



## Pengembangan Model Jaringan Syaraf Tiruan untuk Mendeteksi Anomali Satelit LAPAN- TUBSAT

Agus Herawan<sup>#1</sup>

<sup>#</sup>Pusat Teknologi Satelit - LAPAN

Jl. Cagak Satelit Km.04 Rancabungur - Bogor

<sup>1</sup>agus.herawan@lapan.go.id

**Abstrak**— Kasus satelit mengalami anomali seringkali di temukan pada satelit-satelit yang beroperasi pada orbit polar. Namun permasalahan yang muncul adalah kondisi satelit sering berubah-ubah sehingga operator belum bisa mengantisipasi kondisi tersebut. Oleh sebab itu, model deteksi kondisi satelit dapat berperan sebagai *early warning operator* satelit untuk mempersiapkan strategi yang berkaitan dengan kebijakan preventif terkait pencegahan ketika satelit mengalami kondisi tidak normal. Tujuan penelitian ini adalah menerapkan Jaringan Syaraf Tiruan (JST) backpropagation dalam mendeteksi kondisi anomal pada satelit LAPAN-TUBSAT, serta mengetahui tingkat akurasi dari proses deteksi tersebut sehingga diperoleh parameter dan arsitektur jaringan JST terbaik. Proses pembelajaran dan pengujian JST menggunakan data kejadian anomali tahun 2009 sampai 2014. Arsitektur JST yang digunakan adalah jumlah node input 4, dua *hidden layer*, jumlah node lapisan tersembunyi (*hidden neuron*) divariasikan pada nilai 5, 10, 15 dan 20. Parameter yang diberikan pada proses pembelajaran antara lain adalah fungsi aktivasi, toleransi galat, jumlah *epoch* maksimal dan variasi nilai laju pembelajaran (*learning rate*). Empat parameter input yang digunakan yakni elektron (*mep0e1*), proton (*mep0p1*), indeks Kp serta indeks Dst. Hasil penelitian menunjukkan bahwa arsitektur jaringan syaraf terbaik dihasilkan oleh jaringan dengan jumlah input node empat, *hidden neuron* 20 dan 10, nilai *learning rate* sebesar 0.05 dengan 306 *epoch*, menghasilkan rata-rata akurasi sebesar 98.13%, serta nilai *precision* dan *recall* sebesar 98.21% dan 94.81%.

**Kata kunci**— Anomali, Backpropagation, JST, LAPAN-TUBSAT, *Learning rate*

### I. PENDAHULUAN

Prediksi adalah perkiraan tentang sesuatu yang akan terjadi pada waktu mendatang yang berdasarkan pada data

yang ada pada waktu sekarang dan waktu lampau. Pada bidang satelit, prediksi digunakan untuk merepresentasikan pergerakan nilai-nilai kondisi orbit, kondisi satelit dan anomali satelit. *Anomaly event* berkaitan dengan record dari kegagalan sebuah sistem satelit yang dipicu oleh faktor tertentu (kondisi ekstrim lingkungan antariksa, problem mekanik maupun listrik ataupun *false command*). *Non anomaly event* berkaitan dengan kondisi umum satelit yang beroperasi dalam keadaan normal dan tidak ditemukan adanya gejala kondisi antariksa yang dapat memicu terjadinya atau berpotensi untuk memicunya kegagalan pada sistem satelit. Anomali terkait dengan proses *charging*. Secara umum, *charging* ini dapat dikelompokkan menjadi dua yakni *absolute charging* (pemuatan listrik pada seluruh permukaan satelit) dan *differential charging* (pemuatan listrik parsial pada permukaan satelit) [1].

Cuaca antariksa menunjukkan kondisi di matahari dan angin surya, magnetosfer, ionosfer, dan termosfer yang dapat mempengaruhi kondisi dan kemampuan sistem teknologi satelit. Satelit-satelit yang ditempatkan di orbit rendah dan orbit tinggi sering mengalami kejadian anomali operasional baik pada sistem maupun pada sub sistem satelit, mulai dari kegagalan fungsi instrumen yang ringan hingga dapat dipulihkan (*recovery*). Kasus anomali satelit dapat di temukan pada satelit-satelit yang beroperasi pada orbit polar. Jika keadaan ini berlangsung dalam waktu yang cukup lama, bisa merusak komponen yang ada sehingga satelit tersebut akan mengalami kegagalan dalam menjalankan misi utamanya.

Generasi pertama dari satelit mikro Indonesia LAPAN-TUBSAT berhasil dikembangkan dan diluncurkan pada bulan Januari 2007 di Sriharikota, India. Satelit ini ditempatkan di ketinggian 630 km dan kemiringannya hampir 8 derajat. Dalam satu hari, satelit melewati wilayah kutub *south atlantic anomaly* 2 kali di setiap orbit. Daerah kutub dan *south atlantic anomaly* dikenal sebagai daerah berbahaya untuk satelit di orbit karena fluks dan energi partikel bermuatan tinggi.

Fenomena anomali merupakan ancaman utama bagi satelit di ruang angkasa [2].

Penelitian yang telah dilakukan berhasil melakukan tindakan preventif berupa mematikan dan mereset timer semua peralatan yang berada di dalam satelit. Satelit LAPAN-TUBSAT menghadapi beberapa kejadian anomali. Penelitian [3] fenomena terjadinya anomali pada satelit LAPAN-TUBSAT dikenal sebagai *single event latchup*. *Single event latchup* merupakan kejadian yang mengganggu fungsi kerja suatu komponen dan menyebabkan kerusakan permanen bila tidak dilakukan tindakan untuk menghilangkan kondisi tersebut.

*Single event latchup* pada satelit LAPAN-TUBSAT ini terjadi karena partikel bermuatan berenergi tinggi yang menumbuk bagian yang sensitif pada alat mikroelektronik dan menyebabkan output atau kinerja dari perangkat tersebut *error*. Gangguan yang terjadi pada satelit di orbit dapat dibedakan menjadi 2, yaitu: *Non-Destructive Single Event Effect*. Kondisi ini bisa berlangsung permanen atau sementara dan tidak mengganggu fungsi kerja dari komponen tersebut. Sedangkan *Destructive single event effects* yakni kejadian SEE yang mengganggu fungsi kerja suatu komponen dan menyebabkan kerusakan permanen bila tidak dilakukan tindakan untuk menghilangkan kondisi tersebut. SEE jenis ini salah satunya yakni anomali pada satelit yang dikenal dengan kejadian *Single Event Latchup* (SEL)

Kejadian anomali atau *anomali* maupun tidak dapat dibedakan dari efek yang ditimbulkan ketika satelit LAPAN-TUBSAT melewati stasiun bumi. Ketika terjadi anomali, temperatur satelit LAPAN-TUBSAT akan mengalami panas dengan ditandai naiknya arus pada main power bus satelit.

Kejadian anomali satelit disebabkan oleh aktifitas geomagnet dengan menggunakan parameter indeks kp dan indeks Dst [4] dan partikel elektron ( $mep0e1$ ) dan proton ( $mep0p1$ ) [5].

Beberapa penelitian tentang jaringan syaraf tiruan antara lain Penelitian [6] menyajikan metode mengidentifikasi dan mengklasifikasikan anomali jaringan menggunakan jaringan syaraf tiruan untuk menganalisis data yang dikumpulkan melalui protokol Netflow. Penelitian yang dilakukan mengusulkan menggunakan *multilayer perceptron*, dilatih dengan algoritma *backpropagation*. Penelitian [7] telah mengadopsi jaringan syaraf tiruan untuk membangun sebuah model prediksi untuk fluks elektron di orbit *geosynchronous*.

Penelitian [8] telah mengusulkan perceptron *multilayer* untuk memprediksi besarnya gempa bumi, terdiri dari tiga lapisan utama; lapisan input, lapisan tersembunyi dan lapisan keluaran. Hasil percobaan menunjukkan bahwa jaringan syaraf plastik menghasilkan 128 model untuk menentukan model prediksi terbaik. Penelitian [9] telah mengusulkan sistem dengan algoritma *neural network forward multilayered feed* dan *backpropagation* untuk prediksi penyakit jantung dalam empat tahap. Dataset yang disediakan oleh repositori pembelajaran mesin University of California, Irvine [UCI] digunakan untuk

pelatihan dan pengujian. Dataset terdiri dari 14 atribut dari 303 pasien termasuk label kelasnya. Hasil eksperimen menunjukkan bahwa akurasi yang diperoleh dengan menggunakan pendekatan ini adalah 92%. Penelitian [10] melakukan prediksi curah hujan di wilayah DELHI (India) telah dianalisis menggunakan algoritma propagasi balik jaringan syaraf. Model tiga lapis telah digunakan untuk melatih dan mempelajari berbagai atribut neuron tersembunyi dalam jaringan. Penelitian [11] mengusulkan algoritma untuk identifikasi driver real-time menggunakan kombinasi deteksi anomali tanpa pengawasan dan jaringan syaraf. Algoritma yang diusulkan menggunakan sinyal nonfisiologis sebagai input, yaitu sinyal perilaku mengemudi dari sensor inersia (mis. Akselerometer) dan sinyal geolokasi dari sensor GPS.

Penelitian [12] mengusulkan untuk memecahkan masalah peramalan seri waktu multivariat data telemetri menggunakan ansambel jaringan syaraf. Pendekatan untuk pembentukan ansambel jaringan syaraf dianalisis dan akurasi prediksi dievaluasi. Kemungkinan pelatihan ansambel jaringan syaraf dipelajari untuk mengurangi kesalahan peramalan deret waktu multivarian. Penelitian [13] melakukan pendekatan jaringan syaraf untuk prediksi data telemetri satelit disajikan. Dengan memanfaatkan kemampuan belajar mandiri, beradaptasi sendiri, dan nonlinear, jaringan syaraf BP tiga lapis digunakan untuk membuat model prediksi data telemetri satelit. Model jaringan syaraf BP memiliki kecepatan konvergensi yang cepat dan presisi prediksi yang tinggi. Hasil percobaan menunjukkan bahwa metode ini efisien dan praktis untuk prediksi data telemetri satelit in-orbit.

Penelitian [14] mendeteksi anomali dalam data historis menggunakan teknik pembelajaran mesin dapat mengarah pada pemantauan kesehatan sistem. Tujuan dari penelitian ini adalah untuk membangun model berbasis data berbasis jaringan syaraf yang akan digunakan untuk deteksi anomali di bagian tertentu dari pembangkit listrik tenaga panas. Bagian yang dipilih adalah Steam Superheaters dan Steam Drum. Input untuk jaringan syaraf adalah beberapa variabel proses paling penting dari bagian ini. Semua input dapat diamati dari sistem pemantauan instalasi pembangkit listrik termal, dan perilaku anomali / normalnya diakui oleh pengalaman operator. Penelitian [15] telah mengusulkan jaringan syaraf C-LSTM untuk memodelkan informasi spasial dan temporal yang terkandung dalam data lalu lintas secara efektif, yang merupakan sinyal deret waktu satu dimensi.

Penelitian [16] telah mengembangkan model dua tingkat ansambel jaringan syaraf untuk perkiraan seri waktu telemetri dari subsistem pesawat ruang angkasa. Kemungkinan pelatihan tambahan dari ansambel jaringan syaraf ini diperiksa. Hasil penelitian menunjukkan bahwa penggunaan ansambel jaringan syaraf dengan penimbangan dinamis memungkinkan untuk mengurangi kesalahan peramalan.

Permasalahan yang terjadi yakni satelit LAPAN-TUBSAT mengalami kejadian *anomali* yang tidak dapat diantisipasi oleh operator satelit. Oleh sebab itu, model

deteksi yang akan dibangun dapat berperan sebagai *early warning* terhadap operator satelit untuk mempersiapkan strategi yang berkaitan dengan kebijakan preventif terkait pencegahan ketika satelit berada dalam kondisi anomali.

Salah satu teknik yang dapat digunakan untuk prediksi adalah Jaringan Saraf Tiruan (JST). JST memiliki keunggulan dalam hal kemampuan prediksi dan klasifikasi terhadap data yang belum diberikan pada saat pembelajaran sebelumnya sehingga teknik ini diharapkan dapat digunakan untuk membuat pemodelan deteksi anomali pada satelit LAPAN-TUBSAT. Penelitian ini menggunakan algoritma pembelajaran propagasi balik dimana masalah utama yang dihadapi dalam JST propagasi balik adalah lamanya iterasi yang dilakukan.

Pada penelitian ini diterapkan Jaringan Syaraf Tiruan (JST) Propagasi Balik untuk mendeteksi anomali. Data-data penyebab kejadian anomali akan diolah dengan JST Propagasi Balik untuk mengetahui tingkat akurasi dari proses deteksi tersebut. Oleh karena propagasi balik tidak dapat memberikan kepastian tentang berapa *epoch* yang harus dilalui untuk mencapai kondisi yang diinginkan, maka dalam penelitian ini dicari bagaimana parameter-parameter jaringan dibuat, untuk mendapatkan hasil yang optimal dengan mempertimbangkan beberapa parameter seperti algoritma pelatihan, jumlah node pada lapisan jaringan, serta laju pembelajaran. Arsitektur JST terbaik yang diperoleh nantinya akan digunakan untuk melakukan deteksi anomali pada satelit LAPAN-TUBSAT.

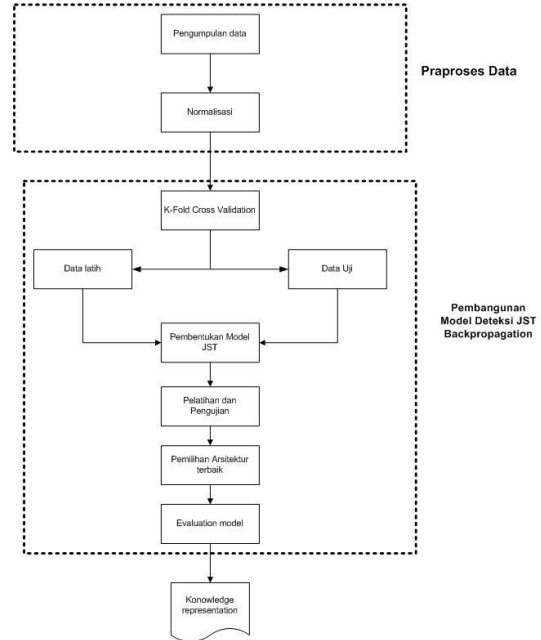
II. METODE PENELITIAN

Metode yang digunakan dalam penelitian ini terbagi menjadi dua bagian yakni praproses data dan pembangunan model deteksi JST backpropagation. Pada bagian praproses data terdiri dari pengumpulan data penelitian dan melakukan normalisasi data. Pada bagian pembangunan model terdiri dari pembagian data latihan dan uji menggunakan k-fold cross validation, pembentukan model jaringan syaraf tiruan, pelatihan dan pengujian jaringan syaraf, pemilihan arsitektur jaringan syaraf terbaik, mengevaluasi model jaringan dengan confusion matrix serta tahap akhir yakni representasi pengetahuan yakni memvisualisasikan ke dalam bentuk graphical user interface (GUI). Metode penelitian yang digunakan disajikan pada Gambar 1.

A. Pengumpulan Data

Data yang digunakan pada penelitian ini ialah data penyebab anomali pada satelit LAPAN-TUBSAT. Data penelitian ini merupakan data dari partikel yang diukur dari satelit NOAA-15 serta indeks geomagnet dari NASA tahun 2009 - 2014 dikarenakan intensitas badai matahari yang sangat tinggi. Penelitian ini menggunakan 4 parameter. Parameter tersebut ialah mpe0e1 (elektron), mpe0p1 (proton), nilai indeks Kp serta nilai indeks Dst. Parameter mep0e1 dan mep0p1 dipilih karena penyebab utama anomali atau *anomali* berada pada tingkat fluks partikel dengan energi 30 - 80 keV. Parameter indeks Kp dan indeks Dst merupakan indikator magnetic. Fluktuasi

partikel energetik dilihat dari kedua indeks tersebut. Indeks kp digunakan untuk lintang tinggi dan indeks Dst digunakan untuk lintang rendah. Pada data ini satelit akan dikategorikan menjadi dua yaitu normal berarti satelit tidak mengalami anomali dan anomali yang berarti satelit mengalami kejadian anomali. Jumlah atribut yang akan digunakan disajikan pada Tabel 1.



Gambar 1. Metode penelitian

TABEL I  
ATRIBUT YANG DIGUNAKAN

Atribut	Keterangan
mep0e1	Partikel elektron dengan kanal E1 energi 30 KeV
mep0p1	Partikel proton dengan kanal P1 energi 80 KeV
Kp Index	Aktifitas geomagnet
Dst Index	Indeks badai geomagnet

Data ini terdiri atas 1720 jumlah data dengan 4 parameter yakni mep0e1 (elektron), mep0p1 (proton), Kp indeks dan Dst indeks. Data-data tersebut digunakan untuk melakukan pelatihan program dan sebagai data latihan dan data uji untuk sistem. Sebagai outputnya merupakan deteksi satelit dalam kondisi anomali atau normal. Data-data yang digunakan untuk data latihan serta data uji merupakan data rata-rata harian partikel yang di ukur oleh satelit NOAA serta indeks geomagnet dari NASA tahun 2009 sampai 2014 dikarenakan tahun yang diambil merupakan tahun dimana intensitas badai matahari sedang tinggi. Jumlah kategori data yang digunakan yakni sebanyak 1258 data normal dan 462 satelit mengalami anomali.

B. Normalisasi

Sebelum data digunakan akan dilakukan praproses untuk meningkatkan efisiensi dan skalabilitas dari data yang dihasilkan oleh satelit dalam bentuk textfile. Praproses data adalah kegiatan mempersiapkan data yang akan digunakan, agar informasi atau pengetahuan yang ingin diambil dari data tersebut dapat diambil dengan lebih mudah. Data yang akan digunakan yakni data dari tahun 2009 sampai 2014. Untuk keperluan penelitian ini data-data penyebab kejadian anomali akan diproses menjadi data rata-rata harian. Praproses ini dilakukan dengan menggunakan perangkat lunak Microsoft Excel 2010. Normalisasi data dilakukan pada atribut data numerik yang memiliki pengaruh terhadap atribut berskala kecil dengan skala nilai antara 0.0 sampai 1.0. Normalisasi dapat mengatasi atribut yang memiliki nilai rentang yang cukup besar. Metode yang digunakan untuk normalisasi data pada penelitian ini yaitu *min-max normalization*. *Min-max normalization* melakukan transformasi linear pada data asli. Untuk melakukan normalisasi data, perlu mengetahui minimum ( $X_{min}$ ) dan maksimum ( $X_{max}$ ) dari data.

C. Pembagian Data Latih dan Data Uji

Komposisi data terbagi menjadi data pelatihan dan data pengujian. Data pelatihan digunakan oleh jaringan untuk membentuk model melalui proses pembelajaran JST. Data pengujian digunakan untuk menguji ketepatan prediksi dari model yang terbentuk. Teknik yang digunakan untuk membagi data uji dan data latih adalah *k-fold cross validation*. Teknik ini membagi data menjadi *k subset* dengan ukuran yang sama. Pembagian data latih dan data uji dilakukan dengan menggunakan metode *k-fold cross validation* dengan menggunakan *k* sama dengan 5

D. Pembentukan Model JST

Pembentukan model prediksi dimaksudkan untuk menentukan parameter dari arsitektur jaringan yang akan digunakan untuk pembelajaran. Pembentukan model prediksi dilakukan dengan menggunakan jaringan syaraf tiruan backpropagation dengan 2 (dua) *hidden layer*. Jumlah node untuk lapisan input sama dengan jumlah variabel input, karena data input sudah berbentuk data numerik sehingga tidak mengalami praproses data. Jumlah node pada lapisan output yakni 1 (satu) kategori. Adapun untuk jumlah node pada *hidden layer* pada penelitian ini akan divariasikan untuk mendapatkan hasil yang lebih optimal.


Selain jumlah node pada tiap lapisan arsitektur JST, ditetapkan beberapa parameter yang akan diberikan pada proses pembelajaran dan diuji untuk membentuk model prediksi, antara lain adalah fungsi aktivasi, toleransi galat, jumlah *epoch* maksimal, laju pembelajaran (*learning rate*) dan fungsi pelatihan (*training function*). Arsitektur jaringan syaraf tiruan yang digunakan untuk deteksi dibentuk oleh *input layer*, dua *hidden layer*, dan satu *neuron* pada *output layer*. Desain arsitektur jaringan

syaraf tiruan dilakukan untuk deteksi *single event anomali* ini dimulai dengan menentukan banyaknya *input layer*, banyaknya *hidden layer*, dan banyaknya *output layer* yang diinginkan. *Input layer* yang akan digunakan sebanyak 4 yakni nilai partikel  $mpe0e1(x1)$ ,  $mpe0p1(x2)$ , nilai indeks  $Kp(x3)$  serta nilai indeks  $Dst(x4)$ . Variasi jumlah *hidden neuron* yang digunakan adalah 5,10, 15 dan 20. Selain jumlah node pada tiap lapisan arsitektur JST, ditetapkan beberapa parameter yang akan diberikan pada proses pelatihan dan diuji untuk membentuk model prediksi, antara lain adalah fungsi aktivasi, toleransi galat, jumlah *epoch*, laju pelatihan (*learning rate*) dan fungsi pelatihan (*training function*). Parameter yang divariasikan dalam proses pembelajaran adalah *hidden neuron* dan laju pembelajaran (*learning rate*). Spesifikasi struktur jaringan yang akan di rancang disajikan pada Tabel 2.

TABEL II  
STRUKTUR JARINGAN YANG AKAN DIGUNAKAN

Karakteristik	Spesifikasi
Arsitektur	2 <i>hidden layer</i>
Algoritma Pelatihan	<i>Backpropagation</i>
Jumlah Input layer	4 <i>input layer</i>
Jumlah hidden neuron	5, 10, 15 dan 20
Toleransi Galat	0.001
Fungsi aktivasi hidden dan output layer	Sigmoid biner
Maksimum <i>epoch</i>	10000
<i>Learning rate</i>	0.01, 0.02, 0.03, 0.04, 0.05, 0.06, 0.07, 0.08, 0.09, 0.1

Untuk inialisasi bobot awal digunakan inialisasi secara random. Fungsi aktivasi yang digunakan pada lapisan tersembunyi adalah sigmoid biner dengan jumlah *epoch* maksimal yang ditetapkan dalam penelitian ini adalah 10000. Variasi nilai laju pelatihan yang digunakan yakni 10 *learning rate* yaitu 0.01, 0.02, 0.03, 0.04, 0.05, 0.06, 0.07, 0.08, 0.09 dan 0.1. Desain jaringan syaraf tiruan ditunjukkan pada Gambar 2.



Gambar 2. Rancangan arsitektur jaringan syaraf tiruan yang akan dibangun

E. Pelatihan dan Pengujian Jaringan Syaraf Tiruan

Setelah model terbentuk selanjutnya dilakukan proses pelatihan, dimana pada proses ini menggunakan data pelatihan. Pelatihan dilakukan bertujuan untuk mengenali pola-pola dari data masukan pada data pelatihan untuk dilatih pada jaringan yang akan menghasilkan keluaran untuk dibandingkan dengan data target. Pengujian jaringan bertujuan untuk mengetahui apakah jaringan dapat melakukan pengenalan terhadap data baru yang dimasukkan ke dalamnya yaitu ditunjukkan dengan persentase akurasi jaringan dalam mengenali data pengujian, sehingga arsitektur jaringan yang digunakan untuk pengujian adalah arsitektur terbaik yang diperoleh dari hasil pelatihan jaringan.

F. Pemilihan Arsitektur Model Terbaik

Dari hasil pelatihan dan pengujian dengan berbagai kasus data inialisasi yang berbeda-beda, dipilih jaringan optimal dengan nilai epoch terkecil. Setelah proses pelatihan dan pengujian dilakukan pada masing-masing kelompok arsitektur, dipilih hasil yang memenuhi kriteria, yaitu model yang memiliki akurasi tinggi dan epoch terkecil. Selanjutnya adalah menganalisis dan mengevaluasi kinerja model berdasarkan parameter dan data yang digunakan.

G. Evaluasi Model

Dalam penelitian ini dipilih alat ukur evaluasi berupa *confusion matrix* dengan tujuan untuk mempermudah dalam menganalisis performa algoritme *backpropagation*, karena *confusion matrix* memberikan informasi dalam bentuk angka sehingga dapat dihitung rasio keberhasilan prediksi. *Confusion matrix* digunakan sebagai dasar dari variasi ukuran penilaian seperti akurasi, *precision* dan *recall*. Tabel 5 menyajikan *confusion matrix* untuk mendeteksi kondisi satelit. Dalam penelitian ini, nilai akurasi, *precision* dan *recall* dinyatakan dalam persen, semakin tinggi *persentase* ketiga nilai tersebut, maka semakin baik kinerja metode deteksi.

TABEL III  
CONFUSION MATRIX UNTUK MEMPREDIKSI SINGLE EVENT ANOMALI SATELIT

	Kelas Hasil Prediksi	
	Anomali	Normal
Anomali	True Positive (TP)	False Negatif (FN)
Normal	False Positif (FP)	True Negatif (TN)

Keterangan:

TP (*True Positive*) : kondisi *anomali* yang diprediksi benar sebagai *anomali*

FN (*False Negative*) : kondisi *anomali* yang diprediksi salah sebagai normal.

FP (*False Positive*) : kondisi normal yang diprediksi salah sebagai *anomali*.

TN (*True Negative*) : kondisi normal yang diprediksi benar sebagai normal

H. Representasi Pengetahuan

Tahapan representasi pengetahuan merupakan tahapan akhir pada penelitian ini, dimana pada tahap ini pola yang telah ditemukan dipresentasikan ke pengguna dengan teknik visualisasi agar pengguna dapat memahaminya.

III. HASIL DAN PEMBAHASAN

A. Praproses Data

Praproses data yang dilakukan pada penelitian ini adalah pembersihan data, analisa relevansi (Han dan Kember 2010). Pembersihan data dengan dilakukan untuk menghilangkan noise akibat data yang rusak atau tidak lengkap. Analisa relevansi dilakukan untuk menghilangkan atribut yang dianggap belum relevan terlibat dalam penelitian ini. Data-data partikel dari satelit NOAA maupun data indeks Kp dan Dst masih berbentuk textfile. Sehingga dilakukan praproses data dengan mengubahnya ke dalam ekstensi \*.xls. Data kejadian anomali yang dialami oleh satelit selanjutnya akan diolah oleh jaringan. Agar data dapat dikenali oleh jaringan, maka data harus direpresentasikan ke dalam bentuk numerik antara 0 dan 1, baik variabel maupun isinya yang merupakan masukan penyebab anomali beserta kategorinya dan keluaran yang merupakan deteksi anomali.

Hal ini dikarenakan jaringan menggunakan fungsi aktivasi sigmoid biner (*logsig*) dengan nilai 0 sampai 1. Nilai-nilai yang digunakan diperoleh berdasarkan kategori dari masing-masing variabel selain juga untuk memudahkan mengingat dalam pendefinisianya. Hasil yang ingin diperoleh pada tahap ini, yaitu nilai untuk memprediksi satelit anomali atau tidak. Hasil yang maksud adalah jika output bernilai 0 berarti satelit normal dan jika output bernilai 1 berarti satelit mengalami anomali. Banyaknya data menjadi 1720 yang terbagi menjadi 1258 termasuk kelas kejadian normal dan 462 termasuk kelas kejadian anomali. Permasalahan data dalam skala yang berbeda dapat diselesaikan dengan metode normalisasi.

B. Pembagian Data Latih dan Data Uji

Dari data yang diperoleh, dilakukan pembuatan data latih dan data target yang digunakan sebagai input data sistem. Dalam sistem target akan dibaca "anomali" jika target 1 dan "normal" jika target 0. Kedua data tersebut disimpan dengan format excel. Data yang telah disimpan dalam format excel akan ditampilkan di workspace pada Matlab dengan cara import data. Pembagian data latih dan data uji dengan proporsi 80% data latih dan 20% data uji dan metode uji *5-fold cross validation*. Jumlah data yang diperoleh sebanyak 1720 record dan dibagi menjadi 5 subset secara acak sehingga setiap subset terdiri atas 1375 record. Percobaan terus dilakukan hingga setiap subset pernah dijadikan data uji seperti terlampir pada Tabel 4.

TABEL IV  
SUSUNAN DATA LATIH DAN DATA UJI

Fold	Pelatihan	Pengujian
Fold I	S1, S2, S3, S4	S5
Fold II	S1, S2, S3, S5	S4
Fold III	S1, S2, S4, S5	S3
Fold IV	S1, S3, S4, S5	S2
Fold V	S2, S3, S4, S5	S1

C. Pembentukan Model Jaringan Syaraf Tiruan

Jaringan saraf tiruan dibangun didasarkan pada rancangan struktur jaringan yang akan dibangun seperti yang tersaji pada Tabel 5. Proses pelatihan dan pengujian menghasilkan informasi akurasi dengan variasi nilai learning rate dan jumlah hidden neuron. Tahap pelatihan jaringan menggunakan algoritma pembelajaran *levenberg marquardt (trainlm)*. Pelatihan jaringan dilakukan menggunakan matlab. Proses pelatihan dilakukan menggunakan data-data pelatihan dengan target error ditentukan sebesar 0.001 dan untuk nilai *learning rate* ditentukan dari 0.01 sampai 0.1. Tahap pelatihan jaringan akan menghasilkan nilai bobot dan bias yang akan digunakan pada tahap pengujian jaringan. Jika ada dua atau lebih nilai parameter yang menghasilkan akurasi yang sama, penentuan parameter JST optimal akan dilihat berdasarkan nilai parameter yang memiliki *epoch* terkecil

Tahap pelatihan menggunakan jaringan layar jamak (*multi layer network*) dengan dua *hidden layer*. Kombinasi nilai hidden neuron yang digunakan adalah 20-5, 20-10, 20-15 dan 20-20. Fungsi aktivasi yang digunakan pada *hidden layer* dan *output layer* yakni fungsi aktivasi *sigmoid biner (logsig)*. Tahap pengujian jaringan digunakan untuk menguji yang belum pernah dilatih sebelumnya untuk mengetahui nilai akurasi yang dihasilkan. Hasil yang di peroleh pada tahap ini adalah output berupa kondisi satelit. Hasil percobaan dengan 5 *fold cross validation* dengan nilai *learning rate* dan *hidden neuron* berbeda disajikan pada Tabel 5.

Dari Tabel 5 dapat dilihat masing-masing akurasi tiap arsitektur dengan nilai *learning rate* yang berbeda tiap percobaan dengan menggunakan 5 *fold*. Percobaan pertama dengan menggunakan learning rate 0.01 diperoleh rata-rata akurasi tertinggi sebesar 98.42% pada arsitektur 20-20. Percobaan kedua dengan menggunakan *learning rate* 0.02 diperoleh rata-rata akurasi tertinggi sebesar 98.36% pada arsitektur 20-15 dan 20-20. Percobaan ketiga dengan menggunakan *learning rate* 0.03 diperoleh rata-rata akurasi tertinggi sebesar 98.65% pada arsitektur 20-20. Percobaan keempat dengan menggunakan *learning rate* 0.04 diperoleh rata-rata akurasi tertinggi sebesar 98.42% pada arsitektur 20-20. Percobaan kelima dengan menggunakan *learning rate* 0.05 diperoleh rata-rata akurasi tertinggi sebesar 98.54%

pada arsitektur 20-5. Percobaan keenam dengan menggunakan *learning rate* 0.06 diperoleh rata-rata akurasi tertinggi sebesar 98.54% pada arsitektur 20-10. Percobaan ketujuh dengan menggunakan *learning rate* 0.07 diperoleh rata-rata akurasi tertinggi sebesar 98.36% pada arsitektur 20-15. Percobaan kedelapan dengan menggunakan learning rate 0.08 diperoleh rata-rata akurasi tertinggi sebesar 98.48% pada arsitektur 20-5. Percobaan kesembilan dengan menggunakan *learning rate* 0.09 diperoleh rata-rata akurasi tertinggi sebesar 98.36% pada arsitektur 20-15. Percobaan kesepuluh dengan menggunakan learning rate 0.1 diperoleh rata-rata akurasi tertinggi sebesar 98.36% pada arsitektur 20-20. Rata-rata akurasi untuk setiap arsitektur dengan *learning rate* yang berbeda disajikan pada Gambar 3.

D. Arsitektur jaringan yang terbaik

Berdasarkan hasil pengujian dengan mempertimbangkan beberapa variasi parameter jaringan, maka ditetapkan arsitektur terbaik dengan melihat epoch tekecil dan waktu tercepat yang dapat digunakan untuk melakukan deteksi anomali sebagaimana yang disajikan pada Gambar 4.

Arsitektur terbaik dipilih dengan menetapkan parameter terbaik yang digunakan dalam mendeteksi anomali. Semakin tinggi tingkat akurasi yang dihasilkan maka semakin baik jaringan mengenali data baru yang akan diberikan dan diharapkan bisa memberikan hasil prediksi yang cukup baik. Apabila diperoleh tingkat akurasi yang besarnya sama pada beberapa laju pembelajaran dan jumlah hidden neuron maka yang dipilih adalah variasi parameter laju pembelajaran dan jumlah *hidden neuron* yang memberikan nilai epoch yang terkecil. Berdasarkan Gambar 4, diperoleh hasil bahwa arsitektur jaringan terbaik yakni model dengan arsitektur 4-20-10-1 dengan laju pembelajaran sebesar 0.05. *Epoch* yang dihasilkan sebesar 306 dan waktu yang diperoleh yakni 2 detik. Arsitektur terbaik pada model deteksi anomali ini disajikan pada Gambar 5.

Pengujian arsitektur terbaik terhadap data baru dimaksudkan untuk menguji ketepatan jaringan dalam melakukan prediksi. Data baru yang akan diuji tanpa memiliki data target, sehingga target hasil prediksi yang akan dihasilkan akan dibandingkan dengan data aktual. Data baru yang akan di uji yang merupakan data tahun 2014. Data baru yang akan di uji ini merupakan data yang belum pernah diikuti baik dalam proses pelatihan maupun pengujian.

TABEL V  
HASIL AKURASI TIAP FOLD UNTUK TIAP ARSITEKTUR DAN LEARNING RATE


Learning rate	Hidden neuron	Akurasi					Rata-rata
		fold 1	fold 2	fold 3	fold 4	fold 5	
0.01	20-5	98.25%	98.83%	96.50%	99.12%	97.66%	98.07%
	20-10	98.54%	99.12%	97.37%	99.12%	97.95%	98.42%
	20-15	98.54%	97.96%	97.36%	98.83%	98.25%	98.19%
	20-20	98.54%	99.70%	97.37%	99.41%	98.25%	98.65%
0.02	20-5	98.25%	98.25%	96.20%	98.83%	97.08%	97.72%
	20-10	98.54%	98.25%	97.37%	99.41%	98.25%	98.36%
	20-15	97.97%	98.24%	97.66%	99.12%	97.66%	98.36%
	20-20	98.25%	98.25%	97.08%	98.83%	98.25%	98.13%
0.03	20-5	98.54%	99.41%	97.66%	98.54%	97.95%	98.42%
	20-10	97.96%	99.41%	97.08%	99.41%	93.37%	98.25%
	20-15	98.54%	97.67%	97.66%	99.12%	99.41%	98.48%
	20-20	98.25%	98.54%	97.95%	99.12%	99.40%	98.65%
0.04	20-5	98.25%	99.12%	97.37%	98.54%	97.66%	98.19%
	20-10	97.67%	97.67%	97.08%	98.54%	97.60%	97.72%
	20-15	98.25%	99.12%	96.79%	98.83%	97.66%	98.13%
	20-20	98.54%	98.83%	97.37%	98.83%	97.66%	98.25%
0.05	20-5	98.83%	98.83%	98.25%	98.54%	98.25%	98.54%
	20-10	97.96%	98.83%	97.37%	98.54%	97.95%	98.13%
	20-15	98.25%	97.96%	97.08%	99.41%	97.66%	98.07%
	20-20	98.83%	99.41%	96.79%	98.25%	98.83%	98.42%
0.06	20-5	97.67%	98.54%	98.25%	96.79%	97.95%	97.84%
	20-10	98.25%	98.25%	97.66%	99.12%	99.40%	98.54%
	20-15	98.54%	97.96%	97.66%	99.40%	97.66%	98.24%
	20-20	98.54%	98.25%	96.50%	98.25%	97.95%	97.90%
0.07	20-5	98.54%	98.25%	97.08%	99.41%	97.68%	98.19%
	20-10	98.25%	97.65%	97.08%	97.96%	98.25%	97.90%
	20-15	98.25%	99.12%	97.95%	99.12%	97.37%	98.36%
	20-20	98.54%	98.83%	97.37%	98.545	97.95%	98.25%
0.08	20-5	98.25%	99.41%	97.37%	99.41%	97.95%	98.48%
	20-10	98.54%	98.54%	97.66%	98.54%	97.37%	98.13%
	20-15	97.96%	98.25%	97.37%	98.83%	97.66%	98.01%
	20-20	98.54%	98.25%	97.66%	98.79%	97.37%	98.12%
0.09	20-5	97.96%	98.54%	97.08%	98.83%	98.54%	98.19%
	20-10	98.25%	98.83%	97.37%	98.83%	98.25%	98.31%
	20-15	98.54%	98.54%	97.37%	99.12%	98.25%	98.36%
	20-20	98.54%	98.54%	97374%	98.84%	98.25%	98.11%
0.1	20-5	98.54%	99.12%	96.79%	98.83%	97.95%	98.25%
	20-10	97.96%	98.83%	97.08%	97.76%	97.37%	97.80%
	20-15	98.25%	98.70%	97.37%	99.41%	97.66%	98.27%
	20-20	98.54%	98.54%	97.37%	99.12%	98.25%	98.36%

E. Evaluasi Model

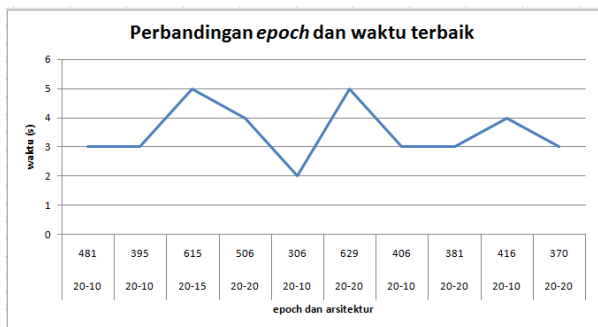
Confusion matrix yang dihasilkan oleh model arsitektur terbaik menghasilkan tingkat akurasi rata-rata sebesar 98.13%. Dari data keseluruhan sebanyak 343 data, 88 data berhasil diprediksi benar sebagai kondisi anomali, sementara 248 data diprediksi benar sebagai kondisi normal. 3 data diprediksi

salah sebagai kondisi anomali dan 4 data diprediksi salah sebagai kondisi normal. di prediksi masuk ke dalam kelas anomali dan sebanyak 4 data anomali salah prediksi masuk ke dalam kondisi normal. Hasil confusion matriks terbaik disajikan pada Tabel 6.

Evaluasi model juga dilakukan dengan melihat nilai precision dan recall. Nilai rata-rata recall dan precision yang dihasilkan pada jaringan terbaik 4-20-10-1 yakni sebesar 94.81% dan 98.21%. Ini berarti bahwa kinerja metode prediksi semakin baik dalam mendeteksi anomali. Hasil akurasi *precision* dan *recall* terbaik pada jaringan 4-20-10-1 dengan nilai laju pembelajaran 0.05 disajikan pada Gambar 7.



Gambar 3. Hasil akurasi terbaik masing-masing learning rate

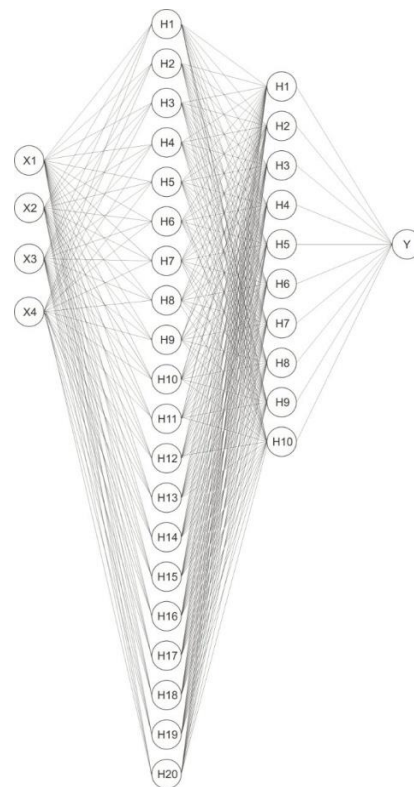


Gambar 4. Perbandingan epoch dan waktu terbaik masing-masing arsitektur

F. Representasi Pengetahuan

Sebuah aplikasi sederhana dengan menggunakan Matlab telah dibangun yang dapat digunakan untuk melakukan proses training, proses testing dan proses prediksi. Pada aplikasi ini terdiri dari beberapa form aplikasi, diantaranya: a) *form* utama aplikasi untuk mendeteksi kondisi satelit, b) *form* proses training, c) *form* proses testing, d) *form* deteksi anomali satelit.

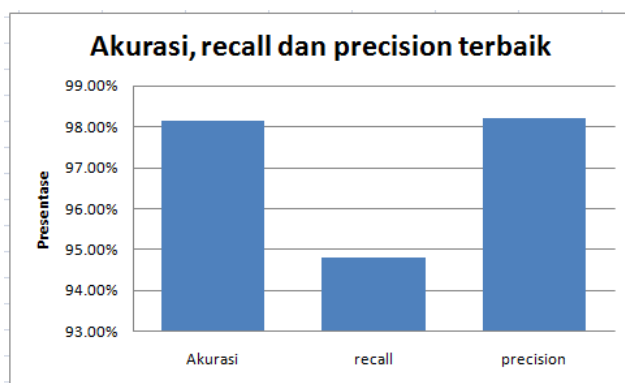
*Form* training data merupakan form yang dibuat untuk melakukan proses training atau pelatihan data JST. Konfigurasi JST yang digunakan dapat diatur pada form ini, yaitu jumlah neuron pada *hidden layer*, fungsi aktivasi yang akan digunakan, target MSE, jumlah *epoch* dan *learning rate*. Tombol buka file digunakan untuk meload atau memanggil file data yang akan ditraining. Tombol training digunakan untuk memberikan perintah untuk melakukan proses pelatihan JST pada data. Tampilan form pelatihan disajikan pada Gambar 7.



Gambar 5. Arsitektur jaringan syaraf tiruan terbaik pada model prediksi

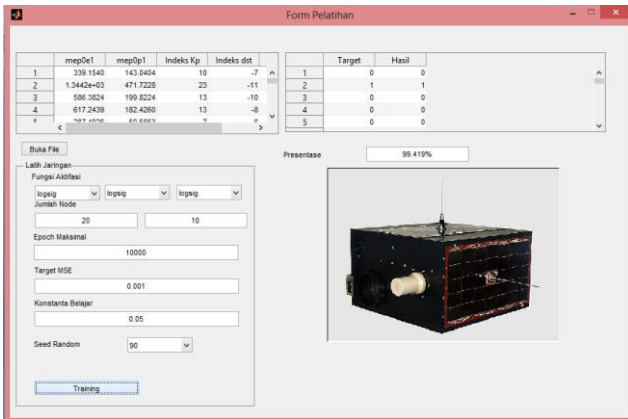
TABEL VI. CONFUSION MATRIX YANG DIHASILKAN MODEL 4-20-10-1

	kelas hasil prediksi	
	<i>anomali</i>	Normal
<i>anomali</i>	88	4
normal	3	248



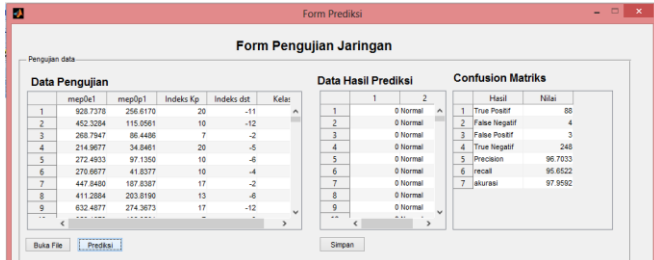
Gambar 6. Nilai akurasi, *precision* dan *recall* terbaik






Gambar 7. Tampilan form proses training

Form pengujian merupakan form yang digunakan untuk memprediksi hasil dari pelatihan yang telah dilakukan. Form ini berisi data pengujian, hasil prediksi data serta dilengkapi dengan evaluasi model berupa nilai *confusion matriks* serta nilai-nilai akurasi pengujian, *precision* serta *recall*. Tombol buka file digunakan untuk meload atau memanggil file data uji yang akan dilakukan pengujian. Tombol prediksi digunakan untuk memberikan perintah untuk melakukan proses prediksi dari data yang telah diinput untuk pengujian. Hasil output akhir dari proses prediksi tersebut akan tampil pada form hasil prediksi berupa data kelas kondisi satelit, serta secara otomatis akan dimasukkan ke dalam *confusion matriks*. Tampilan form pengujian data disajikan pada Gambar 8.



Gambar 8. Tampilan form proses pengujian data dan prediksi

Form deteksi merupakan *form* yang digunakan untuk memprediksi hasil ketika data baru yang tidak dimasukkan pada proses training maupun pengujian. *Form* ini berisi 4 buah input, yaitu : mep0e1 (elektron), mep0p1 (proton), indeks Kp serta indeks Dst. Input dituliskan satu persatu pada *form*, kemudian tombol prediksi digunakan untuk eksekusi proses prediksi tersebut. Hasil output akhir dari proses prediksi tersebut akan tampil pada *form* hasil prediksi berupa kondisi satelit dalam keadaan normal atau dalam keadaan *anomali*. Tampilan *form* deteksi data disajikan pada Gambar 9.



Gambar 9. Tampilan Form Validasi Data

IV. KESIMPULAN

Penelitian ini telah berhasil menerapkan model deteksi anomali pada satelit LAPAN-TUBSAT dengan menggunakan jaringan syaraf tiruan *backpropagation*. Arsitektur jaringan syaraf terbaik yakni model jaringan dengan arsitektur 4-20-10-1 dengan laju pembelajaran sebesar 0.05. *Epoch* yang dihasilkan sebesar 306 *epoch* dengan waktu pembelajaran sebesar 2 detik. Nilai rata-rata akurasi maksimal yang dicapai adalah 98.13%. Sedangkan Nilai rata-rata *recall* dan *precision* yang dihasilkan pada jaringan terbaik 4-20-10-1 yakni sebesar 94.81% dan 98.21%

REFERENSI

- [1] Ahmad N, "Charging phenomena on LAPAN-A1 satellite", In Proceeding of IWSWI Conference, pp. 39-43, 2010
- [2] Y. Xue, S. Yang, Z.Chao, D. Ba, H. An, L. Chen, G. Gue, "Investigation Of Single Event Anomali", Journal of Nuclear Techniques, vol. 35, no. 9, pp. 692-697, 2012.
- [3] N. Najati, "Effect of space environment disturbance in LAPAN-TUBSAT satellite", Journal of Aerospace Technology, vol. 10, no. 1, pp. 21-26, 2012.
- [4] N. Ahmad, Neflia, " Analisis Kondisi Antariksa di Orbit LAPAN-A2 Menjelak Puncak Aktivitas Matahari Siklus 24 ", Jurnal Sains Dirgantara, vol. 8, pp. 187-201, 2011
- [5] N. Ahmad, K. Kusumaningrum, " Flux And Distribution Of Particles The Cause Of Satellite Anomalies In Low Orbit ", Journal of Aerospace Sains, vol. 6, no. 2, pp. 133-142, 2011.
- [6] S.Andropov, A.Guirik, M.Budko, " Network Anomlay Detetction using Artificial Neural Network," in *Proc 20th Conference of Open Innovations Association (FRUCT)*, 2017
- [7] D. Shin, D. Lee, K. Kim, J. Hwang, "Artificial neural network prediction model for geosynchronous electron fluxes", *Space Weather Journal*, vol. 14, no. 4, pp. 313-321, 2016.
- [8] J. Mahmoudi, A. Arjomand, M. Rezaei, H Mohammadi, " Predicting the earthquake magnitude using the multilayer perceptron neural network with two hidden layers, *Civil Engineering Journal*, vol. 2, no. 1, pp.1-12, 2016
- [9] Shinde A, Kale S, Samant R, Ataharya S, Gorpade S, "Heart disease prediction system using multilayered feed forward neural network and backpropagation neural network", *International Journal of Computer Application*, vol. 166, no. 7, pp 32-36, 2017.
- [10] Ankit C, "Rainfall prediction using backpropagation feed forward network", *International Journal of Computer Application*, vol. 119, no. 4, pp. 1-5, 2015.
- [11] T. Transpaset, C. Saiprasert, S. Thajchayapong, " Combining Unsupervised Anomaly Detection and Neural Networks for Driver Identification", *Journal of Advanced Transportation* , Volume 2017, Article ID 6057830, 13 pages <https://doi.org/10.1155/2017/6057830>
- [12] A. Doudkin, M. Maruskho, " Ensembles of Neural Network for Telemetry Multivariate Time Series Forecasting", in *Proc PRIP 2016*, pp. 53-62

- [13] Y. Gao, J. Feng, T. Yang, M. Xu, " A Neural Network Approach for Satellite Telemetry Data Prediction", in *Proc International Conference on Electronics, Communications and Control*, 2012, doi : 10.1109/ICECC.2012.261
- [14] L. Banjanovic, A. Hajradrevic, M. Kantardizch, F. Mehmedovic, I. Dzmanovic " Neural Network Based data driven modelling of anomaly detection in thermal power plant, *Journal of Control, Measurement, Electronics, Computing and Communications* ,Vol. 58, 2017
- [15] T., Y., Kim, S., B., Cho, " Web traffic anomaly detection using C-LTSM neural network", *Expert Systems with applications*, Vol. 106, pp 66-76, 2018, <https://doi.org/10.1016/j.eswa.2018.04.004>
- [16] E., E., Maruskho, A., A., Doudkin " Ensembles of neural networks for forecasting of time series of spacecraft telemetry ", *Journal Optical Memory and Neural Networks*, Vol 26, pp 47-54, 2017