

LAPORAN PENELITIAN (MANDIRI)

**Machining Dynamic Stability
Pada Proses Pemesinan Milling**



PENULIS

**Khairul Jauhari, ST, MT
NIDN : 8818620016**

**PROGRAM STUDI TEKNIK MESIN
INSTITUT TEKNOLOGI INDONESIA
AGUSTUS 2022**

LEMBAR PENGESAHAN

Judul Penelitian : Machining Dynamic Stability Pada Proses Pemesinan Milling
Daftar Mitra : LT MEPPPO – BRIN
Ketua Tim Pengusul
Nama Lengkap : Ir. Khairul Jauhari, ST, MT, IPP
NIDK : 8818620016
Jabatan Fungsional : Asisten Ahli
Program Studi : Teknik Mesin
Perguruan Tinggi : Institut Teknologi Indonesia
Bidang Keahlian : Intelligent Manufacturing
Alamat/Telp/E-mail : Kampus ITI, Puspiptek, Tangerang Selatan
Anggota Tim Pengusul
Nama Lengkap :-
NIDK :-
Program Studi :-
Perguruan Tinggi :-
Lokasi Kegiatan/Mitra
Wilayah Mitra : Tersebar di Beberapa Wilayah
Kabupaten/Kota/Prop: Tersebar di Berbagai Kabupaten/Kota
Jarak PT ke Lokasi :-
Luaran Yang Dihasilkan : Laporan Kegiatan
Jangka Waktu Pelaksanaan : 6 Bulan
Biaya Total (RAB) : Rp. 10.000.000,-

Tangerang Selatan, 1 Agustus 2022


Mengetahui

Program Studi Teknik Mesin

Kepala Prodi Teknik Mesin


Victor Tuapetel ST, MT, Ph.D
NIDN 0322096803

Peneliti


Khairul Jauhari, ST, MT
NIDK 8818620016

Mengetahui Kepala Pusat Riset &
Pengabdian Masyarakat


Dr. Ir. Joellaningstih, M.T.
NIDN 0310076406



Puji syukur penulis panjatkan kehadirat Allah SWT yang telah melimpahkan rahmat dan karunia-Nya kepada Penulis yang dalam hal ini juga bertindak sebagai Anggota Peneliti, sehingga penulis dapat melewati masa penelitian dengan mengangkat tema ” Machining Dynamic Stability Pada Proses Pemesinan Milling ” dan telah menyelesaikan seluruh kegiatan penelitian tahap preliminary hingga penulisan laporan akhir yang merupakan tahapan akhir dari proses penelitian.

Keberhasilan penulis dalam menyelesaikan laporan akhir ini tidak lepas dari bantuan orang-orang yang dengan segenap hati memberikan bantuan, bimbingan dan dukungan, baik moral maupun material. Dalam kesempatan ini penulis mengucapkan terima kasih kepada:

1. Bapak Victor Tuapetel ST, MT, Ph.D. selaku Kepala Program Studi Teknik Mesin ITI.
2. Koordinator Laboraturium Teknologi Mesin Perkakas, Produksi dan Otomasi.
3. Segenap karyawan dan manajemen Laborturium Teknologi Mesin Perkakas, Produksi dan Otomasi khususnya atas segala dukungan dan kerjasamanya.

Penulis menyadari bahwa dalam menulis laporan akhir penelitian ini masih terdapat kekurangan dan keterbatasan, oleh karena itu kritik dan saran yang sifatnya membangun untuk kesempurnaan dan kemajuan penulis dimasa yang akan datang sangat diharapkan. Akhir kata penulis berharap semoga laporan akhir penelitian ini dapat bermanfaat bagi seluruh pembaca.

Tangerang Selatan, 1 Agustus 2022

Penulis



Khairul Jauhari, ST, MT

DAFTAR ISI

| | |
|--|-----|
| HALAMAN PENGESAHAN | i |
| PRAKATA | ii |
| DAFTAR ISI | iii |
| DAFTAR TABEL | iv |
| DAFTAR GAMBAR | v |
| | |
| Bab 1 Pendahuluan | 1 |
| 1.1 Latar Belakang | 1 |
| 1.2 Rumusan dan Batasan Masalah | 4 |
| 1.3 Tujuan Penelitian | 4 |
| 1.4 Manfaat Penelitian | 5 |
| 1.5 Metodologi Penelitian | 5 |
| 1.6 Sistematika Penulisan | 6 |
| Bab 2 Landasan Teori | 8 |
| 2.1 Tinjauan Pustaka | 8 |
| 2.2 Model Receptance Coupling Substructure Analysis (RCSA)..... | 14 |
| 2.3 ANSYS parametric design language (APDL)..... | 18 |
| Bab 3 Metode Penelitian | 20 |
| 3.1 Objek Penelitian | 20 |
| 3.2 Peralatan Penelitian | 22 |
| 3.3 Diagram Alir Penelitian | 23 |
| 3.4 Analisis Data | 25 |
| Bab 4 Analisa data & pembahasan | 27 |
| 4.1 Pemodelan RCSA pada spindle | 27 |
| 4.2 Analisis respon FRF pada spindle sebagai variabel desain | 31 |
| Bab 5 Penutup | 39 |
| 5.1 Kesimpulan | 39 |
| 5.2 Saran | 39 |

DAFTAR TABEL

| | | |
|------------|--|----|
| Tabel 2.1 | <i>Syntax script</i> fungsi “ <i>fmincon</i> ” | 17 |
| Tabel 2.2 | Program M-File <i>script</i> untuk algoritma optimasi dengan MCA .. | 17 |
| Tabel 2.3 | Program M-File <i>script</i> untuk <i>objective function</i> | 17 |
| Tabel 2.4 | Program M-file <i>script</i> untuk <i>constraint function</i> | 18 |
| | | |
| Tabel 3.1 | Model geometri dan sifat mekanik elemen poros <i>spindle</i> | 21 |
| Tabel 3.2 | Model elemen <i>disk</i> pada <i>spindle</i> | 22 |
| Tabel 3.3 | Model elemen <i>bearing</i> pada <i>spindle</i> | 22 |
| Tabel 3.4 | Model <i>unbalance mass</i> pada <i>spindle</i> | 22 |
| Tabel 3.5 | Spesifikasi komponen <i>spindle head</i> | 22 |
| Tabel 3.6 | <i>Spindle assembly V-30</i> | 23 |
| Tabel 3.7 | Model geometri dan sifat mekanik elemen poros <i>turbocharger</i> .. | 24 |
| Tabel 3.8 | Model elemen <i>disk</i> pada <i>turbocharger</i> | 24 |
| Tabel 3.9 | Model elemen <i>bearing</i> pada <i>turbocharger</i> | 24 |
| Tabel 3.10 | Model <i>unbalance mass</i> pada <i>turbocharger</i> | 24 |
| Tabel 3.11 | Perangkat lunak (<i>software</i>) | 25 |
| | | |
| Tabel 4.1 | Model geometri <i>disk</i> | 31 |
| Tabel 4.2 | Model properti <i>bearing</i> | 31 |
| Tabel 4.3 | Perbandingan frekuensi natural <i>simple rotor-disk</i> pada kecepatan operasi 25000 rpm | 33 |
| Tabel 4.4 | Perbandingan kecepatan kritis <i>simple rotor-disk</i> pada kisaran kecepatan operasi 0 – 30000 rpm | 34 |
| Tabel 4.5 | Perbandingan respon <i>unbalance simple rotor-disk</i> pada kisaran kecepatan operasi 0 – 30000 rpm | 36 |
| Tabel 4.6 | Perbandingan kecepatan kritis dan simpangan respon <i>unbalance</i> antara hasil simulasi numerik terhadap referensi pada kondisi sebelum optimasi | 36 |
| Tabel 4.7 | Perbandingan kecepatan kritis dan simpangan respon <i>unbalance</i> antara hasil simulasi numerik terhadap referensi pada kondisi optimum dengan model MATLAB | 40 |
| Tabel 4.8 | Diameter poros (<i>shaft</i>) model <i>turbocharger</i> untuk kondisi sebelum dan sesudah optimasi (dengan variabel desain hanya dimensi poros) | 41 |
| Tabel 4.9 | Parameter <i>optimum</i> model <i>turbocharger</i> dari hasil optimasi algoritma MCA, GA dan HGA (dengan variabel desain hanya dimensi poros <i>turbocharger</i>) | 48 |

DAFTAR GAMBAR

| | | |
|-------------|---|----|
| Gambar 1.1 | Grafik statistik produksi domestik otomotif tahun 2007 – 2014 | 2 |
| Gambar 1.2 | Komoditi HS ekspor-impor mesin perkakas tahun 2005 – 2014 | 2 |
| Gambar 1.3 | Diagram alir (<i>flowchart</i>) metodologi penelitian | 7 |
| | | |
| Gambar 2.1 | Model struktur kromosom poros <i>spindle</i> | 12 |
| Gambar 2.2 | Proses <i>single-point crossover</i> | 14 |
| Gambar 2.3 | Proses mutasi pada kromosom turunan (<i>children</i>) | 14 |
| Gambar 2.4 | Diagram alir proses <i>genetic algorithm</i> (GA) | 15 |
| Gambar 2.5 | Diagram alir proses <i>hybrid genetic algorithm</i> (GA) | 19 |
| Gambar 2.6 | Perbandingan respon <i>unbalance</i> sebelum dan sesudah optimasi [32] | 19 |
| Gambar 2.7 | Perbandingan kecepatan kritis sebelum dan sesudah optimasi [33] | 20 |
| Gambar 2.8 | Perbandingan respon <i>unbalance</i> sebelum dan sesudah optimasi [33] | 20 |
| Gambar 2.9 | <i>Net radial displacement spindle</i> sebelum optimasi [34] | 20 |
| Gambar 2.10 | <i>Net radial displacement spindle</i> sesudah optimasi [34] | 20 |
| Gambar 2.11 | Perbandingan respon <i>unbalance</i> sebelum dan sesudah optimasi [35] | 21 |
| Gambar 2.12 | Perbandingan respon <i>unbalance</i> sebelum dan sesudah optimasi [36] | 21 |
| | | |
| Gambar 3.1 | Model elemen hingga (FEM) poros <i>spindle</i> | 21 |
| Gambar 3.2 | Model prototip <i>turbocharger</i> | 23 |
| Gambar 3.3 | Model elemen hingga (FEM) poros <i>turbocharger</i> | 23 |
| Gambar 3.4 | Diagram alir metode penelitian | 26 |
| | | |
| Gambar 4.1 | Model elemen hingga (FEM) <i>simple rotor-disk</i> | 31 |
| Gambar 4.2 | Diagram <i>Campbell</i> : (a) Model referensi Lalane & Feraris, (b) Model MATLAB dan (c) Model ANSYS | 35 |
| Gambar 4.3 | Respon <i>unbalance</i> : (a) Model referensi Lalane & Feraris, (b) Model MATLAB dan (c) Model ANSYS | 38 |
| Gambar 4.4 | Perbandingan bentuk respon <i>unbalance</i> untuk model desain awal (<i>original model</i>) <i>turbocharger</i> . (a) Model Straub dkk. dan (b) model MATLAB | 45 |

DAFTAR ISI

| | |
|---|-----|
| ABSTRAK | ii |
| <i>ABSTRACT</i> | iii |
| DAFTAR ISI | v |
| DAFTAR GAMBAR | vi |
| DAFTAR TABEL | vii |
| Bab I Pendahuluan | 1 |
| I.1 Latar Belakang | 1 |
| I.2 Perumusan Masalah | 2 |
| I.3 Ruang Lingkup Penelitian | 3 |
| I.4 Hipotesis | 4 |
| I.5 Tujuan | 4 |
| I.6 <i>Novelties</i> (Kebaruan) dari Penelitian | 5 |
| I.7 Roadmap Penelitian I | 6 |
| I.8 Permasalahan Penelitian Tahap I | 6 |
| Bab II Tinjauan Pustaka | 7 |
| Bab III Data dan Metodologi | 13 |
| III.1 Data persiapan eksperimen | 13 |
| III.2 Metodologi | 14 |
| Bab IV Hasil dan Pembahasan | 17 |
| Bab V Kesimpulan | 24 |
| DAFTAR PUSTAKA | 25 |

DAFTAR GAMBAR

| | | |
|-----------|---|----|
| Gambar.1 | Peta jalan (roadmap) penelitian tahap 1 | 6 |
| Gambar.2 | (a) masing convolution layer; (b) Squeeze-Net- DCNN architecture | 12 |
| Gambar.3 | (a) Validasi setup eksperimen; (b) Setup eksperimen impact hammer testing | 13 |
| Gambar.4 | Framework peralatan dan bahan penelitian | 14 |
| Gambar.5 | Diagram alir penelitian tahap 1. | 15 |
| Gambar.6 | (a) Modal analysis experiment; (b) Machining experiments | 16 |
| Gambar.7 | The schematic of building models using deep learning | 17 |
| Gambar.8 | Frequency response function (FRF) of the entire spindle system | 18 |
| Gambar.9 | Plot SLD untuk model slot milling | 19 |
| Gambar.10 | The vibration signals are (a) SC; (b) MC; (c) HC | 20 |
| Gambar.11 | Architecture Transfer Learning via-Squeeze-Net | 21 |
| Gambar.12 | Layer conv-1 to conv-10 process | 22 |
| Gambar.13 | Classification accuracy matrix (a) Squeeze-Net; (b) Alex-Net | 23 |

DAFTAR TABEL

| | | |
|---------|---|----|
| Tabel.1 | Modal parameters of the entire spindle system | 18 |
| Tabel.2 | Machining parameters | 19 |
| Tabel.3 | Classification accuracy result | 23 |

Bab I Pendahuluan

I.1 Latar Belakang

Kualitas akhir suatu produk tidak hanya dipengaruhi pada tahapan desain dan jaminan kualitas (QA) dengan standar yang ketat, namun juga dipengaruhi oleh kualitas dari proses pembuatannya (manufaktur). Salah satu faktor yang mempengaruhi kualitas proses manufaktur adalah pemantauan pada kondisi proses pemesinan [18].

Seiring dengan begitu pesatnya perkembangan teknologi saat ini, trend model *process condition monitoring* telah melangkah pada penggunaan teknologi industri 4.0, yang mana saat ini telah mulai banyak diterapkannya teknologi terbaru yang dikenal dengan nama Digital Twin (DT) pada sektor manufaktur khususnya dalam proses *condition monitoring*. Menurut Nasir dan Sassani, ada beberapa aspek proses pemesinan yang melibatkan teknologi DT untuk memantau kondisi proses seperti *surface integrity*, kondisi pahat (*tool condition*), dinamika dan stabilitas mesin (*machine dynamic & stability*), dan keberlanjutan (*sustainability*) [18]. Berfokus pada penerapan teknologi DT pada aspek dinamika dan stabilitas mesin (chatter) saat ini masih menjadi topik penelitian yang jarang dilakukan, karena diperlukan upaya yang tinggi untuk mewujudkannya. Upaya yang dimaksud disini adalah bagaimana kita membuat representasi model chatter yang up-to-date, sebuah model, pada fisik yang sebenarnya dalam proses pemesinan pemotongan logam. seperti penelitian yang dilakukan oleh Afazov dan Scrimieri, dimana mereka menggunakan teknologi Digital Twin untuk mendeteksi terjadinya chatter pada proses milling [19].

Namun, terlepas dari potensi manfaat dan keuntungan dari DT, penerapan teknologi ini baik metodologi dan kerangka kerja untuk industri manufaktur belum banyak dilakukan, terutama untuk pemantauan kondisi proses pemesinan. Oleh karena itu, banyak peneliti yang masih melanjutkan di bidang ini, dan penelitiannya saat ini sebagian besar berkontribusi bagaimana membuat interaksi antara ruang fisik dan virtual [6]. Karena itu, dalam penelitian tahap I ini, metode baru untuk mengaktifkan kembaran digital proses milling dalam aplikasi untuk mendeteksi chatter diusulkan. Untuk tujuan ini, SLD dibangun berdasarkan parameter modal sistem, yang mana hal

ini akan digunakan untuk memilih parameter kondisi pemotongan pada kondisi yang stabil maupun tidak stabil. Sinyal getaran yang terjadi direkam oleh sensor akselerometer pada saat kondisi pemotongan tersebut berlangsung. Untuk meningkatkan keakurasian dalam proses pembelajaran, metode analisis time & frequency yaitu continuous wavelet transform (CWT) digunakan untuk mengubah semua sinyal getaran 1- dimensi menjadi gambar skalogram 2-dimensi. Kemudian, kami menerapkan model jaringan pra-latihan DCNN-Transfer Learning melalui Squeeze-Net dan memodifikasi parameter pada tiga lapisan terakhir sesuai dengan tiga target keluaran yang diinginkan (kondisi stabil, medium chatter dan high chatter). Oleh karena itu, ini adalah suatu bentuk tahapan awal dalam membangun model digital berbasis data-driven. Beberapa perbandingan dengan metode pembelajaran jaringan pra latih lainnya dilakukan untuk memperkuat metode yang diusulkan. Model klasifikasi digital dengan tingkat akurasi yang sangat baik dapat diperoleh dari metode yang diusulkan, yang dalam hal ini mampu merepresentasikan objek fisik terkini seperti tiga kondisi pemotongan milling, yaitu status pemotongan stable condition (SC), medium chatter (MC) dan high chatter (HC), dimana harus selalu terup-to-date dan menyesuaikan dengan data terkini atau merekam data, sehingga dapat digunakan untuk mendeteksi dan memprediksi kondisi awal chatter secara efektif.

I.2 Perumusan Masalah

Digital Twin (DT) merupakan teknologi baru (*emerging technologies*) yang telah mulai banyak digunakan pada berbagai industri salah satunya yaitu pada industri manufaktur. Teknologi ini sangat menjanjikan, terutama pada bidang manufaktur khususnya dalam proses pemesinan dimana penerapan dari teknologi ini mampu memonitor performa, mengoptimasi progress, mensimulasi hasil dan memprediksi potensial kegagalan (*error*). Pada hakikatnya DT sendiri merupakan salinan virtual atau kembaran digital suatu objek (baik berupa proses, sistem, etc) yang merepresentasikan kondisi terkini dari objek fisik aktual yang sedang beroperasi, dalam hal ini peneliti memfokuskan penerapan awal dari teknologi DT ini untuk merepresentasikan kondisi sistem dinamik dari *cutting tool* dengan *workpiece* untuk proses pemesinan khususnya pada proses milling.

Namun, pada kenyataannya bahwa masih terdapat banyak sekali tantangan dalam riset mengenai teori dan konsep bagaimana pengembangan dan penerapan teknologi DT ini untuk merepresentasikan kondisi sistem dinamik dari *cutting tool* dengan *workpiece* pada aspek “*machine dynamic and stability (chatter)*”. Tantangan ini terjadi karena model DT yang dibangun tersebut modelnya harus terus diperbaharui dan disesuaikan dengan kondisi objek fisik yang sedang beroperasi, yang tentu saja melibatkan streaming langsung data dari objek kedalam algoritma yang menyesuaikan kondisi kembaran digital.

Oleh karena itu, berdasarkan hasil kajian literatur yang telah dilakukan oleh peneliti maka diperoleh beberapa rumusan masalah dalam pengembangan dan penerapan teknologi DT untuk merepresentasikan kondisi sistem dinamik dari *cutting tool* dengan *workpiece* pada aspek “*machine dynamic and stability (chatter)*”, yaitu:

1. Bagaimana membangun model framework digital twin dengan konstruksi 5 dimensi (konsep terkini) yang merepresentasikan sistem fisik yang modelnya dapat terus terupdate dan menyesuaikan dengan kondisi objek fisik dalam memonitoring fault condition milling machining process khususnya dalam hal machine dynamic stability/chatter?
2. Bagaimana membangun model kembaran digital atau DT dari suatu sistem milling machining process dengan tingkat model digital yang mirip dan akurat performanya terhadap kondisi operasi dari physical objek-nya sehingga mampu mendeteksi dan memprediksi terjadinya fault condition stability chatter yang dibangun berdasarkan data-driven based model dan algoritma machine/deep learning?

I.3 Ruang Lingkup Penelitian

Agar kegiatan penelitian I ini dapat lebih fokus dan terarah dalam mencapai tujuan penelitian maka perlu ditentukan beberapa poin batasan masalah yang terkait pada penelitian pengembangan dan penerapan teknologi DT ini untuk merepresentasikan kondisi sistem dinamik dari *cutting tool* dengan *workpiece* pada aspek “*machine*

dynamic and stability (chatter)” yang berbasis pada *data-driven model* dan *physical based model* adalah sebagai berikut:

1. SLD sebagai model profil karakteristik virtual dari model awal DT proses pemesinan yang berbasis pada *data-driven* dan model analitik dalam hal ini dengan menggunakan metode RCSA.
2. Data set yang digunakan untuk membangun model adalah berupa data-data hasil pengukuran (*data-driven*) dan data hasil pemodelan (*physical-model*). Untuk *data-driven* diperoleh dari *accelerometer signal* sedangkan untuk data *physical-model* diperoleh dari pemodelan simulasi dengan parameter yang berasal dari hasil ekstrak data eksperimen.
3. Pemodelan simulasi yang akan digunakan adalah simulasi model FRF dinamika *spindle system* dengan RCSA, simulasi *stability lobe digram (SLD)*, simulasi *milling process*.
4. Pengujian modus getar pada struktur *spindle system* menggunakan *hammer impact testing* untuk menentukan karakteristik dinamis FRF *spindle system*.
5. Parameter pemesinan berupa jenis material workpiece berupa aluminium, dimensi dari geometri spindle-holder-tool system maupun workpiece, kecepatan spindle, depth of cut, feedrate, dll.

I.4 Hipotesis

.

I.5 Tujuan

Maksud dari penelitian mengenai “pengembangan dan penerapan teknologi DT untuk merepresentasikan kondisi sistem dinamik dari *cutting tool* dengan *workpiece* pada aspek “*machine dynamic and stability (chatter)* yang berbasis pada *data-driven model* dan *physical based model*” ini adalah usaha untuk mewujudkan suatu model awal DT (*virtual object*) yang mirip dan akurat sebagai bentuk representasi dari suatu kondisi sistem fisik berupa proses *milling* pada *machine tools*, sehingga sistem ini nantinya dapat diterapkan untuk mendeteksi maupun memprediksi terjadinya suatu kesalahan

atau kegagalan didalam suatu proses pemesinan milling. Adapun tujuan dari penelitian ini adalah:

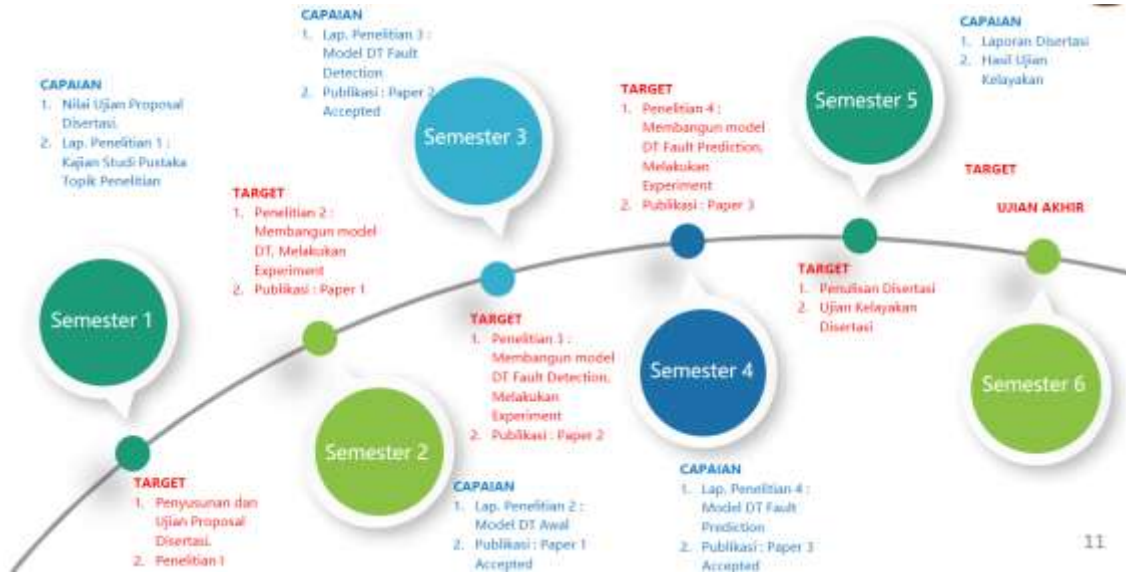
1. Membangun model *framework* 5 dimensi dari suatu model SLD sebagai model profil karakteristik virtual dari model awal DT proses pemesinan yang merepresentasikan sistem fisik yang modelnya dapat terus *terupdate* dan menyesuaikan dengan kondisi objek fisik pada aspek “*machine dynamic and stability (chatter)*” (dilakukan pada Penelitian I).
2. Membangun model awal kembaran digital atau DT model pendeteksi chatter menggunakan aplikasi deep learning yang dapat mengidentifikasi kondisi stabil atau tidak stabil (chatter). Model dibangun berdasarkan metode data driven dimana data sinyal getaran yang terukur dari proses milling dilatih dan diuji menggunakan beberapa metode supervised deep-learning. (dilakukan pada Penelitian I).

I.6 Novelties (Kebaruan) dari Penelitian

A. Keterbaruan dan orisinalitas (*novelty and originality*) dari penelitian ini adalah:

1. Penelitian ini membangun model DT dengan konstruksi 5 dimensi (konsep terkini) untuk diimplementasikan sebagai model DT monitoring fault condition milling machining process dynamic stability/chatter, namun yang dilakukan oleh (Zhuang, 2021) adalah terkait aplikasi tool wear for the turning process, begitupula yang dilakukan oleh (Qiao, 2019) pada aspek machine tools condition prediction.
2. Pemodelan DT yang dibuat mampu mendeteksi awal terjadinya kondisi chatter pada proses milling dan dibangun berdasarkan pada data-set serta algoritma machine/deep learning yang optimum. Namun yang dilakukan oleh (Avazof, 2021) hanya menggunakan metode TFA untuk mendeteksi chatter milling, kemudian (Vashish, 2021) hanya membuat model chatter detection in milling dengan data simulasi & deep learning tanpa DT, begitu pula yang dilakukan (Hanel, 2019) hanya membuat model digital twin for machining process tanpa melibatkan chatter.

I.7 Roadmap Penelitian I



Gambar 1. Peta jalan (roadmap) penelitian

I.8 Permasalahan Penelitian Tahap I

Bagaimana membangun model framework digital twin dengan konstruksi 5 dimensi (konsep terkini) yang merepresentasikan sistem fisik yang modelnya dapat terus terupdate dan menyesuaikan dengan kondisi objek fisik dalam memonitoring fault condition milling machining process khususnya dalam hal machine dynamic stability/chatter.

Bab II Tinjauan Pustaka

Banyak peneliti telah mengembangkan metode analitis dan numerik yang akurat untuk memprediksi masalah terjadinya chatter dalam proses pemotongan logam dengan menggunakan teknik analisis secara offline. Smith dan Tlustý menyajikan metode analitis untuk menghasilkan stability lobe diagram (SLD) dengan menggunakan simulasi domain waktu untuk getaran chatter dalam proses milling [1]. Selain itu, Altintas dan Budak menggunakan teknik alternatif (zero of order) berdasarkan pendekatan deret Fourier untuk menghasilkan diagram stabilitas lobus (SLD), yang bergantung pada orientasi sudut pahat saat berputar melalui pemotongan (koefisien dinamis milling) [2]. Secara numerik, metode semi-diskritisasi yang dikembangkan oleh Insperger dan Stepan merupakan metode numerik yang efisien untuk analisis stabilitas sistem tunda-linier [3,4], sehingga dapat diterapkan untuk memprediksi stabilitas proses milling. Selanjutnya, Ding et al. melakukan perbaikan pada metode yang diusulkan oleh Insperger dan Stepan dengan mengusulkan metode full-discretization berdasarkan skema integrasi langsung untuk memprediksi stabilitas proses milling [5]. Pada dasarnya, pengembangan SLD didasarkan pada asumsi bahwa dinamika sistem spindel tidak berubah selama rentang kecepatan putar spindel. Namun pada kenyataannya operasi pemesinan yang sebenarnya selalu mengandung begitu banyak karakteristik nonlinier. Dengan demikian, SLD bisa saja salah menafsirkan atribut status sinyal (stabil atau tidak stabil) yang penting dalam proses pemesinan [6]. Oleh karena itu, respon waktu dan frekuensi harus diamati secara bersamaan.

Transformasi Fourier yang dikenal secara umum sebagai model transformasi yang mengubah sinyal domain waktu menjadi sinyal domain frekuensi (spektrum), terutama sangat cocok untuk sinyal yang bersifat stasioner [7]. Berdasarkan beberapa penelitian sebelumnya terkait dengan identifikasi chatter, analisis spektrum frekuensi menunjukkan bahwa frekuensi chatter merupakan kelipatan kali dari frekuensi tinggi spindel atau frekuensi toothpass dengan amplitudo tinggi yang muncul dalam spektrum Fourier [8]. Oleh karena itu, sinyal chatter adalah sinyal yang bersifat non-stasioner di mana frekuensi komponennya selalu berubah terhadap waktu. Dengan keterbatasan

kemampuan yang ada pada transformasi Fourier, informasi terkait sinyal non-stasioner yang terjadi baik pada respon waktu maupun frekuensi tidak muncul dengan baik.

Berdasarkan hasil penelitian sebelumnya, diketahui bahwa transformasi wavelet kontinu dan diskrit (WT) sangat efektif dan fleksibel untuk memproses sinyal stasioner dan non-stasioner terutama pada proses pemesinan [9]. Perubahan yang tiba-tiba pada amplitudo hasil dekomposisi sinyal getaran dapat dianggap sebagai indikasi yang valid untuk mengidentifikasi terjadinya chatter [6]. Kemudian dengan menggunakan transformasi Fourier ke tingkat yang lebih detail dari sinyal yang didekomposisi, spektrum Fourier secara jelas dapat menunjukkan terjadinya chatter [10].

Saat ini, berbagai model Deep Learning (DL) telah banyak diterapkan untuk mendeteksi terjadinya chatter pada proses pemotongan milling, terutama model convolution neural network (CNNs) yang paling sering digunakan. Tran et al. mengusulkan model baru dari algoritma Deep CNN untuk mendeteksi terjadinya chatter pada proses milling. Mereka menggunakan continuous wavelet transform (CWT) untuk mengubah semua sinyal gaya potong 1-dimensi menjadi gambar skalogram 2-dimensi sebagai masukan DCNN. Beberapa perbandingan dengan metode pembelajaran tradisional lainnya dilakukan untuk memperkuat metode yang diusulkan dan akurasi yang tinggi juga dicapai [11]. Sener et al. juga mengusulkan model kustomisasi dari algoritma Deep-CNN untuk mendeteksi terjadinya chatter pada proses milling. Dalam penelitian ini, mereka menggunakan CWT untuk mengubah semua sinyal getaran percepatan 1-dimensi menjadi gambar skalogram 2-dimensi sebagai input DCNN. Berbagai skenario dengan dan tanpa parameter pemotongan dilakukan, ditemukan bahwa dengan menambahkan parameter pemotongan yang diketahui ke dalam klasifikasi keakurasian dalam mendeteksi dapat ditingkatkan [12].

Sebagian besar studi terbaru menggunakan pelatihan jaringan dengan bobot yang diinisialisasi secara acak dari awal. Namun, Unver dkk. memanfaatkan jaringan saraf yang ada (disebut pembelajaran transfer) yang telah dilatih pada kumpulan data besar untuk mendeteksi chatter dalam proses milling melalui jaringan Alex-Net [13]. Mereka menggunakan simulasi proses milling dengan domain waktu, dekomposisi empiris IMF-ensemble (EMD) dan Hilbert Huang Transform (HHT) untuk mempersiapkan gambar untuk diinputkan pada lapisan konvolusi terdepan sebagai persyaratan Alex-Net. Hasil yang diperoleh bahwa Alex-Net yang ditransfer dapat

untuk secara akurat mendeteksi chatter ketika menerima sinyal secara online dari sistem kerja nyata.

2.1. Stability map analysis

Pada tahap proses pemesinan diperlukan peta stabilitas (SLD) untuk memilih parameter pemesinan agar tidak terjadi kondisi yang tidak stabil. SLD dapat diperoleh secara analitik menggunakan model stabilitas chatter dengan ekspansi deret Fourier seperti yang diusulkan oleh Altintas dan Budak [2,14]. Model formulasi ketebalan chip sesaat untuk gigi (j) dalam hal posisi sudut, j diturunkan seperti di bawah ini:

$$h(\phi_j) = (f_t \sin(\phi_j) + n_{j-1} - n_j) \cdot g(\phi_j) \quad (1)$$

dimana fungsi switching, $g(\phi_j)$, sama dengan satu ketika gigi ke-j terlibat dalam pemotongan (yaitu, antara sudut awal pemotongan dan sudut keluar) dan nol sebaliknya. Juga, n_{j-1} menunjukkan arah getaran normal dari gigi sebelumnya dan n_j getaran gigi saat ini. Selanjutnya, komponen gaya tangensial dan normal (radial) kemudian ditulis sebagai fungsi dari ketebalan chip:

$$F_{t,j} = K_t a h(\phi_j), F_{n,j} = K_n F_{t,j} = K_n K_t a h(\phi_j) \quad (2)$$

dimana K_t dan K_n adalah koefisien potong tangensial dan normal, dan a adalah kedalaman potong. Setelah itu, gaya penggilingan diperoleh sebagai;

$$\begin{pmatrix} F_x \\ F_y \end{pmatrix} = \frac{1}{2} a K_t \begin{bmatrix} a_{xx} & a_{xy} \\ a_{yx} & a_{yy} \end{bmatrix} \begin{pmatrix} \Delta x \\ \Delta y \end{pmatrix} = \frac{1}{2} a K_t [A] (\Delta) \quad (3)$$

dimana matriks A dikenal sebagai "koefisien gaya dinamis yang berubah-ubah waktu" dengan koefisien yang diselesaikan sebagai;

$$a_{xx} = \frac{1}{2} (\cos(2\phi) - 2K_n \phi + K_n \sin(2\phi)) \mathbf{I}_{\phi_s}^{\phi_e}$$

$$\begin{aligned}
a_{xx} &= \frac{1}{2} (\cos(2\phi) - 2K_n\phi + K_n \sin(2\phi)) \mathbf{I}_{\phi_s}^{\phi_e} \\
a_{xy} &= \frac{1}{2} (-\sin(2\phi) - 2\phi + K_n \cos(2\phi)) \mathbf{I}_{\phi_s}^{\phi_e} \\
a_{yx} &= \frac{1}{2} (-\sin(2\phi) + 2\phi + K_n \cos(2\phi)) \mathbf{I}_{\phi_s}^{\phi_e} \\
a_{yy} &= \frac{1}{2} (-\cos(2\phi) - 2K_n\phi - K_n \sin(2\phi)) \mathbf{I}_{\phi_s}^{\phi_e}
\end{aligned} \tag{4}$$

Nilai Eigen dari persamaan karakteristik dari ekspresi di atas menghasilkan;

$$\begin{aligned}
\Lambda &= \frac{N_t}{2\pi} \left(-\frac{1}{2} aK_t (1 - e^{-i\omega_c\tau}) \right) \\
\Lambda &= -\frac{N_t}{4\pi} aK_t (1 - e^{-i\omega_c\tau})
\end{aligned} \tag{5}$$

Kecepatan spindle yang bergantung pada frekuensi yang sesuai ditentukan oleh persamaan berikut;

$$\begin{aligned}
\Omega &= \frac{60}{N_t\tau}, \tau = \frac{1}{\omega_c} (\varepsilon + j \cdot 2\pi), \\
\varepsilon &= \pi - 2\psi, \psi = \frac{1}{\tan(\kappa)}
\end{aligned} \tag{6}$$

dimana menunjukkan, jeda fase antara lintasan gigi berikutnya, N_t adalah jumlah gigi, adalah periode lewatnya gigi, adalah jumlah gelombang yang tercetak pada permukaan potong selama pemotongan gigi, dan adalah kecepatan potong.

Akhirnya, ekspresi yang bergantung pada frekuensi untuk kedalaman batas stabilitas pemotongan, alim yang memplot SLD dapat dihitung sebagai;

$$a_{\text{lim}} = -\frac{2\pi}{N_t K_t} \Lambda_{\text{Re}} \left(1 + \frac{\Lambda_{\text{Im}}}{\Lambda_{\text{Re}}} \frac{\sin(\omega_c\tau)}{(1 - \cos(\omega_c\tau))} \right) \tag{7}$$

2.2. Continuous wavelet transform

Dalam penelitian ini digunakan salah satu jenis transformasi wavelet, yaitu continuous wavelet transform (CWT). CWT digunakan untuk mengubah representasi

sinyal domain waktu satu dimensi menjadi representasi domain frekuensi waktu. Keuntungan menggunakan CWT adalah sangat efektif untuk menganalisis sinyal non-linier dan non-stasioner yang terjadi pada proses pemotongan frais. CWT sinyal $f(t)$ kemudian diberikan oleh persamaan sebagai [9];

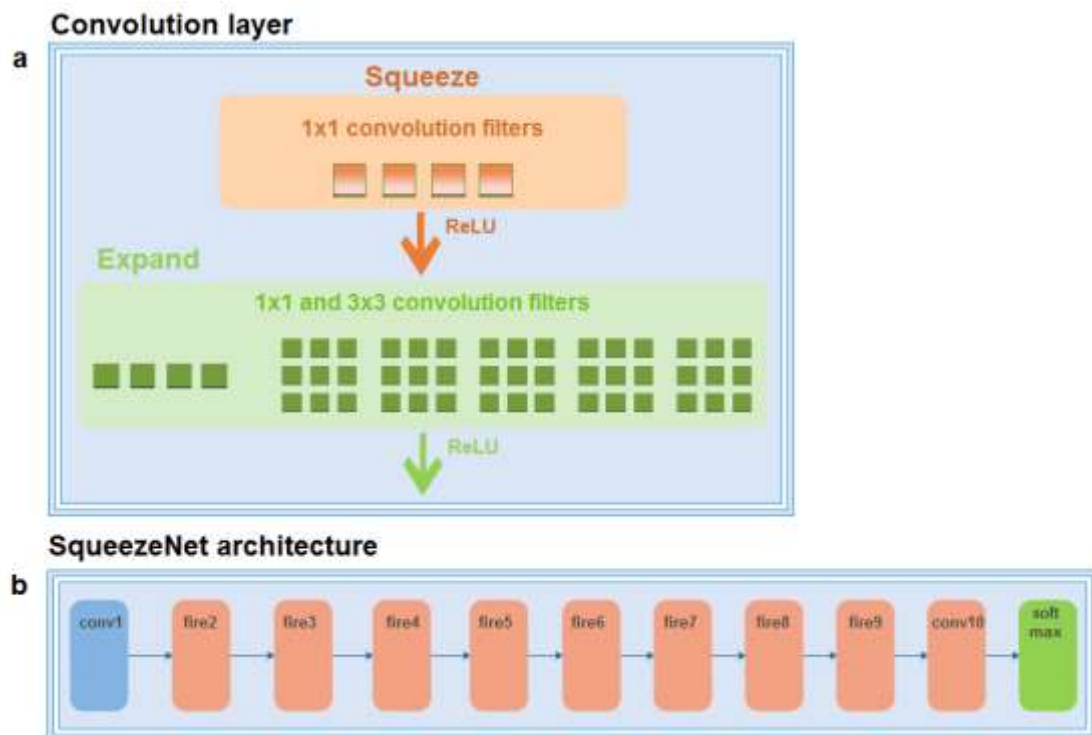
$$CWT(a_s, b) = \frac{1}{\sqrt{a_s}} \int_{-\infty}^{+\infty} f(t) \cdot \psi\left(\frac{t-b}{a_s}\right) \cdot dt \quad (8)$$

dimana b adalah parameter posisi dan a_s sebagai parameter skala dari fungsi wavelet, $f(t)$. Dalam CWT sendiri terdapat beberapa jenis fungsi wavelet. Setiap jenis fungsi wavelet memiliki bentuk tertentu, kehalusan tertentu, dan kekompakan, dan tentu saja masing-masing memiliki tujuan tertentu. Wavelet morlet analitik adalah fungsi eksponensial kompleks dengan amplop Gaussian yang sering digunakan dalam berbagai aplikasi. Diketahui bahwa dengan fungsi morlet wavelet ini mampu memberikan resolusi waktu dan frekuensi yang baik [15]. Oleh karena itu, pada penelitian ini akan digunakan fungsi morlet wavelet untuk menganalisis perilaku getaran non-linier dan non-stasioner. sinyal yang dihasilkan oleh proses pemotongan.

2.3. Transfer Learning Squeeze-Net – Deep CNN

Transfer learning adalah bagian dari atau jenis deep learning yang menggunakan model jaringan pra-terlatih untuk mempelajari tugas baru. Menyetel jaringan dengan pembelajaran transfer biasanya jauh lebih cepat dan lebih mudah daripada melatih jaringan dengan bobot yang diinisialisasi secara acak dari awal. Sehingga dapat dengan cepat mentransfer fitur yang dipelajari ke tugas baru menggunakan lebih sedikit gambar pelatihan. Ada banyak jenis jaringan berbeda yang dapat digunakan seperti Alex-Net dan Google-Net untuk model pengembangan awal, ResNet-50 dan X-Ception untuk segmentasi semantik, Squeeze-Net dan Mobile-Net untuk model penerapan. menemukan bahwa Squeeze-Net memiliki beberapa keunggulan diantaranya memiliki ukuran 510x yang lebih kecil dan parameter yang lebih sedikit jika dibandingkan dengan Alex-Net, sehingga mengurangi model komputasi [16]. Oleh karena itu, pada penelitian ini akan digunakan Squeeze-Net untuk membangun model digital twin pendeteksi obrolan.

Transfer Learning DeepCNN-Squeeze-Net dimulai dengan lapisan konvolusi mandiri (conv-1), diikuti oleh 8 modul api (fire-2- fire-9), diakhiri dengan lapisan konvolusi akhir (conv-10). Kami secara bertahap meningkatkan jumlah filter per modul api dari awal hingga akhir jaringan. Squeeze-Net melakukan max-pooling dengan langkah 2 setelah lapisan konv-1, api-4, api-8, dan konv-10, seperti yang ditunjukkan pada Gambar 2.a modul api terdiri dari lapisan konvolusi pemerasan (yang hanya memiliki filter 1x1), diumpankan ke lapisan perluasan yang memiliki campuran filter konvolusi 1x1 dan 3x3, kami mengilustrasikannya pada Gambar. 2a.

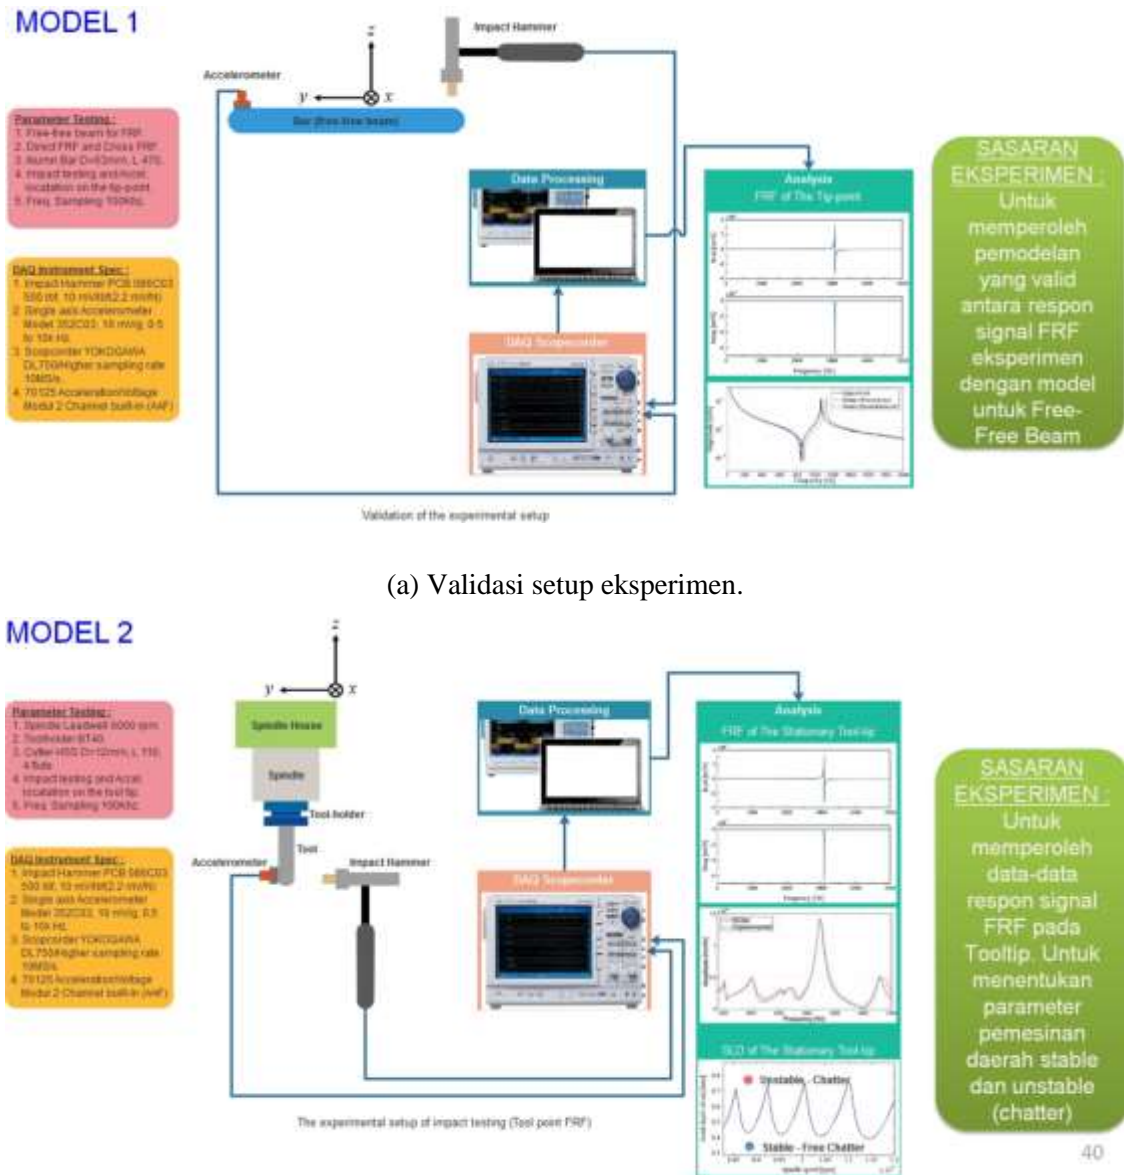


Gambar 2. (a) Each of convolution layer; (b) Squeeze-Net- DCNN architecture.

Bab III Data dan Metodologi

III.1 Data persiapan eksperimen

Mesin milling CNC dengan tiga sumbu (Leadwell-V30), daya maksimum 10 HP dan kecepatan spindel maksimum 8000 rpm digunakan dalam percobaan pemotongan logam dengan proses milling. Tool pemotong end-mill HSS empat flute dengan panjang 110 mm, diameter 12 mm, dan sudut heliks 30° dengan dudukan pahat tipe BT40 digunakan selama percobaan. Model keseluruhan dari prosedur eksperimental tahap 1 ini ditunjukkan pada Gambar. 3.



Gambar 3. (b) Setup eksperimen impact hammer testing.

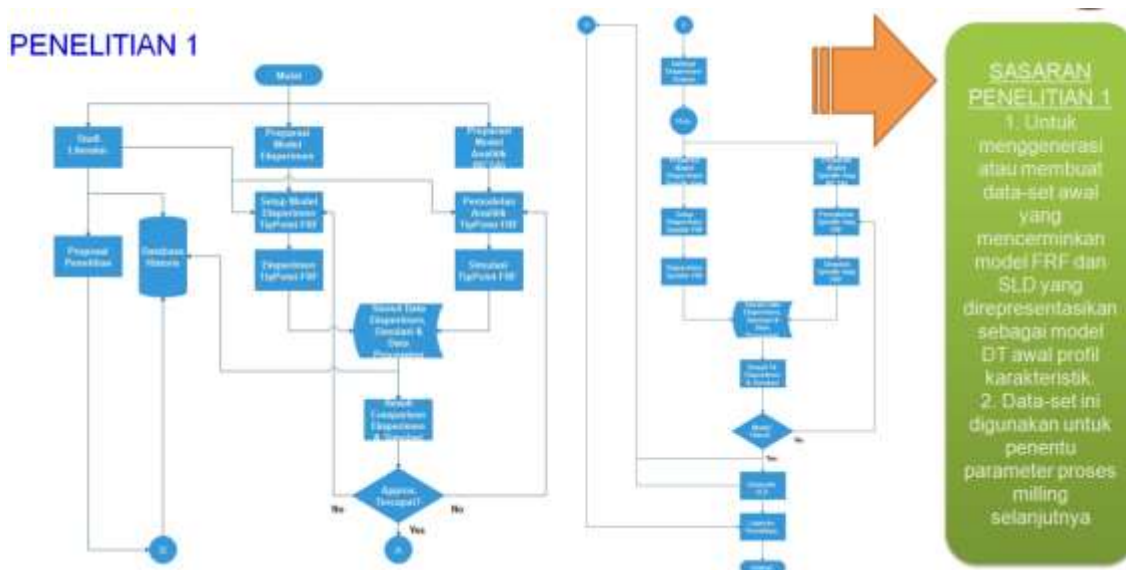
Kebutuhan peralatan dan bahan penelitian yang diperlukan selama pelaksanaan pada tahap 1 ini ditunjukkan pada Gambar 4



Gambar 4. Framework peralatan dan bahan penelitian.

III.2 Metodologi

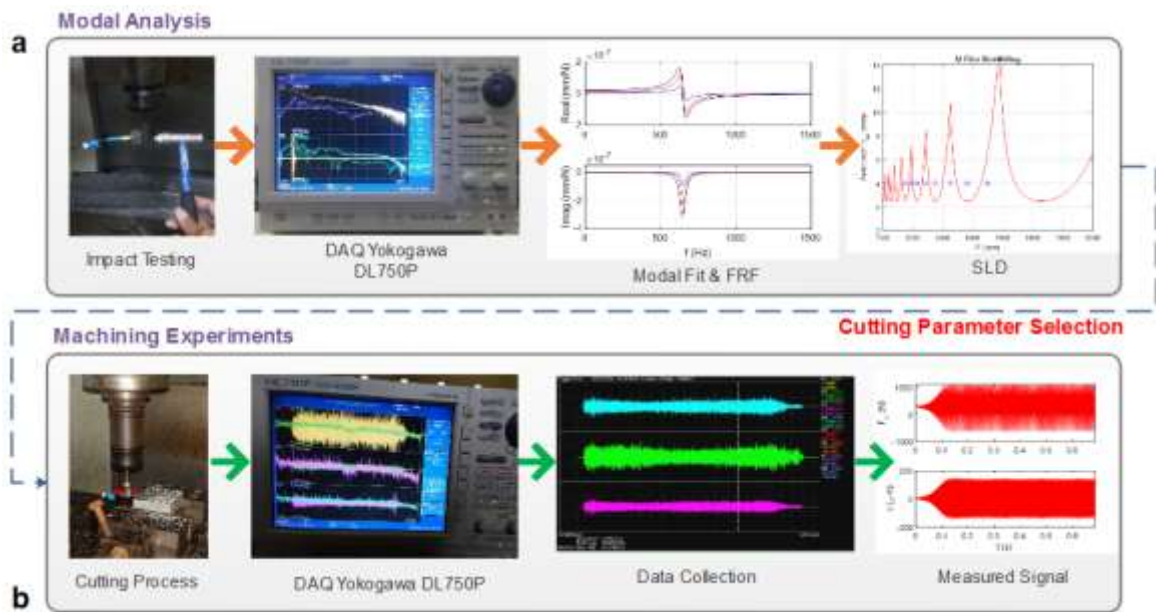
Sasaran yang ingin dicapai pada penelitian 1 adalah menggenerasi atau membuat data-set awal dengan cara pertama, validasi pemodelan eksperimen awal antara respon signal FRF eksperimen dengan model untuk kondisi free-free beam. Kedua, memperoleh karakteristik model FRF spindle-holder-tool assy yang valid berdasarkan eksperimen guna menentukan parameter stability region. Data-set awal yang mencerminkan Model FRF dan SLD pada tahap ini bisa digunakan sebagai penentu parameter proses pemesinan milling selanjutnya dan juga direpresentasikan sebagai model DT awal. Diagram alir dari penelitian tahap 1 ditunjukkan pada Gambar 5.



Gambar 5. Diagram alir penelitian tahap 1.

Seperti yang ditunjukkan dalam percobaan analisis modal, pengujian palu tumbukan dilakukan terlebih dahulu untuk menentukan karakteristik dinamis sistem spindel (FRF) sebagai parameter untuk menghasilkan SLD. Pemotong end-mill dengan panjang gantung 60 mm, sensor akselerometer 3-sumbu (Dytran3413A2) yang dipasang di ujung pahat, palu impuls (Dytran5800B3) dan akuisisi data Yokogawa DL750 digunakan selama eksperimen analisis modal. Model rinci dari setup pengujian impact hammer test ditunjukkan pada Gambar. 6.a.

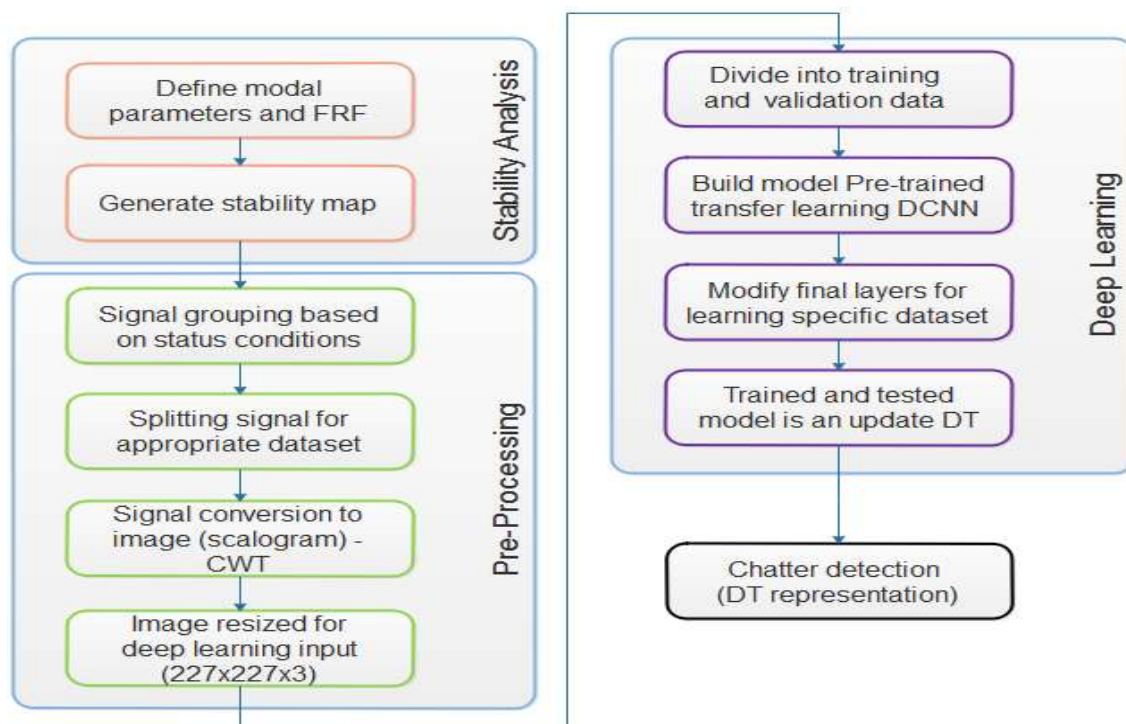
Dalam percobaan pemotongan, beberapa parameter pemotongan dipilih berdasarkan SLD, kemudian percobaan milling dilakukan dalam kondisi pemotongan kering. Proses pemotongan model slot milling dilakukan untuk memotong blok aluminium berukuran 25x25x20 mm (Al6061-T6). Sensor akselerometer 3-sumbu yang sama dipasang pada sisi benda kerja, dan Yokogawa DL750 digunakan selama eksperimen pemotongan. Akhirnya, sinyal yang dikumpulkan dari setiap pemotongan ditransfer ke MATLAB™ untuk pengkondisian sinyal seperti yang ditunjukkan pada Gambar 6.b.



Gambar 6. (a) Modal analysis experiment; (b) Machining experiments.

Bab IV Hasil dan Pembahasan

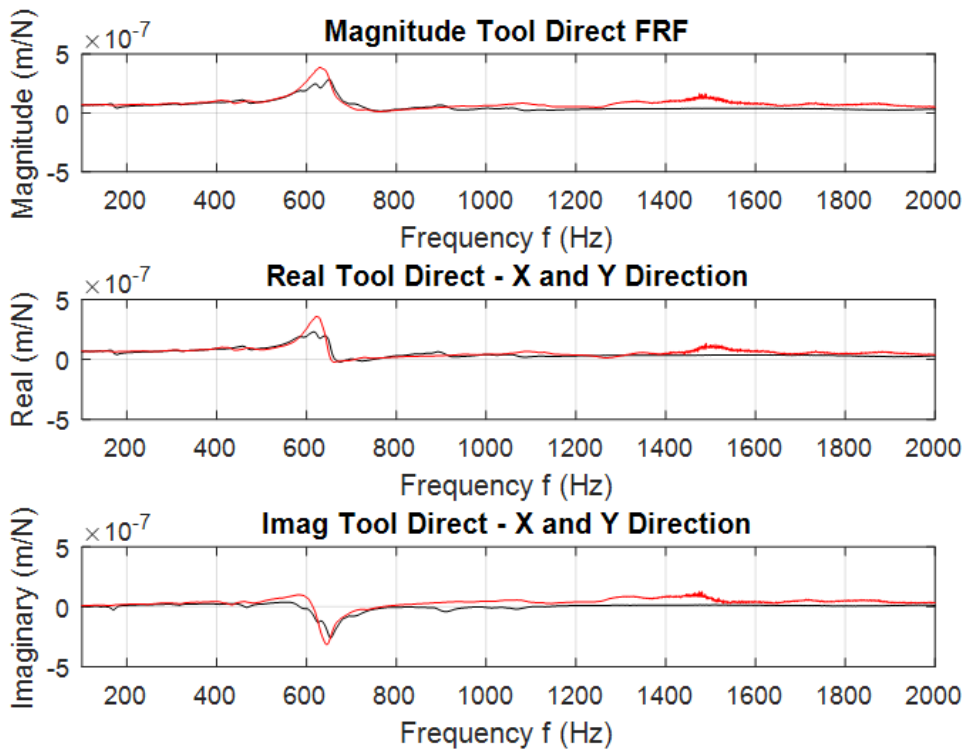
Gambar 7 menunjukkan skema model baru yang diusulkan dalam memungkinkan model digital dari kembaran proses pemesinan milling untuk mendeteksi terjadinya chatter, dimana model ini terdiri dari beberapa tahap; (1) SLD digunakan untuk memilih parameter pemesinan sehingga mampu menghindari kondisi yang tidak stabil; (2) Sinyal getaran pada parameter pemotongan yang berbeda diatur sesuai dengan kondisinya (stabil, transisi atau tidak stabil); (3) Setiap sinyal dipecah menjadi sinyal yang lebih kecil agar sesuai dengan input yang diperlukan dalam melatih menggunakan CNN; (4) Konversi sinyal ke citra dilakukan dengan menggunakan metode CWT untuk setiap sampel; (5) Data pembelajaran diperoleh dengan membagi dataset menjadi data latih dan data validasi; (6) Model Transfer Learning melalui Squeeze-Net-DCNN dibangun untuk mendeteksi adanya chatter; (7) model DT dari proses pemesinan milling bertujuan untuk mengklasifikasikan kondisi pemesinan stabil/tidak stabil dapat diperoleh.



Gambar 7. The schematic of building models using deep learning.

4.1. Stability map analysis

Seperti yang dapat dilihat pada Gambar 6.a, tooltip diketuk oleh hammer impuls pada arah sumbu X dan Y sebanyak 5 kali secara berulang, sehingga kondisi koherensi terbaik dapat tercapai. Respon sinyal-sinyal diukur dengan 3-sumbu sensor akselerometer yang terletak pada tooltip dan sinyal diperoleh dengan laju pengambilan sampel 10 kHz oleh sistem penyimpanan data Yokogawa DL750. Gambar 8 menunjukkan fungsi respons frekuensi eksperimental (FRF) dari seluruh sistem spindel. Dengan menggunakan metode modal fitting, parameter modal dapat diestimasi dari bagian nyata dan imajiner dari sistem FRF secara eksperimental seperti teknik yang diusulkan oleh Schmitz & Smith [17]. Dan, Tabel 1 menunjukkan parameter modal yang diperoleh dalam pengujian ini.

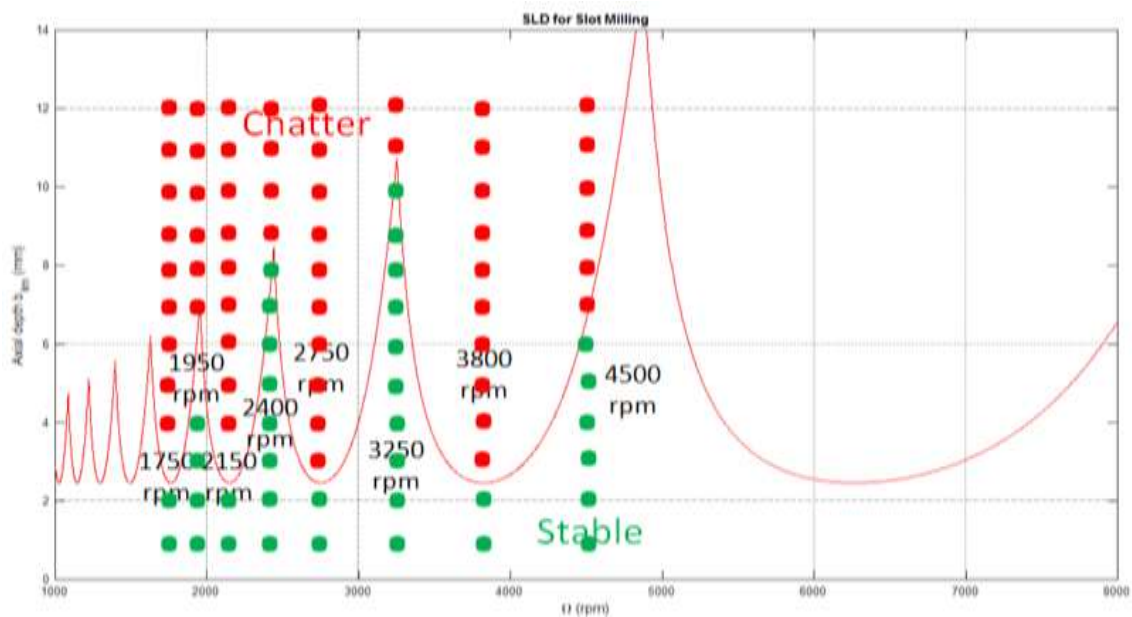


Gambar 8. Frequency response function (FRF) of the entire spindle system.

Table 1. Modal parameters of the entire spindle system.

| Axis | Natural frequency f_n (Hz) | Damping ratio ζ (%) | Stiffness k (N/m) |
|------|------------------------------|---------------------------|---------------------|
| X | 653 | 2.5 | 7.6×10^7 |
| Y | 645 | 3.2 | 4.9×10^7 |

Berdasarkan parameter modal dan faktor orientasi arah, FRF terorientasi yang baru dapat dihitung sehingga SLD dapat dihasilkan untuk memprediksi area stabilitas seperti yang ditunjukkan pada Gambar. 9. Dalam studi ini, proses pemotongan slot milling dipertimbangkan, DOC dimulai dari kedalaman pemotongan yang stabil (titik hijau) hingga chatter (titik merah) pada setiap kecepatan spindel, sehingga semua parameter pemotongan tersebut menjadi objek pengamatan terjadinya chatter pada proses pemotongan. Tabel 2 menunjukkan daftar parameter pemotongan yang digunakan dalam penelitian ini.




Gambar 9. Plot SLD untuk model slot milling.

Table 2. Machining parameters.

| | | | | | | | | |
|-----------------|------|------|------|------|------|------|------|------|
| Feed (mm/tooth) | 0.25 | | | | | | | |
| Spin speed(rpm) | 1750 | 1950 | 2150 | 2400 | 2750 | 3250 | 3800 | 4500 |
| Axial depth(mm) | 1-12 | 1-12 | 1-12 | 1-12 | 1-12 | 1-12 | 1-12 | 1-12 |
| Number of tests | 12 | 13 | 12 | 13 | 12 | 12 | 12 | 12 |

Sebanyak 98 percobaan proses pemotongan milling dilakukan dengan rentang kecepatan spindel 1750 rpm (pada kecepatan rendah) hingga 4500 rpm (kecepatan tinggi) dan rentang DOC dari 1 hingga 12 mm, dan dengan laju feed konstan 0,25 mm /gigi. Status setiap kondisi pemotongan ditunjukkan pada Gambar 10. Akselerometer 3-sumbu dipasang di sisi benda kerja, dan digunakan untuk memperoleh sinyal getaran. Sinyal getaran dalam arah x, y, dan z diperoleh melalui modul data akuisisi jenis

70125, dengan sensitivitas 50,8, 51,96 dan 50,01 mV/g dan laju sampling 10 kHz. Gambar 10 menunjukkan sinyal getaran pada kondisi pemotongan SC, MC, dan tidak stabil (HC).



Gambar 10. The vibration signals are (a) SC; (b) MC; (c) HC.

4.2. Dataset pre-processing

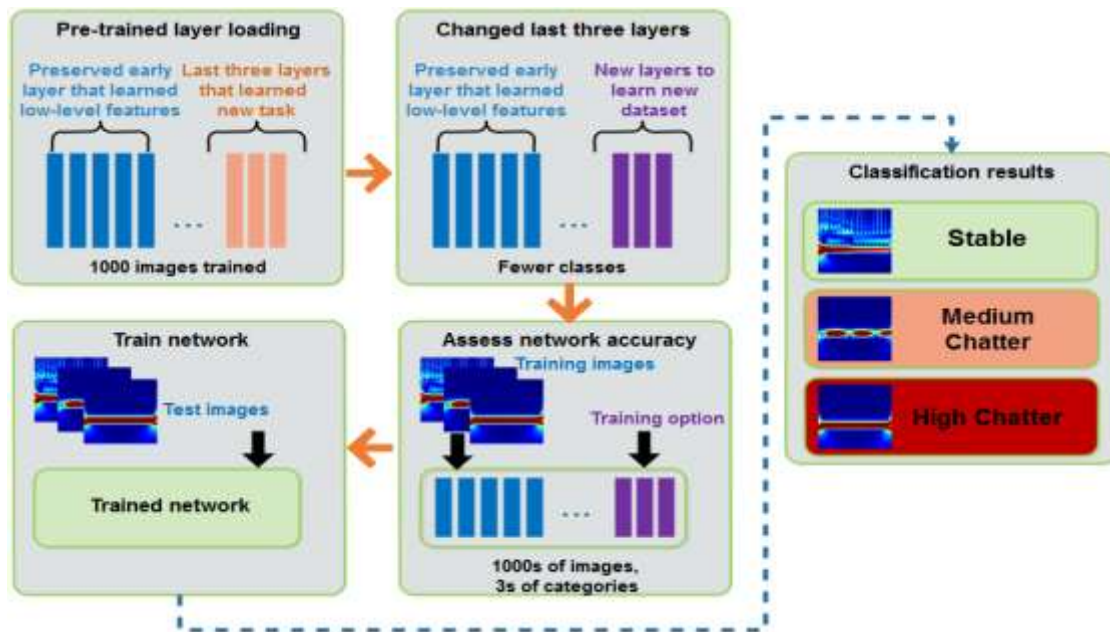
Setelah semua sinyal getaran ini terkumpul, semua sinyal tersebut disusun untuk membentuk sebuah dataset. Dataset dibuat sebagai struktur array dengan dua bidang: data dinamis dan statis, serta data label. Bidang Data adalah matriks 98×13040 di mana setiap baris adalah proses pemotongan slot milling yang diambil sampelnya pada 10 kHz. Label adalah larik sel 98×1 dari label status kondisi, satu untuk setiap baris Data. Tiga kategori status kondisi adalah: SC, MC, dan HC.

Dalam hal ini, kami melakukan pra-proses setiap sinyal dengan panjang sampel 13040, yang dapat dipecah menjadi sinyal yang lebih kecil dengan panjang sampel 1304 untuk meningkatkan ukuran dataset dan membuatnya cocok untuk melatih algoritma CNN. Untuk keperluan ini, kami mengambil sebanyak 34, 30, dan 34 sinyal masing-masing kondisi (SC, MC, dan HC), masing-masing sinyal dibagi menjadi 10 buah panjang kelompok data. Oleh karena itu, setiap kategori akan menyediakan sebanyak 340, 300, 340 sinyal dan totalnya akan menjadi 980 sinyal.

Setelah itu, semua (980 sinyal) sinyal getaran 1-D ini diubah menjadi gambar sinyal 2-D menggunakan CWT dan koefisien CWT direpresentasikan sebagai gambar scalogram. Untuk tujuan ini, kami mengambil CWT sinyal 1-D dan semua koefisien disusun untuk membentuk scalogram CWT. Setiap scalogram direpresentasikan dalam peta warna tipe jet 128 warna. semua scalogram diubah menjadi gambar dan disimpan dalam folder yang sesuai dengan masing-masing kategori. Karena model Squeeze-Net hanya menerima 227×227 gambar masukan, semua gambar scalogram diubah ukurannya menjadi $227 \times 227 \times 3$ gambar berwarna RGB.

4.3. Transfer Learning via Squeeze-Net for chatter detection

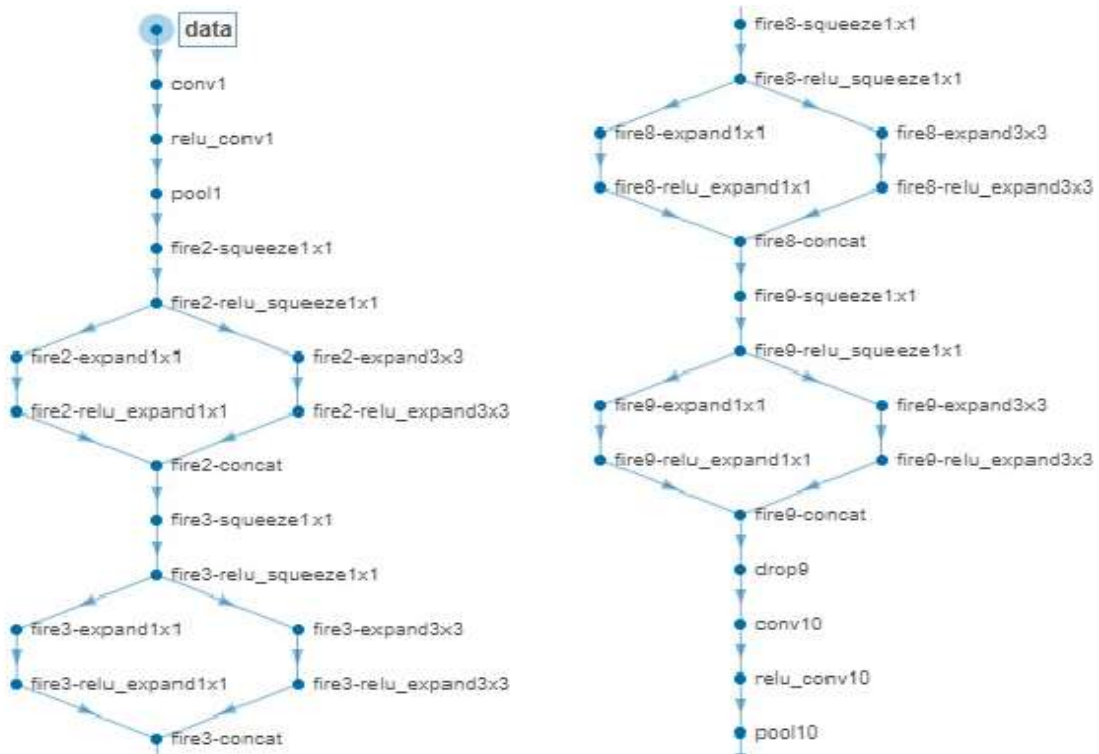
Gambar 11 menunjukkan bentuk Transfer Learning-DCNN yang diusulkan menggunakan Squeeze-Net, jaringan saraf konvolusi yang telah dilatih sebelumnya, untuk mengklasifikasikan kumpulan gambar baru. Jadi, setelah semua gambar scalogram sinyal getaran diubah ukurannya dan disimpan dalam tiga folder yang sesuai dengan masing-masing kategori SC, MC, dan HC, dari 980 dataset gambar ini, 90% akan digunakan untuk pelatihan dan 10% akan digunakan untuk validasi.



Gambar 11. Architecture Transfer Learning via-Squeeze-Net.

Seperti terlihat pada Gambar 11, semua scalogram dimasukkan sebagai input ke lapisan awal jaringan Squeeze-Net. Squeeze-Net sendiri memiliki total 68 layer dimana jaringan terdiri dari Conv-1, ReLu-1, Pool-1 hingga Conv-9, ReLu-2, Pool-9 sebagai layer yang telah diawetkan (pre-trained), lapisan yang sepenuhnya terhubung, lapisan soft-max dan lapisan klasifikasi. Konfigurasi rinci dari lapisan-lapisan ini ditunjukkan pada Gambar 12. Lapisan 2 sampai 9 adalah lapisan api yang terdiri dari beberapa filter, yaitu lapisan squeeze convolution (yang hanya memiliki filter 1x1) dan lapisan expand yang memiliki campuran 1x1 dan filter konvolusi 3x3, pada bagian ini kami tidak mengubah lapisan apa pun seperti yang ditunjukkan pada Gambar. 12. Karena Squeeze-Net asli dirancang untuk membuat 1000 klasifikasi gambar yang berbeda,

maka 3 lapisan terakhir harus dimodifikasi untuk prediksi (SC /MC/HC) untuk kasus kita. Jadi, 3 lapisan terakhirnya, yang merupakan lapisan yang terhubung penuh, lapisan soft-max dan lapisan klasifikasi, mereka diubah dengan parameter baru untuk lapisan yang terhubung penuh, untuk menentukan jumlah kelas di lapisan soft-max baru dan kemudian lapisan klasifikasi baru terakhir yang sesuai dengan kategori (SC/MC/HC).

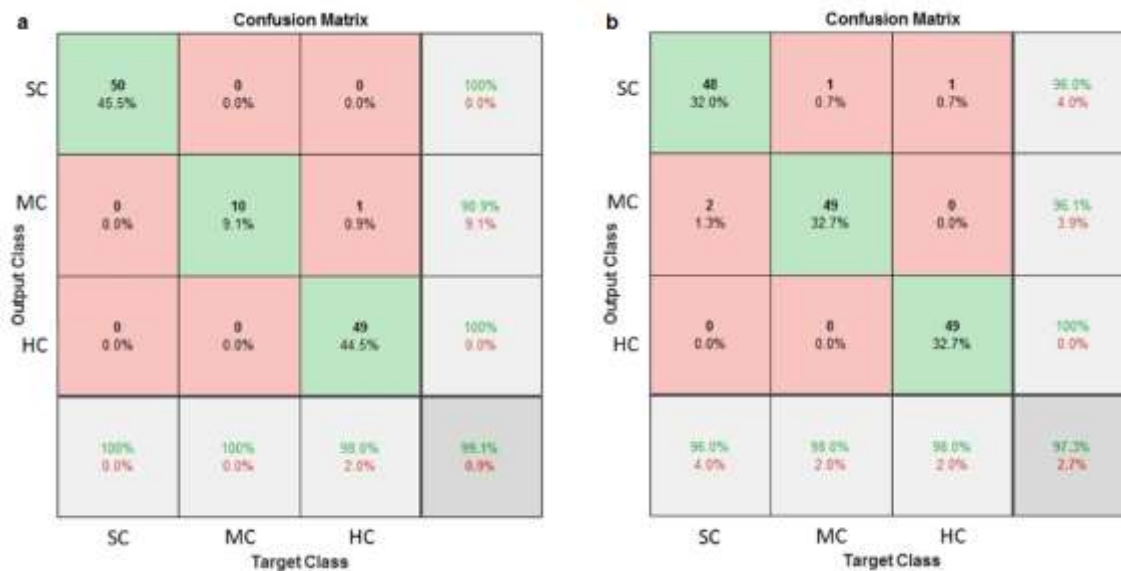


Gambar 12. Layer conv-1 to conv-10 process.

Setelah 3 lapisan terakhir ini diubah dan disetel dengan baik, kami melatih jaringan ini kepada kumpulan gambar baru kami dengan parameter ('WeightLearnRateFactor',10,'BiasLearnRateFactor',10),('MiniBatchSize',20,'MaxEpochs',8),and(Shuffle,'everyepoch','ValidationData',TestImages,'ValidationFrequency',10,'InitialLearnRate',1e-4), kemudian setelah tahapan pelatihan dan validasi selesai maka siap untuk digunakan mengklasifikasikan masalah kondisi (ST, MC, dan HC).

Gambar 13 menunjukkan matriks konfusi untuk melihat keakurasian klasifikasi dataset pelatihan model yang diusulkan jika dibandingkan dengan jaringan pra-pelatihan Alex-Net. Ditemukan bahwa dengan perlakuan parameter yang sama antara

Squeeze-Net dan Alex-Net, akurasi tingkat klasifikasi dan waktu iterasi sangat berhasil dicapai (99,1%) oleh Squeeze-Net sehingga sangat cocok dalam penerapan suatu sistem. Rincian perbandingan capaian pelatihan dan validasi kedua model jaringan dapat dilihat pada Tabel 3.



Gambar 13. Classification accuracy matrix (a) Squeeze-Net; (b) Alex-Net.

Table 3. Classification accuracy result.

| Network models | Alex-Net | Proposed model |
|-----------------------------|----------|----------------|
| Classification Accuracy (%) | 97.3 | 99.1 |

Bab V Kesimpulan

Laporan ini menyajikan studi pendahuluan tentang pengembangan model DT dari proses pemesinan milling untuk mendeteksi adanya chatter. Dalam studi ini, pendekatan baru berdasarkan analisis peta stabilitas (SLD), metode data-driven dan pembelajaran mendalam (Deep Learning) diusulkan. Tahapan dalam membangun model dimulai dengan menentukan FRF, membangkitkan SLD untuk memilih parameter pemotongan, kemudian data sinyal getaran diproses menggunakan CWT untuk meningkatkan akurasi proses pembelajaran. Dengan menerapkan metode transfer learning yang merupakan upaya untuk mengurangi penggunaan dataset dan mempercepat proses pembelajaran tanpa harus melatih jaringan dengan bobot yang diinisialisasi secara acak dari awal. Didapatkan bahwa dengan jaringan Squeeze-Net, tingkat akurasi klasifikasi dan waktu iterasi sangat berhasil dicapai dan tentunya model ini sangat cocok bila diimplementasikan pada perangkat keras sehingga upaya mewujudkan model DT tidak lagi mustahil.

DAFTAR PUSTAKA

- [1] S. Smith, J. Tlustý. Efficient simulation programs for chatter in milling, *CIRP Ann.* 1993; 42 (1); 463–466.
- [2] Altintas, Y., & Budak, E. Analytical prediction of stability lobes in milling. *CIRP Annals* 1995; 44(1); 357–362.
- [3] T. Insperger, G. Stepan. Semi-discretization method for delayed systems. *International Journal for Numerical Methods in Engineering* 2002; 55(5); 503–518.
- [4] T. Insperger, G. Stepan. Updated semi-discretization method for periodic delay-differential equations with discrete delay. *International Journal for Numerical Methods in Engineering* 2004; 61(1); 117–141.
- [5] Y. Ding, L. MinZhu, X.J. Zhang, H. Ding. A full-discretization method for prediction of milling stability. *International Journal of Machine Tools & Manufacture* 2010; 50; 502–509.
- [6] Feng, J., Sun, Z., Jiang, Z., Yang, L. “Identification of chatter in milling of Ti-6Al-4V titanium alloy thin-walled workpieces based on cutting force signals and surface topography”, *International Journal of Advanced Manufacturing Technology* 2015; 82; pp. 1909-1920.
- [7] Elbestawi, A., Papazafiriou, A., Du, X. “Inprocess monitoring of tool wear in milling using cutting force signature”. *International Journal of Machine Tools and Manufacture* 1991; 31; pp. 55-73.
- [8] Huang, P., Li, J., Sun, J., Zhou, J. “Vibration analysis in milling titanium alloy based on signal processing of cutting force”. *International Journal of Advanced Manufacturing Technology* 2013; 64; pp. 613-621.
- [9] Berger S, Harlay J, Rokni M, Papadopoulos M. Wavelet based cutting state identification. *J Sound Vib* 1998; 213(5):813–827.
- [10] Tangjitsitcharoen, S., Saksri, T., Ratanakuakangwan, S. “Advance in chatter detection in ball end milling process by utilizing wavelet transform”. *Journal of Intelligent Manufacturing* 2015; 26; pp. 485- 499.

- [11] Minh-Quang Tran, Meng-Kun Liu, Quoc-Viet Tran, Milling chatter detection using scalogram and deep convolutional neural network, *Int. J. Adv. Manuf. Technol.* 2020; 107 (3); 1505–1516.
- [12] Sener, Batihan, Gudelek, M Ugur, Ozbayoglu, A Murat, & Unver, Hakki Ozgur .Anovel chatter detectionmethod formilling using deep convolution neural networks. *Measurement* 2021; page 109689.
- [13] Unver, H.O., Sener, B. A novel transfer learning framework for chatter detection using convolutional neural networks. *J Intell Manuf* 2021; <https://doi.org/10.1007/s10845-021-01839-3>.
- [14] Budak, E. Analytical models for high performance milling. Part ii: Process dynamics and stability. *International Journal of Machine Tools and Manufacture* 2006; 46(12–13), 1489–1499.
- [15] Najmi AH, Sadowsky J. The continuous wavelet transform and variable resolution time-frequency analysis. *Johns Hopkins Apl Techn Digest* 1997; 18(1):134–139.
- [16] Iandola, Forrest N., Song Han, Matthew W. Moskewicz, Khalid Ashraf, William J. Dally, and Kurt Keutzer. "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size." Preprint, submitted November 4, 2016. <https://arxiv.org/abs/1602.07360>.
- [17] Schmitz TL, Smith KS. *Mechanical Vibrations: Modeling and Measurement*. New York: Springer; 2012.
- [18] V. Nasir, F. Sassani. A review on deep learning in machining and tool monitoring: methods, opportunities, and challenges. *The International Journal of Advanced Manufacturing Technology* 2021; 115; 2683–2709.
- [19] S. Afazov, D.Scrimieri. Chatter model for enabling a digital twin in machining. *The International Journal of Advanced Manufacturing Technology* 2020; 110; 2439–2444.