот, после чего с помощью операции децимации (уменьшения числа частотных составляющих вдвое) можно получить коэффициенты аппроксимации на выходе фильтра низких частот и детализирующие коэффициенты на выходе фильтра высоких частот (рис. 1).




Рисунок 1 – Схема вычислений при БВП

Таким образом, данные вычисления позволяют рассчитывать коэффициенты разложения на основании коэффициентов предыдущего уровня.

В отличие от БВП, в результате которого на каждом уровне декомпозируется только низкочастотная составляющая (аппроксимирующие коэффициенты), при пакетном ВП (ПВП) операции декомпозиции подвергается и высокочастотная компонента [5], [6], [9], которая также может нести полезную информацию об исследуемом процессе. В этом случае происходит замена вейвлета $\psi(t)$ на два новых вейвлета (6) и (7):

$$\psi_{2j}(t) = \sqrt{2} \sum h_n \psi_j(2t - n), \quad (6)$$

$$\psi_{2j+1}(t) = \sqrt{2} \sum g_n \psi_j(2t - n). \quad (7)$$

Масштабирующая функция определяет функцию ψ_0 , а материнский вейвлет определяет функцию ψ_1 . Это семейство функций образует базис вейвлет-пакетов.

Для обработки звукового сигнала процесса резания выбрано ПВП, так как с его помощью можно детально проанализировать низкочастотные и высокочастотные составляющие сигнала.

На рис. 2 показаны три исходных звуковых сигнала процесса резания, полученных при различной степени износа инструмента (<0,15 мм; 0,15 – 0,3 мм; >0,3 мм). Результатом разложения данных сигналов при помощи ПВП до четвертого уровня будут 16 окон, представляющих собой вейвлет-коэффициенты. Среднеквадратические значения коэффициентов (СКЗ или RMS – root-mean-square value) в окнах определяют энергетический уровень сигнала в соответствующих частотных диапазонах.




Рисунок 2 – Звуковые сигналы процесса резания. Степень износа режущего инструмента при регистрации сигнала: а) < 0,15 мм; б) 0,15 – 0,3 мм; в) >0,3 мм

Для определения информативных окон необходимо выбрать такие, которые наиболее чувствительны к изменению износа. Декомпозировав несколько (порядка двадцати) звуковых сигналов процесса резания с известной степенью износа инструмента, определили степень корреляции СКЗ вейвлет-коэффициентов в каждом

окне со степенью износа (рис. 3). Окна с наибольшим коэффициентом корреляции следует принять как информативные.

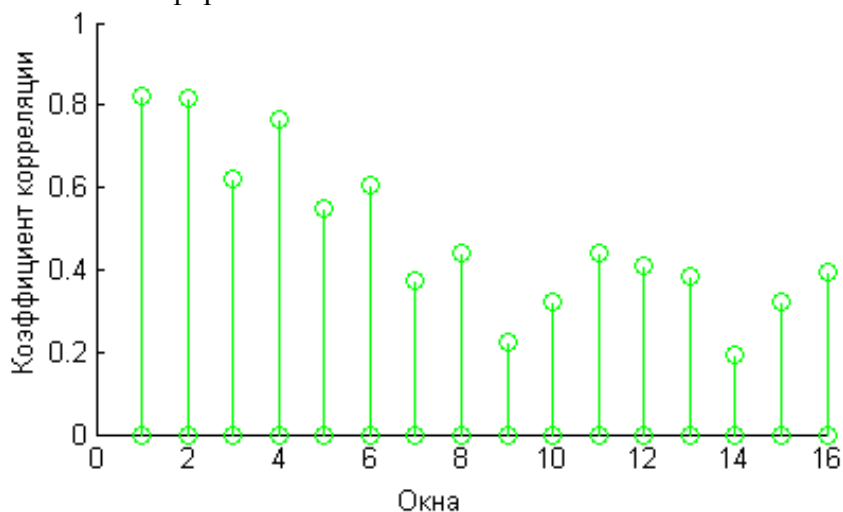


Рисунок 3 – Коэффициенты корреляции СКЗ вейвлет-коэффициентов каждого окна со степенью износа

Моделирование износа

В качестве средств для моделирования износа инструмента по результатам вейвлет-преобразования звукового сигнала были использованы многослойная нейронная сеть (МНС) и нейро-нечеткая сеть (ННС).

Анализ результатов, полученных при обработке сигналов, позволил в качестве значимых частотных диапазонов выбрать диапазоны 1 – 6, 8, 11. СКЗ вейвлет-коэффициентов в соответствующих окнах определяют входной вектор НС. Значения выходного вектора определяет степень износа режущего инструмента.

В табл. 1 приведены результаты обучения и тестирования МНС различной архитектуры, обученных по методу Левенберга-Марквардта [10].

Варьировались следующие параметры архитектуры МНС: количество слоев, количество нейронов в слоях, функции активации (гиперболический тангенс и логарифмическая сигмоидная). Исследования проводились по таким характеристикам, как время обучения сети, количество итераций и ошибка оценивания значений износа обученной НС по тестовой выборке. Максимально допустимое количество циклов обучения было задано равным 1500, а значение максимально допустимой ошибки обучения равнялось 0,0001. Инициализация весов при каждой попытке обучения НС выполнялась случайным образом. Было проведено 20 попыток обучения МНС каждого из исследуемых типов архитектуры.

Как видно из табл. 1, оптимальной из исследуемых архитектур МНС для данной задачи моделирования износа режущего инструмента является трехслойная нейронная сеть с количеством нейронов в слоях соответственно 8, 3 и 1 («8 – 3 – 1»), с логарифмической сигмоидной функцией активации нейронов. Хотя среднее количество итераций и время обучения данной МНС несколько выше, чем у двухслойной НС («8 – 1») с аналогичной функцией активации, но средняя ошибка оценивания, которую можно достичь с помощью МНС «8 – 3 – 1» (2,1 %), гораздо

ниже, чем у МНС «8 – 1» (3,7 %). Кроме того, при обучении МНС «8 – 1» два раза не была достигнута цель обучения (ошибка обучения 0,0001) за допустимое число итераций.

Результаты тестирования МНС «8 – 3 – 1» с логарифмической сигмоидной функцией активации представлены на рис. 4. Ошибка оценивания износа составила 2,1 %.

Таблица – Результаты обучения и тестирования МНС различной архитектуры

Количество нейронов в слоях	1 слой – 8 нейронов 2 слой – 3 нейрона 3 слой – 1 нейрон						1 слой – 8 нейронов 2 слой – 2 нейрона 3 слой – 1 нейрон						1 слой – 8 нейронов 2 слой – 1 нейрон					
	Гиперболический тангенс			Логарифмическая сигмоидная			Гиперболический тангенс			Логарифмическая сигмоидная			Гиперболический тангенс			Логарифмическая сигмоидная		
	№ попытки обучения сети	Кол-во итераций	Время обучения	Ошибки тест.	Кол-во итераций	Время обучения	Ошибки тест.	Кол-во итераций	Время обучения	Ошибки тест.	Кол-во итераций	Время обучения	Ошибки тест.	Кол-во итераций	Время обучения	Ошибки тест.	Кол-во итераций	Время обучения
1	377	3,69	0,022	560	5,20	0,023	478	4,34	0,021	399	3,59	0,021	750	4,95	0,023	383	2,56	0,032
2	334	3,00	0,023	542	5,55	0,021	450	3,94	0,022	410	3,58	0,021	391	2,53	0,032	750	4,70	0,033
3	475	4,19	0,024	696	6,52	0,020	442	3,84	0,021	306	2,72	0,021	633	3,95	0,032	302	2,00	0,037
4	633	5,42	0,022	290	2,73	0,020	414	3,61	0,020	580	4,98	0,023	506	3,27	0,031	592	3,64	0,037
5	419	3,61	0,020	373	3,38	0,020	664	5,72	0,021	419	3,67	0,021	582	3,69	0,032	336	2,22	0,038
6	421	3,67	0,026	243	2,27	0,021	446	3,88	0,021	515	4,47	0,020	404	2,58	0,032	484	3,02	0,038
7	582	5,11	0,022	265	2,44	0,021	501	4,38	0,031	750	6,38	0,022	лок. мин	-		323	2,09	0,037
8	518	4,44	0,021	356	3,23	0,023	654	5,50	0,021	325	2,88	0,020	701	4,44	0,032	305	2,00	0,038
9	673	5,72	0,021	643	5,81	0,022	419	3,66	0,023	478	4,14	0,021	лок. мин	-		485	3,06	0,038
10	668	5,66	0,021	369	3,45	0,021	412	3,56	0,021	220	2,00	0,023	750	4,66	0,021	342	2,24	0,037
11	244	2,19	0,023	388	3,52	0,020	556	4,75	0,022	750	6,44	0,022	лок. мин	-		750	4,67	0,047
12	438	3,77	0,022	556	5,02	0,020	609	5,22	0,023	750	6,45	0,024	506	3,20	0,032	585	3,66	0,037
13	494	4,22	0,024	406	3,81	0,021	423	3,70	0,022	лок. мин	-		589	3,66	0,032	397	2,55	0,037
14	699	5,92	0,020	356	3,22	0,021	494	4,27	0,020	504	4,56	0,022	750	4,67	0,023	259	1,72	0,038
15	412	3,58	0,024	219	2,02	0,022	443	3,86	0,021	303	2,70	0,021	750	4,69	0,023	413	2,66	0,036
16	394	3,63	0,020	267	2,47	0,020	554	4,78	0,021	649	5,58	0,021	543	3,44	0,032	299	1,97	0,037
17	384	3,52	0,024	504	4,89	0,021	439	3,80	0,022	385	3,45	0,020	750	4,77	0,032	236	1,63	0,037
18	357	3,30	0,029	382	3,56	0,021	488	4,22	0,020	353	3,09	0,020	750	4,58	0,031	315	2,09	0,037
19	518	4,81	0,025	491	4,34	0,023	508	4,41	0,020	297	2,58	0,021	750	4,59	0,032	431	2,78	0,039
20	439	3,97	0,023	584	5,19	0,023	352	3,08	0,021	388	3,33	0,021	460	2,97	0,032	440	2,81	0,037
Среднее количество итераций	474			425			487			462			621			421		
Среднее время обучения		4,17			3,93			4,23			4,03			3,92			2,70	
Средняя ошибка тестирования			0,023			0,021			0,022			0,021			0,030			0,037
Количество обучений с попаданием в локальный минимум	0			0			0			1			3			0		
Количество обучений с недостигнутой целью	0			0			0			3			6			2		

Для сравнения с оптимальной архитектурой МНС «8–3–1» для задачи моделирования износа инструмента была исследована нейро-нечеткая сеть для аналогичной задачи. ННС, используя такую же обучающую выборку, достигла цели обучения за 7 итераций. При этом ошибка оценивания износа составила 1,8 %. Результаты тестирования ННС по тестовой выборке представлены на рис. 5. На рис. 4 и рис. 5 точками отмечены реальные значения степени износа, а звездочками – значения, полученные при помощи соответствующей модели.

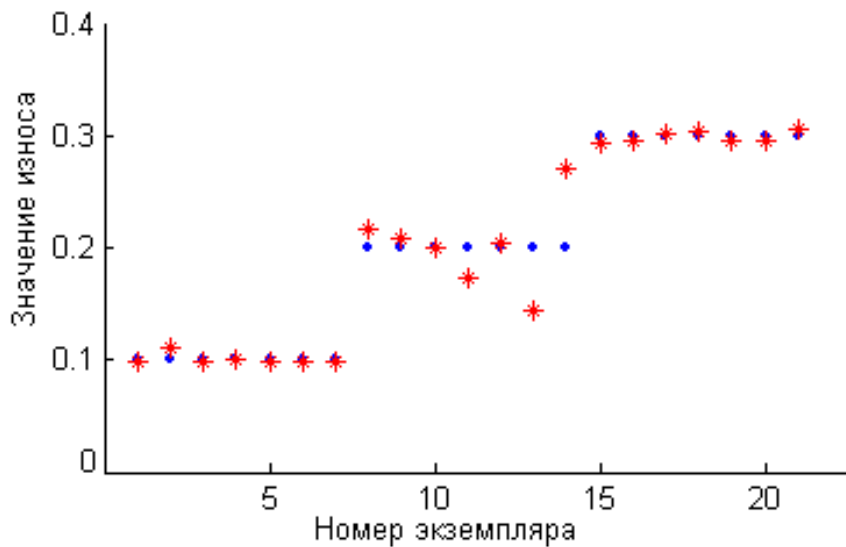


Рисунок 4 – Результаты тестирования МНС

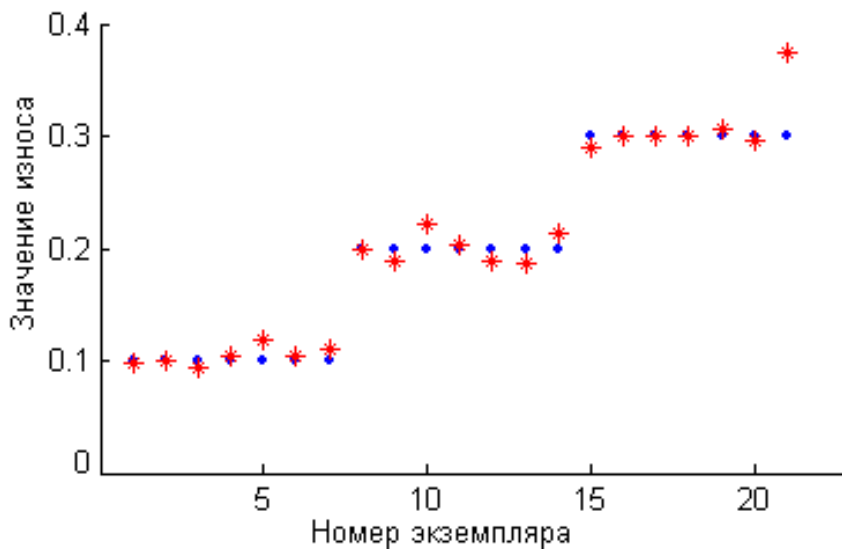


Рисунок 5 – Результаты тестирования ННС

Заключение

Результаты оценивания значений износа с помощью многослойной нейронной сети (ошибка 2,1 %) и нейро-нечеткой сети (ошибка 1,8 %) показали эффективность и целесообразность использования данных методов моделирования в задачах диагностики износа режущего инструмента, причем нейро-нечеткая сеть достигла

цели обучения за значительно меньшее количество итераций, чем многослойная нейронная сеть. Важную роль в получении результатов оценки износа играет этап обработки диагностического (в данном случае – звукового) сигнала. Выбранный в работе метод пакетного вейвлет-преобразования способствует хорошей частотной локализации сигнала. Это позволяет детально проанализировать все частотные составляющие сигнала и затем выбрать характеристики, чувствительные к изменению износа.

Литература

1. Tadashi Kondo, Abhijit S. Pandya, Jacek M. Zurada. Logistic GMDH-type Neural Networks and their Application to the Identification of the X-ray Film Characteristic Curve // Proc. IEEE International Conf. on Systems, Man and Cybernetics. – 1999. – Vol. 1. – P. 437-442.
2. Li Xiaoli, Yao Yingxue, Yuan Zhejun. On-line tool condition monitoring system with wavelet fuzzy neural network // Journal of Intelligent Manufacturing. – 1997. – P. 271-276.
3. Дубровин В.И., Афонин Ю.С., Зинченко Р.Н., Емельяненко С.С., Манило Т.В. Подход к построению модели по звуковому сигналу с использованием вейвлет-преобразования // Радиотехника. Информатика. Управління. – 2007. – № 1. – С. 112-115.
4. Поликар Р. Введение в вейвлет-преобразование. – Изд. 2-е, перераб. и доп. – СПб.: АВТЭКС, 2001. – 59 с.
5. Дьяконов В.П. Вейвлеты. От теории к практике. – М.: Солон-Пресс, 2004. – 400 с.
6. Дремин И.М., Иванов О.В., Нечитайло В.А. Вейвлеты и их использование // Успехи физических наук. – 2000. – Т. 171, № 5. – С. 465-501.
7. Jaideva S. Goswami, Andrew K. Chan. Fundamentals of wavelets. Theory, algorithms and applications. – Wiley Interscience, 1999. – 324 p.
8. Новиков Л.В. Спектральный анализ сигналов в базисе вейвлетов // Научное приборостроение. – 2000. – № 3. – С. 57-64.
9. Чуи К. Введение в вейвлеты. – М.: Мир, 2001. – 412 с.
10. Хайкин С. Нейронные сети: Полный курс: Пер. с англ. – 2-е издание. – М.: Вильямс, 2006. – 1104 с.

Ю.М. Внуков, В.І. Дубровін, Ю.С. Аронін, Т.В. Манило

Моделювання зносу інструменту за результатами вейвлет-перетворення звукового сигналу

Досліджується проблема моделювання зносу інструменту за звуковим сигналом. Як основний інструмент обробки звукового сигналу пропонується використовувати пакетне вейвлет-перетворення. Для задачі моделювання зносу були використані багатосарова нейронна мережа та нейро-нечітка мережа. Досліджується оптимальна структура нейронної мережі.

Iu.N. Vnukov, V.I. Dubrovin, Iu.S. Afonin, T.V. Manilo

Tool Wear Modeling from Results of the Packet Wavelet Transform of Acoustic Signals

The problem of tool wear modeling using acoustic signals is investigated. The packet wavelet transform as the main mathematical tool for the task of acoustic signal processing is proposed to use. The multi-layer and fuzzy neural networks for the task of tool wear modeling are used. The optimal neuronet structure is investigated.

Статья поступила в редакцию 26.10.2007.