

Deteksi Osilasi Kontrol pada Proses Industri dengan Menggunakan Jaringan Saraf Tiruan - Review

Nukman T. Tsanya¹, Awang N.I. Wardana², Nazrul Effendy³

^{1,2,3}Departemen Teknik Nuklir dan Teknik Fisika, Fakultas Teknik, Universitas Gadjah Mada, Yogyakarta
Email: nazrul@ugm.ac.id

Abstract— Loop control oscillation is one of the most common problems in industrial processes. The oscillations cause the process variables cannot be maintained at the desired conditions, which will cause financial losses to the industry. Over the past few years, many studies have been carried out, and one approach that is increasingly being used is artificial neural networks (ANN). This paper provides an overview of the characteristics of ANN and its application for detecting and diagnosing control oscillations in industrial processes. The most chosen ANN architectures for the oscillation detection process are multilayer perceptron (MLP), convolution neural network (CNN), and recurrent neural network (RNN). Each architecture has different characteristics and functions. MLP has the features of being simple and flexible compared to other networks. CNN works very well for performing detection techniques using pattern recognition. In comparison, RNN is very well used to detect dynamic systems in industrial processes.

Index Terms—Detection, Industry, Oscillation, Artificial Neural Network.

Abstrak— Osilasi kontrol *loop* adalah salah satu masalah yang sering terjadi di proses industri. Osilasi menyebabkan variabel proses tidak dapat dipertahankan pada kondisi yang diinginkan yang akan menyebabkan kerugian finansial pada industri. Selama beberapa tahun terakhir sudah banyak penelitian yang dilakukan, dan salah satu pendekatan yang semakin banyak digunakan adalah menggunakan jaringan saraf tiruan (JST). Tulisan ini memberikan gambaran tentang karakteristik JST dan penerapannya untuk deteksi dan diagnosis osilasi kontrol pada proses industri. Dari beberapa studi yang dipelajari, arsitektur JST yang paling umum dipilih untuk proses deteksi osilasi adalah *multilayer perceptron* (MLP), *convolutional neural network* (CNN) dan *recurrent neural network* (RNN). Tiap arsitektur tersebut memiliki karakteristik dan fungsi yang berbeda. MLP memiliki karakteristik yang sederhana, dan fleksibel dibandingkan jaringan lainnya. CNN bekerja sangat baik untuk melakukan teknik deteksi dengan menggunakan pengenalan pola. Sementara RNN sangat baik digunakan untuk mendeteksi sistem dinamis pada proses industri.

Kata Kunci—Deteksi, Industri, Osilasi, Jaringan Saraf Tiruan.

I. PENDAHULUAN

Osilasi dalam industri proses adalah masalah umum yang mempengaruhi hingga 30% dan 41% dari kontrol *loop*. Masalah ini dapat sangat menurunkan keuntungan pabrik karena mengganggu operasi normal pabrik, meningkatkan variabilitas dalam kualitas produk,

mempercepat keausan peralatan (katup kontrol), dan mengakibatkan konsumsi energi dan bahan baku yang berlebihan [1], [2].

Langkah pertama dalam menghilangkan osilasi kontrol *loop* adalah dengan mendeteksinya. Sumber osilasi *loop* kontrol bisa dihasilkan dari beberapa sumber seperti tuning kontrol yang tidak tepat, interaksi *multiloop*, kesalahan sensor, gangguan osilasi eksternal dan permasalahan katub kontrol. Beberapa teknik deteksi dan diagnosis sudah banyak dikembangkan dan digunakan, penerapan teknik ini pada data industri nyata menunjukkan efisiensi yang rendah. Hal ini mengindikasikan bahwa deteksi dan diagnosis osilasi masih memerlukan perbaikan.

Deteksi dan diagnosis osilasi dapat dilakukan dengan inspeksi visual secara langsung untuk semua kontrol *loop* pada suatu deret waktu. Sayangnya, hal ini tidak mungkin dilakukan lagi karena diagnosis lengkap diperlukan. Dengan semakin berkembangnya proses industri biasanya, proses industri memiliki hingga 500 dan 5000 *loop* kontrol. Inspeksi visual akan sangat menghabiskan banyak sumber daya, belum lagi dengan ketelitian dan keakuratan yang didapatkan terhadap osilasi yang tidak diketahui. Untuk mengatasi keterbatasan ini, diperlukan suatu sistem teknik deteksi osilasi otomatis yang dapat melakukan tugas dengan efisiensi dan keakuratan yang sebaik-baiknya.

Selama 20 tahun terakhir, para peneliti telah mengembangkan metode deteksi otomatis [3]. Sayangnya, dalam pengaliksiannya masih terdapat beberapa masalah pada deteksi otomatis, diantaranya data industri biasanya rusak oleh kebisingan dan gangguan, frekuensi dan amplitudo osilasi mungkin tidak teratur, kondisi deteksi tergantung keadaan program dan hardware, serta deteksi otomatis harus bisa berkembang terhadap osilasi yang tidak direncanakan. Untuk itu semua komponen pengaruh ini harus dimasukkan ke dalam algoritma, sehingga akan membuatnya menjadi kompleks dan luas.

Salah satu pendekatan populer yang diyakini bisa menyelesaikan berbagai masalah dalam deteksi adalah dengan teknik dan aplikasi jaringan saraf tiruan (JST) [4]–[7]. JST telah semakin banyak dieksplorasi selama dua dekade terakhir termasuk di proses industri. Beberapa teknik JST dapat diterapkan pada kerja komputer, pengenalan suara, diagnosa visual dan kontrol proses. Dengan semakin mudahnya aksesibilitas ke perangkat pendukung serta semakin banyaknya

penelitian yang dilakukan dengan menggunakan JST. Pemanfaatan teknik ini menjadi salah satu inovasi penyelesaian masalah di proses industri terutama sistem deteksi osilasi kontrol.

Tulisan ini bertujuan untuk memberikan gambaran singkat tentang penerapan JST dalam mendeteksi osilasi atau perilaku yang tidak diharapkan dalam proses industri. Berbagai aplikasi JST yang berhasil untuk deteksi osilasi, dengan teknik pra-pemrosesan dan metode pelatihan yang dilakukan (untuk memastikan hasil yang konsisten), akan banyak berguna bagi calon peneliti yang ingin mengadopsi penggunaannya dalam analisis mereka sebagai metode pengujian alternatif. Oleh karena itu, tulisan ini akan menganalisis beberapa metodologi dan studi yang mencoba mendeteksi osilasi dan perilaku abnormal dalam proses industri.

II. OSILASI KONTROL DALAM PROSES INDUSTRI

Osilasi adalah fenomena penyimpangan periodik dari set point yang ditentukan, dan sering mengandung sifat random. Hal ini bisa sangat merugikan karena akan meningkatkan variabilitas yang berarti bahwa variabel proses tidak dapat dipertahankan pada kondisi yang diinginkan. Osilasi bisa dibedakan menjadi beberapa jenis berdasarkan sumber dan frekuensinya. Osilasi frekuensi rendah biasanya memiliki periode yang lama antara bulan hingga tahun. Osilasi pada frekuensi ini sulit dideteksi karena osilasi ini bisa disebabkan oleh faktor luar seperti noise karena petir dan cuaca. Namun jenis osilasi ini relatif lebih mudah dikontrol dan bisa dihilangkan dengan pengontrolan yang baik [1].

Osilasi frekuensi menengah memiliki periode waktu relatif cepat antara jam hingga hari. Osilasi inilah yang paling sering menjadi masalah di industri. Penyebab osilasi antara lain penyetelan pengontrol yang buruk, stiksi / kekakuan katub kontrol, dan berbagai gangguan eksternal. Osilasi frekuensi tinggi sebagian besar disebabkan oleh gangguan dalam pengukuran sensor. Osilasi ini bisa diatasi dengan menggunakan filter pada kontrol proses itu sendiri.

A. Penyebab Osilasi

Penyebab terjadinya osilasi adalah karena penyetelan (*tuning*) pengontrol yang buruk, interaksi proses, gangguan eksternal dan stiksi. Stiksi adalah penyebab yang paling sering dari osilasi kontrol. Stiksi terjadi pada katup kontrol yang disebabkan oleh gesekan statis yang berlebihan antara batang katub dan *packing*, yang membuat posisi katub berubah-ubah setiap kali sinyal kontrol diberikan pada katub kontrol. Kondisi ini akan menyebabkan terjadinya nonlinieritas antara sinyal *output* kontrol dan posisi bukaan katub.

Penyetelan pengontrol yang buruk dapat menjadi penyebab osilasi. Osilasi ini dihasilkan ketika gain pengontrol diatur dekat dengan gain limit dari proses. Selain itu juga bisa terjadi karena aksi penyetelan yang berlebihan yang mengakibatkan sinyal akan terjadi kompresi / damper yang berlebihan. Osilasi juga bisa terjadi karena interaksi dari proses. Karena proses industri terdiri dari interaksi banyak sub -proses, ketika

satu *loop* beresilasi dapat menyebabkan beberapa *loop* lain ikut beresilasi dengannya. *Loop* akan beresilasi dengan periode osilasi yang sama. Gangguan eksternal juga bisa menjadi penyebab dari osilasi. Gangguan ini dapat berupa noise yang menyebabkan sinyal kontrol tidak sama dengan yang diinginkan.

B. Deteksi Osilasi

Loop kontrol sangat umum untuk beresilasi dalam proses industri, yang dapat disebabkan oleh berbagai hal. Setelah osilasi dihasilkan di suatu tempat, osilasi dapat menyebar ke seluruh pabrik karena adanya saling intervensi dan resonansi pada osilasi di kontrol proses. Osilasi di seluruh pabrik semacam ini akan menyebabkan kinerja kontrol yang buruk, kualitas produk yang rendah, dan konsumsi energi yang berlebihan. Hal ini akan semakin menyulitkan untuk mengetahui di mana sumber penyebab dari osilasi di proses industri dan melakukan perawatan serta perbaikan. Oleh karena itu, masih diperlukan metode yang tepat untuk mendeteksi dan mendiagnosis osilasi secara tepat pada suatu proses industri yang luas dan kompleks.

Dambros dkk mengklasifikasikan metode deteksi menjadi dua kelompok utama: yaitu *single time series oscillation detection* (STSOD), di mana metode ini berfokus pada deteksi loop / variabel individu, dan *plant-wide oscillation detection* (PWOD), di mana metode ini menerapkan deteksi langsung menyeluruh terhadap set loop/variabel industri proses [2]. Metode deteksi STSOD dapat diklasifikasikan ke dalam 5 jenis yaitu metode domain waktu, metode berbasis *auto-covariance function* (ACF), metode domain frekuensi, metode *continuous wavelet transform* (CWD), dan metode dekomposisi. Metode domain waktu biasanya lebih sederhana dan lebih mudah dalam komputasinya. Kebisingan sering menjadi masalah utama metode ini. Metode berbasis ACF cocok untuk mendeteksi deret waktu dengan noise yang kuat. Metode-metode ini memerlukan transformasi data ke domain ACF, yang hanya membutuhkan program sederhana dalam komputasi. Metode ini tidak cocok untuk deret waktu dengan banyak osilasi, dan osilasi yang tidak reguler / random osilasi.

Metode deteksi domain frekuensi sangat cocok untuk deteksi dengan inspeksi visual. Hal ini karena osilasi dijelaskan berupa puncak yang dapat terlihat dalam spektrum kurva grafik. Namun, metode ini memiliki otomatisasi yang sulit, karena kebisingan dan gangguan juga menghasilkan puncak dalam spektrum yang perlu dihilangkan untuk mendapatkan visual osilasi yang sebenarnya.

Metode deteksi CWD memungkinkan untuk melakukan deteksi dan diagnosis di domain waktu dan frekuensi dengan fungsi transform. Namun, metode berdasarkan CWD ini sulit untuk otomatisasinya dan memerlukan parameter dalam jumlah yang besar, yang merupakan salah satu alasan metode ini belum banyak digunakan. Metode dekomposisi memungkinkan deteksi osilasi untuk dilakukan pada deret waktu yang memiliki

beberapa osilasi. Metode ini relatif lebih sulit untuk diterapkan dan membutuhkan lebih banyak upaya komputasi.

Metode deteksi PWOD adalah deteksi osilasi secara menyeluruh terhadap osilasi yang dihasilkan di suatu tempat di proses industri yang kemudian menyebar ke berbagai *loop* yang berbeda. Deteksi osilasi PWOD didasarkan pada osilasi dalam satu pengukuran adalah sama di lain, bahkan ketika bentuk gelombang berbeda dan ketika interferensi, seperti osilasi lainnya. Banyak metode STSOD yang juga dapat diterapkan untuk deteksi osilasi menyeluruh di proses industri. Jika periode osilasi dikuantifikasi, deteksi menyeluruh dapat dilakukan dengan mengelompokkan *loop* yang berosilasi dengan periode yang sama. Metode inilah yang banyak digunakan untuk aplikasi JST yaitu dengan meneliti kondisi masing-masing *loop* pada jaringan-jaringan saraf. Beberapa syarat metode deteksi osilasi yang baik antara lain adalah sepenuhnya otomatis, memiliki ketahanan terhadap kebisingan dan gangguan, mampu untuk mengevaluasi periode dan amplitudo osilasi; deteksi osilasi ganda dan terputus-putus, semakin sederhana metode semakin baik.

C. Jaringan Saraf Tiruan

JST merupakan salah satu teknik pembelajaran mesin. Pembelajaran mesin adalah pembelajaran untuk algoritme komputer yang dapat dikembangkan dan ditingkatkan secara otomatis melalui pengolahan dan penggunaan data. Yang membuat pembelajaran mesin sangat menarik adalah teknik ini memiliki kemampuan belajar mandiri.

Meskipun ada banyak jenis JST, prinsip dasarnya serupa. JST dapat dianggap sebagai aproksimator universal, di mana hubungan antara dua ruang vektor yang digunakan menjadi sebuah sistem. JST dapat terdiri dari beberapa lapisan, antara lain lapisan *input*, lapisan *output*, dan lapisan tersembunyi di antara mereka. Menghubungkan setiap lapisan adalah *neuron* (atau *node* syaraf) yang mengandung koefisien bobot yang mempengaruhi keseluruhan struktur jaringan.

Faktor penting pada JST adalah pilihan fungsi pelatihan, di mana sistem diberi pembelajaran agar dapat bekerja sendiri sesuai dengan pasangan data yang dilatihkan. Sebelum dilakukan penelitian perlu dilakukan pra-pemrosesan data yaitu pemetaan data ke dalam bentuk yang lebih sesuai dengan kebutuhan pengelompokan JST dari data input. Ini bertujuan untuk membantu menurunkan variabel data yang banyak, memudahkan generalisasi fitur dan klasifikasi, dan menghilangkan noise sebaik mungkin. Proses ini akan memudahkan untuk pembuatan sistem sehingga penggunaan waktu dan biaya dapat lebih efisien. Selain itu perlu juga dipertimbangkan faktor ukuran neuron tersembunyi dari setiap lapisan, ukuran sampel ruang input, dan kondisi pengujian.

Ada beberapa jenis JST yang sedang dikembangkan di proses industri. Secara garis besar JST yang digunakan di proses industri adalah *multi layer perceptron* (MLP), *convolutional neural network* (CNN) dan *Recurrent*

Neural network (RNN). Di antara jenis-jenis JST tersebut, MLP merupakan JST yang paling umum digunakan [8].


MLP dan CNN dapat digunakan untuk klasifikasi Gambar namun MLP mengambil vektor sebagai input dan CNN mengambil tensor sebagai input sehingga CNN dapat memahami hubungan spasial (hubungan antara piksel gambar yang berdekatan) antara piksel gambar lebih baik sehingga untuk gambar yang rumit CNN akan berkinerja lebih baik daripada MLP. CNN dirancang untuk bekerja untuk klasifikasi gambar atau Video [9]. RNN dirancang untuk bekerja untuk masalah yang berkaitan dengan prediksi seperti prediksi hasil akhir dari proses dengan menggunakan kombinasi input dan output sebelumnya.

III. REVIEW JARINGAN SARAF TIRUAN DI PROSES INDUSTRI

JST adalah salah satu metode deteksi yang paling sering digunakan untuk deteksi osilasi kontrol *loop*. Beberapa penelitian telah menunjukkan bahwa JST memiliki kemampuan yang baik untuk mendeteksi, mengklasifikasikan dan mendiagnosis osilasi kontrol *loop* pada proses industri. Penelitian saat ini membuktikan bahwa deteksi osilasi dan proses diagnosis berdasarkan teknik JST dapat diandalkan dalam deteksi osilasi untuk proses industri yang semakin kompleks. JST memungkinkan semua deteksi osilasi dilakukan secara otomatis dan akurasi serta efisiensi dan efektivitasnya bisa semakin ditingkatkan dengan melakukan pelatihan sistem dan pembelajaran mandiri. Ini memungkinkan sistem untuk dapat diperbaharui mengikuti keadaan dan pengembangan proses industri kedepannya.

A. Jaringan Saraf Multi Layer Perceptron

Jaringan saraf *multilayer perceptron* adalah jaringan yang paling umum digunakan. MLP standar berisi *perceptron* terhubung yang membentuk beberapa lapisan. Sebuah MLP mempunyai lapisan *input*, minimal satu lapisan tersembunyi, dan lapisan *output*. Permodelan ini merupakan jenis jaringan *feedforward* (FF) yaitu lapisan *input* memberikan sinyal *input* vektor pada jaringan. *Input* ini diproses pada lapisan kedua, lalu *output* dari lapisan yang kedua diproses sebagai *input* ke lapisan yang ketiga dan seterusnya [10]. Jaringan ini mempunyai karakteristik tidak ada pengulangan pembelajaran (*loop*) di mana signal bergerak dari lapisan *input* dan melewati lapisan tersembunyi dan kemudian menuju lapisan *output*. Gambar 1 memperlihatkan struktur suatu MLP.



Gambar 1. Struktur Multilayer Perceptron [11]

TABLE I
RINGKASAN TINJAUAN JURNAL

Penulis	Jurnal	Arsitektur JST	Proses
Hwang dkk (1993) [12]	mendeteksi dan mendiagnosis kesalahan pada model matematis pembangkit nuklir tipe reaktor air bertekanan	MLP	3 JST FF untuk identifikasi parameter, Pemberian <i>threshold</i> untuk berbagai variasi parameter dan kuantifikasi deteksi.
Rengaswamy dkk (2001) [13]	pemantauan kontrol dengan <i>qualitative shape analysis</i> (QSA)	MLP	JST FF untuk identifikasi <i>primitives</i> dan mengkarakterisasi sifat dan jenis osilasi
Heo dan Lee (2018)	deteksi dan klasifikasi kesalahan menggunakan JST	MLP	JST FF untuk klasifikasi kesalahan menggunakan <i>xavier initializer</i> dan ADAM optimizer
Dambros dkk (2019)	deteksi osilasi kontrol loop menggunakan JST	MLP	3 FF untuk deteksi osilasi, kuantifikasi periode, dan kuantifikasi amplitudo osilasi.
Pavlenko dkk (2019)	menjaga keandalan unit turbopump menggunakan JST	MLP	FF untuk monitoring dan identifikasi parameter dikombinasikan dengan <i>finite element model</i> (FEM)
Yamashita (2006)	metode deteksi pada stiksi katub kontrol di proses industri	CNN	
Mohd Amiruddin dkk (2018)	deteksi stiksi dengan pengenalan pola	CNN	<i>choudhury's model</i> untuk menghasilkan perilaku stiksi
Dambros dkk (2019)	deteksi osilasi dengan menggunakan teknik pengenalan pola	CNN	transformasi diagram PV(OP) menjadi pixel gambar dan JST untuk klasifikasinya
Vazquez dkk (2019)	mendeteksi kondisi dan karakteristik stiksi katub control	CNN	eksperimen pengoperasian katub kontrol pada kondisi normal dan kondisi stiction dengan variasi vairabel kekencangan mur dan baut katub dan JST untuk identifikasi osilasi dan kesalahan stiksi.
Kamaruddin dkk (2020)	deteksi stiksi dengan <i>butterfly shape-based detection</i> (BSD)	CNN	kerangka jaringan BSD-CNN untuk mengukur keparahan stiksi
Zabiri dan Marzuki (2010)	deteksi stiksi dengan berbagai jaringan saraf tiruan	RNN	<i>choudhury's model</i> untuk menghasilkan perilaku stiksi dan JST NARXSP untuk identifikasi
Taqvi dkk (2018)	sistem deteksi kesalahan pada kolom distilasi dengan menggunakan JST NARX	RNN	NARX

Jumlah lapisan yang lebih banyak akan mengkompensasi kelemahan sifat *perceptron* yang hanya bisa melakukan perhitungan *linier* dan memungkinkan perhitungan *nonlinier* untuk dilakukan. Pada deteksi osilasi hal ini sangat penting karena pada proses industri kebanyakan osilasi yang terjadi karena proses dinamis tidak hanya statis. Selain itu dengan semakin berkembangnya proses industri, sistem ini juga dapat berkembang untuk memecahkan masalah yang ada [14].

Penambahan jumlah lapisan juga bisa meningkatkan akurasi deteksi yang didapatkan. Meskipun memiliki lebih banyak lapisan memberikan peningkatan akurasi deteksi secara keseluruhan, perlu diingat bahwa dibutuhkan waktu dan usaha yang lebih dalam proses deteksi dan pelatihan sistemnya. Selan itu tidak selalu penambahan lapisan akan menambah performa sistem. Ada batas penambahan jumlah lapisan yang ditambahkan yang akan menambahkan akurasi deteksi hingga sangat sedikit atau bahkan tidak sama sekali. Ini mungkin berarti bahwa jaringan saraf telah mencapai potensi maksimumnya untuk akurasi dalam membedakan sampel yang salah dari sampel normal dengan data *input*. Untuk itu masih diperlukan kajian lebih lanjut lagi mengenai berapa dan pengaruhnya jumlah lapisan ini terhadap performa sistem deteksi [14].

Jaringan saraf tiruan telah digunakan untuk mendeteksi dan mendiagnosis kesalahan pada pembangkit listrik tenaga nuklir [12], [15]–[17]. Ada tiga jaringan saraf yang berbeda digunakan, yang pertama

untuk identifikasi parameter, yang kedua untuk menetapkan batas ambang kesalahan, dan yang ketiga untuk deteksi dan diagnosis kondisi kesalahan pada proses.

Rengaswamy dkk mengidentifikasi tujuh jenis jaringan saraf kompleks yang digunakan untuk mendeteksi dan mendiagnosis berbagai jenis osilasi [13]. Deteksi osilasi dilakukan dengan *qualitative shape analysis* (QSA) yaitu membandingkan antara sinyal terukur dan bentuk gelombang referensi. Identifikasi dilakukan pada *primitive* (set unit fundamental QSA) yang nantinya akan dapat dikuantifikasikan untuk mengetahui bentuk dan jenis osilasi.

Heo dan Lee melakukan mengaplikasikan JST pada proses Tennessee Eastman yang menjadi *benchmark* untuk berbagai proses industri termasuk deteksi kesalahan [14], [18]. JST diinisiasi dengan menggunakan *Xavier initialization* untuk memastikan signal tidak hilang atau terganggu dan rusak dan *Adam optimizer* untuk pelatihannya. Dengan mengkombinasikan dua *hyperparameters* (jumlah lapisan tersembunyi dan jumlah neuron bisa didapatkan akurasi yang sangat tinggi hingga 97,26 % dan akurasi sistem deteksi masih bisa ditingkatkan lagi dengan menggunakan augmentasi data *input*.


Dambros dkk [1] menggunakan teknik deteksi STSOD yang diaplikasikan ke setiap *loop time series*. Metode ini menggunakan 3 *feedforward* jaringan syaraf yang dilatih dengan data buatan dengan fitur berbeda yang ditujukan

untuk deteksi osilasi, kuantifikasi periode, dan kuantifikasi amplitudo osilasi. Digunakan juga teknik transformasi dari domain waktu ke domain frekuensi, teknik ini dapat mempelajari berbagai fitur yang ditemukan pada deret waktu industri, yang mencakup data dengan *noise*, gangguan (rata-rata nonstasioner), *intermiten*, saturasi, dan nonregularitas dalam osilasi. Bentuk gelombang yang dihasilkan akan harmonik dalam domain frekuensi, sehingga efek luaran bisa diabaikan.

Pavlenko dkk menjelaskan bahwa metode deteksi JST juga bisa digunakan sebagai dasar untuk kegiatan *predictive maintenance* sehingga keandalan mesin dapat tetap terjaga [19]. Penelitian ini dilakukan di berbagai mesin terutama bearing mesin induksi. JST digunakan untuk mengartikan dan menganalisis sinyal *wavelet* dan perilaku variabel untuk diagnosa kesalahan. Jaringan FF dikombinasikan dengan *finite element model* (FEM) akan memonitoring dan identifikasi parameter pada bearing mesin induksi. Dengan demikian dapat diketahui kondisi mesin industri dan dilakukan perkiraan kapan diperlukan adanya perbaikan.

B. Pengenalan Pola

Pengaplikasian JST lainnya untuk teknik deteksi osiliasi kontrol yang sering digunakan adalah menggunakan pengenalan pola dengan menggunakan jaringan saraf konvolusi (*convolutional neural network*, CNN) [5]. CNN adalah salah satu jenis dari JST yang merupakan pengembangan MLP yang dirancang untuk mengolah data dua dimensi. Cara kerja CNN memiliki kesamaan dengan MLP, namun dalam bentuk dua dimensi. Gambar 2 memperlihatkan bagaimana cara kerja CNN.

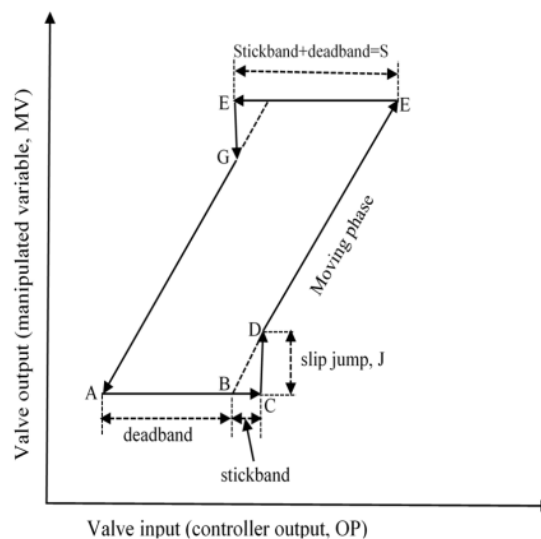


Gambar 2. Cara kerja CNN [20]

Dalam beberapa tahun terakhir, model CNN menjadi terobosan besar dalam visi komputer dan banyak digunakan dalam berbagai aplikasi seperti klasifikasi citra, segmentasi citra, pelacakan objek, termasuk untuk deteksi osilasi. CNN dirancang khusus untuk visi komputer yang digunakan untuk menerima dan memproses data piksel. CNN lebih dipilih daripada JST lain sebagai alat deteksi karena akurasi yang unggul pada klasifikasi gambar pada kumpulan data besar. Arsitektur CNN lebih baik digunakan untuk desain perancangan halus, yang berarti lebih baik dilatih dengan koneksi dan parameter yang memiliki jumlah tidak sebanyak JST lainnya.

Pada deteksi osilasi teknik pengenalan pola dilakukan dengan mengamati hubungan antara keluaran pengontrol (OP) dan posisi katup aktual (MV) dari katup kontrol pada diagram MV(OP). Teknik ini sering digunakan

untuk medeteksi nonlinearitas pada katub kontrol yang terjadi karena tidak sesuainya hubungan antara OP dan MV. Untuk melihat bagaimana nonlinearitas pada katub stiksi terjadi dapat dilihat pada Gambar 3.



Gambar 3. Nonlinearitas pada katub kontrol [21]

Dalam keadaan normal, OP dan MV akan memiliki hubungan yang linear. Saat terjadi stiksi, hubungan linier antara OP dan MV tidak lagi berlaku, dan katup berperilaku seperti yang digambarkan pada Gambar 3. Perilaku input-output dari katub kontrol terdiri dari *deadband*, *stickband*, *slip jump*, dan *moving phase*.

Ketika katup bermasalah terjadi stiksi, katub akan menempel, posisi katub (MV) tidak berubah sementara keluaran pengontrol (OP) terus berubah. Katup terlepas dari stiksi ketika perubahan kumulatif dalam OP sama dengan stiction band, dan pada titik ini MV tiba-tiba berubah (ini ditandai dengan slip jump). Setelah katup terlepas dari stiksi, maka katub terus bergerak ke atas atau ke bawah (ini disebut moving phase). Ketika OP mengubah arah gerakannya, katub akan menempel lagi, dan katub akan berhenti bergerak. Katub dapat menempel beberapa kali, dan setiap kali, *stickband* serta *slip jump* dapat bervariasi. Stiksi katub tidak statis tetapi lebih cenderung dinamis. Inilah yang akan menimbulkan osilasi pada kontrol katub terjadi [22].

Beberapa teknik untuk mengatasi sudah diusulkan yaitu dengan melihat perubahan OP dan MV. Yamashita menginisiasi penggunaan teknik pengenalan pola dimana teknik yang diusulkan mengenali arah gerakan dalam diagram MV(OP), kemudian urutan arah diklasifikasikan dalam urutan khas yang ditemukan pada *loop* dengan stiksi katub dan kombinasinya [23]. Dambros dkk merumuskan metode deteksi dan diagnosis osilasi berbasis bentuk gelombang, di mana bentuk plot MV-OP ditransformasikan menjadi gambar 8 x 8 piksel yang digunakan sebagai data pelatihan untuk melatih jaringan [24]. Pengolahan data pada dasarnya adalah transformasi diagram MV(OP) menjadi citra berukuran 8x8 piksel. Dengan menggunakan matriks nilai OP dan

MV time series disesuaikan dan menggambarkan masing-masing pixel. Data kemudian dibagi menjadi 3 set yaitu data training, validasi, dan data tes.

Dengan mengubah diagram MV(OP) menjadi citra berukuran 8x8 piksel, CNN akan melakukan pelatihan pengolahan citra untuk dapat membedakan berbagai keadaan yang terjadi pada katub kontrol. Hasil yang didapatkan deteksi CNN metode ini memiliki akurasi yang sangat tinggi namun memerlukan waktu dan usaha yang banyak karena diperlukan banyak data agar pengenalan pola dari CNN dapat semakin akurat.

Kamarudin dkk melakukan sistem deteksi stiksi dengan menggunakan *butterfly shape-based detection* (BSD) [25]. Metode deteksi ini merupakan pengembangan dari model deteksi *stenman*. Pada kebanyakan metode deteksi pola, plot data untuk menunjukkan adanya osilasi yang disebabkan stiksi adalah bentuk elips. Namun, bentuk elips belum bisa menggambarkan osilasi secara akurat karena osilasi juga bisa terjadi karena efek *loop* lainnya yang berosilasi, gangguan eksternal dan penyetelan berlebihan. Untuk itu digunakan BSD dibandingkan bentuk plot elips untuk sistem deteksi osilasi stiksi. CNN kemudian digunakan untuk mengkategorikan gambar BSD sesuai dengan tingkat keparahan stiksi yang diamati.

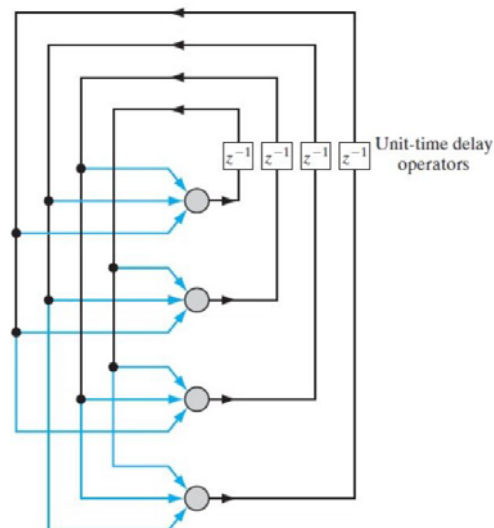
Deteksi stiksi juga bisa dilakukan dengan pandangan yang sebaliknya. Dibandingkan dengan penelitian yang ada selama ini menggunakan data industri untuk mendeteksi stiksi katub kontrol, penelitian bisa dilakukan menggunakan eksperimen untuk melihat bagaimana perilaku katub kontrol pada keadaan normal dan keadaan stiksi. Amiruddin dkk menggunakan simulasi untuk mendapatkan kumpulan data yang digunakan untuk melatih JST [26]. Semua data dihasilkan dengan menjalankan simulasi proses *loop* dengan MATLAB Simulink. Model yang digunakan untuk menghasilkan perilaku stiksi adalah dengan model *Choudhury*. Sedangkan untuk kondisi non stiksi disimulasikan untuk menggambarkan kondisi tuning yang baik, kondisi tuning berlebihan dan kondisi proses yang mengalami gangguan osilasi eksternal. Tiga kondisi non-stiksi ini digunakan agar data dapat menunjukkan secara akurat osilasi yang benar-benar disebabkan oleh stiksi. Data kemudian akan di plot sesuai diagram MV(OP) yang kemudian dengan CNN akan dikuantifikasi dan dilasifikasikan sesuai bentuk plot diagram MV(OP).

Vazquez dkk melakukan eksperimen akan memvariasikan dua data yaitu data katub kontrol normal dan katub kontrol pada saat stiksi [27]. Selanjutnya, CNN digunakan untuk mengidentifikasi karakteristik katub kontrol dengan memvariasikan plot MV dan OP untuk pelatihannya. Eksperimen ini bertujuan untuk membuat kondisi stiksi pada katub kontrol dan menggunakan informasi yang ada sebagai platform untuk membangun model berbasis data yang kemudian dengan menggunakan metode deteksi berdasarkan CNN untuk mendeteksi osilasi yang terjadi. Dari eksperimen dan pelatihan didapatkan bahwa perubahan kecil pada nilai

OP karena faktor yang tidak diinginkan / gangguan dari luar seperti kondisi pengencangan mur dan baut yang tidak semestinya (pada eksperimen kekencangan baut katub kontrol divariasikan untuk berkurang hingga 25%) akan menyebabkan perbedaan yang signifikan antara MV dan OP diamati.

C. Jaringan Saraf Berulang


Pendekatan lainnya yang biasa digunakan adalah dengan menggunakan jaringan saraf berulang (*recurrent neural network*, RNN). Di antara arsitektur JST, RNN adalah pilihan yang sangat baik untuk digunakan karena memiliki kemampuan belajar tambahan karena dimasukkannya umpan balik yang didorong secara dinamis. Tidak seperti MLP yang murni statis, RNN tidak hanya menggunakan input dalam memprediksi contoh output tertentu, tetapi juga keadaan apa pun di antaranya untuk berkontribusi dalam memprediksi nilai output berikutnya [10]. Untuk melihat bagaimana struktur RNN dapat dilihat pada Gambar 4.



Gambar 4. Struktur jaringan saraf RNN [28]

RNN, memiliki potensi yang lebih baik secara keseluruhan untuk memecahkan masalah berbagai masalah pada metode deteksi osilasi terutama osilasi yang bersifat dinamis. Namun dalam pembuatannya RNN memiliki sistem yang lebih rumit dibandingkan dengan berbagai JST lainnya. Bentuk yang paling umum adalah jaringan *long short-term memory*, *nonlinear autoregressive with exogenous input* (NARX), dan *nonlinear autoregressive network with exogenous inputs series paralel* (NARXSP) yang menggunakan output untuk mempengaruhi input dalam loop umpan balik.

Taqvi dkk memberikan contoh aplikasi JST NARX digunakan sebagai model prediksi [29]. Model ini umumnya digunakan untuk identifikasi sistem dinamis. NARX digunakan sebagai prediktor, untuk prediksi nilai selanjutnya dari sinyal input. JST NARX memiliki kemampuan untuk mengambil keputusan cerdas untuk masalah deteksi kesalahan di lingkungan industri nyata.



Gambar 5. Arsitektur NARX [30]

Gambar 5a menampilkan arsitektur NARX standar memungkinkan output untuk diumpankan kembali ke input dari jaringan saraf feedforward. Ini dianggap sebagai jaringan FF dengan umpan balik dari output ke input. Dalam arsitektur NARXSP, Gambar 5b, output sebenarnya yang tersedia selama pelatihan jaringan digunakan sebagai pengganti feed back output yang diperkirakan. Keuntungannya adalah input ke jaringan feedforward menjadi lebih akurat [29].

Zabiri dan Marzuki telah menguji dari enam jenis JST yang berbeda, dengan membandingkan dan memvalidasi kinerjanya pada skenario stiksi [31]. RNN dengan NARXSP terbukti paling baik untuk memprediksi perilaku katup di semua skenario stiksi yang berbeda. NARXSP menjadi satu-satunya struktur yang dapat mendeteksi secara akurat perilaku katup stiksi. Kekokohan (*robust*) yang baik dari model stiksi berbasis NARXSP juga ditunjukkan terhadap ketidakpastian dalam parameter dan skenario stiksi.

IV. KESIMPULAN

JST semakin banyak digunakan dalam penerapannya untuk sistem deteksi osilasi kontrol. Tulisan ini memberikan tinjauan mengenai berbagai penelitian dan penerapannya yang dilakukan pada proses industri. Teknik JST dipilih karena potensi dan karakteristiknya yang mampu menyelesaikan berbagai permasalahan di proses deteksi osilasi kontrol.

JST memiliki kemampuan utama untuk pembelajaran mandiri sehingga dapat mengikuti perkembangan proses industri. Selain itu JST juga sangat fleksibel sehingga memiliki berbagai macam bentuk atau teknik pengembangan yang bisa digunakan. Meskipun teknik yang digunakan berbeda prinsip dasar yang sama yaitu dengan memanfaatkan vektor yang terhubung menjadi sebuah aproksimator universal untuk mendapatkan sistem kinerja deteksi tertentu.

Ada berbagai jenis JST yang bisa digunakan untuk deteksi osilasi kontrol pada proses industri. Namun yang paling banyak digunakan adalah MLP, CNN, dan RNN MLP banyak digunakan karena memiliki karakteristik yang sederhana, fleksibel, dan penggunaannya yang cukup baik. Sedangkan CNN digunakan untuk deteksi dengan pengenalan pola dan gambar, dan RNN digunakan karena memiliki potensi yang paling baik dari semua jenis JST.

UCAPAN TERIMA KASIH

Para penulis paper ini mengucapkan terima kasih kepada Fakultas Teknik, Universitas Gadjah Mada atas dukungan fasilitas untuk pelaksanaan penelitian ini.

REFERENCES

- [1] J. W. V. Dambros, J. O. Trierweiler, M. Farenzena, and M. Kloft, "Oscillation Detection in Process Industries by a Machine Learning-Based Approach," *Ind. Eng. Chem. Res.*, vol. 58, no. 31, pp. 14180–14192, Aug. 2019, doi: 10.1021/acs.iecr.9b01456.
- [2] J. W. V. Dambros, J. O. Trierweiler, and M. Farenzena, "Oscillation detection in process industries – Part I: Review of the detection methods," *Journal of Process Control*, vol. 78, pp. 108–123, Jun. 2019, doi: 10.1016/j.jprocont.2019.04.002.
- [3] D. F. Rabba, A. N. I. Wardana, and N. Effendy, "Intermittent Oscillation Diagnosis in a Control Loop Using Extreme Gradient Boosting," *Jurnal Nasional Teknik Elektro*, in press.
- [4] E. D. Kurniawan, N. Effendy, A. Arif, K. Dwianto, and N. Muddin, "Soft sensor for the prediction of oxygen content in boiler flue gas using neural networks and extreme gradient boosting," *Neural Comput & Applic*, Sep. 2022, doi: 10.1007/s00521-022-07771-8.
- [5] N. Effendy, D. Ruhyadi, R. Pratama, D. F. Rabba, A. F. Aulia, and A. Y. Atmadja, "Forest quality assessment based on bird sound recognition using convolutional neural networks," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 12, no. 4, Art. no. 4, Aug. 2022, doi: 10.11591/ijece.v12i4.pp4235-4242.
- [6] S. N. Sembodo, N. Effendy, K. Dwianto, and N. Muddin, "Radial basis network estimator of oxygen content in the flue gas of debutanizer reboiler," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 12, no. 3, pp. 3044–3050, 2022, doi: 10.11591/ijece.v12i3.pp3044-3050.
- [7] N. Effendy, E. D. Kurniawan, K. Dwianto, A. Arif, and N. Muddin, "The Prediction of Oxygen Content of the Flue Gas in a Gas-Fired Boiler System Using Neural Networks and Random Forest," *IAES International Journal of Artificial Intelligence (IJ-AI)*, vol. 11, no. 3, pp. 923–929, 2022.
- [8] R. Bacci di Capaci and C. Scali, "Review and comparison of techniques of analysis of valve stiction: From modeling to smart diagnosis," *Chemical Engineering Research and Design*, vol. 130, pp. 230–265, Feb. 2018, doi: 10.1016/j.cherd.2017.12.038.
- [9] T. Wang, Y. Chen, M. Qiao, and H. Snoussi, "A fast and robust convolutional neural network-based defect detection model in product quality control," *Int J Adv Manuf Technol*, vol. 94, no. 9–12, pp. 3465–3471, Feb. 2018, doi: 10.1007/s00170-017-0882-0.
- [10] A. A. A. Mohd Amiruddin, H. Zabiri, S. A. A. Taqvi, and L. D. Tufa, "Neural network applications in fault diagnosis and detection: an overview of implementations in engineering-related systems," *Neural Comput & Applic*, vol. 32, no. 2, pp. 447–472, Jan. 2020, doi: 10.1007/s00521-018-3911-5.
- [11] J. Kim, M. Jin, Y. Homma, A. Sim, W. Kroeger, and K. Wu, "Extract Dynamic Information to Improve Time Series Modeling: a Case Study with Scientific Workflow. 2022." doi: 10.48550/arXiv.2205.09703.
- [12] B. C. Hwang, M. Saif, and M. Jamshidi, "Neural Based Fault Detection and Identification for a Nuclear Reactor," *IFAC Proceedings Volumes*, vol. 26, no. 2, Part 5, pp. 547–550, Jul. 1993, doi: 10.1016/S1474-6670(17)48326-1.
- [13] R. Rengaswamy, T. Häggglund, and V. Venkatasubramanian, "A qualitative shape analysis formalism for monitoring control loop performance," *Engineering Applications of Artificial Intelligence*, vol. 14, no. 1, pp. 23–33, Feb. 2001, doi: 10.1016/S0952-1976(00)00051-8.
- [14] S. Heo and J. H. Lee, "Fault detection and classification using artificial neural networks," *IFAC-PapersOnLine*, vol. 51, no. 18, pp. 470–475, 2018, doi: 10.1016/j.ifacol.2018.09.380.
- [15] Z. Wang, H. Xia, W. Yin, and B. Yang, "An improved generative adversarial network for fault diagnosis of rotating machine in nuclear power plant," *Annals of Nuclear Energy*, vol. 180, p. 109434, Jan. 2023, doi: 10.1016/j.anucene.2022.109434.
- [16] S. R. Kumar and J. Devakumar, "Performance evaluation of neural network topologies for online state estimation and fault detection in pressurized water reactor," *Annals of Nuclear*

- Energy, vol. 175, p. 109235, Sep. 2022, doi: 10.1016/j.anucene.2022.109235.
- [17] S. Yong and Z. Linzi, "Robust deep auto-encoding network for real-time anomaly detection at nuclear power plants," *Process Safety and Environmental Protection*, vol. 163, pp. 438–452, Jul. 2022, doi: 10.1016/j.psep.2022.05.039.
- [18] D. E. P. Lebukun, A. N. I. Wardana, and N. Effendy, "Implementation of Plant-Wide PI-Fuzzy Controller in Tennessee Eastman Process," in *2019 International Seminar on Application for Technology of Information and Communication (iSemantic)*, 2019, pp. 450–454.
- [19] I. Pavlenko, V. Ivanov, I. Kuric, O. Gusak, and O. Liaposhchenko, "Ensuring Vibration Reliability of Turbopump Units Using Artificial Neural Networks," in *Advances in Manufacturing II*, Cham, 2019, pp. 165–175. doi: 10.1007/978-3-030-18715-6_14.
- [20] N. Mohd Aszemi and D. D. D. Panneer Selvam, "Hyperparameter Optimization in Convolutional Neural Network using Genetic Algorithms," *International Journal of Advanced Computer Science and Applications*, vol. 10, pp. 269–278, Jun. 2019, doi: 10.14569/IJACSA.2019.0100638.
- [21] V. Prabhu, R. Velnath, S. Krishnakumar, and M. Prathap, "Linear Sliding Stem Control Valve Hunting Analysis and Extrapolation of Valve Monitoring Features," *International Journal of Innovative Technology and Exploring Engineering*, vol. 9, no. 4, pp. 1385–1389, 2020, doi: <https://doi.org/10.35940/ijitee.d1640.029420>.
- [22] D. Zheng, X. Sun, S. K. Damarla, A. Shah, J. Amalraj, and B. Huang, "Valve Stiction Detection and Quantification Using a K-Means Clustering Based Moving Window Approach," *Industrial & Engineering Chemistry Research*, vol. 60, no. 6, pp. 2563–2577, Feb. 2021, doi: 10.1021/acs.iecr.0c05609.
- [23] Y. Yamashita, "An automatic method for detection of valve stiction in process control loops," *Control Engineering Practice*, vol. 14, no. 5, pp. 503–510, May 2006, doi: 10.1016/j.conengprac.2005.03.004.
- [24] J. W. V. Dambros, M. Farenzena, and J. O. Trierweiler, "Oscillation Detection and Diagnosis in Process Industries by Pattern Recognition Technique," *IFAC-PapersOnLine*, vol. 52, no. 1, pp. 299–304, 2019, doi: 10.1016/j.ifacol.2019.06.078.
- [25] B. Kamaruddin, H. Zabiri, A. A. A. Mohd Amiruddin, W. K. Teh, M. Ramasamy, and S. S. Jeremiah, "A simple model-free butterfly shape-based detection (BSD) method integrated with deep learning CNN for valve stiction detection and quantification," *Journal of Process Control*, vol. 87, pp. 1–16, Mar. 2020, doi: 10.1016/j.jprocont.2020.01.001.
- [26] A. A. A. Mohd Amiruddin, H. Zabiri, S. S. Jeremiah, W. K. Teh, and B. Kamaruddin, "Valve stiction detection through improved pattern recognition using neural networks," *Control Engineering Practice*, vol. 90, pp. 63–84, Sep. 2019, doi: 10.1016/j.conengprac.2019.06.008.
- [27] N. R. Vazquez, D. Fernandes, and D. Chen, "Control valve stiction: experimentation, modeling, model validation, and detection with convolution neural network," *International Journal of Chemical Engineering and Applications*, vol. 10, Oct. 2019, doi: 10.18178/ijcea.2019.10.6.768.
- [28] D. Kozikowski, A. Sulich, and T. Zema, *Artificial Intelligence Usage and Ethics in the Choice Theory*. 2020. doi: 10.5281/zenodo.4083767.
- [29] S. A. Taqvi, L. D. Tufa, H. Zabiri, A. S. Maulud, and F. Uddin, "Fault detection in distillation column using NARX neural network," *Neural Comput & Applic*, vol. 32, no. 8, pp. 3503–3519, Apr. 2020, doi: 10.1007/s00521-018-3658-z.
- [30] S. Malekmohamadi Faradonbe, F. Safi-Esfahani, and M. Karimian-kelishadrokh, "A Review on Neural Turing Machine (NTM)," *SN COMPUT. SCI.*, vol. 1, no. 6, p. 333, Oct. 2020, doi: 10.1007/s42979-020-00341-6.
- [31] H. Zabiri and N. Mazuki, "A Black-Box Approach in Modeling Valve Stiction," vol. 4, no. 8, p. 8, 2010.