

УДК 629.735.083.03.004.58:004.801.3(045)

О.Г. КУЧЕР, С.О. ДМИТРИЄВ, О.В. ПОПОВ, О.С. ЯКУШЕНКО

Національний авіаційний університет, Київ, Україна

МЕТОДИКА ВИЗНАЧЕННЯ ОПТИМАЛЬНОЇ АРХІТЕКТУРИ НЕЙРОННОЇ МЕРЕЖІ ДІАГНОСТУВАННЯ ТРДД

Розглянуті питання побудови ефективної процедури навчання і оптимальної структури нейронної мережі для діагностування конструктивних вузлів проточної частини газотурбінного двигуна. При цьому вирішуються завдання уточнення структури, вибору алгоритму навчання з тестуванням за критеріями швидкості навчання, якості розпізнавання за навчальною та перевіркою вибірки та за зміною функціонала похибки. У підсумку, авторами розроблено методику оптимізації структури нейронної мережі з метою уникання ефекту «перенавчання» мережі при вирішенні завдань параметричного діагностування авіаційного газотурбінного двоконтурного двигуна.

Ключові слова: нейронна мережа, навчання мережі, діагностування, оптимізація структури, кількість нейронів, критерій адекватності, перенавчання мережі.

Постановка проблеми та задач

Представлена робота є продовженням розробок, приведених авторами у наукових працях [1 – 13].

Перспективним напрямком автоматизованого діагностування турбореактивного двоконтурного двигуна (ТРДД) з глибиною діагностування до конструктивного вузла є використання у складі експертної системи нейронних мереж (НМ). Однією з особливостей такої мережі є гнучкість і поліморфізм її структури. Найважливішими при побудові (розробки архітектури) НМ є три питання: визначення типу НМ; вибір методу її навчання; визначення кількості шарів та нейронів у її шарах і характеристик нейрона – функції активації (ФА). При цьому рекомендації такого вибору відсутні або носять загальний характер. З огляду на це об'єктом цієї роботи є створення методики отримання оптимальної архітектури НМ з урахуванням гіпотези про виникнення відмови одного або 2-х вузлів проточної частини ТРДД одночасно. Об'єктом досліджень обрано статичні НМ.

Вибір алгоритму навчання мережі

Як об'єкт контролю обрано ТРДД ПС-90А [14]. Набір діагностичних даних для навчання НМ містив інформацію про 16 класів. Кожен клас був представлений 20 точками. Перші 20 точок представляють бездефектний ГТД (1 клас), з 21 по 120 – первинні класи, що характеризують деградацію одного з вузлів – зовнішнього контуру вентилятора (2), компресора високого тиску (3), камери згоряння (4), турбін високого (5) і низького тиску(6), з 121 по 320 – вто-

ринні класи, що є попарними комбінаціями первинних класів: комбінація класів 2 + 3 (7), 2+4 (8), 2+5 (9), 2+ 6 (10), 3 + 4 (11), 3 + 5 (12), 3 + 6 (13), 4 + 5 (14), 4 + 6 (15), 5 + 6 (16). Усього навчальний набір містить 320 точок. Докладний опис навчального набору та метод його формування наведено у роботах [2, 11]. Найбільш доцільно почати побудову НМ з вибору алгоритму навчання. У роботі було апробовано 12 найбільш відомих методів навчання: алгоритми сполучених градієнтів: Флетчера-Пауела (скорочена назва CGF), Полака-Рібейри (CGP), регуляризації Bayesian (BR); Бієля-Пауела (CGB); квазіньютонів алгоритми: Левенберга-Марквардта (LM), Бройдена-Флетчера (BFG), одноступінчатий метод пересічних Батіті (OSS); градієнтний граничний алгоритм зворотного поширення помилки (RP); метод градієнтного спуску з урахуванням моментів та адаптивного навчання (GDX) та ін [3].

Якість розпізнавання стану ГТД оцінювалась за допомогою чотирьох критеріїв, що характеризують помилки розпізнавання при відношенні двигуна до справного або несправного станів:

- помилка класифікації – всі помилки неправильної класифікації стану двигуна;
- помилка першого роду;
- помилка не розпізнавання в подвійній відмові хоча б одного з двох вузлів, що відмовили;
- груба помилка – помилка другого роду.

Оцінка ефективності алгоритму навчання НМ (рис. 1, 2) здійснювалась на основі навчальної (НВ) та перевіркою (ПВ) вибірок. Остання була сформована за тими ж принципами що й НМ і мала таку ж структуру але відрізнялася від неї тим, що перша була побудована на початковій стадії розвитку де-

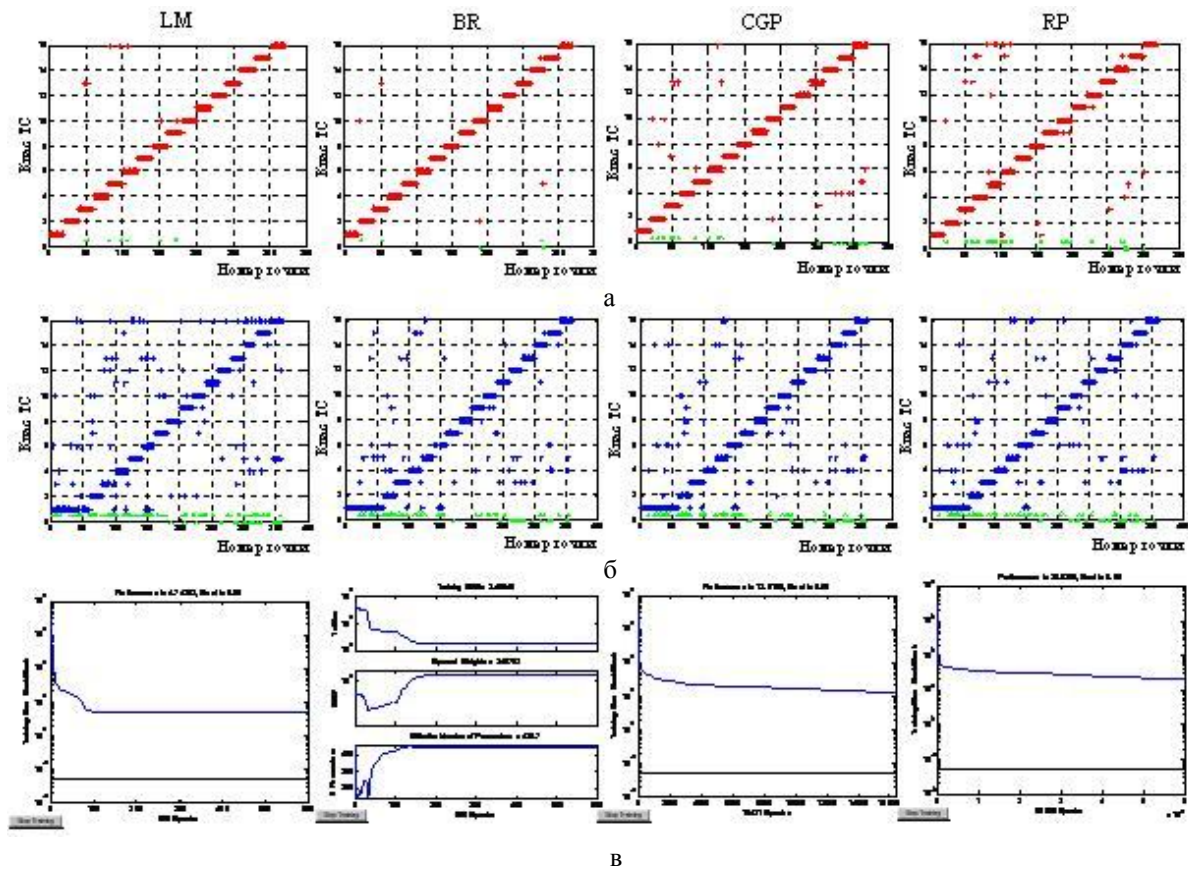


Рис. 1. Результат класифікації першою групою методів:
 а – НВ; б – ПВ; в – функціонал помилки

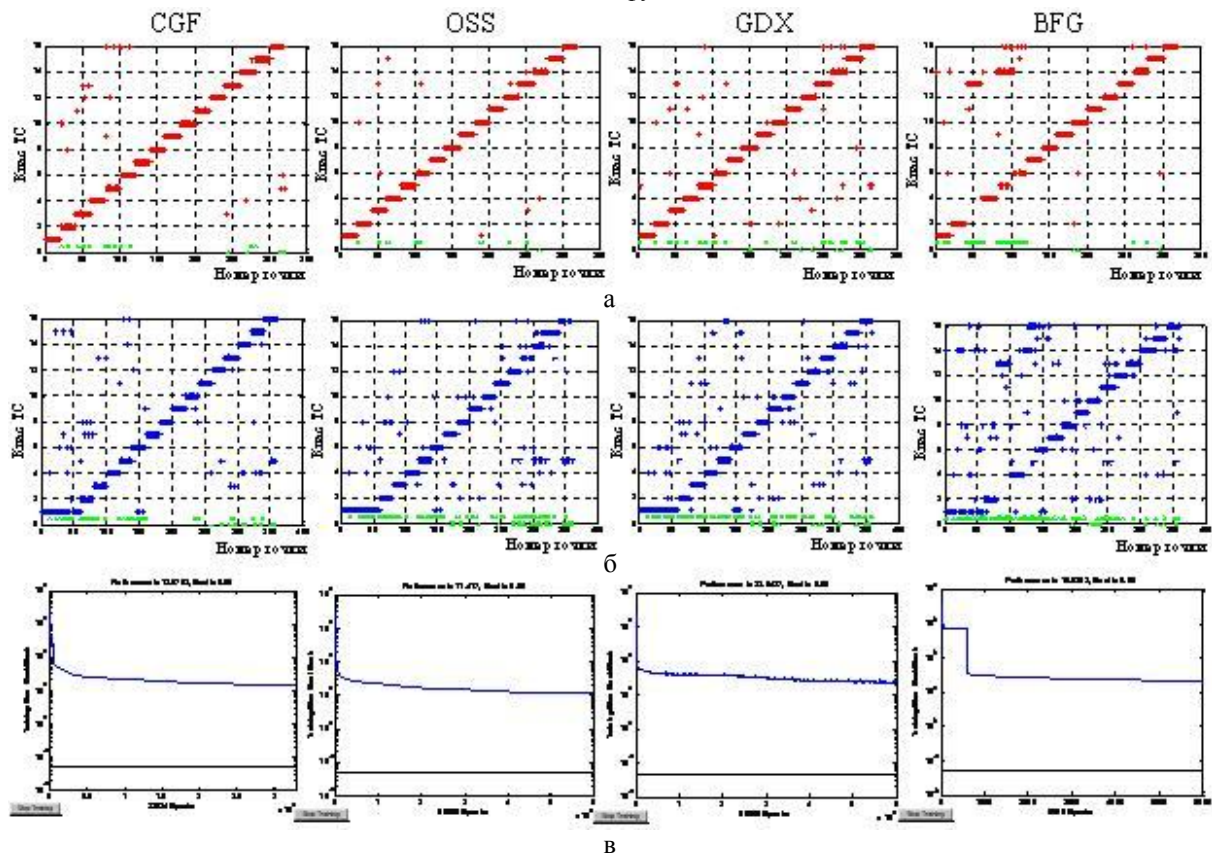


Рис. 2. Результат класифікації другою групою методів:
 а – НВ; б – ПВ; в – функціонал помилки

Фекту, друга – на пізній. Процес навчання НМ в цілому випадковий тому було проведено декілька (5) спроб апробації алгоритмів навчання НМ.

На рис. 1 и 2 наведені результати процесу навчання мережі для однієї з спроб та підсумки класифікації стану ГТД.

У верхній частині а) вказані результати розпізнавання даних НВ різними методами. Для наочності результати показані у координатах клас ТС - номер точки. Якщо точки графіка лежать на відповідних полицях, які відповідають даному стану ГТД то розпізнавання стану здійснюється вірно в іншому випадку мають місце помилки класифікації. Якщо точки розміщуються над першою полицею то замість нормального стану ГТД розпізнається один з дефектних станів тобто мають місце помилки першого роду. Якщо точки графіка з 21 по 320 лежать на рівні 1-ї полиці то замість дефектів розпізнається нормальний стан ГТД – помилки другого роду і т.д. На рівні б) приведені результати розпізнавання ПВ, яка тестується за даними НВ, тому помилок класифікації тут значно більше. На рівні в) показано динаміку зміни функціонала помилки SSE (Sum squared error) цих алгоритмів в процесі навчання. За характером зміни цієї кривої можна судити про швидкість та якість навчання НМ в т.ч. на початковій стадії процесу. Навчання мережі буде тим якіс-

нішим чим менше значення функціонала помилки SSE. Якщо крива перетинає встановлену граничну межу то це має означати 100 % якість навчання, при якій помилки класифікації відсутні.

Швидкість зміни кривої на початковій стадії процесу дозволяють класифікувати алгоритми за швидкістю навчання.

Всі розглянуті алгоритми навчання мережі можна умовно розділити на три групи за критерієм час навчання - кількість кроків обчислень функціоналу. До першої групи віднесено методи LM та BR, в яких кількість кроків розрахунків функціоналу невелика, але час розрахунку кожного кроку значний. В інших час розрахунку кроку зменшується, але й зменшується середня швидкість сходження функціоналу за один крок.

Щоб тестування алгоритмів проходило в однакових умовах для всіх типів алгоритмів встановлено єдиний час тестування і визначені граничні значення кількості кроків розрахунків функціоналу для різних алгоритмів від 600 до $6 \cdot 10^4$.

Аналізуючи результати апробації обраних алгоритмів навчання НМ за результатами навчання можна зробити висновок, що найбільш ефективними алгоритмами для НВ є: LM та BR, далі алгоритми займають наступні позиції: CGP, OSS, SCG, CGF, RP, BFG, GD (рис. 3).




Рис. 3. Результати тестування на якість розпізнавання НВ: а – помилки класифікації; б – помилки не розпізнавання відмови двох вузлів; в – грубі помилки




Рис. 4. Результати тестування на якість розпізнавання ПВ: а – помилки класифікації; б – помилки не розпізнавання відмови двох вузлів; в – грубі помилки

Щодо швидкості навчання на початковому етапі, коли обмежений час навчання, то за ефективністю алгоритми розміщуються в такому порядку:

- 1 – CGF, 2 – RP, 3 – CGP,
- 4 – CGB, 5 – LM,
- 6 – BFG, 7 – OSS.

Інша картина просліджується з результатами розпізнавання за ПВ (рис. 4). За якістю розпізнавання алгоритми розміщуються в порядку CGF, CGP, SCG, BR, RP, GDX, LM, OSS, BFG. Але в цьому разі на якість розпізнавання впливає те що стан ГТД змінився і це відбулося в дещо іншому напрямку, що було зафіксовано в процесі навчання за НВ, хоча генеральний напрям змін залишився.

Незважаючи на наведені на рис. 4 результати, все ж таки у подальшому при визначенні кількості шарів та функції активації, саме алгоритм LM надає найбільш ефективні результати.

Вибір кількості шарів мережі та ФА нейронів

Наступним етапом побудови архітектури НМ є визначення кількості шарів. Основним принципами при цьому є те, що кількість нейронів вхідного шару повинна бути не меншою ніж кількість ознак, які характеризують стан об'єкту, а кількість нейронів вихідного шару повинна дорівнювати кількості класів технічного стану об'єкту розпізнавання. НМ набувала кращих якостей якщо кількість нейронів інших (проміжних) шарів була не меншою за кількість нейронів вихідного шару. Апробація проводилася для 2, 3, 4 та 5-ти шарової НМ. Для 2-х шарової мережі (11,16) для підвищення якості розпізнавання оптимальна кількість нейронів першого шару по-

винна бути більшою за кількість вхідних ознак відсотків на 30 %. Якість також зростала при невеликому рості кількості нейронів мережі в середніх шарах. Для 3-х шарової мережі (7,16,16) для НВ кількість помилок значно зменшилась. Найбільшу ефективність при розпізнаванні було отримано для 4-х шарової мережі при кількості нейронів (7,16,17,16), при менших значеннях шарів виникає більший відсоток помилок класифікації та помилок другого роду, що є неприпустимими, для 5-ти шарової мережі спостерігався ефект перенавчання при кількості нейронів (7,16,17,19,16) (рис. 5).

Вибір типу ФА нейронів був проведений для 3-х шарової мережі з прямим поширенням сигналу. Кількість нейронів у шарах була, відповідно рівною (7,16,16). Розгляду підлягали три типи ФА: гіперболічний тангенс (TANSIG), логістична (LOGSIG) та лінійна (PURELIN) у різних комбінаціях. При цьому в якості базового використовувався алгоритм LM. Порівняння ефективності різних комбінацій нейронів проводилося за ступенем адекватності мережі навчальному наборові даних. На рис. 6 приведені чотири найбільш характерні комбінації ФА з $3^3=27$ можливих. Найкращими властивостями при розпізнаванні стану двигуна володіє функція активації Tansig, тому комбінація ФА Tansig-Tansig-Tansig є найкращою, але непогані властивості також мають інші комбінації в т.ч. ФА Tansig-logsig-purelin (рис. 6).

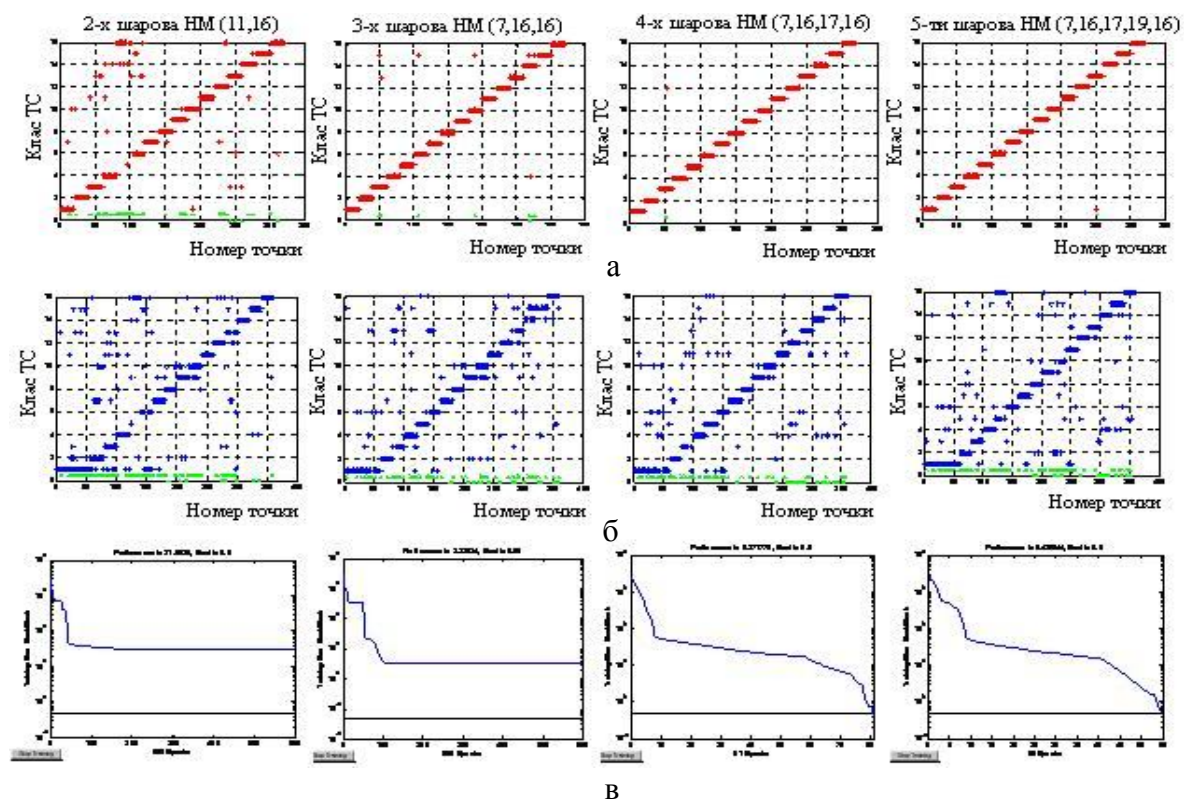


Рис. 5. Результат класифікації багат шарових НМ:
а – НВ; б – ПВ; в – функціонал помилки

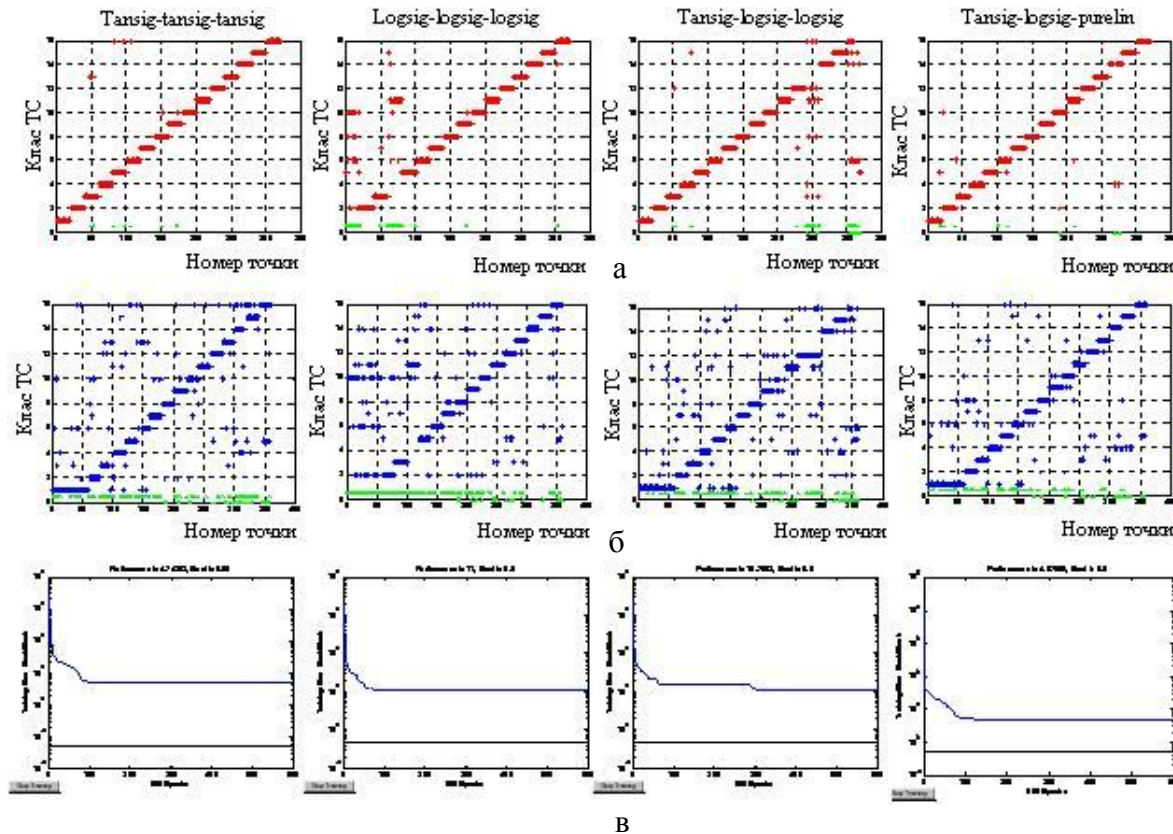


Рис. 6. Результат класифікації трьохшарової мережі з різними функціями активації:
а – НВ; б – ПВ; в – функціонал помилки

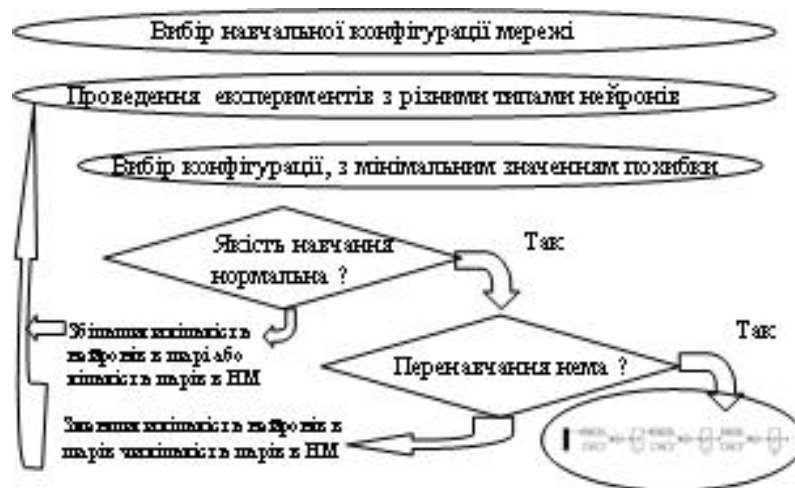


Рис. 7. Послідовність уточнення структури НМ

Проведений аналіз показав, що в першому шарі завжди повинна стояти ФА Tansig в другому можлива ФА logsig і на третьому останньому можлива ФА purelin.

Визначення ефекту перенавантаження нейронної мережі

На наступному етапі роботи було виконано спробу розробити метод оцінки виникнення явища

перенавантаження нейронної мережі. Для цього використано метод, описаний у загальному вигляді у роботі [12]. Цей метод полягає у порівнянні якості розпізнавання навченою мережею навчального набору даних, за яким проводилося навчання, та окремого тестового набору, який не приймав участі у процесі навчання але взятий з однієї генеральної сукупності.

Алгоритм отримання тестового набору аналогічний алгоритму формування навчального набору. Єдиною відмінністю цих наборів є кількість точок,

що репрезентують справний клас ТС. У тестовому наборі їхня кількість збільшена до 60 проти 20 у навчальному. Перевірочний набір не може слугувати цим набором так як умови формування НВ та ПВ різні. Тестовий набір формується з характеристиками НВ.

Загальний алгоритм оптимізації структури НМ зображений на рис. 7.

Висновки

Представлений метод дозволяє побудувати ефективну процедуру навчання нейронної мережі з оптимальною структурою для розпізнавання класу ТС ГТД.

За функцію активації в такій мережі доцільно використовувати функцію гіперболічного тангенса але можливо використання в кінцевих шарах і логістичну або лінійну функцію, для формування архітектури нейронної мережі необхідно використовувати процедури визначення оптимальної кількості шарів мережі та кількості нейронів в кожному шарі, а для навчання мережі – алгоритми:

- Лавенберга-Маркварта,
- регуляризації Bayesian,
- Полака-Рібейри,
- градієнтний алгоритм зворотного розповсюдження помилки.

Приведені дані дозволяють визначити критерій, за допомогою якого виявляється ефект перенавчання.

Література

1. Кучер А.Г. Определение технического состояния ТРДД по данным экспериментальных исследований с использованием нейронных сетей и методов распознавания образов / А.Г. Кучер, С.А. Дмитриев, А.В. Попов // *Авіаційно-космічна техніка і технологія*. – 2007. – № 10/46. – С. 153-164.
2. Комплексний метод розпізнавання стану ТРДД з використанням нейронних мереж та методів розпізнавання образів / О.Г. Кучер, С.О. Дмитрієв, О.В. Попов, О.В. Тишкевич // *Авіаційно-космічна техніка і технологія*. – 2008. – № 10/57. – С. 51-61.
3. Дмитрієв С.О. Оцінка технічного стану проточної частини газотурбінного двигуна за параметрами робочого процесу / С.О. Дмитрієв, О.Г. Кучер, О.В. Попов // *Вісник Інженерної академії України*. – Миколаїв, 2009. – № 1. – С. 8-11.

4. Многокритериальное диагностирование проточной части авиационного газотурбинного двигателя / А.Г. Кучер, С.А. Дмитриев, А.В. Попов, А.С. Якушенко // *Авіаційно-космічна техніка і технологія*. – 2009. – № 8/65. – С. 153-158.

5. Кучер О.Г. Розпізнавання технічного стану авіаційних ГТД з використанням нейронних мереж / О.Г. Кучер, О.С. Якушенко, В.Ю. Сухоруков // *Вісник двигунобудування*. – 2002. – № 1. – С. 101-106.

6. Кучер О.Г. Оптимизация метода обучения нейронной сети для распознавания класса технического состояния ГТД / О.Г. Кучер, О.С. Якушенко, В.Ю. Сухоруков // *Авиационно-космическая техника и технология*. – 2007. – № 1/15. – С. 184-188.

7. Дмитрієв С.О. Параметричне оцінювання технічного стану проточної частини газотурбінного двигуна / С.О. Дмитрієв, О.Г. Кучер, О.В. Попов // *Матеріали II Міжнародної науково-практичної конференції «ПРТК-2009»* – К.: НАУ, 2009. – С. 107-108.

8. Використання штучного інтелекту при вирішенні завдань діагностування авіаційних газотурбінних двигунів / С.О. Дмитрієв, О.Г. Кучер, О.В. Попов, І.А. Слепухіна // *Матеріали IX Міжнародної науково-технічної конференції „АВІА – 2009”*. – К.: НАУ, 2009. – Т. 2. – С. 17.29-17.32.

9. Дмитриев С.А. Диагностирование проточной части авиационного турбореактивного двухконтурного двигателя на примере АИ-25 / С.А. Дмитриев, А.В. Попов // *Матеріали міжнародної наукової конференції ISDMCI'2009, 18-22 травня*. – Херсон: ХНТУ, 2009. – С. 509-511.

10. Вибір компонентів і параметрів нейронної мережі діагностики ТРДД / О.Г. Кучер, О.С. Якушенко, В.С. Мільцов, В.М. Охмакевич // *Матеріали IX Міжнародної науково-технічної конференції „АВІА – 2009”*. – К.: НАУ, 2009. – Т. 2. – С. 13.5-13.7.

11. Якушенко О.С. Нейронні мережі для діагностування газотурбінних двигунів / О.С. Якушенко // *Вісник НАУ*. – К., 2004. – № 2 (20). – С. 67-71.

12. Медведев В.С. Нейронные сети. Matlab 6 / В.С. Медведев, В.Г. Потемкин; под общ. ред. В.Г. Потемкина. – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.

13. Первинна оптимізація архітектури нейронної мережі діагностування ТРДД // О.Г. Кучер, О.С. Якушенко, В.М. Степаненко, В.С. Мільцов // *Вісник двигунобудування*. – 2009. – № 3. – С. 166-171.

14. Двигатель ПС-90А. Руководство по технической эксплуатации. В 3-х книгах. – Пермь: ПНПО "Авиадвигатель", 1990.

Рецензент: д-р техн. наук, проф., декан механіко-енергетичного факультету В.В.Панін, Національний авіаційний університет, Київ.

МЕТОДИКА ОПРЕДЕЛЕНИЯ ОПТИМАЛЬНОЙ АРХИТЕКТУРЫ НЕЙРОННОЙ СЕТИ ДИАГНОСТИРОВАНИЯ ТРДД

А.Г. Кучер, С.А. Дмитриев, А.В. Попов, А.С. Якушенко

Рассмотрены вопросы построения эффективной процедуры обучения и оптимальной структуры нейронной сети для диагностирования конструктивных узлов проточной части газотурбинного двигателя. При этом решаются задачи уточнения структуры, выбора алгоритма обучения с тестированием по критериям скорости обучения, качества распознавания по учебной и проверочной выборкам и по изменению функционала ошибки. В итоге, авторами разработана методика оптимизации структуры нейронной сети с целью избегания эффекта «переобучения» сети при решении задач параметрической диагностики авиационного газотурбинного двухконтурного двигателя.

Ключевые слова: нейронная сеть, обучение сети, диагностирование, оптимизация структуры, количество нейронов, критерий адекватности, переобучение сети.

METHOD OF DETERMINATION OPTIMUM ARCHITECTURE OF NATURAL NETWORK OF BPE DIAGNOSTICS

O.G. Kucher, S.O. Dmitriev, O.V. Popov, A.C. Yakushenko

In this article are consider questions of construction effective procedure of teaching and optimum natural network structure for diagnosticating of structural units of flowing part of turbo-engine. The tasks of classification of structure decide thus, choice of teaching algorithm with testing on the criteria of teaching speed, qualities of recognition on educational and verification selections and on the change of functional of error. In the total, authors are develop the method of optimization of natural network structure with the purpose of avoidance of effect of «overteaching» of network at the decision of tasks of self-reactance diagnostics of aviation by-pass engine.

Keywords: natural network, teaching of network, diagnosticating, optimization of structure, amount of neurons, criterion of adequacy, overteaching of network.

Кучер Олексій Григорович – д-р техн. наук, проф. кафедри авіаційних двигунів Національного авіаційного університету, Київ, Україна, e-mail: kucher@nau.edu.ua.

Дмитрієв Сергій Олексійович – д-р техн. наук, проф., завідувач кафедри збереження льотної придатності авіаційної техніки Національного авіаційного університету, Київ, Україна, e-mail: sad@nau.edu.ua

Попов Олександр Вікторович – канд. техн. наук, доцент кафедри збереження льотної придатності авіаційної техніки Національного авіаційного університету, Київ, Україна, e-mail: popche@ukr.net.

Якушенко Олександр Сергійович – канд. техн. наук, старший науковий співробітник кафедри авіаційних двигунів Національного авіаційного університету, Київ, Україна, e-mail: yuysss@mail.ru.