

DOI 10.15421/4222218
УДК 539.3

*Р. О. Щербак, А. Є. Шевельова, д-р фіз.-мат. наук,
Т. В. Ходанен, канд. фіз.-мат. наук*

ВИКОРИСТАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ ДОВГОВІЧНОСТІ ЕЛЕМЕНТІВ КОНСТРУКЦІЙ

Розглянуто задачу прогнозування швидкості росту втомних тріщин в алюмінієвому сплаві 2024-T351 з використанням нейронних мереж. Реалізовано два алгоритми методів машинного навчання – генетичний та зворотного поширення помилки. Побудовано криві навчання для обох алгоритмів і отримано числові результати для задачі прогнозування швидкості росту втомних тріщин на основні експериментальних даних про її залежність від коефіцієнту інтенсивності напружень та величини циклічних навантажень. Проведено порівняння цих алгоритмів за значеннями похибки та часу навчання, визначено перевагу алгоритму зворотного поширення помилки у швидкості навчання та збіжності до оптимального результату.

Ключові слова: циклічне навантаження; втомні тріщини; коефіцієнт інтенсивності напружень; нейронні мережі; методи машинного навчання; генетичний алгоритм; алгоритм зворотного поширення помилки.

Вступ. У багатьох елементах конструкцій руйнування виникає через втому, поступове накопичення пошкоджень і розпочинається з невеликої тріщини, яка росте під дією повторно-змінного (циклічного) навантаження. Втомні тріщини утворюються переважно в області концентраторів механічних напружень. Основними факторами, що можуть прискорювати руйнування елементів конструкцій при довготривалій експлуатації, є дефекти поверхні, температура та інші зовнішні чинники, характер та умови навантаження.

Зростання втомних тріщин було предметом досліджень як у роботах зарубіжних, так і вітчизняних авторів, зокрема, Н. А. Richard, М. Sander [7], П. В. Яснія [1]. Незважаючи на численні спостереження і літературні дані прогнозування росту втомних тріщин здебільшого засновано на експериментальних даних і практичному досвіді. У [8, 2, 5] наведено деякі математичні моделі росту втомних тріщин (Періса, Вокера, Формана) як залежність швидкості їхнього росту від амплітуди коефіцієнтів інтенсивності напружень (KIH) при циклічних навантаженнях.

Встановлення відповідності цих моделей експериментальним даним є складним і вартісним. Тому існує потреба розв'язувати такі задачі механіки руйнування іншими методами, зокрема із застосуванням нейронних мереж та машинного навчання, що дозволяє отримати задові-

льні результати, спростивши розрахунки та передавши їх виконання обраному методу.

Руйнування елементів конструкцій зі сплаву алюмінію було досліджено в авіаційній галузі, де вони найширше застосовуються. Тому найбільш повні експериментальні дані щодо утворення тріщин представлено саме за цими матеріалами [6]. Новий підхід – використання нейронних мереж для прогнозування росту тріщини в алюмінієвому сплаві D16chT під дією циклічного навантаження – застосовано І. Дідич, О. Пастухом, Ю. Пиндусом, О. Яснієм у [3].

У даній роботі проведено порівняння генетичного алгоритму та алгоритму зворотного поширення помилки для навчання нейронної мережі для визначення швидкості росту втомних тріщин на базі вибірки, що містить залежність цієї швидкості від параметрів величини циклічного навантаження та пристоу коефіцієнта інтенсивності напружень.

Основні моделі росту втомних тріщин. Основна мета задачі про зростання втомних тріщин – визначення тривалості роботи чи довговічності відповідного елемента конструкції. Наразі не існує єдиної достатньо точної моделі, що дозволяє визначати швидкість росту втомних тріщин в елементах конструкцій та визначати їхню залишкову довговічність. Зазвичай спочатку тріщини зростають стабільно, тобто з кожним циклом навантаження розмір тріщини збільшується несуттєво. Після певної критичної кількості циклів навантаження тріщина починає зростати нестабільно, що призводить до втрати елементом конструкції придатності до експлуатації [7].

Швидкість росту тріщини не є сталою в часі, а збільшується залежно від інтенсивності навантаження та розміру самої тріщини. Однією з найвідоміших моделей росту втомних тріщин є закон (або модель) Періса, що має вигляд формули:

$$\frac{da}{dN} = C\Delta K^m, \quad \Delta K_{\text{порогове}} < \Delta K < K_{Ic},$$

де a – довжина тріщини; N – кількість циклів навантаження; $\Delta K_{\text{порогове}}$ – порогове значення втомлюваності; K_{Ic} – критичний проміжок стійкості матеріалу до розламування; C та m – так звані сталі Періса.

Закон Періса дає задовільні результати (у порівнянні з експериментом) для значень росту втомної тріщини від $10^{-8} \frac{\text{мм}}{\text{цикл}}$ до $10^{-6} \frac{\text{мм}}{\text{цикл}}$, однак, здебільшого ці значення визначаються з характеристик матеріалу [8].

Модель (або закон) Вокера – модифікація закону Періса, що включає додатковий параметр – величину циклічного навантаження R , яка відсутня у формулах закону Періса. Причому $R = \frac{\sigma_{\min}}{\sigma_{\max}}$, де σ_{\min} і σ_{\max} – найменше та найбільше навантаження протягом одного циклу.

Закон Вокера має вигляд:

$$\frac{da}{dN} = C_w \left(\overline{\Delta K}_w^m \right),$$

де

$$\overline{\Delta K} = K_{max}(1 - R)^{\gamma_w},$$

а $K_{max} = \frac{\Delta K}{(1-R)}$, або

$$\frac{da}{dN} = C_w \left(\frac{\Delta K}{(1 - R)^{1-\gamma_w}} \right)^{m_w}.$$

Модель Вокера дозволяє ввести до розгляду значення R , однак потрєбує введення третього параметру для наближення до кривої залежності $\frac{da}{dN}$ до $\Delta K - \gamma_w$ [2].

Закон Періса є однією з найпростіших та найпоширеніших моделей, однак вона не включає багато факторів, що впливають на зростання втомних тріщин. Наприклад, немає можливості моделювати граничну область росту втомної тріщини, або ж пришвидшення росту тріщини в місцях, де КІН наближається до значень критичного проміжку значень КІН – K_{Ic} .

Існують й інші, більш точні й ускладнені моделі. Наприклад, модель Формана:

$$\frac{da}{dN} = \frac{C_F(\Delta K)^{m_F}}{(1 - R)K_{Ic} - \Delta K'}$$

де C_F та m_F – параметри, визначені матеріалом; K_{Ic} – критичний проміжок значень КІН.

Якщо ці параметри відомі, модель Формана може бути застосована для моделювання асиметричності навантажень та ефектів прискорення росту втомних тріщин у проміжку значень КІН, що наближається до критичного [5].

Машинне навчання. Машинне навчання – це галузь штучного інтелекту, мета якої є розробка методів, що втілюватимуть різноманітні форми навчання, особливо механізми, що здатні утворювати знання, базуючись на прикладах або даних. Основними методами машинного навчання [4] є кероване навчання (або навчання з учителем), навчання без учителя і навчання з підкріпленням.

Нейронні мережі – це нелінійні математичні засоби, що симулюють обробку інформації людським мозком за допомогою простих об'єктів (штучних нейронів), установлених у структури (шари). Для одношарових нейронних мереж вхід x^t , заданий як вектор ознак $x^t = (\overline{x_1}, \overline{x_n})$, обробляється нейронами за допомогою ваг $w_i, i = \overline{1, n}$, що видає z , який приводить до фінального результату y з використанням функції активації $\varphi, y = \varphi(z)$. Обробка відбувається за допомогою функції передачі, яку найчастіше використовують як оператор зваженої суми, однак за потреби можливі й альтернативні варіанти. Процедура в загальному випадку задається таким чином:

$$z = \sum_{i=1}^n w_i x_i + b = w^t x + b,$$

або

$$z = wx + b,$$

де b – зміщення (bias) – спроба імітувати людський фільтр, що дозволяє пристосувати отримані дані до необхідних потреб.

Отже, будь-який штучний нейрон можна розглядати як математичну функцію, що призводить до виходу y , послідовно застосовуючи лінійну функцію передачі та нелінійну активаційну функцію на входах

$$x_i, \quad i = \overline{1, n}, \quad y = \varphi(z).$$

Найчастіше налаштовують (навчають) нейронні мережі, мінімізуючи функцію помилки (інколи звану функцією вартості чи функцією втрати) $E(w)$. Загалом ця функція обчислює різницю між очікуваними (\hat{y}) та отриманими (y) виходами нейронної мережі.

Постановка задачі. Швидкість зростання тріщини задано за допомогою рівняння:

$$\frac{da}{dN} = f(\Delta K, R),$$

де N – кількість циклів навантаження; a – довжина тріщини; $\Delta K = K_{max} - K_{min}$, (K_{max} і K_{min} – найбільше та найменше значення КІН, відповідно); $R = \frac{\sigma_{min}}{\sigma_{max}}$, де σ_{min} і σ_{max} – найменше та найбільше навантаження протягом одного циклу.

КІН задано формулою:

$$K = \sigma \sqrt{\pi a} Y,$$

де Y – функція виправлення, що залежить від геометрії структури та самої тріщини [6].

Необхідно побудувати нейронну мережу, що моделює зростання втомних тріщин при циклічному навантаженні, на вхідній вибірці даних, поділеній на навчальну, що бере безпосередню участь у налаштуванні мережі, і тестову, що застосовується для перевірки результатів налаштування, порівняти між собою два алгоритми навчання, що застосовуються у нейронних мережах, – зворотного поширення помилки та генетичний, та оцінити ефективність обох алгоритмів.

Таким чином, задача полягає у визначенні залежності швидкості зростання втомної тріщини $\frac{da}{dN}$ від величини циклічного навантаження R та проміжку значень КІН ΔK на вибірці зі 114 значень для алюмінієвого сплаву 2024-T351 [9].

Застосування методів машинного навчання для розв'язання задачі. Програма, написана мовою Python, складається з 9 модулів, кожен із яких міститься в окремому файлі та реалізує різні функції, що відповідають за отримання даних із файлу вибірки, створення та навчання нейронної мережі: 1) main – задання параметрів, запуск необхідні для роботи функції інших модулів; 2) get_data – отримання вибірки даних, активаційних функцій; 3) neuron_class – клас, що втілює необхідні операції для роботи нейронів мережі; 4) create_network – побудова нейронної мережі; 5) calculations – проведення обчислень, навчання, виведення результатів, створення графіків; 6) genetic_algorithm_functions – необхідні для генетичного алгоритму функції; 7) backpropagation_functions – необхідні для алгоритму зворотного поширення помилки функції; 8) learning_algorithms – навчання мережі; 9) activation_functions – зберігання активаційних функцій.

Для програми було задано параметри мінімальної похибки мережі, при досягненні якої навчання вважається завершеним (0,01), кількості епох навчання мережі, при досягненні якої навчання вважається завершеним (200), мінімальної початкової ваги нейронів (1), максимальної початкової ваги нейронів (1), коефіцієнту навчання нейронної мережі для алгоритму зворотного поширення помилки (0,005), імовірності схрещування в генетичному алгоритмі (0,75), імовірності мутації в генетичному алгоритмі (0,25), довжини популяції кожного покоління в генетичному алгоритмі (100).

Після запуску програма надає інформацію про кількість утворених рівнів нейронної мережі та кількість нейронів на кожному з них. Далі розпочинається навчання за допомогою алгоритму зворотного поширення помилки. Після його завершення на екран виводяться середньоквадратичні похибки на навчальній і тестовій вибірках та будуються три графіки: порівняння очікуваного й отриманого результату на навчальній вибірці, крива навчання мережі та порівняння очікуваного й отриманого результатів.

Далі розпочинається навчання за допомогою генетичного алгоритму. Після його завершення на екран виводиться відповідна порівняльна інформація, як і на попередньому етапі.

Результати розрахунку за генетичним алгоритмом та алгоритмом зворотного поширення помилки. Найкращі результати протягом тестування було отримано на мережі з двома проміжними шарами, що містять два та один нейрони, відповідно. Активаційна функція нейронів проміжних шарів – гіперболічний тангенс.

Після навчання за допомогою алгоритму зворотного поширення помилки, було отримано значення похибки мережі на навчальній вибірці, яка дорівнює 0,051. Порівняння результатів роботи мережі з очікуваним результатом на навчальній вибірці продемонстровано на рис. 1.

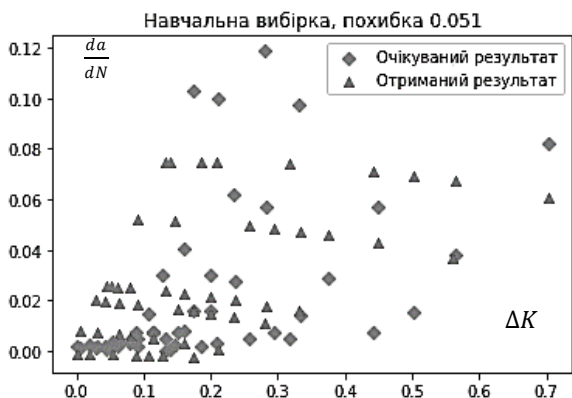


Рис. 1 – Залежність швидкості росту втомної тріщини $\frac{da}{dN}$ від проміжку значень КІН ΔK , отримана за допомогою навчання за алгоритмом зворотного поширення помилки на навчальній вибірці

Крива навчання мережі (рис. 2) є досить гладкою, на що вказує поступовий градієнтний спуск до оптимального результату. Тут і далі на рисунках вісь x – це епоха навчання мережі, y – величина середньоквадратичної похибки. Значення похибки мережі на тестовій вибірці дорівнює 0,039. Порівняння результатів роботи мережі з очікуваним результатом на тестовій вибірці продемонстровано на рис. 3.




Рис. 2 – Крива навчання нейронної мережі за допомогою алгоритму зворотного поширення помилки

Навчання за допомогою генетичного алгоритму призвело до похибки на навчальній вибірці, що дорівнює 0,031. Порівняння результатів роботи мережі з очікуваним результатом на навчальній вибірці продемонстровано на рис. 4. Крива навчання, що показана на рис. 5, вказує на певну хаотичність процесу навчання, спостерігаються певні стрибки значень похибки та відсутність поступової збіжності до оптимального результату. На тестовій вибірці похибка становить 0,023.




Рис. 3 – Залежність швидкості росту втомної тріщини $\frac{da}{dN}$ від проміжку значень КІН ΔK , отримана за допомогою навчання за алгоритмом зворотного поширення помилки на тестовій вибірці




Рис. 4 – Залежність швидкості росту втомної тріщини $\frac{da}{dN}$ від проміжку значень КІН ΔK , отримана за допомогою навчання за генетичним алгоритмом на навчальній вибірці

Порівняння результатів роботи мережі з очікуваним результатом на тестовій вибірці продемонстровано на рис. 6.

Варто зазначити, що генетичний алгоритм витрачає більше часу на навчання, порівняно із алгоритмом зворотного поширення помилки, через необхідність утворення великої кількості особин популяції на кожній епосі навчання.




Рис. 5 – Крива навчання нейронної мережі за допомогою генетичного алгоритму




Рис. 6 – Залежність швидкості росту втомної тріщини $\frac{da}{dN}$ від проміжку значень КІН ΔK , отримана за допомогою навчання за генетичним алгоритмом на тестовій вибірці

Висновки. Сформульовано математичну постановку задачі прогнозування зростання втомних тріщин за допомогою методів машинного навчання. Створено та протестовано програмний код, що утворює нейронну мережу для визначення швидкості росту втомної тріщини залежно від параметрів величини циклічного навантаження та проміжку значень коефіцієнту інтенсивності напружень. Цей код утілює процес її навчання за допомогою алгоритмів зворотного поширення помилки та генетичного. Проведено порівняння цих алгоритмів за значеннями середньоквадратичної похибки та часу навчання, визначено перевагу алгоритму зворотного поширення помилки у швидкості навчання та збіжності до оптимального результату.

БІБЛІОГРАФІЧНІ ПОСИЛАННЯ

1. **Ясній П. В.** Пластично деформовані матеріали: втома і тріщинотривкість. Львів : Світ, 1998. 292 с.
2. **Beden S. M., Abdullah S., Arrifin A. K.** Review of Fatigue Crack Propagation Models for **Metallic** Components // European Journal of Scientific Research. 2009. Vol. 28. P. 364–397.
3. **Didych I., Pastukh O., Pyndus Yu., Yasniy O.** Evaluation of Structural Elements Lifetime by Neural Network. // Acta Metallurgica Slovaca. 2018. Vol. 24. Iss. 1. P. 82–87. <https://journals.scicell.org/index.php/AMS/article/view/250>.
4. **Jordan M. I., Mitchell T. M.** Machine learning: Trends, perspectives, and prospects // Science. 2015. Vol. 349. Iss. 6245. P. 255–260. <https://doi.org/10.1126/science.aaa8415>.
5. **Kršćanski S., Brnić J.** Prediction of Fatigue Crack Growth in Metallic Specimens under Constant Amplitude Loading Using Virtual Crack Closure and Forman Model // Metals. 2020. Vol. 10. Iss. 7. 14 p. <https://doi.org/10.3390/met10070977>.
6. **Revankar S. T., Wolf B., Roznic J. R.** Metal Fatigue Crack Growth Models // International Journal of Advanced Engineering Applications. 2012. Vol. 6. Iss. 4. P. 85–91.
7. **Richard H. A., Sander M.** Fatigue Crack Growth Detect – Assess – Avoid // Solid Mechanics and Its Applications. Springer Cham. 2016. Vol. 227. 292 p. <https://doi.org/10.1007/978-3-319-32534-7>.
8. **Pugno N., Ciavarella M., Cornetti P., Carpinteri A.** A generalized Paris' law for fatigue crack growth // Journal of the Mechanics and Physics of Solids. 2006. Vol. 54. Iss. 7. P. 1333–1349. <https://doi.org/10.1016/j.jmps.2006.01.007>.
9. **Zhi L.** Neural Network-based Modelling and Prediction for Crack Growth Process in Alloys // Faculty of Science, Engineering and Technology Swinburne University of Technology Hawthorn, VIC 3122, Australia. 2019. 178 p. https://researchbank.swinburne.edu.au/file/70a0e67a-a468-473c-8cdc-b6c320c91244/1/linxian_zhi_thesis.pdf.

UDC 539.3

R. O. Shcherbak,

A. E. Sheveleva, Dr. Sci. (Phys.-Math.)
ORCID ID: 0000-0001-6688-094

T. V. Khodanen, PhD (Phys.-Math.)
ORCID ID: 0000-0001-9194-3634

APPLICATION OF MACHINE LEARNING METHODS FOR FORECASTING THE DURABILITY OF STRUCTURAL ELEMENTS

In this work the problem of forecasting the speed of fatigue cracks in the aluminum alloy 2024-T351 with neural networks is considered. Two algorithms of machine learning, genetic and backpropagation, were implemented. Learning curves for both algorithms were plotted and the numerical results for the problem of forecasting the speed of fatigue crack growth were found by using the experimental data of its dependence on the coefficient of the stress intensity factor and the amount of cyclic loading. Both algorithms were compared by characteristics of the error and the learning time, the advantage of the backpropagation algorithm by the learning speed and the convergence to the optimal result was determined.

Keywords: cyclic loading; fatigue cracks; stress intensity factor; neural networks; machine learning methods; genetic algorithm; backpropagation algorithm.

Introduction. In many structural elements the fracture appears due to fatigue, gradual damage accumulation and starts with a small crack that slowly grows under repeated-variable cyclic loading. Fatigue cracks usually appear in the concentration area of mechanical stresses. The main factors that can speed up the fracturing of the structural elements during the long-term operation are defects of the surface, temperature and other outside factors, nature and conditions of the loading.

Fatigue crack growth was a study subject for both foreign and domestic papers, for example of H. A. Richard, M. Sander [7], P. V. Yasniy [1]. Regardless of the numerous observations and scientific data fatigue crack growth forecasting is mostly based on experimental data and practical experience. In the papers [8, 2, 5] some mathematical models of fatigue crack growth are given (e.g. Paris, Walker, Forman) as a dependence of their growth speed on the amplitude of stress intensity factor (SIF) with the cyclic loading. Matching of these models to the experimental data is usually difficult and costly. Because of that there's a need to solve such problems of fracture mechanics with other methods, in particular by using neural networks and machine learning. These allow getting the satisfactory results while also simplifying the calculations and letting them be done by the chosen method.

Fracture of structural elements made out of aluminum alloy has been researched in the aviation field where they are being used most actively. That is why most experimental data on crack propagation exists concerning exactly these materials [9]. The new approach of using neural networks to predict crack growth in aluminum alloy D16chT under the cyclic loading was used by I. Didych, O. Pastukh, Y. Pyndus and O. Yasniy in the paper [3].

In the present work the genetic algorithm and backpropagation algorithm for neural network learning and determining speed of fatigue crack growth were compared on the basis of a sample that consists of dependence between the aforementioned speed on the parameters of the amount of cyclic loading and the increment of SIF.

Problem statement. Crack propagation speed is given by the equation:

$$\frac{da}{dN} = f(\Delta K, R),$$

where N is amount of loading cycles; a is crack length; $\Delta K = K_{max} - K_{min}$, where K_{max} and K_{min} are accordingly, the biggest and the smallest SIF values, $R = \frac{\sigma_{min}}{\sigma_{max}}$, where σ_{min} i σ_{max} are the biggest and the smallest loading during one cycle.

Stress intensity factor is given by the formula:

$$K = \sigma\sqrt{\pi a}Y,$$

where Y is correction function, which depends on geometry of the structure and the crack itself [6].

The task is to build a neural network which models the crack growth during the cyclic loading on the input data sample, split into training set that takes direct part in the network learning and test, that is being used for veri-

fyng the results of the training, compare the two learning algorithms of learning used in the neural networks – backpropagation and genetic and estimate the effectiveness of both of them.

Thereby, the problem consists of determining the speed of fatigue crack growth $\frac{da}{dN}$ dependency on the amount of cyclic loading R and the increment of SIF ΔK on the data sample with 114 values for the aluminum alloy 2024-T351 [9].

Conclusions. The mathematical problem of fatigue crack growth forecasting by the machine learning methods was formulated. The programming code that creates a neural network for determining the speed of fatigue crack growth depending on the parameters of amount of cyclic loading and the increment of stress intensity factor was written and tested. This code embodies the process of neural network learning with backpropagation and genetic algorithm. The algorithms were compared by the values of mean squared error and learning time, the advantage of the backpropagation algorithm by the learning speed and the convergence to the optimal result was determined.

REFERENCES

1. **Yasniy P.V.** Plastically deformed materials: fatigue and crack resistance. Lviv : Svit, 1998. 292 p. (in Ukrainian).
2. **Beden S. M., Abdullah S., Arrifin A. K.** Review of Fatigue Crack Propagation Models for **Metallic** Components // European Journal of Scientific Research. 2009. Vol. 28. P. 364–397.
3. **Didych I., Pastukh O., Pyndus Yu., Yasniy O.** Evaluation of Structural Elements Lifetime by Neural Network. // Acta Metallurgica Slovaca. 2018. Vol. 24. Iss. 1. P. 82–87. <https://journals.scicell.org/index.php/AMS/article/view/250>.
4. **Jordan M. I., Mitchell T. M.** Machine learning: Trends, perspectives, and prospects // Science. 2015. Vol. 349. Iss. 6245. P. 255–260. <https://doi.org/10.1126/science.aaa8415>.
5. **Kršćanski S., Brnić J.** Prediction of Fatigue Crack Growth in Metallic Specimens under Constant Amplitude Loading Using Virtual Crack Closure and Forman Model // Metals. 2020. Vol. 10. Iss. 7. 14 p. <https://doi.org/10.3390/met10070977>.
6. **Revankar S. T., Wolf B., Roznic J. R.** Metal Fatigue Crack Growth Models // International Journal of Advanced Engineering Applications. 2012. Vol. 6. Iss. 4. P. 85–91.
7. **Richard H. A., Sander M.** Fatigue Crack Growth Detect – Assess – Avoid // Solid Mechanics and Its Applications. Springer Cham. 2016. Vol. 227. 292 p. <https://doi.org/10.1007/978-3-319-32534-7>.
8. **Pugno N., Ciavarella M., Cornetti P., Carpinteri A.** A generalized Paris' law for fatigue crack growth // Journal of the Mechanics and Physics of Solids. 2006. Vol. 54. Iss. 7. P. 1333–1349. <https://doi.org/10.1016/j.jmps.2006.01.007>.
9. **Zhi L.** Neural Network-based Modelling and Prediction for Crack Growth Process in Alloys // Faculty of Science, Engineering and Technology Swinburne University of Technology Hawthorn, VIC 3122, Australia. 2019. 178 p. https://researchbank.swinburne.edu.au/file/70a0e67a-a468-473c-8cdc-b6c320c91244/1/linxian_zhi_thesis.pdf.