

BAB V

PEMBAHASAN

5.1 Pembuatan Model Prediksi *Container Throughput* dengan *Artificial Neural Network*

Dalam penelitian ini, penentuan model prediksi *container throughput* dilakukan dengan menggunakan metode *Artificial Neural Network* dengan algoritma *backpropagation* dengan *software* MATLAB. *Artificial Neural Network* dengan algoritma *backpropagation* merupakan salah satu model jaringan yang populer pada ANN. Model jaringan ini banyak digunakan dan diaplikasikan pada berbagai jenis penyelesaian suatu masalah yang berkaitan dengan identifikasi, prediksi, pengenalan pola dan lainnya. Kelebihan lain yang dimiliki oleh metode ini adalah kemampuannya untuk belajar yang bersifat adaptif dan kebal terhadap adanya kesalahan (*fault tolerance*). Selain itu, metode ini digunakan karena kemampuannya untuk menangani masalah yang bersifat non-linier dan mampu mengatasi efek multikolinieritas (Moosmayer et al., 2013).

Dalam proses pembelajarannya, *Artificial Neural Network* memiliki dua metode yaitu *supervised learning* dan *unsupervised learning* di mana algoritma *backpropagation* termasuk pada proses pembelajaran *supervised learning*. Metode pembelajaran disebut sebagai *supervised learning* apabila output yang diharapkan telah diketahui sebelumnya, sehingga konsep kerja pada jaringan adalah mengidentifikasi dan mempelajari pola-pola yang ada variabel input terhadap variabel outputnya.

Pada penelitian ini, *Artificial Neural Network* dengan algoritma *backpropagation* diterapkan untuk membuat model prediksi *container throughput volume*. Terdapat 3 variabel input yang digunakan dalam penelitian ini, yaitu Produk Domestik Bruto (PDB) Jawa Tengah, populasi Jawa Tengah, dan juga inflasi. Pemilihan variabel ini dilakukan berdasarkan studi literatur dan data historis yang tersedia. Total data yang digunakan

adalah 95 bulan. Kemudian data ini dibagi menjadi 2 yaitu data pelatihan dan data pengujian. Data pelatihan digunakan untuk membangun jaringan syaraf yang selanjutnya akan diuji dengan data baru yang tidak diikuti dalam proses pelatihan yang disebut dengan data pengujian. Pemilihan anggota data *training* dan *testing* secara acak didasarkan pada penelitian yang dilakukan oleh Roy et al (2008) yang menyatakan bahwa metode yang secara umum digunakan adalah dengan pemilihan secara *random (random selection)*.

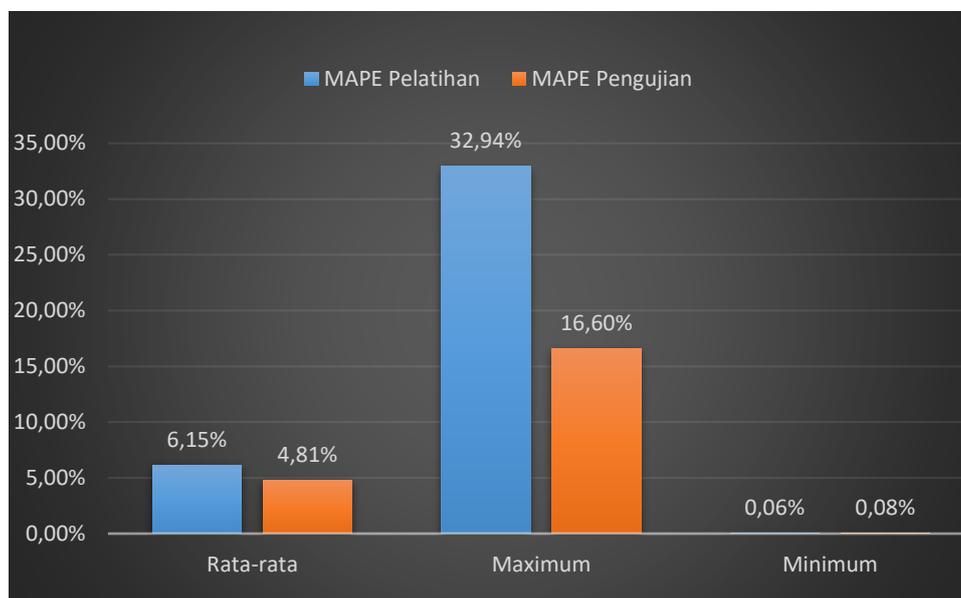
Pengolahan data dengan algoritma *backpropagation*, memiliki beberapa parameter yang disebut *training* parameter dan harus ditetapkan terlebih dahulu. Parameter tersebut adalah fungsi aktivasi, metode pembelajaran, jumlah lapisan tersembunyi dan neuron yang ada di dalamnya, jumlah epoch, nilai *learning rate*, dan nilai momentum. Perubahan atas parameter ini berpengaruh terhadap performansi jaringan. Karena tidak adanya ketentuan khusus, penetapan parameter tersebut dilakukan dengan teknik percobaan dengan mempertimbangkan nilai MSE yang dihasilkan oleh jaringan dan berdasarkan studi literatur penelitian sebelumnya. Selain itu pada metode ini juga perlu dilakukan normalisasi data input maupun target karena fungsi aktivasi yang digunakan berada pada skala tertentu.

Adapun kelemahan yang dimiliki oleh metode ini adalah proses *training* yang mungkin terjadi dalam waktu lama untuk jumlah data yang besar. *Training* parameter yang diatur dengan teknik percobaan sangat bergantung kepada peneliti. Peneliti perlu mencoba beberapa kali untuk memasukkan nilai dari parameter tersebut agar dapat memperoleh hasil yang lebih baik, sehingga hasil yang diperoleh mungkin saja berbeda dengan yang lain dalam kasus yang sama.

5.2 Perbandingan Volume Container Throughput pada Target dan Output Jaringan

Hasil dari penelitian ini adalah prediksi volume *container throughput* dari output jaringan. Perbandingan antara volume *container throughput* pada target asli dengan output jaringan dapat dilihat pada nilai *error* yang dihasilkan. Dalam penelitian ini perbandingan tersebut diukur dengan melihat nilai MAPE dan koefisien korelasi baik untuk data pelatihan maupun pengujian. Nilai MAPE data pelatihan dan pengujian yang

dihasilkan oleh jaringan dapat dilihat pada Gambar 5.1 Nilai MAPE Data Pelatihan berikut.



Gambar 5.1 Nilai MAPE Data Pelatihan dan Pengujian

Nilai MAPE ini didapatkan dari hasil perhitungan manual dengan rumus MAPE untuk melihat berapa persen *error* output jaringan terhadap data target asli. Selain nilai MAPE, koefisien korelasi juga dihasilkan dalam penelitian ini. Untuk data pelatihan didapatkan koefisien korelasi sebesar 0,90015, sedangkan untuk data pengujian didapatkan koefisien korelasi sebesar 0,8974 dimana hasil tersebut mendekati 1 yang berarti bahwa antara target output pada data asli dengan output jaringan menunjukkan kecocokan yang baik. Walaupun hanya sebagian kecil data yang benar-benar menempati posisi yang sama antara target output asli dengan output jaringan. Namun, setelah berdiskusi dengan pihak TPKS, hasil prediksi dari model *container throughput* yang telah dibuat masih dapat ditoleransi sehingga model tersebut masih layak untuk digunakan sebagai model prediksi dan membantu pihak TPKS dalam pengambilan keputusan dan kebijakan terkait pengelolaan *container throughput*.

Adapun hasil dari model prediksi tersebut jika diterapkan untuk memprediksi volume *container throughput* selama beberapa bulan kedepan adalah yang dapat dilihat pada Tabel 5.1 berikut.

Tabel 5.1 Prediksi Volume *Container Throughput*

Waktu Prediksi	Prediksi Volume <i>Container Throughput</i> (TEUs)
Des-17	45.540
Jan-18	45.625
Feb-18	45.619
Mar-18	48.771
Apr-18	44.696
Mei-18	43.138
Jun-18	40.647
Jul-18	40.052
Agu-18	42.897
Sep-18	45.709
Okt-18	45.397
Nov-18	45.755
Des-18	45.356

Tabel 5.1 di atas merupakan hasil prediksi volume *container throughput* berdasarkan model prediksi yang telah dibuat menggunakan ANN. Setelah melakukan konfirmasi ke pihak TPKS, jumlah *container throughput* pada bulan Desember 2017 adalah sebesar 54.892 TEUs, sehingga dapat diketahui bahwa output ANN memiliki *error* sebesar 9.352 TEUs atau setara 17,03%. Oleh karena itu kemudian peneliti mengevaluasi kembali faktor yang mempengaruhi *error tersebut*. Setelah diidentifikasi dapat diketahui bahwa ada beberapa data yang menjadi *outlier* dan berpengaruh terhadap model prediksi menggunakan ANN. Data tersebut dapat dilihat pada Tabel 5.2 berikut.

Tabel 5.2 Data *Outlier*

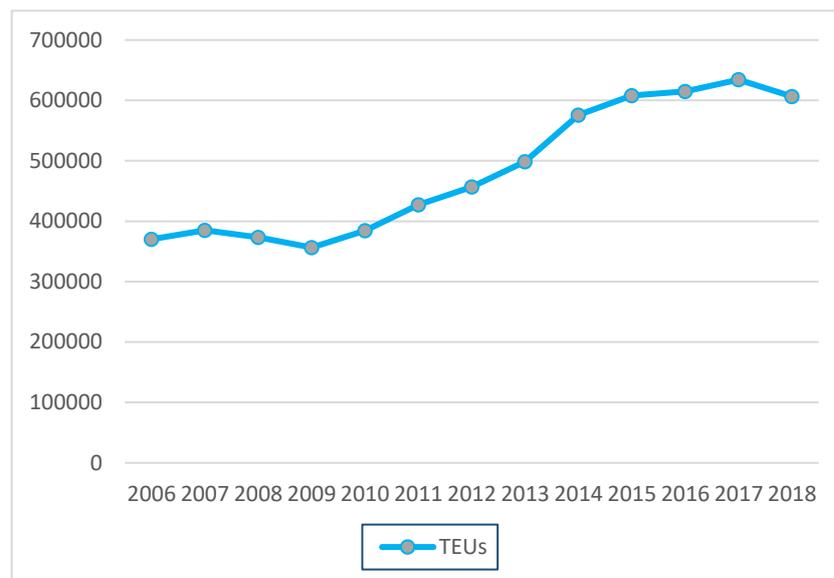
PDB Jawa Tengah	Populasi	Inflasi	Container Throughput	Output ANN	Error	Error Absolute	MAPE
Rp72.460.854,00	2.774.851	8,79%	30.799	40.944	-10.145	10.145	32,94%
Rp91.855.055,24	2.828.698	3,21%	38.324	50.351	-12.027	12.027	31,38%
Rp85.152.443,03	2.815.447	7,26%	35.684	45.613	-9.929	9.929	27,82%
Rp62.547.670,06	2.743.628	3,97%	42.153	35.156	6.997	6.997	16,60%

Tabel 5.2 menunjukkan data-data dengan nilai error yang cukup besar, setelah dievaluasi dapat diketahui bahwa pada data perama, merupakan periode dengan tingkat inflasi yang paling tinggi pada tahun 2013. Meskipun pada periode tersebut PDB daerah yang dihasilkan relatif naik dari periode sebelumnya, namun dengan adanya variabel tingkat inflasi yang sangat tinggi sehingga mengakibatkan penurunan volume *container throughput* yang cukup signifikan dari periode-periode sebelumnya. Hal tersebut menjadi *outlier* dalam pola data yang mengakibatkan terjadinya *error* yang cukup besar pada output ANN, begitu pula untuk data ketiga. Sedangkan untuk data yang kedua sesuai dengan nilai variabel PDB yang cukup tinggi, output ANN menghasilkan nilai prediksi yang tinggi pula, namun hasil prediksi memiliki *error* yang cukup besar jika dibandingkan dengan data aktualnya, hal ini diakibatkan karena kendala yang terjadi pada faktor-faktor lainnya seperti kinerja fasilitas pelabuhan pada saat itu. Pada data keempat terdapat *error* yang cukup besar pula, variabel PDB mengalami penurunan yang cukup signifikan sehingga terjadi penurunan pada volume *container throughput*. Oleh karena itu, peneliti melakukan prediksi kembali dengan menghilangkan data-data yang menjadi *outlier*. Tabel 5.3 berikut merupakan hasil prediksi *container throughput volume* setelah menghilangkan data *outlier*.

Tabel 5.3 Prediksi Volume *Container Throughput* Tanpa Data *Outlier*

Waktu Prediksi	Prediksi Volume <i>Container Throughput</i> (TEUs)
Des-17	53.253
Jan-18	53.190
Feb-18	53.186
Mar-18	48.935
Apr-18	46.338
Mei-18	50.985
Jun-18	51.029
Jul-18	45.405
Agu-18	51.100
Sep-18	49.817
Okt-18	54.983
Nov-18	52.578
Des-18	50.754

Tabel 5.3 di atas menunjukkan bahwa output ANN pada Desember 2017 adalah sebesar 53.253 TEUs dan jumlah aktual volume *container throughput* di TPKS pada Desember 2017 adalah sebesar 54.892 TEUs, sehingga dapat diketahui bahwa *error* yang dihasilkan adalah sebanyak 1.639 TEUs atau serara 2,9% dimana nilai tersebut merupakan hasil yang cukup akurat atau mendekati output aktual, sehingga dapat dikatakan bahwa model prediksi di atas merupakan model prediksi yang valid.



Gambar 5. 2 Pertumbuhan Volume *Container Throughput* 2006-2018

Pada Gambar 5.2 di atas dapat diketahui bahwa pertumbuhan *container throughput* terus meningkat dari tahun ketahun. Kapasitas lapangan penumpukan *container* (*container yard*) di TPKS adalah sebesar 800.000 TEUs. Pada tahun 2017 diketahui bahwa jumlah *container* adalah sebanyak 634.265 TEUs, sedangkan menurut prediksi menggunakan ANN jumlah *container* pada tahun 2018 adalah sebanyak 606.300 TEUs. Diperlukan adanya pembangunan *container yard* sehingga dapat memfasilitasi pertumbuhan *container volume* secara maksimal.

Selain itu diperlukan pula peningkatan fasilitas pelabuhan seperti penambahan *container crane* (CC). *Container crane* adalah *crane* yang digunakan untuk membongkar atau memuat peti kemas dari dan ke dermaga ke kapal peti kemas atau memindahkan peti kemas dari satu tempat ketempat lain di dalam terminal peti kemas. Pada saat ini TPKS memiliki tujuh buah CC dengan masing-masing CC memiliki kapasitas teoritis yang

dapat mengangkut kontainer sebanyak 25TEUs/jam, dan memiliki jam kerja selama 18 jam perhari yang dibagi menjadi 3 shift. Berikut merupakan rincian mengenai CC yang ada di TPKS :

Tabel 5. 4 Rincian *Container Crane* TPKS

Kapasitas Teoritis	25TEUs/CC/jam
Jam Kerja	18 jam/hari
Hari Kerja Efektif	20 hari/bulan
Jumlah CC	7
Total Kapasitas CC Keseluruhan	63.000 TEUs/bulan

Pada tabel diatas dapat diketahui bahwa kapasitas teoritis dari tujuh CC yang ada di TPKS adalah sebesar 63.000 TEUs/bulan. Pada hasil peramalan dapat diketahui bahwa jumlah kontainer terendah adalah sebesar 45.405 TEUs pada bulan Juli 2018 dimana jumlah tersebut setara dengan 72,07% dari kapasitas keseluruhan yang dapat diangkut oleh CC dalam satu bulan, sedangkan jumlah tertinggi adalah 54.983 TEUs pada bulan Oktober 2018 atau setara dengan 87,27% dari kapasitas keseluruhan yang dapat diangkut oleh CC dalam satu bulan. Kapasitas teoritis CC belum mempertimbangkan *downtime* mesin atau kapasitas teoritis dapat dikatakan sebagai asumsi bahwa semua mesin dapat bekerja 100%. Namun bukan tidak mungkin bahwa mesin akan mengalami *downtime*. Dengan kapasitas teoritis yang ada sekarang, hasil prediksi *container* sudah memakai sedikitnya 72% dari kapasitas keseluruhan. Jumlah tersebut sudah dapat dikatakan cukup tinggi bahkan tanpa mempertimbangkan *downtime* mesin yang mengakibatkan berkurangnya kapasitas CC pada TPKS. Oleh karena itu perlu dilakukan penambahan CC sehingga jika terjadi lonjakan arus kontainer maka TPKS dapat meminimalisir waktu tunggu yang lama dalam proses bongkar muat yang diakibatkan oleh kapasitas CC yang tidak memadai. Namun penambahan CC juga tidak boleh dilakukan secara berlebihan karna dapat merugikan perusahaan. Oleh karena itu dalam jangka pendek, peneliti hanya menyarankan untuk menambah 1 atau 2 CC saja, sehingga kapasitas teoritis CC pada TPKS dapat bertambah dan pengangkutan kontainerpun dapat dilakukan lebih cepat serta menghindari resiko waktu pengangkutan yang lama.