

IDENTIFICATION OF THE STEEL HARDNESS BY MEANS OF ARTIFICIAL NEURAL NETWORKS

Stanimir Y. Yordanov

TU Gabrovo

Raicho T. Ilarionov

TU-Gabrovo

Nikolay Shopov

UFT-Plovdiv

Ivan S. Simeonov

TU-Gabrovo

Hristo Kilifarev

TU-Gabrovo

Hristo Ibrishimov

TU-Gabrovo

Abstract

The paper deals with apparatus-programme system destined for recognition of materials by means of an analysis of signals received by ultrasonic sensors using the apparatus of artificial neural networks.

Keywords: ultrasonic sensors, artificial neural network, analysis of signals

ВЪВЕДЕНИЕ

Съвременните системи за управление решаващи задачи в реално време и използващи по-рано натрупан опит представляват особен интерес за индустрията. Системите с интелигентно управление са се отделили в три основни направления: експертни системи, системи работещи на базата на развити множества и изкуствени невронни мрежи (ИНМ). Всяко едно от тези направления притежава свой предимства и недостатъци, но системите с най-висок паралелизъм са ИНМ. Основно предимство на невронните мрежи е формализирането на много задачи. Изградена ИНМ може да решава редица нестандартни задачи. Такъв тип задача е и разпознаване на състав, състояние и структура на материали и вещества. Относно използването на ИНМ за разпознаване и класификация на високочестотни сигнали има доста публикации. В [1] Каргир показва използването на ИНМ за откриване на нехомогенност в съставни материали. Високочестотният сигнал се разлага посредством Fast Fourier Transform (FFT) и се подаван на невронната мрежа. На Back-Propagation ИНМ се подава амплитудата на спектъра на изследвания сигнал. По този начин вероятността за откриване на нееднород-

ден състав е около 71.11 %, а вероятността за получаване на грешен резултат (тоест, съобщение за нееднородност, когато няма такава) е около 15.58 %. Други автори използват шаблони за разпознаване на свръх звукови спектрални сигнали. В [2] е показано детайлно това приложение на ИНМ. При спектралния метод за разпознаване се изпраща високочестотен пакет от импулси към материала. При преминаването през дадена среда ултразвукът намалява своя интензитет, което води до неговото отслабване. Това се дължи на феномени като разсейване, абсорбция, отражение, пречупване и лъчева дивергенция. Абсорбцията на ултразвуковата енергия от средата, в която ултразвукът се разпространява, зависи от характеристиките на тази среда (еластичност и плътност), както и от честотата на използвания ултразвук. В резултат на това, характеристичните параметри на отразената акустична вълна по посока на разпространението ѝ се модифицират. По този начин ултразвуковият сигнал носи информация за характеристиките на средата между излъчвателя и приемника [3]. Разработената интелигентна сензорна система извлича тази информация и позволява да бъде изследван контролируемият обект.

Научно-приложната идея залегнала в настоящата разработка се състои в използването на ултразвуков безконтактен метод за изследване на стомана X40 с различна твърдост на закалката, с цел разпознаване и окачествяване на образците в реално време посредством апарата на ИНМ.

СТРУКТУРА НА ОПИТНАТА ПОСТАНОВКА


За осъществяване на изследванията е използвана апаратно-програмна система показана на фиг.1.

Системата е изградена от две функционално обособени подсистеми:

- Измервателна подсистема;
- Разпознаваща подсистема.

ИЗМЕРВАТЕЛНА ПОДСИСТЕМА

Процеса на измерване и съхраняване на информацията е реализиран на базата на модулите на National Instrument.




Фиг. 1. Измервателна подсистема
1) Сензорен модул; 2)Измервателен модул;
3) Разпознаваща подсистема
(виртуален инструмент)

Системата е изградена на три нива. Първото ниво (сензорен модул) (фиг.1), е предназначено да генерира ултразвуков сигнал, който се разпространява в средата и да приеме отразената вълна, преобразува в електрически сигнал и усили до ниво подходящо за обработка.


Второто ниво е изградено на базата на многофункционалният модул на NI USB-6251 M Series производство на фирмата National instrument.

В реализираната измервателна система се използват три аналогови канала и един цифров канал. Към първият аналогов канал е свързан „сензорния модул”. По този канал се извършва измерването на сигнала получен от ултразвуковият сензор. Към другите

два канала са свързани температурен сензор и сензор за влажност. Тези два сигнала се използват за въвеждане на корекционни коефициенти.



Фиг. 2. LabView виртуален модул



Фиг. 3. LabView програмен модул

Третото ниво представлява виртуален инструмент изграден в среда на LabView. Реализацията е направена в среда на LabView 9 (фиг.2). и функционира в следния алгоритъм:

1. Измерване и съхраняване температурата на околната среда.
2. Измерване и съхраняване на влажността на околната среда.
3. Генериране на стартов импулс пускащ измервателната глава.
4. Измерване на сигнала получен от ултразвуковия сензор за предварително зададен период от време.
5. Записване на данните във файл.
6. Отрязване на отрицателната полувайна
7. Отстраняване на високочестотното трептение;
8. От полученият сигнал посредством дискретно вейвлетно преобразуване (discrete wavelet transform, DWT) или посредством бързо преобразование на Фурие (fast Fourier transform, FFT) се извличат знакоопределящите елементи носещи информация за изследвания обект;

9. Сравняване на получените данни с натрупана база от данни;
 10. Вземане на решение за принадлежност към определен клас;
 11. Извеждане на подходяща информация за състоянието на обекта за изследване.
- Точки 6 -9 се обработват в среда на Matlab.

РАЗПОЗНАВАЩА ПОДСИСТЕМА

Получените данни се обработват, демодулират и оценяват от разработен за целта специализиран софтуер. Тези измервания имат смисъл, когато параметрите на състоянието на средата, като температура, налягане и др. са измерени едновременно с ултразвуковите параметри при това с висока точност. Сигналите се обработват с алгоритми базирани на законите за разпространение на вълните и взаимодействието на акустичните вълни с изследваната (контролируема) среда.

Процеса на разпознаване се основава на коефициенти получени в резултат на спектрална обработка на измерените данни от ултразвуковите сензори. На базата на направените анализи се :

- определят целевите вектори;
- съставят се обучаващи и контролни извадки;
- обучава се невронната мрежа с избраните обучаващите извадки;
- обучената системата се тества с обучаващите и контролни извадки;
- Приема се решение за принадлежност на контролната извадка към определен клас.

В разработката са използвани няколко типа невронни мрежи една от които е ИНМ с радиално базисни активационни функции. Този тип ИНМ притежават свойствата на универсалния апроксиматор. Това позволява, всяка функция с достатъчна точност да бъде моделирана, след като се избере оптималното отклонение. Характерна особеност на невронната мрежа с радиално базисни функции (РБФ) се явява голямата разлика между параметрите в теглата на първия и втория слой. Затова обучението на мрежата се разделя на два етапа. На първият етап се определят центровете при зададено количество скрити елементи в модела. На този етап се използва само информацията от наблюдението на реал-

ния входен сигнал. Когато броят и положението на центровете на РБФ бъде определено те се фиксират. Следващата задача се състои в намирането на средноквадратичната грешка. Тази задача позволява да се приложат прости и линейни алгоритми за намиране на оптималния теглови вектор.

Програма за изследване и разпознаване е написана в среда на Matlab.

ЕКСПЕРИМЕНТ

Разработената апаратно-програмна среда бе използвана при изследване на стомана Х40, с различна твърдост. За целта бяха изработени образци (фиг.4.) с размер $\Phi 50$, дебелина 10mm и твърдости $HR_c = 34$, $HR_c = 36$, $HR_c = 40$, $HR_c = 46$ и $HR_c = 50$




Фиг. 4. Изследвани образци

С помощта на апаратно програмната система бяха направени поредица от експериментални измервания на по четири образца фиг. 4. Изследванията са проведени при следните параметри на опитната постановка. Честота на възбуждане на ултразвуковия сензор е 40kHz. Честота на измерване 1.25MSamples. Разстояние до образец 25 mm. Температура в помещението по време на експеримента е 32 °C. Направени са по 100 измервания за образец общо по 400 за образци с еднаква твърдост.

На фиг. 5 са показани по един измерен сигнал за всяка твърдост. Получените данни се филтрират, като се отстранява високочестотното трептене. За целта сигнала се пропуска през амплитуден детектор и се подава към функцията реализираща дискретно уейвлетно преобразуване (DWT).

Уейвлетното (wavelet) преобразуване е едно от перспективните и най-бързо развиващи се методи за анализ на сигнали.



Фиг.5. Експериментални данни от измерване на образците

То се явява междинно между изцяло спектралното и времевото представяне.

Уейвлетите /wavelets/ [4] представляват функции със солитоноподобна форма, локализирани по оста на независима променлива (t или n), с възможност за преместване по нея и мащабиране (свиване/разширение) и имащи вид на кратки вълнови пакети с нулева средна стойност на уейвлетната функция. Към настоящия момент са известни множество ортогонални базисни уейвлет функции - на Хаар, Добеши, коифлети, симлети и др, имащи възможност за бързо преобразуване [4]. То се реализира на базата на итерационен алгоритъм.

Оригиналният сигнал преминава през два филтъра-филтър на високи честоти G и филтър на ниски честоти H . Установено е, че всяка втора дискретна стойност може да се премахне без загуба на информация. Операцията е наречена редуциране на дискретните стойности (двоична децимация). Получават се две дискретни поредици - коефициентите на апроксимация на ниво $m=1$ $a_{1,k}$ от филтъра G и детайлизиращите коефициенти $d_{1,k}$ от филтъра H . При разлагане на по-високо ниво коефициентите на апроксимация от ниво $m=1$ ($a_{1,k}$) се подлагат на аналогични операции.

Детайлизиращите коефициенти $d_{1,k}$ отразяват главно високочестотния шум, докато апроксимиращите коефициенти $a_{1,k}$ отразяват характерните особености на оригиналния сигнал. Процесът на декомпозиция може да се извърши последователно (пирамидален алгоритъм на Mallat [5], като сигналът се разложи на множество нискочестотни и високочестотни компоненти. Получените, като резултат уейвлетни коефициенти са приложени и изследвани в качеството на признаци за разпознаване.

С прилагане на DWT за синтез на признаково пространство на класификатора са търсени два основни ефекта:

- Елиминиране на евристичните подходи посредством строго математическо обосноваване на процедурите по формиране на признаковите пространства.
- Редукция на признаковото пространство.

От изходните данни са формирани обучаваща и контролна извадки. Обучаващата извадка е формирана по метода на собствено-

случайните извадки с повторен избор, чрез случаен подбор на номерата на реализациите. Извадката има обем $N = 300$ бр. Контролната извадка, с обем $N = 50$ бр., е съставена посредством подбор на реализациите, които не са включени в обучаващата извадка, без повторен избор.

С помощта на обучаващата извадка са формирани признаци с DWT, реализирано съгласно алгоритъма на Mallat с уейвлити на Симлет. Получените уейвлетни коефициенти $a[n]$ и $d[n]$, след така реализираната трансформация, са изследвани в качеството на признаци и са подадени за обучение на невронния класификатор.


Разработеният софтуер за разпознаване позволява структурата на невронната мрежа да бъде променяна с цел търсене на оптимално решение по точност и бързина на заключението.

Едновременно с формирането на признаковото пространство се извършва и редукция, определена от характера на извършваната уейвлетна трансформация. Подборът на информативни признаци за класификация е осъществен по метода на последователно отхвърляне.


Направени са изследване по уейвлити на Симлет1 (фиг.6 и 7) с използване на апроксимиращите $a_8[n]$ и детайлиращи $d_8[n]$ коефициенти на ниво на декомпозиция съответно $n=9$ в качеството на признаци за класификация.. Така синтезираните данни бе извършено обучение на невронната мрежа.

Невронната мрежа е проектирана с 18 входа, един междинен слой и един изход. Броят на входовете се определя от броя на апроксимиращите $a_8[n]$ и детайлиращи $d_8[n]$ коефициенти. Изследванията са направени при ниво на декомпозиция съответно $n=9$, следователно броят на получените коефициенти е 9. В зависимост от правилото за определяне броят невроните в междинния слой $m = 3*n-1$, където n са броят на входовете на ИНМ, а m е броят на невроните.

Бе определен размера на междинния слой $m=53$. На входовете на ИНМ се подават стойностите на апроксимиращите и детайлиращи коефициенти. На изхода се получава число указващо принадлежността на разпознавания материал към даден клас. Диапазона на разпознаване на един образец е ± 0.5 единици от номиналната стойност за




а) тестващите извадки.




б) обучаващи извадки

Фиг. 6. Апроксимиращи коефициенти



а) тестващи извадки.



б) обучаващи извадки

Фиг. 7. Детайлиращи коефициенти

дадената твърдост. Например стомана X40 с твърдост $HRc = 46$ се кодира с 4. Ако на изхода на невронната мрежа се получи сигнал в границите от 3.5 до 4.5 то се счита, че пробата е разпозната успешно и се причислява към този клас.

Обучаващи сигнали бяха подадени на ИНМ за разпознаване по 5 пъти, а верификационните сигнали са тествани по 10 пъти всеки. В таблица 1 са показани получените резултати при разпознаване на образците.

Таблица 1

№	Твърдост HRc	Вид серия	Брой правилни отговори	% на разпознаване
1	34	Обучаващи	300/300	100
		Тестващи	48/50	99.98
2	36	Обучаващи	300/300	100
		Тестващи	38/50	76
3	40	Обучаващи	300/300	100
		Тестващи	50/50	100
4	46	Обучаващи	300/300	100
		Тестващи	49/50	98
5	50	Обучаващи	300/300	100
		Тестващи	48/50	96

От получените резултати се вижда, че при подаване на обучаващ вектор за разпознаване процента на разпознаване е 100%. Високата степен на разпознаване се дължи на доброто обучение на невронната мрежа. Това се постигна като всеки входен сигнал бе подаден за обучение няколко пъти на ИНМ. Точността на разпознаване на тестващите поредици варира в границите от 76% до 100. Най-голяма точност се получава при разпознаване се постига при твърдост $HRc = 40$. (100%). Най-ниската се получава при твърдост $HRc = 36$ (76%). Десет от събраните измервания са причислени към елементите с твърдост $HRc = 34$. Това се дължи на много близките стойности на твърдостта на един от образците до другият клас.

Високите стойности на процента на разпознаване доказва работоспособността на методиката и възможността за прилагането и в практиката

ЗАКЛЮЧЕНИЕ

Представената в статията разработка има две цели:

1. Да провери работоспособността на идеята за разпознаване на материали посредством анализ на сигнали получени от ултразвукови сензори.

2. Да провери хипотезата за определяне твърдостта на стомани посредством анализ на сигнали получени от ултразвукови сензори с апарата на изкуствените невронни мрежи.

Получените резултати показаха, че невронните мрежи могат да се използват за бърза класификация и разпознаване на различни материали. Фактически ИНМ могат да бъдат обучени за разпознаване на различни материали или за разпознаване на физически състояния на материали. Създадената система за разпознаване на материали посредством анализ с ИНМ на сигнали от ултразвукови сензори е стъпка към създаването на интелигентен контролер с вградени функции за анализ на вещества и материали в реално време.

ЛИТЕРАТУРА

- [1] P. Karpur, Split-spectrum technique as a preprocessor for enhanced reliability in ultrasonic signal analyses, Material Evaluation/June 1992, p793.
- [2] M. Kitahara, J. D. Achenbach, Q. C. Guo, M. L. Peterson, Neural network for crack-depth determination from ultrasonic backscattering data, Review of Progress in Quantitative Nondestructive Evaluation, Vol. 11, pg. 701.
- [3] Dorin Ciobanu, Razvan Ciocan, Artificial neural network for ultrasonic spectroscopy data analysis, Proceedings AROEND Symposium 1996.
- [4] Baltes, H., W. Göpel, J. Hesse. Sensors Update. Volume 3. Sensor Technology-Applications-Markets. Weinheim-Berlin-New York-Chichester-Brisbane-Singapore-Toronto, Wiley-VCH Verlag GmbH, 1998.
- [5] Mallat S., "Multiresolution approximations and wavelet orthonormal bases of $L_2(R)$," Trans. Amer. Math. Soc., 315:69--87, 1989

This study was carried out in the framework of the DRNF 02/9 project titled "Design and development of a device for non-contact ultrasonic investigation of materials aimed at embedding in automated manufacture systems", financed by the National Science Fund of the Bulgarian Ministry of Education, Youth and Science.