

PERANCANGAN PROGRAM PENGESTIMASI PROBABILITAS KEGAGALAN PERALATAN PENUKAR PANAS AKIBAT KOROSI SERAGAM BERBASIS DEEP NEURAL NETWORK

Jaka Fajar Fatriansyah, Donanta Dhaneswara, Muthia Hanifa, Fernanda Hartoyo, Agrin Febrian Pradana, Muhammad Anis, Andrian Fauzi

Department of Metallurgical and Materials Engineering, Faculty of Engineering, Universitas Indonesia, Indonesia

Kedeputian Bidang Pembangunan Manusia dan Kebudayaan Sekretariat Kabinet RI, Jl. Veteran No.18, Gambir, Jakarta Pusat, 10110, Indonesia

Corresponding author: donanta.dhaneswara@ui.ac.id

Abstrak

Meningkatnya standar keamanan dan ketatnya persaingan antar perusahaan meningkatkan kebutuhan bagi suatu perusahaan untuk mengendalikan kegagalan pada peralatan. Inspeksi secara teratur dilakukan sebagai bagian dari rangkaian pemeliharaan dan manajemen integritas peralatan. Dalam merencanakan dan melakukan inspeksi, diperlukan strategi yang tepat agar inspeksi yang dilakukan tepat sasaran dan sesuai dengan kebutuhan. *Risk-based inspection* merupakan teknik pengambilan keputusan dalam perencanaan pemeliharaan yang berdasar pada risiko. Pada saat ini, penggunaan metode-metode kecerdasan buatan untuk kegiatan penilaian risiko, pemodelan konsekuensi, dan perencanaan pemeliharaan telah dilakukan. Penelitian ini bertujuan untuk mengembangkan suatu program yang memanfaatkan pembelajaran mesin dan kecerdasan buatan untuk melakukan penilaian salah satu komponen risiko yaitu probabilitas kegagalan (*Probability of Failure*, PoF) pada bagian cangkang dalam peralatan penukar panas menggunakan *deep learning*. Model ini dapat membantu operator yang bekerja di bidang minyak dan gas untuk menentukan tingkatan risiko sehingga inspeksi dapat dilakukan dengan lebih efisien dan terarah. Penelitian ini menghasilkan sebuah program dan disain program pembelajaran mesin berbasis *deep learning* yang digunakan untuk memprediksi risiko kegagalan akibat korosi seragam pada peralatan sisi dalam cangkang peralatan penukar panas cangkang dan buluh (*shell-and-tube heat exchanger*) berdasarkan standar API 581 dengan akurasi sebesar 89% yang didapatkan dengan parameter-parameter diantaranya *learning rate* sebesar 0.001, *epoch* sebesar 150, *random state* sebesar 60, tiga *hidden layer*, dan *test size* sebesar 0.2.

Kata kunci: Inspeksi, Inspeksi Berbasis Risiko, pembelajaran mendalam, penukar panas, korosi seragam

Abstract

Increasing regulations and safety standards along with competition among companies increase the need for a company to control and predict failure on equipments. Planned inspections are carried out as a part of equipments' maintenance and integrity management. Appropriate strategies are needed in planning and performing inspections so that the inspections are performed in an efficient manner according to the equipments'

How to cite:	Jaka Fajar Fatriansyah, Donanta Dhaneswara, Muthia Hanifa, Fernanda Hartoyo, Agrin Febrian Pradana, Muhammad Anis, Andrian Fauzi (2023) Perancangan Program Pengestimasian Probabilitas Kegagalan Peralatan Penukar Panas Akibat Korosi Seragam Berbasis Deep Neural Network, 8 (3), http://dx.doi.org/10.36418/syntax-literate.v8i3.11486
E-ISSN:	2548-1398
Published by:	Ridwan Institute

needs. Risk-based inspection is a decision-making technique in maintenance planning which is based on the risk of each equipment. In recent years, incorporation of artificial intelligence methods for risk assessment, consequence modelling, and maintenance planning has been carried out. This research aims to develop a program which utilizes machine learning and artificial intelligence to perform assessment on one of the components of risk, namely the Probability of Failure (PoF), of a shell-and-tube heat exchanger's inner shell component by using deep learning methods. This model may help operators working in oil and gas field to determine risk levels so that inspections can be done efficiently. This research produced a deep learning-based machine learning program and program design used to predict the risk of failure caused by uniform corrosion on the inner shell component in shell-and-tube heat exchangers based on API RBI 581 standards, yielding accuracy of 89% which is obtained using the following parameters; a learning rate of 0.001, an epoch of 150, random state of 60, three hidden layers, and a test size of 0.2.

Keywords: *Inspection, Risk-Based Inspection, deep learning, heat exchanger, uniform corrosion*

Pendahuluan

Peralatan Penukar panas adalah alat yang digunakan untuk memindahkan energi termal melalui suatu permukaan perpindahan panas dari satu fluida ke fluida kedua dengan temperatur yang lebih rendah (Faes, et al., 2019). Peralatan Penukar panas memiliki aplikasi industri dan domestik yang luas. Berbagai jenis peralatan penukar panas telah dikembangkan untuk penggunaan dalam pembangkit listrik tenaga uap, pabrik-pabrik pemrosesan kimia, sistem AC dalam bangunan, sistem energi kendaraan, dan unit pendingin (Zohuri, 2017).

Kegagalan yang umum dijumpai pada dalam industri minyak dan gas korosi. Korosi merupakan suatu kegagalan yang dijumpai akibat pengikisan pada dinding peralatan penukar panas hingga dapat menyebabkan kebocoran. Meningkatnya standar keamanan dan ketatnya persaingan antar perusahaan meningkatkan kebutuhan bagi suatu perusahaan untuk mengendalikan kegagalan pada peralatan (Bhatia, Khan, Patel, & Abbassi, 2019). Kegagalan peralatan merupakan salah satu penyebab terjadinya kecelakaan dan hal-hal tidak diinginkan lainnya, seperti ledakan, kebakaran, dan lain-lain (Rachman & Ratnayake, 2019).

Salah satu cara untuk menanggulangi kegagalan adalah dengan melakukan inspeksi pada peralatan. Inspeksi yang dilakukan membutuhkan biaya dan sumber daya yang tidak sedikit, sehingga bersamaan dengan meningkatnya kepentingan inspeksi, muncul juga kebutuhan untuk melakukan manajemen inspeksi. Sebagai salah satu bentuk manajemen inspeksi, dilakukan Risk-based Inspection (RBI). Risk Based Inspection (RBI) merupakan metode yang digunakan untuk melakukan inspeksi berbasis risiko yang dilakukan berdasarkan prioritas risiko sehingga mempermudah dalam melakukan inspeksi yang optimal sehingga perhitungan dapat dilakukan secara efektif dan efisien (Bertolini et.al., 2009) tanpa mempengaruhi lingkungan (Ratnayake & Markeset, 2011).

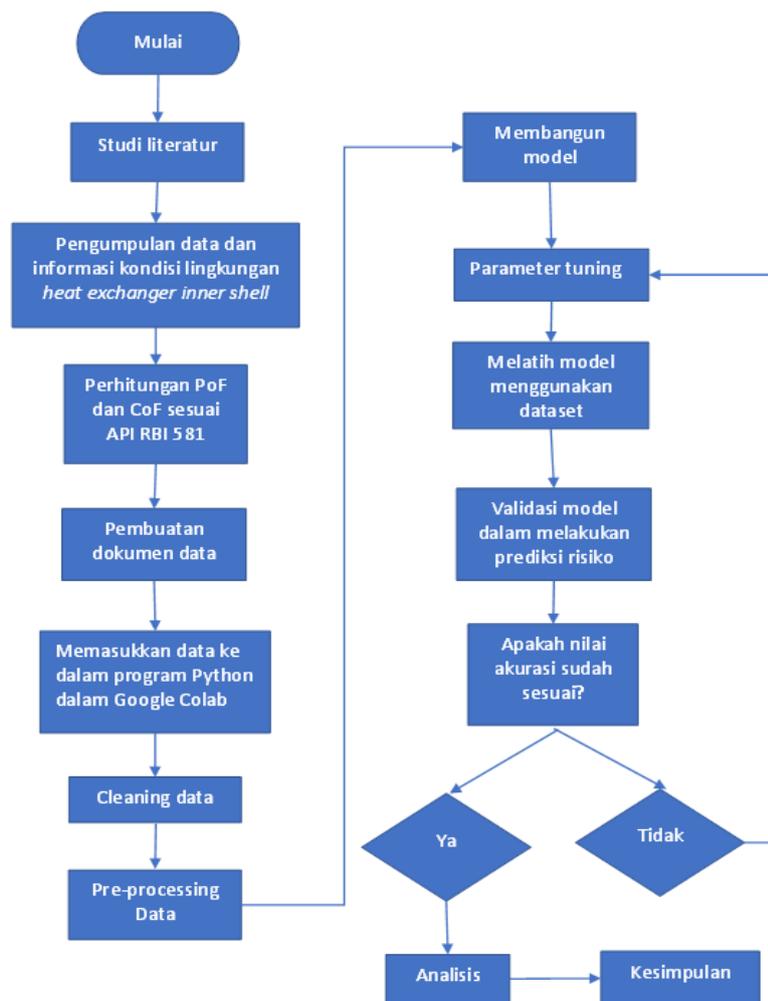
Namun pada saat ini program yang digunakan untuk melakukan estimasi risiko memiliki harga yang cukup mahal, waktu yang lama dan dilakukan dengan cara kualitatif. Untuk mengatasi masalah ini dilakukan proses pemeriksaan dengan menggunakan algoritma pembelajaran mesin. Deep learning adalah salah satu bagian dari pembelajaran mesin yang menyerupai kemampuan dari otak manusia dengan mempelajari tingkat tinggi dalam data menggunakan ilmu arsitektur dalam pembangunan modelnya menjadi beberapa layer (Rere, 2017; Fatriansyah, Surip, & Hartoyo, Mechanical Property

Prediction of Poly(Lactic Acid) Blends Using Deep Neural Network, 2022; Arunika, Fatriansyah, & Ramadheena, 2022).

Penelitian ini bertujuan untuk melakukan *risk assessment* dengan model penilaian risiko kegagalan bejana tekan minyak dan gas akibat korosi seragam dengan menggunakan *deep learning* untuk melakukan proses peningkatan level risiko, mempersingkat waktu, meningkatkan akurasi, efisiensi pengolahan data, dan lebih murah dibandingkan dengan penilaian risiko cara konvensional.

Metode Penelitian

Penelitian ini memiliki tujuan utama mengembangkan rancang bangun aplikasi pengolahan data untuk melakukan penilaian risiko yang berpedoman pada RBI berbasis pendekatan *deep learning*, untuk memfasilitasi transfer pengetahuan dan menggunakan kembali data penilaian RBI yang telah lalu (Rachman & Ratnayake, 2019). Tugas model *deep learning* yang dibuat adalah memprediksi nilai PoF berdasarkan beberapa fitur terkait kondisi desain dan operasional. Permasalahan ini termasuk masalah klasifikasi yang diarahkan (*supervised classification*). Selain itu, dilakukan juga analisis terhadap performa model *deep learning*. Diagram alir penelitian dapat dilihat pada Gambar 1 di bawah ini.



Gambar 1. Alur Penelitian

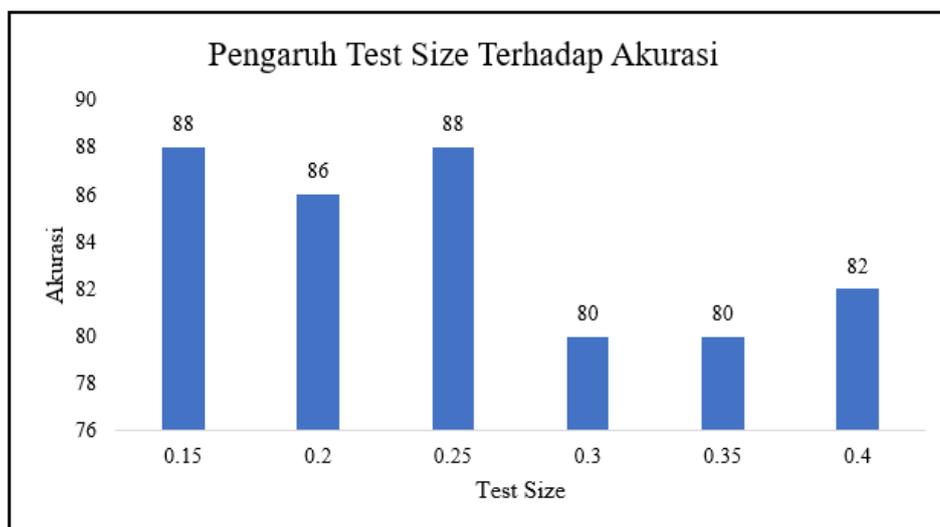
Hasil dan Pembahasan

Data Desain dan Kondisi Operasional Peralatan Penukar Panas

Pada penelitian ini data yang digunakan mengenai peralatan penukar panas cangkang-buluh kelas R dalam standar TEMA (*Tubular Exchanger Manufacturers Association*) yang terbuat dari baja karbon dan umum digunakan dalam industri minyak dan gas dengan melakukan pembuatan data melalui pemanfaatan *function* RAND dan IF pada *Microsoft Excel* hingga mendapatkan data 446 nilai risiko yang akan di input pada program *deep learning*. Data yang didapatkan adalah data desain dan kondisi operasional peralatan penukar panas.

Pengaruh Parameter Pada Kinerja Model *Deep Learning*

Dataset yang telah diinputkan dapat dibagi menjadi dua yaitu *training dataset* dan *testing dataset*. Pada percobaan ini dilakukan percobaan beberapa variasi untuk menemukan parameter optimum yang dapat menghasilkan nilai akurasi model yang paling maksimal. Parameter *test size* yang digunakan sebagai presentase *testing dataset* yang menentukan jumlah data yang digunakan untuk melakukan pengujian pada model. *Test size* yang kecil dapat menghasilkan akurasi yang besar, namun nilai tersebut tidak valid karena berasal dari pembelajaran yang banyak dan ukuran *testing data* yang tidak mencerminkan variasi yang terdapat di keseluruhan dataset. Pada Gambar 2. menunjukkan pengaruh variasi parameter *test size* terhadap kinerja model yang dihasilkan.



Gambar 2. Grafik Pengaruh *Test Size* Terhadap Akurasi Model *Deep Learning*

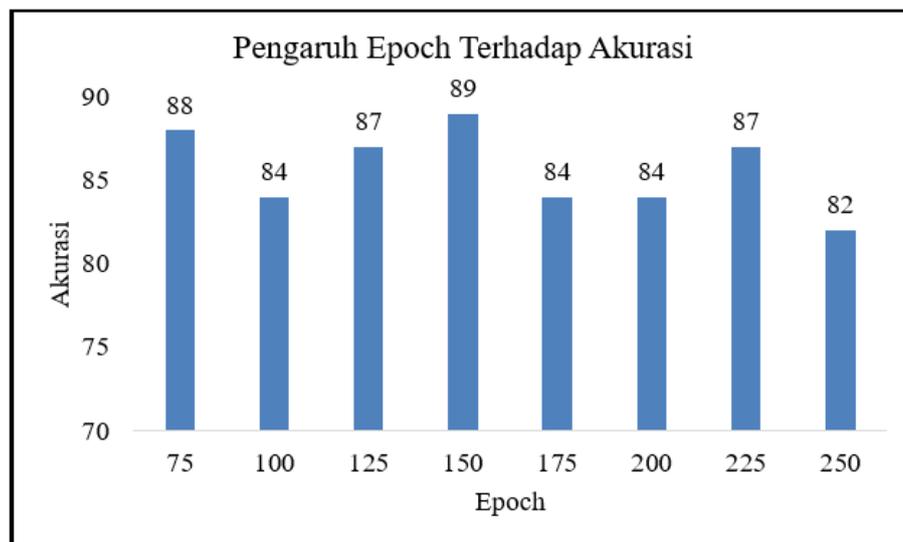
Gambar 2 menunjukkan bahwa berdasarkan hasil percobaan, didapati bahwa akurasi yang lebih tinggi dihasilkan dengan *test size* sebesar 0.15 hingga 0.25 (15% – 25%) dari keseluruhan dataset. dengan nilai akurasi sebesar 88% untuk klasifikasi kategori probabilitas. Selain *test size* pada tahap *pre-processing* terdapat parameter lain yang mempengaruhi kinerja model yaitu *random state* yang digunakan untuk mengatasi masalah pada *training* yang memilih data secara random, sehingga dapat menghindari kesalahan dimana *training* tidak menghasilkan akurasi yang berubah-ubah. Mengubah *random state* dapat mengubah akurasi, sehingga akurasi yang fluktuatif namun tidak terlalu jauh dalam satu rentang *random state* tertentu dapat menggambarkan kinerja model. Dari Tabel 1. dapat terlihat bahwa parameter optimum adalah saat *random state* menggunakan nilai 60 dengan akurasi sebesar 89% dalam menentukan kategori *of failure*.

Data ini didapatkan nilai *random state* berbeda dalam rentang 60-65 memberikan nilai akurasi yang berbeda-beda.

Tabel 1
Pengaruh Parameter Random State Pada Akurasi
Model Deep Learning

<i>Random State</i>	Akurasi (%)
60	89
61	77
62	81
63	80
64	79
65	77

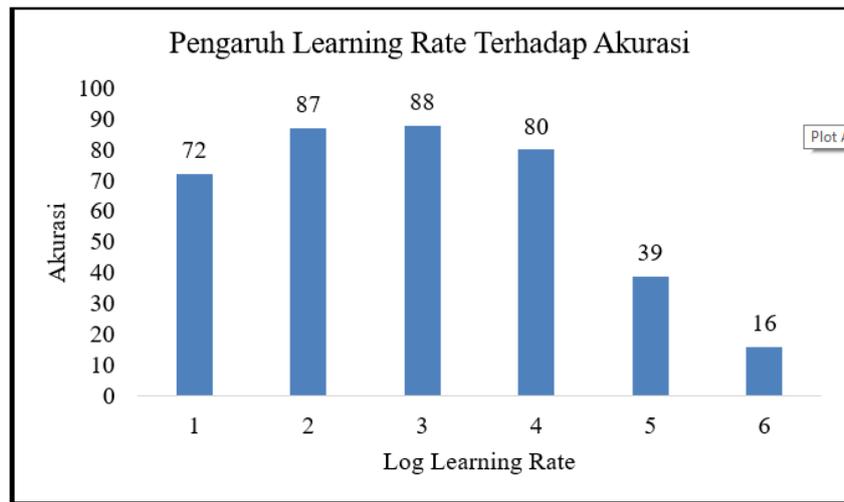
Pada penelitian tahapan selanjutnya adalah melakukan *training* pada model. *Epoch* merupakan jumlah berapa kali seluruh *dataset* dimasukkan ke dalam model. Bobot yang diinisialisasi di awal akan mengalami perubahan ketika siklus simulasi *dataset* berikutnya (*epoch* berikutnya) dimulai. (Tran, Taesam, & Jong-Suk, 2020). Optimisasi *epoch* dilakukan untuk mengurangi dua masalah, yaitu *overfitting* dan *underfitting*. *Epoch* pada umumnya memiliki pengaruh yang cukup besar pada model. Nilai *epoch* yang semakin tinggi umumnya akan menghasilkan akurasi yang lebih tinggi karena model memiliki kesempatan belajar yang lebih banyak, namun rentan terhadap *overfitting* dan membutuhkan waktu *training* yang lebih lama. Pada penelitian ini akan dilakukan percobaan pengaruh jumlah *epoch* terhadap akurasi. Dapat terlihat bahwa akurasi tertinggi didapatkan dengan menggunakan jumlah *epoch* 150 dengan akurasi sebesar 89%. Hal ini dapat dilihat pada Gambar 3. dapat terlihat bahwa peningkatan akurasi diiringi dengan peningkatan jumlah *epoch* dan cenderung *fluktuatif* pada variasi *epoch*.



Gambar 3. Pengaruh Jumlah Epoch Pada Akurasi Deep Learning

Sepanjang percobaan *epoch*, akurasinya bersifat *fluktuatif* dan tidak pernah benar-benar turun secara signifikan. Hal ini dapat berarti keseluruhan nilai yang dicobakan masih berada dalam rentang optimal *epoch*. Selain penentuan parameter *epoch*, pada

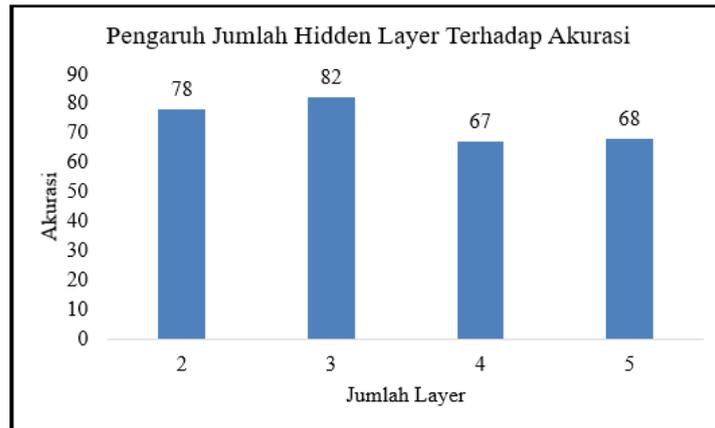
penelitian ini juga dilakukan penentuan parameter *learning rate*. *Learning rate* merupakan parameter yang memiliki pengaruh signifikan dalam proses training. Apabila *learning rate* terlalu besar maka langkah pembelajaran (step size) akan semakin besar dan algoritma menjadi tidak stabil, namun apabila *learning rate* terlalu kecil, progres pembelajaran akan semakin lambat untuk mencapai titik optimalnya. Oleh karena itu, nilai *learning rate* harus dipilih dengan tepat. Dapat terlihat pada Gambar 4. adanya pengaruh variasi *learning rate* terhadap akurasi model *deep learning* dalam menentukan kategori PoF.



Gambar 4. Pengaruh Parameter Learning Rate Terhadap Akurasi Deep Learning

Berdasarkan grafik di atas, didapatkan bahwa akurasi yang tertinggi dihasilkan oleh *learning rate* sebesar 10^{-3} dengan nilai 88 persen dan akurasi terendah dihasilkan oleh *learning rate* sebesar 10^{-6} dengan nilai 16 persen. Sehingga ditunjukkan bahwa *learning rate* yang optimal adalah antara 10^{-2} dan 10^{-3} . Hal ini serupa dengan hasil penelitian Rathore et al. (2018) yang menemukan nilai akurasi pada learning rate 10^{-1} , 10^{-2} , dan 10^{-3} berkisar diantara 83-91%.

Layer merupakan jumlah lapisan yang menjadi penyusun pada *deep neural network* yang terdiri dari *layer input* yang menerima input dari luar, *hidden layer* merupakan lapisan tersembunyi dan tidak dapat diamati secara langsung, dan *layer output* yang berisi keluaran dari *deep neural network*. Sedangkan *dense* merupakan jumlah node dalam *layer* yang digunakan untuk dapat mengetahui lebar dari model berdasarkan jumlah *perceptron* dalam satu *layer* model sehingga dapat mengetahui kemampuannya untuk melakukan prediksi (Iskand & Welly, 2016). Seperti yang ditunjukkan pada grafik, perbedaan jumlah *hidden layer* menunjukkan efek yang tidak begitu signifikan terhadap akurasi model. akurasi tertinggi ditunjukkan oleh model dengan tiga *hidden layer*, dengan akurasi sebesar 82 persen, sementara akurasi terendah ditunjukkan oleh model dengan 4 *hidden layer*, dengan akurasi sebesar 67 persen. Berdasarkan hal ini, maka model dengan tiga *layer* dianggap sebagai model dengan akurasi tertinggi dari percobaan ini dan digunakan untuk percobaan-percobaan berikutnya untuk mengetahui pengaruh parameter-parameter lain terhadap nilai akurasi. Hal ini sejalan dengan yang ditemukan oleh Uzair dan Jamil (2020) bahwa tiga *layer* adalah jumlah *hidden layer* optimal untuk model-model yang digunakan dalam berbagai masalah.



Gambar 5. Pengaruh Jumlah Layer Pada Akurasi Deep Learning

Hasil Evaluasi Kinerja Deep Learning

Evaluasi model dilakukan dengan menggunakan *confusion matrix*. *Confusion matrix* menyajikan matriks dengan gambaran mengenai tingkat kesalahan serta kualitas hasil prediksi dari program *deep learning* (Novakovic, Veljovic, Ilic, Zeljko, & Tomovic, 2017). Pada penelitian ini didapatkan hasil *confusion matrix* dengan model *program deep learning* yang dapat terlihat pada Gambar 6. untuk *confusion matrix* kategori *probability of failure* yang terdiri dari 5 kelas kategori *probability of failure* yang menunjukkan matriks dua dimensi dengan membandingkan hasil kelas data sebenarnya dengan kelas yang didapatkan dari model yang telah dibuat. Hasil dari *confusion matrix* yang didapatkan pada Gambar 6. akurasi tertinggi didapatkan dengan menggunakan parameter dengan nilai *test size* 20%, *layer* berjumlah 3 dengan *dense* 64, 32, 16, jumlah *epoch* sebesar 150, dan nilai *learning rate* sebesar 1×10^{-3} dengan nilai *random state* sebesar 60.

Kelas PoF		Prediksi				
		1 (A)	2 (B)	3 (C)	4 (D)	5 (E)
Aktual	1 (A)	14	0	0	0	0
	2 (B)	0	37	1	2	1
	3 (C)	0	1	4	1	0
	4 (D)	0	0	1	10	0
	5 (E)	0	0	0	3	15

Gambar 6. Confusion Matrix Kategori Probability Of Failure

Sedangkan perhitungan parameter terkait yang didapatkan dari *classification report* dari *confusion matrix* yang dapat dilihat dari pada Tabel 2. Dari *classification report* didapatkan data hasil berupa *precision*, *recall*, *F-1 score* dan juga *accuracy* yang didukung oleh *support* yang dianalisis berdasarkan *rata-rata weight* dan nilai rata-rata makro dengan akurasi tertinggi sebesar 89% untuk klasifikasi kategori *probability of failure*.

Tabel 2
Classification Report Untuk Klasifikasi Kategori Probability Of Failure

	Precision	Recallz	F1-score	Support
0	1,00	1,00	1,00	14
1	0,97	0,90	0,94	41
2	0,67	0,67	0,67	6
3	0,62	0,91	0,74	11
4	0,94	0,83	0,88	18
Accuracy			0,89	90
Macro avg	0,84	0,85	0,85	90
Weighted avg	0,91	0,93	0,89	90

Pembahasan

Analisis Pengaruh Parameter terhadap Kinerja Program

Parameter *test size* yang baik berdasarkan percobaan yang telah dilakukan adalah persentase *test size* yang rendah. Hal ini terjadi karena pada saat dataset yang digunakan untuk *testing* semakin besar maka dataset yang digunakan untuk *training* akan semakin sedikit sehingga akan menurunkan kinerja *algoritma* model *deep learning* karena program yang digunakan untuk belajar mengenali *output* yang diinginkan tidak cukup untuk mendukung kinerja program menjadi tidak optimal dan menyebabkan *underfitting*, begitu juga sebaliknya saat *testing dataset* semakin kecil maka data yang digunakan untuk *training dataset* akan semakin besar dan dapat menyebabkan adanya *overfitting* atau bahkan tidak mengalami perubahan akurasi (Chollet, 2018).

Parameter *random state* yang digunakan untuk mengatasi permasalahan yang ditimbulkan pada proses *training dataset* (SciPay.org, 2020) menghasilkan nilai akurasi yang fluktuatif menggambarkan kinerja dari model yang telah dibangun. *Random State* bekerja pada model bergantung pada ukuran dataset yang digunakan dan tidak terlalu mempengaruhi akurasi model secara signifikan, namun *random state* dapat memberikan gambaran kinerja model yang baik sehingga jika perubahan *random state* menghasilkan perubahan akurasi yang besar maka dapat terindikasi bahwa model yang dibuat tidak memiliki performa yang optimal (Han, 2019). Hal ini umumnya ditemukan pada sistem kompleks (Fatriansyah & Orihara, 2015; Fatriansyah, Sasaki, & Orihara, 2014).

Jumlah *epoch* mempengaruhi akurasi yang dihasilkan oleh model. Dari percobaan yang telah dilakukan, terlihat bahwa peningkatan akurasi diiringi dengan peningkatan jumlah *epoch* dan cenderung *fluktuatif* untuk menunjukkan pengaruh *epoch* pada akurasi model dan memiliki titik optimum yang dapat meningkatkan akurasi. Peningkatan akurasi akan diiringi dengan peningkatan jumlah *epoch* dikarenakan jumlah *epoch* yang kecil menyebabkan iterasi menjadi terbatas, sehingga parameter yang digunakan belum maksimal dalam melakukan peningkatan kinerja pada model sehingga akurasinya menjadi (Danshi, et al., 2017), namun untuk jumlah *epoch* diperbesar akan terjadi peningkatan kinerja parameter secara bertahap sehingga dapat menghasilkan hasil yang lebih optimal dengan adanya titik optimum yang bergantung pada data, jumlah data,

network dan *problem* yang ada digunakan. Jumlah *epoch* juga mempengaruhi *overfitting* dan *underfitting* yang terjadi pada model *deep learning* serta lamanya waktu *training* pada model *deep learning* dimana semakin besar nilai *epoch* yang digunakan maka akan semakin besar waktu yang diperlukan untuk melakukan *training* model dengan iterasi yang semakin besar.

Untuk parameter *learning rate*, adanya peningkatan nilai *learning rate* akan menyebabkan nilai *loss* yang besar pada saat proses *running* dalam melakukan *training* sehingga dapat terlihat bahwa semakin besar nilai *learning* akan mengalami penurunan akurasi karena adanya *loss* yang semakin besar. Sedangkan untuk nilai *learning rate* yang semakin kecil menunjukkan adanya penurunan akurasi yang disebabkan karena adanya perlambatan konvergensi pada nilai *loss* yang terjadi selama proses *running* sehingga memperlambat prosesnya, karena jika *learning rate* semakin kecil maka waktu yang dibutuhkan untuk *training model* akan semakin lama (Thohari & Hertantyo, 2018). Untuk itu nilai dari *learning rate* memiliki titik optimum yang apabila kurang dari atau lebih dari titik optimum akan menyebabkan penurunan akurasi yang disebabkan karena adanya pengaruh dari *loss* yang dihasilkan.

Pembuatan model *deep learning* dengan variasi jumlah *hidden layer* yang ditentukan untuk dapat mengetahui pengaruh parameter jumlah *layer* untuk dapat mengoptimasi kinerja model *deep learning*. Jumlah *layer* yang digunakan pada penelitian ini adalah 1 *hidden layer*, 2 *hidden layer*, 3 *hidden layer* dengan adanya variasi pada *dense* yang digunakan. Parameter jumlah *layer* dan *dense* dapat mempengaruhi fluktuasi eror pada kinerja model. *Hidden layer* merupakan *layer* dapat mempengaruhi akurasi yang dihasilkan, dimana semakin besar jumlah *hidden layer* maka akurasi yang didapatkan akan semakin besar. Peningkatan jumlah *layer* yang diiringi peningkatan jumlah akurasi terjadi karena pada jumlah *layer* yang lebih banyak akan mampu untuk mendukung kinerja model yang lebih baik karena memiliki kompleksitas model yang baik untuk dapat mengatasi masalah yang ada sehingga menghasilkan efisiensi model yang baik (Tran, Taesam, & Jong-Suk, 2020).

Analisis Kinerja Program *Deep Learning* dalam Melakukan Prediksi Risiko Pada Bejana Tekan

Kinerja model *deep learning* dapat diketahui dengan evaluasi model yang sebelumnya sudah dilakukan *training* dengan menggunakan *metrics evaluation* berupa *confusion matrix* untuk dapat mengetahui hasil prediksi dari model yang telah dibuat dalam bentuk *accuracy*, *precision*, dan *recall* (Novakovic, Veljovic, Ilic, Zeljko, & Tomovic, 2017). *Confusion matrix* menyajikan matriks dengan gambaran mengenai tingkat kesalahan serta kualitas hasil prediksi dari program *deep learning*. *Confusion matrix* mengevaluasi akurasi dari klasifikasi data yang dilakukan oleh model. Perhitungan akurasi dapat dilakukan dengan persamaan.1 berikut ini :

$$\text{Akurasi} = \frac{\text{jumlah sampel data diklasifikasikan dengan benar}}{\text{jumlah total sampel data}} \quad (1)$$

Dari hasil perhitungan akurasi yang dilakukan untuk beberapa percobaan parameter pada model *deep learning* dihasilkan akurasi optimum untuk melakukan prediksi kelas probabilitas kegagalan adalah sebesar 89%. Nilai akurasi yang didapatkan menyatakan bahwa pada prediksi kategori probabilitas dapat dikatakan bahwa dari 446 dataset terdapat 396 data yang dapat diprediksi dengan benar.

Nilai akurasi yang dihasilkan juga memiliki kelemahan yang disebabkan karena tidak meratanya distribusi data untuk setiap kelas yang ada. Hal ini dapat menyebabkan bias yang besar pada kelas dengan data yang lebih banyak meskipun akurasi yang dihasilkan tetap besar (Tharwat, 2018). Hal ini dapat dilihat pada data kelas 2 yang dapat ditebak dengan benar lebih besar dibandingkan dengan kelas lainnya yaitu sebanyak 37 data dikarenakan jumlah data kelas kategori probabilitas 2 lebih banyak pada dataset dibandingkan dengan data kategori kelas lainnya. Karena adanya bias dalam melakukan klasifikasi kategori probabilitas dapat menyebabkan kesalahan klasifikasi yang dapat berakibat fatal apabila terjadi kesalahan dalam mengklasifikasikan kategori probabilitas tinggi ke dalam kategori probabilitas rendah yang dapat mempengaruhi jangka waktu inspeksi selanjutnya dan biaya yang dikeluarkan untuk pemeliharaan komponen (Rachman & Ratnayake, 2019). Sehingga untuk mengatasi kelemahan perhitungan akurasi ini dilakukanlah perhitungan presisi dan *recall*.

Presisi membantu kekurangan hasil akurasi dengan menggambarkan prediksi positif dengan hasil prediksi positif yang akurat untuk setiap kelasnya dengan menggunakan Persamaan 2. berikut ini:

$$\text{Presisi} = \frac{\text{jumlah data yang sesuai dengan target di satu kelas}}{\text{jumlah seluruh data yang sesuai target}} \quad (2)$$

Presisi ditentukan untuk setiap kelas PoF, nilai parameter presisi dapat ditentukan dengan memprediksi setiap kelas PoF yang benar dari seluruh prediksi pada kelas tersebut untuk mendapatkan presisi setiap kelas. *Recall* digunakan untuk dapat mengatasi kelemahan dalam perhitungan presisi yang tidak selalu menghasilkan prediksi yang baik dengan menentukan data dengan kelas positif, dimana *recall* dapat dihitung dengan menggunakan rasio sampel positif yang diklasifikasikan dengan benar pada suatu kelas dengan jumlah total sampel positif pada suatu kelas dengan menggunakan Persamaan 3. berikut :

$$\text{Recall} = \frac{\text{jumlah data yang sesuai dengan target di satu kelas}}{\text{jumlah data di satu kelas}} \quad (3)$$

Recall ditentukan untuk setiap kelas PoF dan CoF karena penelitian ini dibatasi untuk kelas CoF hanya untuk 1 kelas hanya untuk 1 kelas sehingga nilai presisi bernilai 1,00 maka nilai parameter presisi dapat ditentukan dengan memprediksi setiap kelas PoF yang benar pada suatu kelas dengan jumlah total sampel positif pada suatu kelas untuk mendapatkan *recall* setiap kelas.

Kesimpulan

Berdasarkan hasil penelitian yang dilakukan, maka telah dibuat program prediksi nilai PoF untuk memprediksi risiko kegagalan pada sisi dalam cangkang peralatan penukar panas akibat korosi uniform menggunakan metode pembelajaran mesin berbasis *deep learning*, yang diharap bisa mempermudah pengguna dalam memprediksi risiko pada sisi dalam cangkang peralatan penukar panas yang berpedoman pada RBI. Dari penelitian ini, dapat diambil kesimpulan untuk menjawab rumusan masalah yang terdapat pada bagian awal studi literatur ini. Kesimpulan yang telah didapatkan adalah sebagai berikut: 1) Telah diperoleh sebuah disain program pembelajaran mesin berbasis *deep learning* yang digunakan untuk memprediksi risiko pada peralatan penukar panas cangkang dan buluh (shell-and-tube heat exchanger) berdasarkan standar API 581. 2)

Perancangan Program Pengestimasi Probabilitas Kegagalan Peralatan Penukar Panas
Akibat Korosi Seragam Berbasis Deep Neural Network

Telah diperoleh program pembelajaran mesin berbasis *deep learning* untuk memprediksi risiko pada peralatan penukar panas cangkang dan buluh dengan akurasi sebesar 89% menggunakan parameter-parameter diantaranya *learning rate* sebesar 0.001, epoch sebesar 150, *random state* sebesar 60, tiga *hidden layer*, dan *test size* sebesar 0.2.

BIBLIOGRAFI

- Arunika, A., Fatriansyah, J. F., & Ramadheena, V. A. (2022). Detection of Asphalt Pavement Segregation Using Machine Learning Linear and Quadratic Discriminant Analyses. *Evergreen*, 9(1), 213-218.
- Bhatia, K., Khan, F., Patel, H., & Abbassi, R. (2019). Dynamic risk-based inspection methodology. *Journal of Loss Prevention in the Process Industries*, 62, 103974.
- Chollet, F. (2018). *Deep Learning with Python, Second Edition*. Shelter Island, NY: Manning Publications.
- Danshi, W., Zhang, M., Li, J., Li, Z., Li, J., Song, C., & Chen, X. (2017). Intelligent constellation diagram analyzer using convolutional neural network-based deep learning. *Optics Express*, XXV(15), 17150.
- Faes, W., Lecompte, S., Ahmed, Z. Y., Van Bael, J., Salenbien, R., Verbeken, K., & De Paepe, M. (2019). Corrosion and corrosion prevention in heat exchangers. *Corrosion Reviews*, 37(2), 131-155.
- Fatriansyah, J. F., & Orihara, H. (2015). Electric-field-induced flow-aligning state in a nematic liquid crystal. *Physical Review E*, 91(4), 042508.
- Fatriansyah, J. F., Sasaki, Y., & Orihara, H. (2014). Nonequilibrium steady-state response of a nematic liquid crystal under simple shear flow and electric fields. *Physical Review E - Statistical, Nonlinear, and Soft Matter Physics*, 90(3), 032504.
- Fatriansyah, J. F., Surip, S. N., & Hartoyo, F. (2022). Mechanical Property Prediction of Poly(Lactic Acid) Blends Using Deep Neural Network. *Evergreen*, 141-144.
- Han, L. W. (2019). *Manipulating machine learning results with random state*. (Toward Data Science) Retrieved Desember 15, 2021, from <https://towardsdatascience.com/manipulating-machine-learning-results-with-random-state-2a6f49b31081>
- Iskand, F. N., & Welly, I. S. (2016). Implementasi Pengenalan Citra Wajah Dengan Algoritma Eigen face Pada Metode Principal Component Analysis (PCA).
- Novakovic, J. D., Veljovic, A., Ilic, S. S., Z. P., & Tomovic, M. (2017). Evaluation of Classification Models in Machine Learning. *Theory and Applications of Mathematics & Computer Science*, VII(1), 39-46.
- Rachman, A., & Ratnayake, C. C. (2019). Machine learning approach for risk-based inspection screening assessment. *Reliability Engineering and System Safety*, CLXXXV, 518-532.

Perancangan Program Pengestimasian Probabilitas Kegagalan Peralatan Penukar Panas
Akibat Korosi Seragam Berbasis Deep Neural Network

- Ratnayake, R. C., & Markeset, T. (2011). Strategy, Technical Integrity Management: Measuring HSE Awareness Using AHP in Selecting a Maintenance. *Journal of Quality in Maintenance Engineering*(16), 44-63.
- Rere, L. M. (2017). *Strategi Metaheuristik Ssingle Solution Optimasi Deep Learning*. Depok: Fakultas Ilmu Komputer, Universitas Indonesia.
- SciPay.org. (2020). *numpy.random.RandomState*. (Scipay.org) Retrieved Desember 12, 2021, from <https://numpy.org/doc/1.16/reference/generated/numpy.random.RandomState.html>
- Tharwat, A. (2018). Classification Assessment Methods. *Applied Computing and Informatics*, 17(1), 168-192.
- Thohari, A. N., & Hertantyo, G. B. (2018). Implementasi Convolutional Neural Network untuk Klasifikasi Pembalap MotoGP Berbasis GPU. *Conference on Electrical Engineering, Telematics, Industrial Technology, and Creative Media*, 50-55.
- Tran, T. T., Taesam, L., & Jong-Suk, K. (2020). Increasing Neurons or Deepening Layers in Forecasting Maximum Temperature Time Series? *Atmosphere*, XI(10), 1072. doi:10.3390/atmos11101072
- Zohuri, B. (2017). *Compact Heat Exchanges: Selection, Application, Design and Evaluation*. Switxerland: Springer International Publishing.

Copyright holder:

Jaka Fajar Fatriansyah, Donanta Dhaneswara,a, Muthia Hanifa, Fernanda Hartoyo, Agrin Febrian Pradana, Muhammad Anis, Andrian Fauzi (2022)

First publication right:

Syntax Literate: Jurnal Ilmiah Indonesia

This article is licensed under:

