

АРХИТЕКТУРА НЕЙРОМОДЕЛЕЙ В СИСТЕМАХ СТАБИЛИЗАЦИИ КАЧЕСТВА ОБРАБАТЫВАЕМЫХ ПОВЕРХНОСТЕЙ**Медведев В. В., Медведев В. С.**

Рассмотрены проблемы построения искусственных нейронных сетей для определения и стабилизации качества обработанной поверхности. Указана общая структура построения таких систем. Подробно рассмотрены варианты построения искусственных нейронных сетей по структурам. Указано, что входной слой нейронной сети, при обработке диагностических данных, преобразованных в спектр, работает как совокупность частотных фильтров. Рассмотрены функции таких экспериментально полученных фильтров. Выявлено два их типа – выделение конкретного частотного диапазона и определение скважности отдельных частот сигнала. Рекомендации по структуре построения сети увязаны с технологическими возможностями существующего оборудования.

Розглянуті проблеми побудови штучних нейронних мереж для визначення й стабілізації якості обробленої поверхні. Зазначено загальну структуру побудови таких систем. Докладно розглянуті варіанти побудови штучних нейронних мереж по структурах. Зазначено, що вхідний шар нейронної мережі, при обробці діагностичних даних, перетворених у спектр, працює як сукупність частотних фільтрів. Розглянуто функції таких експериментально отриманих фільтрів. Виявлено два їхні типи - виділення конкретного частотного діапазону й визначення скважності окремих частот сигналу. Рекомендації зі структури побудови мережі вв'язані з технологічними можливостями існуючого встаткування.

The problems of constructions of artificial neuro-model nets for determination and stabilization of the quality of the machined surface are considered. The general structure for constructing such systems is pointed out. The variants of constructing artificial neural nets according to the structures are considered in details. It is pointed out that the input layer of a neural net works as a set of frequency filters in processing the diagnostic data converted into a spectrum. The function of the experimental filters got experimentally are considered. Two types of them are found out – selection of concrete frequency range and determination of duty rate of separate signal frequencies. The recommendations on the structure of net construction correspond to the technological capabilities of the existing equipment.

Медведев В. В.

ассистент ДонНТУ
vadim.medvedev@ua.fm

Медведев В. С.

ст. преп. каф. ТиУП ДГМА
vyacheslav.medvedev@dgma.donetsk.ua

ДонНТУ – Донецкий национальный технический университет, г. Донецк

ДГМА – Донбасская государственная машиностроительная академия, г. Краматорск

УДК 62-503.51

Медведев В. В., Медведев В. С.

АРХИТЕКТУРА НЕЙРОМОДЕЛЕЙ В СИСТЕМАХ СТАБИЛИЗАЦИИ КАЧЕСТВА ОБРАБАТЫВАЕМЫХ ПОВЕРХНОСТЕЙ

На передовых предприятиях машиностроения Украины постоянно возрастает доля станков типа «обрабатывающий центр». Одним из важнейших преимуществ такого оборудования является возможность его работы без вмешательства операторов. На данный момент периоды работы в автономном режиме недостаточно велики и значительно отстают от требований современного производства. Одним из факторов, которые препятствуют увеличению этого времени, есть ограниченные возможности существующих систем контроля. Особенно это касается контроля качества выпуска деталей непосредственно во время обработки. Одним из решений данного вопроса является применения интеллектуальных систем диагностики и управление. Они корректно функционируют с сильно зашумлёнными сигналами, выделяя из них необходимую для диагностики информацию.

Авторами предложено построение системы диагностики на основе алгоритмов искусственных нейронных сетей (нейросетей) [1]. При этом этап выбора структуры и обучения нейросети является наиболее ответственным в методике создания системы стабилизации качества поверхностного слоя в процессе механической обработки. От точности и гибкости полученной нейромодели зависят все основные показатели такой системы [2]. Именно данный этап позволяет выявить недостатки предварительной подготовки диагностического сигнала.

Основные сложности этапа обучения нейросети заключаются в неопределённости в случае отрицательного результата [3, 4]. Неудачная попытка обучения может быть обусловлена тремя причинами:

- 1) поступающие данные подготовлены неверно;
- 2) в поступающих данных не содержится требуемая информация;
- 2) количество нейронов мало или структура нейросети не позволяет решить задачу данного класса;
- 3) слишком малое количество уроков или неверно выбранный алгоритм обучения.

Таким образом, на неверное решение влияют два фактора – структура подаваемых данных и структура нейросети. Решение данной задачи практически невозможно в условиях цеха и требует лабораторных исследований.

Архитектура нейросети имеет ключевое влияние на возможности её обучения. Сложность создания систем на основе искусственного интеллекта состоит в том, что до настоящего времени не созданы универсальные алгоритмы выбора их структуры. Имеются только обобщённые рекомендации по выбору отдельных элементов.

Целью работы является выявление и обоснование нейросетевой структуры для распознавания качества обрабатываемого поверхностного слоя. При этом её работа основывается только на сигналах от диагностических датчиков – ЭДС резания и электромагнитного поля вблизи зоны резания.

Современная теория рекомендует использовать структуры, состоящие из слоёв, в которых нет связей, пересекающих другие слои, кроме обратных связей. Применение обратной связи показало свою нерациональность во всех проведённых нами экспериментах. Нейросети с обратными связями или имели значительные автоколебания, или значительно увеличивалось время их обучения. В любом случае точность нейросети с обратной связью была значительно ниже, чем без неё. Это доказывает, что вычисляемые технологические параметры изменяются с намного меньшей скоростью, чем период следования входных фреймов. Поэтому в дальнейшем рассматривалась только многослойные структуры, такие как многослойный перцептрон и ему подобные.

Преобразование в спектр позволяет проводить комплексный анализ диагностического сигнала. Если подключить к входам нейросети полученную частотную матрицу, то каждый входной нейрон будет связан синапсами с каждым значением частотного диапазона. Во время обучения нейросети каждому синапсу назначается вес – коэффициент связи. Во время работы на нейроны подаются значения силы сигнала по частотам с этими коэффициентами, как показано на рис. 1, а.




Рис. 1. Совокупность частотных фильтров из синапсов входного слоя (а) и реальный пример одного из фильтров (б)

Их рис. 1 видно, что входной слой нейромодели представляет собой полные частотные фильтры. Их количество равно количеству нейронов входного слоя. Так как веса связей являются не приведенными, такие фильтры имеют возможность полностью не пропускать какие-либо частотные диапазоны и в то же время – пропускать другие, с любым коэффициентом усиления. Часть фильтров, пример которого приведен на рис. 1, б, настроены на пропуск частот, чуть сдвинутых между собой гармоник, то есть скважность диагностического сигнала.

Количество нейронов в первом слое должно быть примерно равно количеству входов. В этом случае количество получаемых частотных фильтров образующихся из входных синапсов будет соответствовать спектральному разрешению. Но при этом во многих эмуляторах существует достаточно жесткое ограничение максимального количества входов. Это связано с тем, что при увеличении количества входов значительно возрастает время обучения. Учитывая эти ограничения, ставят условия самонастраивающимся алгоритмам понижения размерности спектральной матрицы.

В ходе экспериментов было выявлено, что снижение количества нейронов первого слоя от данных рекомендаций приводит к увеличению времени обучения и несколько снижает точность распознавания.

В тоже время, после проведения анализа получаемых частотных фильтров, было выявлено, что вид большинства фильтров схож между собой. На каждом графике частотного фильтра имелись нескольких вершин, расположенных практически с одинаковым интервалом. После анализа графиков фильтров, было выявлено, что количество узких пропускаемых диапазонов ограничено и составляет не более десятка. Это связано с природой возникновения колебаний в технологической системе. В среднем, в диапазонах, не относящихся к указанным пикам, относительная передаточная величина колебалась от 0,1 до 0,4. В табл. 1 приведены характеристики частотных фильтров первого слоя нейросети, позволяющей, в частности, определять шероховатость получаемой поверхности при токарной обработки.

Таблица 1

Характеристики частотных фильтров входного слоя нейросети

Номер нейрона	Средний коэффициент передачи фильтра	Средний коэффициент без вершин	Средний коэффициент без впадин	Процент усиления среднего значения вершин
1	-0,0444	-0,0621	1	-2250
2	-0,0381	-0,0125	-0,3968	1041
3	-0,0334	0,0017	-0,262	784
4	-0,0027	0,0604	-0,413	15144
5	-0,0634	-0,0331	-0,4875	769
6	0,068	0,0831	0,0077	11
7	0,0158	0,0647	-0,2612	-1649
8	-0,0893	-0,0189	-0,6227	697
9	-0,0155	-0,0333	0,056	-362
10	0,0058	0,0371	-0,1978	-3438
11	-0,0471	-0,0294	-0,2427	515
12	-0,0392	-0,0203	-0,1823	465
13	-0,0225	0,0798	-0,3291	1466
14	0,0077	-0,0435	0,3961	5112
15	0,0961	0,0538	0,8994	936
16	0,1005	0,0865	0,1917	191
17	-0,079	-0,0863	-0,0376	48
18	0,0036	0,0254	-0,1617	-4533
19	-0,3461	-0,0438	-0,8682	251
20	0,0552	0,0145	0,5034	911
21	-0,0367	0,0091	-0,6782	1846
22	-0,0697	-0,0207	-0,4409	633
23	-0,0116	-0,0288	1	-8597
24	0,0093	-0,0075	1	10736
25	-0,0004	-0,0082	0,0588	-15893
26	-0,0566	-0,0502	-0,089	157
27	-0,1345	-0,0752	-0,5828	433
28	-0,0046	-0,0399	0,4902	-10695
29	0,0631	0,0761	-0,1189	-188
30	-0,0046	0,0072	-0,23	4959
31	-0,0344	-0,009	-0,3887	1131
32	-0,0396	-0,0791	0,1582	-400

В данной таблице также приведены средние значения фильтров без учётов пиков, силой более 75 % от максимальной. Среднее значение фильтров без пиков стремится к нулю, а среднее значение пиков значительно превосходит общее среднее значение. Поэтому большинство фильтров предназначены для пропуска только узких диапазонов частот, а остальные частоты при условии относительной равномерности графика спектра взаимно компенсируются.

Исходя из выше изложенного, была составлена нейросеть всего с десятью нейронами на входном слое. Точность такой системы при определении текущих режимов резания упала на 18% относительно нейросети с 64 нейронами на входе. При решении задачи определения качества поверхностного слоя результат был неприемлем из-за низкой точности. В итоге, в задачах технологической диагностики рекомендуется в пробной попытке устанавливать количество нейронов входного слоя около 10. Если данная попытка будет неудачна, то необходимо увеличить их количество до количества входов нейросети.

В поставленных опытах также доказано, что для решения технологических задач не требуется построение нейросети со слишком большим количеством нейронов. Экспериментально установлено, что обучение спектральным данным наилучшим образом проходит

в пирамидальных структурах [1]. В них каждый последующий слой содержит примерно в 2 раза меньше нейронов, чем предыдущий. Например, в экспериментах по автоматическому определению параметров спектрального преобразования хорошо себя зарекомендовала структура 20-10-3 с 63 входами и двумя выходами. Если количество входов приближается к 250, наилучшей структурой оказалась 100-50-10 нейронов по слоям соответственно. Также в некоторых случаях оказались работоспособны варианты, у которых в первом слое установлено не более десяти нейронов, а остальная архитектура соответствовала выше представленной.

Установлено, что построение сети более чем с тремя скрытыми слоями нерационально: время обучения значительно возрастает, а точность результата практически остаётся на прежнем уровне.

В экспериментах рассматривались нейроны только с нелинейными активационными функциями, как имеющие более высокую гибкость при обучении. В основном, это функции гиперболического тангенса и сигмоиды.

В последнее время разработчики программных эмуляторов и нейроподобных информационных систем рекомендуют разделять нейросети по выходным параметрам [5]. То есть в каждой сети должен быть только один выход. В экспериментах, проведенных авторами, не было обнаружено значительных отклонений между одно- и двухсетевыми моделями при обучении по глубине резания и подаче. Однако добавление к этим данным скорости резания резко уменьшило скорость обучения, хотя итоговая точность осталась практически неизменной. Поэтому, если есть ограничения по времени обучения, рекомендуется применять к каждому определяемому технологическому параметру отдельную нейросеть.

В экспериментах обнаружено, что при вводе сигнала в долях от максимальной спектральной мощности обучение в пирамидальной структуре сети не происходит. Это связано с математической особенностью входов нейросети – при вводе долей мощности намного сложнее реализовать правильно работающие частотные фильтры. Поэтому как результат быстрого преобразования Фурье, так и алгоритм уменьшения размерности спектральной матрицы должны получать результаты в децибелах ослабления сигнала.

ВЫВОДЫ

Допускается совмещение в одну сеть только технологических параметров, имеющих близкую физическую суть и, главное, соизмеримых числовыми значениями. Нейромодель, диагностирующая качество поверхностного слоя с целью стабилизации последнего, должна иметь пирамидальную структуру. Количество нейронов входного слоя должна быть около 10 или соответствовать количеству входов спектральной матрицы. Это позволит создавать частотные фильтры, настроенные на собственные частоты элементов технологической системы и процессов скола и трения. Для диагностики технологических процессов рекомендуется использовать трёхслойные нейросети.

ЛИТЕРАТУРА

1. Медведев В. В. Построение самонастраивающейся системы контроля состояния механообработки / В. В. Медведев // Сборник тезисов I научно-технической конференции молодых учёных и специалистов «Энергомашиспециальность-2007». – Краматорск : Энергомашиспециальность, 2007. – С. 45–46.
2. Батищев Д. И. Генетические алгоритмы решения экстремальных задач / Под ред. Я. Е. Львовича. – Воронеж : ВГТУ, 1995. – 64 с.
3. Фаззи-нейро система управления приводом, нечувствительным к изменению параметров / Ф. Палис, А. Бух, У. Ладра и др. // Электромашинобудування та електрообладнання. – Одеса : Техніка, 1998. – Вып. 50. – С. 52–59.
4. Suresh P. V. Artificial neural network approach for multiple fault diagnosis: a case study / P. V. Suresh, D. Chaudhri // Transactions on Information and Communications Technologies. – WIT Press, 2004. – Vol. 6. – P. 89–98.
5. Остроухов И. Нейросети: работа над ошибками [Электронный ресурс] / И. Остроухов, П. Панфилов. – Москва : ТОРА-Центр, 2001. – Режим доступа : <http://www.tora-centre.ru/library/nscalp/spekulant02.htm>.