

Створення сурогатної моделі для відновлення приповерхневих профілів електрофізичних характеристик циліндричних об'єктів

В.Я. Гальченко, А.В. Сторчак, Р.В. Трембовецька, В.В. Тичков

Черкаський державний технологічний університет, бульв. Шевченка, 460, 18006, Черкаси, Україна
v.tychkov@chdtu.edu.ua

Анотація

Показано один з етапів розв'язку багатопараметрової оберненої задачі вихрострумівих вимірювань щодо ідентифікації радіальних профілів електрофізичних характеристик циліндричних об'єктів контролю апроксимаційним методом. Метод передбачає використання апріорної інформації про випробування об'єктів контролю циліндричної форми, яку отримано шляхом математичного моделювання за "точною" електродинамічною моделлю Uzal-Dodd-Deeds. Запропоновано як носія апріорної інформації використовувати високопродуктивну в обчислювальному сенсі сурогатну модель процесу контролю. Виконано аналіз методів побудови сурогатних моделей та із урахуванням певних переваг обрано нейромережвий метод створення метамоделі в рамках досліджень, що проводяться. Відзначено особливості, які є характерними для побудови метамodelей, що полягають у необхідності використання комплексозначних нейронних мереж, та вказано шляхи вирішення цієї проблеми. Метамоделі створено на базі комплексозначних нейронних мереж, що розщеплюються. Відпрацьовано обчислювальну технологію побудови сурогатних моделей у середовищі Python 3 з використанням відкритої бібліотеки Keras, наведено об'єктивні чисельні статистичні показники для перевірки адекватності метамodelей. На конкретних даних виконано верифікацію створених сурогатних моделей та проведено оцінку точності апроксимації поверхні відгуку вказаними засобами. Вказано шляхи узагальнення на більш складні випадки створення метамodelей для вимірювальних задач, що характеризуються гіперповерхнями відгуку із більшою розмірністю простору, акцентовано увагу на універсальність підходу, прийняттого для практично будь-якої складної топології гіперповерхні.

Ключові слова: електрофізичні характеристики; вихроструміві вимірювання; приповерхневий профіль; ідентифікація; сурогатна модель.

Отримано: 11.06.2020

Відредаговано: 27.07.2020

Схвалено до друку: 03.08.2020

Вступ

Визначення приповерхневих радіальних профілів матеріальних характеристик циліндричних об'єктів контролю (ОК) неруйнівним вихрострумівим методом вимірювань дозволяє відстежувати структурні особливості матеріалу виробів, що є дуже важливим при контролі проведення багатьох технологічних операцій щодо зміцнення їх поверхні, спостереження модифікації стану в процесі експлуатації, дослідження хімічного та фазового складу тощо [1, 2]. Перспективний підхід щодо розв'язку цієї оберненої вимірювальної задачі запропоновано авторами в [3], де він розглядався у вигляді трьохетапного алгоритму. Враховуючи багатопараметровість задачі ідентифікації профілів, з метою скорочення обсягу вимірювальних операцій накопичення апріорної інформації щодо ОК має сенс виконувати в сурогатній моделі процесу контролю

при варіюванні суттєвими технічними параметрами, зокрема електропровідністю (ЕП), магнітною проникністю (МП) приповерхневого шару, діаметром ОК, частотою збудження вихрових струмів. Слід зауважити, що метамодель створюється заздалегідь перед проведенням вимірювань на основі "точної" електродинамічної моделі шляхом застосування багатовимірних апроксимаційних технік та характеризується мінімальною обчислювальною ресурсоемністю. Поєднання швидкості обрахунків та їх точності забезпечується таким чином використанням методології замісного моделювання, тобто сурогатним моделюванням, як складової загального процесу реконструкції (ідентифікації) приповерхневих профілів матеріалу ОК (рис. 1). Завдання побудови метамodelі становить другий етап алгоритму розв'язку задачі, що розглядається, і саме йому присвячено дослідження, які наведено в цій статті.




Рис. 1. Загальна схема процесу реконструкції радіальних приповерхневих профілів матеріальних характеристик об'єктів контролю

Аналіз останніх досліджень і публікацій

Від точності побудови моделі-замісника, тобто метамоделі, залежить значною мірою подальший ефективний розв'язок задачі ідентифікації профілів електрофізичних параметрів. Тому важливим є вибір методу побудови багатовимірної в загальному випадку апроксимаційної моделі гіперповерхні відгуку, топологія якої може бути достатньо складною та яку неможливо уявити собі наочно. Ці обставини вимагають вибору такого методу, який би забезпечував певну універсальність для всіх можливих топологій гіперповерхонь, оцінку точності яких можна здійснювати за допомогою об'єктивних чисельних показників.

Наразі відомими є декілька груп методів, що використовуються для створення сурогатних моделей. До першої групи слід віднести так звані геометричні метамоделі, до яких належать усі види поліноміальних метамodelей, моделі на основі застосування методології поверхні відгуку RSM (Response Surface Models), багатоваріантні адаптивні регресійні сплайни MARs (Multivariate adaptive regression splines), кубічні сплайни (Cubic Splines), неоднорідні раціональні B-сплайни NURBs (Non-uniform rational B-splines), МГУА-моделі (методу групового урахування аргументів) [4–6]. Усі ці моделі апіорі передбачають певний спеціальний вид апроксимуючої залежності. Для них характерні специфічні проблеми, пов'язані з вибором розмірності моделей та функціональних базисів, оптимізацією структури моделей (за винятком МГУА-моделей, структура яких індуктивно визначається в процесі самоорганізації), неможливістю використання довільних нелінійних суперпозицій базових функцій, що заважає отриманню моделей оптимальної складності, які є одночасно достатньо точними.

До другої групи можна віднести стохастичні метамоделі, серед яких найбільш відомими є моделі на радіально-базисних функціях RBF (Radial Basis Function Models) та моделі на гаусівських процесах GPM (Gaussian Process Models) або Kriging-моделі [4, 7, 8]. Для Kriging-моделей при обчисленнях їхнього виходу виникає необхідність матричних

перетворень, що зі зростанням розмірності задачі значно збільшує час розрахунків. Як і в моделях попередньої групи, для моделей цієї групи є характерним використання тільки однорідних базисних функцій, а не їх комбінацій, що накладає певні обмеження на створення ефективних за точністю та обчислювальними властивостями апроксиматорів. Визначення апроксимаційних коефіцієнтів для цих моделей є досить трудомістким.

Третя група методів створення метамodelей включає до себе такі, які ґрунтуються на евристичній парадигмі [7, 8]. Останнім часом найчастіше використовуються моделі на штучних нейронних мережах ANN (Artificial Neural Networks), зокрема на радіально-базисних функціях RBF-ANN та багат шарових перцептронах MLP-ANN, а також моделі на опорних векторах SVR (Support Vector Regression Models). Особливої уваги як універсальні апроксиматори заслуговують штучні нейронні мережі, що характеризуються важливою здатністю до узагальнення інформації. Вони дозволяють для обраного типу базової моделі відшукати таку сукупність параметрів, що забезпечить високу точність відтворення досліджуваної гіперповерхні на всій області визначення. До того ж складність структури ANN значно менше залежить від розмірності апроксимованої функції, за необхідності мережа може швидко доучитися у разі надходження нових навчальних даних. Досить великий вибір можливих варіантів нелінійних функцій активації нейронів та їх комбінацій суттєво поширює апроксимаційні властивості ANN-метамodelей. Перевагою таких сурогатних моделей є також стійкість до даних, спотворених шумами, та до помірних змін побічних параметрів, що не є шуканими при розв'язку оберненої задачі.

Таким чином, проведений критичний аналіз методів створення метамodelей дозволив визначитися щодо вибору нейромережевого методу створення ефективної сурогатної моделі процесу вихрострумовевого контролю для накопичування апіорної інформації з метою ідентифікації приповерхневих профілів розподілу електрофізичних характеристик ОК. При цьому ефективною буде-

мо вважати метамодель, що, залишаючись не затратною в обчислювальному сенсі, з максимально можливою точністю відтворює топологію гіперповерхні відгуку.

Постановка проблеми

У [3] для розв'язку оберненої задачі оптимізаційним методом було сформовано демонстраційну вибірку навчальних даних значень напруги вихрострумowego перетворювача (ВСП), отриманих у результаті обчислювальних експериментів з використанням “точної” електродинамічної моделі процесу вимірювального контролю електромагнітним методом відповідно до запропонованого комп'ютерного плану експерименту. Для побудови метамоделі збільшимо обсяг даних у табл. 1 “входи-виходи” до 1024, зробивши вибірку репрезентативною. Вибірка забезпечує необхідну для проведення багатопараметрових вимірювань умову надлишковості експериментальних даних. Збільшення кількості відгуків, тобто виходів, досягається шляхом імітації вимірювань при варіюванні вхідних впливів та в загальному випадку й змінах умов вимірювання. Слід нагадати, що напруга, індукована у вимірювальній котушці ВСП, є функцією зміни ЕП та МП у відповідності до одного із можливих радіальних профілів їх розподілу [3] при сталому значенні частоти збудження. Безумовно значно більший практичний інтерес являє залежність напруги ВСП від чотирьох змінних, коли серед її аргументів фігурують ще частота збудження вихрових струмів та діаметр циліндричного ОК, локальні можливі зміни якого імітують варіювання зазору між вимірювальною котушкою та ОК, надаючи ще й можливість визначення засобами ідентифікації цього параметру при вимірюваннях. Така постановка є більш загальною, але й більш складною. Тому на початковому етапі обмежимося спрощеним варіантом формулювання досліджуваної задачі, що обумовлено значно простішим процесом верифікації моделювання, проте це не виключає повернення надалі до більш адекватного її формулювання.

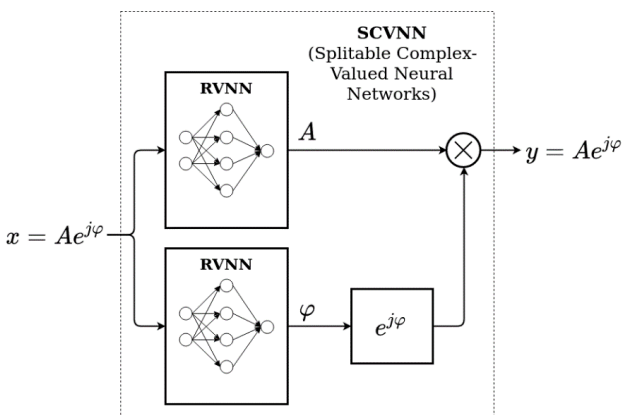


Рис. 2. Архітектура комплексозначної штучної нейронної мережі

Певні ускладнення викликає також той факт, що напругу ВСП подано комплексними числами, тобто вона характеризується модулем та фазою. Зазвичай нейронні мережі в їх класичному варіанті використання оперують дійсними числами, що вимагає в цьому дослідженні дещо інших підходів їх застосування, які відрізняються від загальноприйнятих. Наприклад, використовувати комплексозначні нейронні мережі CVNNs (Complex-Valued Neural Networks) або комплексозначні нейронні мережі SCVNNs (Splitable Complex-Valued Neural Networks), які розщеплюються. Відзначимо, що для регресійних комплексозначних нейронних мереж входи, вихід, зміщення та синаптичні ваги мають комплексні значення. Для комплексозначних мереж, що розщеплюються, зазвичай використовують дійснозначні мережі окремо для реальної та уявної частин вхідних сигналів із наступним об'єднанням у комплексний вихід. Використання комплексозначних нейронних мереж у дослідженнях, що вимагають розрахунки величин, які подаються комплексними числами, є більш природним із математичної точки зору та демонструє кращі результати в порівнянні з дійснозначними нейронними мережами, але є більш складним у реалізації [9].

Тоді мета цього дослідження полягає у створенні на основі MLP-нейромережевої технології високопродуктивної в обчислювальному сенсі багатовимірної комплексозначної сурогатної моделі процесу вихрострумowego контролю циліндричного об'єкта прохідним перетворювачем, що забезпечує високу точність апроксимації відповідної “точної” електродинамічної моделі та накопичення апріорної інформації щодо випробувань при варіюванні суттєвими вхідними параметрами.

Виклад основного матеріалу

Архітектура комплексозначної штучної нейронної мережі SCVNNs, яка використовується в цих дослідженнях, ілюструється на рис. 2. До певних особливостей досліджень слід віднести дій-




Рис. 3. Структура регресійної двохарової дійснозначної штучної MLP-нейронної мережі

Загальна вибірка індукованої напруги $\hat{y} = U$ у вимірювальному витку прохідного ВСП при частоті струму збудження $2,5 \times 10^3$ Гц

№ п/п	Провідність $\times 10^6$, См/м $x_1 = \sigma$	Відносна магнітна проникність $x_2 = \mu_r$	Амплітуда напруги у вимірювальному витку $\times 10^{-2}$, В	Фаза напруги у вимірювальному витку, рад
1	3,49500	10,00000	2,98097	1,45573
2	3,75713	9,25000	2,91591	1,45260
3	3,23288	10,75000	3,04545	1,45901
4	3,62606	10,37500	3,00729	1,45474
5	3,10181	8,87500	2,89974	1,45809
...
1020	2,97587	10,63574	3,04257	1,46162
1021	3,50012	9,13574	2,91228	1,45480
1022	3,76224	11,38574	3,08158	1,45380
1023	3,23799	9,88574	2,97772	1,45814
1024	3,62862	8,89111	2,88989	1,45336

снозначні входи мережі, що є окремим випадком більш загального комплексного їх подання, який наведено на цьому рисунку, та комплексозначний вихід мережі (див. табл. 1).

Для реалізації регресійної комплексозначної штучної нейронної мережі застосовувалися дві окремі дійснозначні мережі RVNNs (Real-Valued Neural Networks) прямого поширення з навчанням методом зворотного розповсюдження похибки (Back Propagation) для визначення оптимальних наборів вагових коефіцієнтів [10].

У більшості випадків двох-трьох прихованих шарів (рис. 3) цілком достатньо для адекватної апроксимації будь-якої неперервної нелінійної гіперповерхні відгуку, що доведено теоретично [10]. Вихідний відгук k -шарової нейромережі, необхідної для нелінійних задач апроксимації, визначається за такими формулами для вихідних значень нейронів відповідно:

$$a_j^{(1)} = f^{(1)} \left(w_{0,j}^{(1)} + \sum_{i=1}^{N^{(Input\ layer)}} x_i w_{i,j}^{(1)} \right), j = 1..N^{(1)};$$

$$a_j^{(k)} = f^{(k)} \left(w_{0,j}^{(k)} + \sum_{i=1}^{N^{(k-1)}} a_i^{(k-1)} w_{i,j}^{(k)} \right), j = 1..N^{(k)};$$

$$k = 2, \dots, Output\ layer; y = a^{(Output\ layer)},$$

де x – вектор вхідних даних; $w^{(k)}$ – вагові коефіцієнти k -го прихованого шару; $w_0^{(k)}$ – зміщення шару нейронів; $N^{(Input\ layer)}$, $N^{(k)}$ – кількість нейронів відповідно вхідного та прихованого шарів; $f^{(k)}$ – функція активації шару нейронів (важиться, що функція активації для всіх нейронів у шарі однакова); $a^{(Output\ layer)}$ – вихід останнього шару нейронної мережі з одиничною функцією активації.

У наведених формулах враховується факт того, що кількість нейронів у різних шарах нейромережі не є однаковою. Вхідні дані для створення метамоделі, отримані за методикою, що викладено у [3], містяться у табл. 1. Вибірка попередньо довільно розділялася на три частини: навчальну (64%), тестову (16%), контрольну (20%). Навчальна частина загальної вибірки даних (Training Set) використовувалася в процесі навчання, в той час коли тестова частина вибірки (Test Set) – винятково для розрахунку похибки апроксимації, тобто застосовувався механізм контрольної крос-валідації для недопущення ефекту “перенавчання” (Overfitting). Одночасне спостереження за зміною в динаміці похибки навчання та похибки валідації на тестових даних дозволило не тільки фіксувати факт “перенавчання” та вчасно зупинити процес підгонки (Early Stopping), але й за необхідності регулювати конфігурацію мережі в сенсі модифікації кількості нейронів у прихованих шарах, забезпечуючи здатність мережі узагальнювати результат на нові вибіркові дані.

Попередньо перед процедурою навчання мережі виконувалося нормування початкових даних з метою приведення їх до єдиної шкали. Для навчання нейромереж застосовувалися сучасні стохастичні оптимізаційні методи градієнтного спуску із накопиченням імпульсу: Adam (Adaptive Moment Estimation), Нестерова (Nesterov accelerated gradient), Adagrad (Adaptive Gradient).

Вибір найкращих мереж із множини їх варіантів здійснювався перевіркою на контрольній частині вибірки (Control Set). У результаті така стратегія дозволяє мінімізувати не похибку навчання, а досягти мінімізації похибки узагальнення, що значно важливіше.

Адекватність побудованих нейромереж зручно контролювати певною сукупністю об'єктивних показників [11], серед яких першочергово слід відзначити продуктивність, що обчислюється за такою формулою:

$$ex = \frac{100}{m} \sum_{i=1}^m \left(1 - \left| \frac{\hat{y}_i - y_i}{\hat{y}_i} \right| \right),$$

де m – кількість зразків даних для перевірки; \hat{y} – бажаний вихід мережі; y – вихід мережі при верифікації за створеною метамоделлю.

Серед інших показників валідації мереж є поширеними середнє абсолютне значення похибки моделі MAE (Mean Absolute Error), середньоквадратична похибка MSE (Mean Square Error), RMSE (Root Mean Square Error), гістограма розподілу залишків, діаграма розсіювання тощо:

$$MAE = \frac{\sum_{i=1}^m |y_i - \hat{y}_i|}{m},$$

$$MSE = \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{m},$$

$$RMSE = \sqrt{MSE}.$$

Обчислювальна технологія побудови метамоделей [12, 13], що включає планування комп'ютерного експерименту, формування репрезентативної вибірки, створення ефективної нейромережевої сурогатної моделі та перевірки її валідності, вже досить повно теоретично опрацьована та добре зарекомендувала себе в багатьох технічних додатках для розв'язку обернених задач.

Моделювання виконувалося в середовищі програмування Python 3 та з використанням відкритої бібліотеки Keras (Tensorflow backend). При чисельних експериментах мережі з найкращою продуктивністю було отримано при навчанні оптимізаційним методом Adam. Це метод стохастичного градієнтного спуску, який базується на адаптивній оцінці моментів першого та другого порядку. Цей метод є ефективним в обчислювальному відношенні та потребує незначних ресурсів пам'яті [14]. В результаті моделювання отримано нейронні мережі відповідно для амплітуди та фази вихідного сигналу ВСП із такими структурами: 2-25(Sigmoid)-25(ReLU)-25(ReLU)-1 та 2-12(Sigmoid)-12(ReLU)-12(ReLU)-1, де Sigmoid – логістична функція активації нейронів, а ReLU (Rectified Linear Unit) – функція активації, яка реалізує простий пороговий перехід у нулі, тобто повертає значення аргументу, якщо він позитивний, і 0 в іншому випадку. Об'єктивні чисельні показники, що характеризують обидві нейромережі, мають такі значення: продуктивності (ex) 98,89% та 94,05%, абсолютні похибки (MAE) 0,0059041 та 0,0218162, середньоквадратичні похибки (MSE) $8,1368052 \times 10^{-5}$ та $7,5470167 \times 10^{-4}$.

Результати верифікаційних обчислень з використанням створеної метамоделі на даних контрольної вибірки, яка взагалі не використовувалася на етапі побудови сурогатної моделі, наведено в табл. 2.

Порівняльний аналіз отриманих результатів свідчить про досить точну апроксимацію нелінійних поверхонь відгуку та відповідну адекватність побудованих дійснозначних метамоделей.

Таблиця 2

Результати апроксимації вихідного сигналу $\hat{y} = U$ прохідного ВСП на даних контрольної вибірки

№ п/п	Номер елемента загальної вибірки	Провідність $\times 10^6$, См/м x_1	Відносна магнітна проникність x_2	“Точне” значення амплітуди $\times 10^{-2}$, В	Результат апроксимації амплітуди $\times 10^{-2}$, В	“Точне” значення фази, рад	Результат апроксимації фази, рад
1	9	3,167	9,81	2,97350	2,97352	1,45875	1,45867
2	11	3,298	10,19	3,00011	3,00035	1,45784	1,45786
3	19	3,135	11,03	3,06949	3,06895	1,46029	1,46028
4	23	3,462	9,34	2,92973	2,92970	1,45539	1,45546
5	28	3,331	9,72	2,96243	2,96229	1,45705	1,45711
...
201	985	3,680	10,31	3,00082	3,00126	1,45416	1,45420
202	989	3,025	9,18	2,92628	2,92628	1,45928	1,45925
203	1 000	3,664	11,29	3,07683	3,07683	1,45480	1,45479
204	1 004	3,009	9,42	2,94548	2,94584	1,45978	1,45981
205	1 007	3,304	8,95	2,90138	2,90092	1,45635	1,45643




Рис. 4. Діаграма розсіювання для амплітуди сигналу




Рис. 5. Гістограма розподілу абсолютної похибки при апроксимації амплітуди сигналу




Рис. 6. Діаграма розсіювання для фази сигналу




Рис. 7. Гістограма розподілу абсолютної похибки при апроксимації фази сигналу

На рис. 4–7 ілюструються діаграми розсіювання та гістограми розподілу абсолютних похибок відповідно для амплітуд і фаз індукованої у вимірювальному витку напруги ВСП, що отримані з використанням створених метамоделей на даних контрольної вибірки. Наведений наочний графічний матеріал також переконливо підтверджує достатньо високі апроксимаційні можливості створених сурогатних моделей.

Висновки

Таким чином, використовуючи нейромережевий метод багатовимірної апроксимації

гіперповерхні відгуку, побудовано адекватну комплексозначну сурогатну MLP-модель процесу вихрострумовевого контролю циліндричного слабомагнітного ОК прохідним перетворювачем. Сурогатна модель виконує функції носія апріорних знань щодо ОК, забезпечує високу обчислювальну ефективність та незначні часові затрати на розрахунки, що дозволяє розв'язувати задачу параметричної ідентифікації радіальних приповерхневих профілів електрофізичних характеристик ОК у реальному часі в процесі виконання вимірювальних операцій.

Создание суррогатной модели для восстановления приповерхностных профилей электрофизических характеристик цилиндрических объектов

В.Я. Гальченко, А.В. Сторчак, Р.В. Трёмбовецька, В.В. Тичков

Черкаський державний технологічний університет, бул. Шевченко, 460, 18006, Черкаси, Україна
v.tychkov@chdtu.edu.ua

Аннотация

Показан один из этапов решения многопараметрической обратной задачи вихрековых измерений для идентификации радиальных профилей электрофизических характеристик цилиндрических объектов контроля аппроксимационным методом. Метод предусматривает использование априорной информации об испытаниях объектов контроля цилиндрической формы, полученной путем математического моделирования с применением “точной” электродинамической модели Uzal-Dodd-Deeds. Предложено в качестве носителя априорной информации использовать высокопроизводительную в вычислительном смысле суррогатную модель процесса контроля. Из известных методов выбран нейросетевой для создания метамодели. Отмечена необходимость использования комплексозначных нейронных сетей, а также указаны пути решения этой проблемы. Метамодели созданы на базе расщепляемых комплексозначных нейронных сетей. Приведены объективные численные статистические показатели для проверки адекватности метамodelей. Выполнена верификация созданных суррогатных моделей и проведена оценка точности аппроксимации поверхностей отклика. Указаны пути обобщения метода на более сложные случаи создания метамodelей для измерительных задач, характеризующихся наличием гиперповерхностей отклика с большей размерностью пространства, акцентировано внимание на универсальности подхода, приемлемого для практически любой сложной топологии гиперповерхности.

Ключевые слова: электрофизические характеристики; вихрековые измерения; радиальный профиль; идентификация; суррогатная модель.

The creation of a surrogate model for restoring surface profiles of the electrophysical characteristics of cylindrical objects

V. Halchenko, A. Storchak, R. Trembovetska, V. Tychkov

Cherkasy State Technological University, Shevchenko Blvd., 460, 18006, Cherkasy, Ukraine
v.tychkov@chdtu.edu.ua

Abstract

One of the stages of solving the multi-parameter inverse problem of eddy current measurements for identification of the radial profiles of the electrophysical characteristics of the cylindrical control objects by the approximation method is shown. The method involves the use of a priori information on testing cylindrical control objects obtained by mathematical modelling using the “accurate” Uzal-Dodd-Deeds electrodynamic model. It is proposed to use a high-performance, in a computational sense, surrogate model of the control process as a carrier of a priori information. The analysis of methods of constructing surrogate models is carried out, and, taking into account the identified advantages in the framework of the research, the neural network method of creating metamodels is selected. The characteristic features for the construction of metamodels, consisting in the need to use complex-valued neural networks, are noted, as well as ways to solve this problem are indicated. Metamodels are based on split complex-valued neural networks. The computational technology for constructing surrogate models in the Python 3 environment using the Keras open-source library has been debugged. The objective numerical statistical indicators to verify the adequacy of metamodels are presented. Based on specific data, the created surrogate models are verified and the accuracy of the approximation of the response surfaces is estimated using the previously presented indicators. Ways of generalizing the method to more complicated cases of creating metamodels

for measuring problems characterized by the presence of response hypersurfaces with a greater dimensionality of space are indicated. Attention is focused on the universality of the approach acceptable for almost any complex hypersurface topology.

Keywords: electrophysical characteristics; eddy current measurements; radial profile; identification; surrogate model.

Список літератури

1. Ida N., Meyendorf N. Handbook of Advanced Nondestructive Evaluation. Springer International Publishing, 2019. 1626 p.
2. Беда П.И., Сапунов В.М., Поляков А.И., Путников Ю.Г. Методические рекомендации по применению вихретоковых измерителей электрической проводимости для контроля свойств немагнитных материалов деталей авиационной техники. Люберцы, 13 ГНИИ Минобороны России. Вып. № 6519. 1992. 108 с. URL: <https://ru.b-ok2.org/book/2995249/84367d>
3. Гальченко В.Я., Тичков В.В., Сторчак А.В., Трёмбовецька Р.В. Відновлення приповерхневих радіальних профілів електрофізичних характеристик циліндричних об'єктів при вихрострумових вимірюваннях із наявністю апріорних даних. Формування вибірки для побудови сурогатної моделі. *Український метрологічний журнал*. 2020. № 1. С. 35–50. doi: <https://doi.org/10.24027/2306-7039.1.2020.204226>
4. Queipo N.V., Haftka R.T., Shyy W., Goel T., Vaidyanathan R., Tucker P.K. Surrogate-based analysis and optimization. *Progress in Aerospace Sciences*, 2005, no. 1 (41), pp. 1–28. doi:10.1016/j.paerosci.2005.02.001
5. Lenth R.V. Response-Surface Methods in R, Using rsm. *Journal of Statistical Software*, 2009, vol. 32, issue 7, pp. 1–17.
6. Bartz-Beielstein T., Naujoks B., Stork J., Zaeferrer M. Tutorial on surrogate-assisted modelling. D1.2. Synergy for Smart Multi-Objective Optimization (31 October 2016). Horizon 2020 – GA № 692286. 65 p. URL: <http://synergy-twinning.eu/files/synergy-d12-161110-0559.pdf>
7. Jiang P., Zhou Q., Shao X. Surrogate Model-Based Engineering Design and Optimization. Singapore, Springer, 2020. 240 p.
8. Forrester A.I.J., Sobester A., Keane A.J. Engineering Design via Surrogate Modelling: A Practical Guide. Chichester, Wiley, 2008. 228 p.
9. Dramsch J.S., Lüthje M., Christensen A.N. Complex-valued neural networks for machine learning on non-stationary physical data. URL: <https://arxiv.org/abs/1905.12321>
10. Руденко О.Г., Бодяньський Є.В. Штучні нейронні мережі: навч. посіб. Харків: ТОВ “Компанія СМІТ”, 2006. 404 с.
11. Джулли А., Пал С. Библиотека Keras – инструмент глубокого обучения. Реализация нейронных сетей с помощью библиотек Theano и TensorFlow. Пер. с англ. Слинкина А.А. Москва: ДМК Пресс, 2018. 294 с.
12. Halchenko V.Ya., Trembovetska R.V., Tychkov V.V., Storchak A.V. Nonlinear surrogate synthesis of the surface circular eddy current probes. *Przegląd elektrotechniczny*, 2019, no. 9, pp. 76–82. doi: 10.15199/48.2019.09.15
13. Halchenko V.Ya., Trembovetska R.V., Tychkov V.V. Development of excitation structure RBF-metamodels of moving concentric eddy current probe. *Electrical Engineering & Electromechanics*, 2019, no. 2, pp. 28–38. doi: 10.20998/2074-272X.2019.2.05
14. Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization. URL: <https://arxiv.org/abs/1412.6980>

References

1. Ida N., Meyendorf N. Handbook of Advanced Nondestructive Evaluation. Springer International Publishing, 2019. 1626 p.
2. Beda P.I., Sapunov V.M., Poljakov A.I., Putnikov Ju.G. Metodicheskie rekomendacii po primeneniju vihretokovyh izmeritelej jelektricheskoj provodimosti dlja kontrolja svojstv nemagnitnyh materialov detalej aviacionnoj tehniky [Guidelines for the use of eddy current conductivity meters to control the properties of non-magnetic materials of parts of aircraft]. 13th Research Institute of the Ministry of Defense of Russia. Lyubertsy, 1992, no. 6519, 108 p. Available at: <https://ru.b-ok2.org/book/2995249/84367d> (in Russian).
3. Halchenko V., Tychkov V., Storchak A., Trembovetska R. Vidnovlennja pry poverhnevyyh radial'nyh profiliv elektrofizychnyyh harakterystyk cylindrychnyyh ob'ektiv pry vyhrostrumovyh vymirjuvannjah iz najavnistju apriornyyh danyh. Formuvannja vybirky dlja pobudovy surogatnoi' modeli [Reconstruction of surface radial profiles of the electrophysical characteristics of cylindrical objects during eddy current measurements with a priori data. The selection formation for the surrogate model construction]. *Ukrainian Metrological Journal*, 2020, no. 1. pp. 35–50. doi: <https://doi.org/10.24027/2306-7039.1.2020.204226> (in Ukrainian).

4. Queipo N.V., Haftka R.T., Shyy W., Goel T., Vaidyanathan R., Tucker P.K. Surrogate-based analysis and optimization. *Progress in Aerospace Sciences*, 2005, no. 1 (41), pp. 1–28. doi:10.1016/j.paerosci.2005.02.001
5. Lenth R.V. Response-Surface Methods in R, Using rsm. *Journal of Statistical Software*, 2009, vol. 32, issue 7, pp. 1–17.
6. Bartz-Beielstein T., Naujoks B., Stork J., Zaeferrer M. Tutorial on surrogate-assisted modelling. D1.2. Synergy for Smart Multi-Objective Optimisation (31 October 2016). Horizon 2020 – GA № 692286. 65 p. Available at: <http://synergy-twinning.eu/files/synergy-d12-161110-0559.pdf>
7. Jiang P., Zhou Q., Shao X. Surrogate Model-Based Engineering Design and Optimization. Singapore, Springer, 2020. 240 p.
8. Forrester A.I.J., Sobester A., Keane A.J. Engineering Design Via Surrogate Modelling: A Practical Guide. Chichester, Wiley, 2008. 228 p.
9. Dramsch J.S., Lüthje M., Christensen A.N. Complex-valued neural networks for machine learning on non-stationary physical data. Available at: <https://arxiv.org/abs/1905.12321>
10. Rudenko O.G., Bodjans'kyj Je.V. Shtuchni neyronni merezhi [Artificial neural networks]. Kharkiv, Kompanija SMIT Publ., 2006. 404 p. (in Ukrainian).
11. Dzhulli A., Pal S. Biblioteka Keras – instrument glubokogo obuchenija. Realizacija neyronnyh setej s pomoshh'ju bibliotek Theano i TensorFlow [Keras Library – A Deep Learning Tool. Implementation of neural networks using Theano and TensorFlow libraries]. Moscow, DMK Press Publ., 2018. 294 p. (in Russian).
12. Halchenko V.Ya., Trembovetska R.V., Tychkov V.V., Storchak A.V. Nonlinear surrogate synthesis of the surface circular eddy current probes. *Przegląd elektrotechniczny*, 2019, no. 9, pp. 76–82. doi: 10.15199/48.2019.09.15
13. Halchenko V.Ya., Trembovetska R.V., Tychkov V.V. Development of excitation structure RBF-meta-models of moving concentric eddy current probe. *Electrical Engineering & Electromechanics*, 2019, no. 2, pp. 28–38. doi: 10.20998/2074-272X.2019.2.05
14. Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization. Available at: <https://arxiv.org/abs/1412.6980>