

**LAPORAN PENELITIAN (MANDIRI)**

**Model Deteksi Chatter pada Proses Pemesinan Shoulder (Side)  
Milling**



**PENULIS**

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

**PROGRAM STUDI TEKNIK MESIN  
INSTITUT TEKNOLOGI INDONESIA  
FEBRUARI 2023**

## LEMBAR PENGESAHAN

Judul Penelitian : Model Deteksi Chatter pada Proses Pemesinan Shoulder (Side) Milling

Daftar Mitra : LT MEPPPO – BRIN/UNDIP

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, 24 Februari 2023


Mengetahui

Program Studi Teknik Mesin

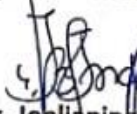
Kepala Prodi Teknik Mesin

  
Victor Tuapetel ST, MT, Ph.D  
NIDN 0322096803

Peneliti

  
Khairul Jauhari, ST, MT  
NIDK 8818620016

Mengetahui Kepala Pusat Riset &  
Pengabdian Masyarakat

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



## KATA PENGANTAR

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 "Model Deteksi Chatter pada Proses Pemesinan Shoulder (Side) 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 Laboratorium Teknologi Mesin Perkakas, Produksi dan Otomasi.
3. Segenap karyawan dan manajemen Laboratorium 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, 24 Februari 2023

Penulis



Ir. Khairul Jauhari, ST, MT, IPP.

## 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 II.....	7
I.8 Permasalahan Penelitian Tahap II.....	8
Bab II Tinjauan Pustaka .....	9
Bab III Data dan Metodologi .....	18
III.1 Data persiapan eksperimen.....	18
III.2 Metodologi .....	19
Bab IV Hasil dan Pembahasan.....	22
Bab V Kesimpulan .....	35
DAFTAR PUSTAKA .....	36

## DAFTAR GAMBAR

Gambar.1	Peta jalan ( <i>roadmap</i> ) penelitian keseluruhan	7
Gambar.2	Detail peta jalan ( <i>roadmap</i> )/langkah kegiatan penelitian 2	7
Gambar.3	(a) masing convolution layer; (b) Squeeze-Net- DCNN architecture	17
Gambar.4	(a) Validasi Setup eksperimen impact hammer testing; (b) Setup eksperimen proses pemesinan milling	18
Gambar.5	Framework peralatan dan bahan penelitian	19
Gambar.6	Diagram alir penelitian tahap 2.	20
Gambar.7	(a) Modal analysis experiment; (b) Machining experiments	21
Gambar.8	The schematic of building models using deep learning	22
Gambar.9	Frequency response function (FRF) of the entire spindle system	23
Gambar.10	Frequency response function (FRF) of the entire workpiece system	24
Gambar.11	Plot SLD untuk model side milling	25
Gambar.12	<i>The vibration signals are (a) NC; (b) SC; (c) HC</i>	26
Gambar.13	<i>The pre-processing vibration signals are (a) NC; (b) SC; (c) HC</i>	29
Gambar.14	<i>Time frequency analysis of vibration signals are (a) CWT; (b) WSST; (c) CWT-VMD; (d) WSST-VMD</i>	30
Gambar.15	Architecture Transfer Learning via Alex-Net dan Squeeze-Net	31
Gambar.16	Layer conv-1 to conv-10 process Squeeze-Net.	32
Gambar.17	Classification accuracy validation matrix (a&b) Alex-Net; (c&d) Squeeze-Net	33

## DAFTAR TABEL

Tabel.1	Modal parameters of the entire spindle system	24
Tabel.2	Modal parameters of the entire workpiece system	24
Tabel.3	Machining parameters	25
Tabel.4	Classification accuracy result	33

# 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 dibidang ini, dan penelitiannya saat ini sebagian besar berkontribusi bagaimana membuat interaksi antara ruang fisik dan virtual [6]. Karena itu, dalam penelitian tahap II ini, metode baru untuk mengaktifkan model *smart machining* pada proses milling dalam aplikasi untuk mendeteksi dan memprediksi *chatter* diusulkan. Untuk tujuan ini, SLD dibangun berdasarkan parameter

modal sistem, yang mana hal ini nantinya digunakan untuk memilih parameter kondisi pemotongan pada kondisi yang stabil maupun tidak stabil. Sinyal getaran yang terjadi diakusisi oleh sensor akselerometer pada saat kondisi pemotongan tersebut berlangsung. Untuk meningkatkan keakurasian dalam proses pembelajaran, metode analisis *time & frequency* yaitu *Synchrosqueeze* berbasis *wavelet transform* (WSST) digunakan untuk mengubah semua sinyal getaran 1-dimensi menjadi sinyal gambar WSST 2-dimensi. Kemudian, kami menerapkan model jaringan pra-latihan DeepCNN-Transfer Learning melalui Squeeze-Net dan memodifikasi parameter pada tiga layer terakhir sesuai dengan tiga target keluaran yang diinginkan (kondisi stabil, *semi chatter* dan *high chatter*). Oleh karena itu, ini adalah suatu bentuk tahapan awal dalam membangun model digital *smart machining* 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. Dalam hal ini mampu merepresentasikan objek fisik terkini seperti tiga kondisi proses pemesinan milling yaitu status pemotongan *stable condition* (NC), *semi chatter* (SC) 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**

*Smart/Intelligent machining* 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 Smart/Intelligent machining 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 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 *Smart/Intelligent machining* ini untuk merepresentasikan kondisi sistem dinamik dari *cutting tool* dengan *workpiece* pada aspek “*machine dynamic and stability (chatter)*”. Tantangan ini terjadi karena model *Smart/Intelligent machining* 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 *Smart/Intelligent machining* 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 *Smart/Intelligent machining* 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 II 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-*Smart/Intelligent machining* 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 *Smart/Intelligent machining* proses pemesinan yang berbasis pada *data-driven* dan model analitik dalam hal ini dengan menggunakan metode ekspansi fourier.
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 digunakan adalah simulasi model FRF dinamika *spindle system* dengan metode RCSA, simulasi *stability lobe digram (SLD)*, simulasi proses pemesinan milling.
4. Pengujian modus getar pada struktur *spindle system* menggunakan *hammer impact/tap testing* untuk menentukan karakteristik dinamis FRF *spindle system*.
5. Parameter pemesinan berupa jenis material *workpiece* berupa baja stainless SUS400, 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 Smart Machining 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 *Smart/Intelligent machining (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 *Smart/Intelligent machining* proses pemesinan yang merepresentasikan sistem fisik yang modelnya dapat terus *terupdate* dan menyesuaikan dengan kondisi objek fisik pada aspek “*machine dynamic and stability (chatter)*” (telah dilakukan pada Penelitian I).
2. Membangun model kembaran digital atau DT *Smart/Intelligent machining* model pendeteksi chatter menggunakan metode *Variational Mode Decomposition (VMD)*, *Synchrosqueeze* berbasis *wavelet transform (WSST)* dan aplikasi *Transfer Learning via Deep Convolution Neural Network (DCNN)* yang dapat mengidentifikasi kondisi stabil atau tidak stabil (*chatter*). Model dibangun berdasarkan metode data driven dimana data sinyal getaran yang terukur dari proses pemesinan milling dilatih dan diuji menggunakan beberapa metode supervised deep learning. (dilakukan pada Penelitian II).

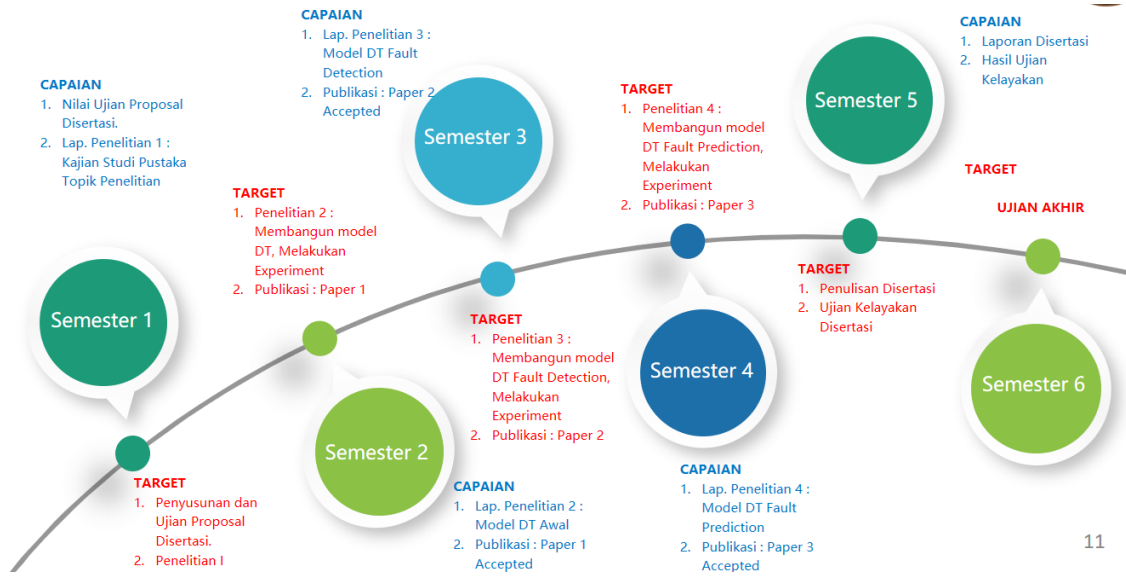
## **I.6 Novelties (Kebaruan) dari Penelitian**

A. Keterbaruan dan orisinalitas (*novelty and originality*) dari penelitian 2 ini adalah:

1. Penelitian ini membangun model DT dengan konstruksi 5 dimensi (konsep terkini) untuk dimplementasikan 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, begitupala yang dilakukan oleh (Qiao, 2019) pada aspek machine tools condition prediction.
2. Pemodelan *Smart Machining* yang dibuat menggunakan metode *Variational Mode Decomposition (VMD)*, *Synchrosqueeze* berbasis *wavelet transform (WSST)* dan aplikasi *Transfer Learning via Deep Convolution Neural Network (DCNN)* yang mampu mendeteksi awal terjadinya kondisi *chatter* pada proses pemesinan *milling* dan dibangun berdasarkan pada data-set serta algoritma *machine/deep learning* yang optimum. Namun yang dilakukan oleh (Avazof,

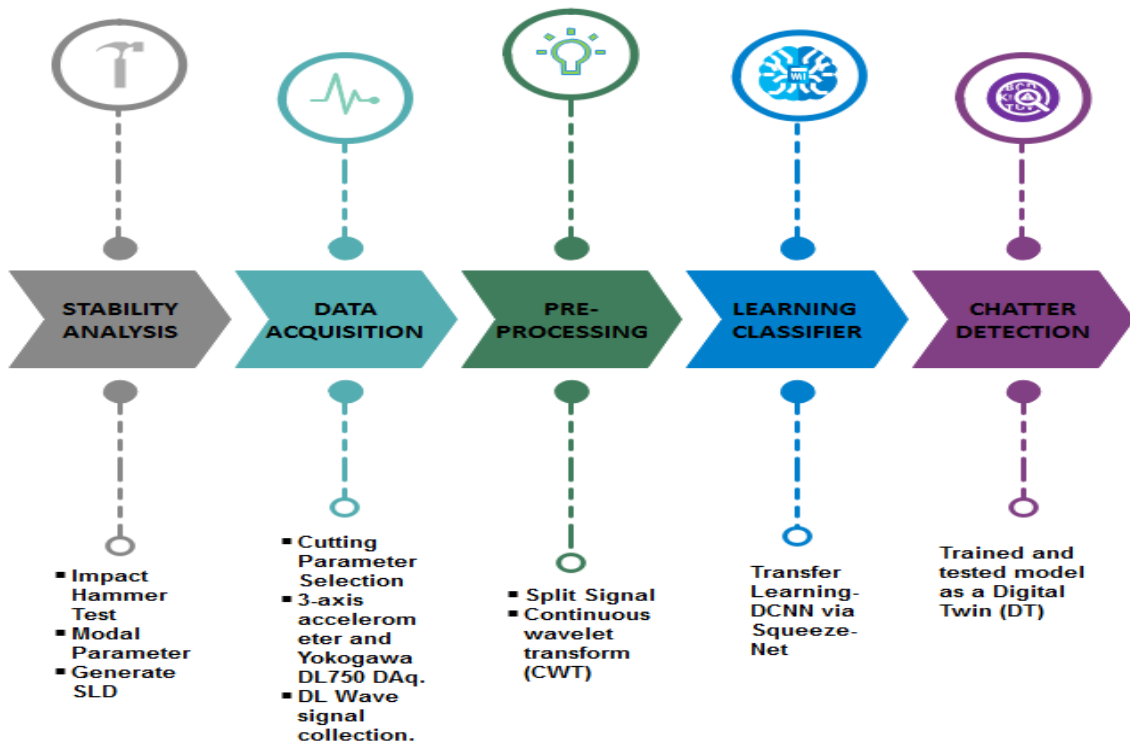
2021) hanya menggunakan metode TFA untuk mendeteksi *chatter milling*, kemudian (Vashish, 2021) hanya membuat model chatter detection in milling dengan data simulasi & deep learning tanpa DT, begitu pula yang dilakukan (Hanel, 2019) hanya membuat model *digital twin for machining process* tanpa melibatkan *chatter*.

## I.7 Roadmap Penelitian II



11

Gambar 1. Peta jalan (*roadmap*) penelitian keseluruhan



Gambar 2. Detail peta jalan (*roadmap*)/langkah kegiatan penelitian 2

## **I.8 Permasalahan Penelitian Tahap II**

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*. Bagaimana membangun model chatter deteksi dengan tingkat akurasi yang baik terhadap sinyal yang berasal dari sensor sehingga mampu memprediksi suatu kondisi pemesinan apakah sinyal tersebut tergolong dalam kategori *high chatter*, *intermediate chatter* atau *stable cutting*. Peningkatan akurasi pada model dibangun dengan menerapkan aplikasi denoising dan dekomposisi sinyal menggunakan metode *Variational Mode Decomposition (VMD)*, *Synchrosqueeze* berbasis *wavelet transform (WSST)* dan aplikasi *Transfer Learning via Deep Convolution Neural Network (DCNN)* yang berbasiskan pada sinyal gambar 2-dimensi.

## 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]. Seiring dengan perkembangan penelitian telah diketahui bahwa tingkat ketajaman citra yang dihasilkan oleh koefisien wavelet CWT sangat mempengaruhi keakurasian citra, sehingga diperlukan suatu metode yang mampu mempertajam kualitas citra yang dapat meningkatkan keakurasian input citra. *Synchrosqueezing transform* (SST) berbasis *wavelet* (WSST) awalnya diperkenalkan dalam konteks analisis sinyal pendengaran [22] dan dipelajari lebih lanjut secara matematis di [1]. Prinsipnya adalah mempertajam representasi "kabur" yang diberikan oleh CWT.

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 transfer pembelajaran) 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

Tahapan awal suatu proses pemesinan milling sangat diperlukan sekali pengetahuan tentang peta stabilitas (SLD) keadaan dari sistem *spindle cutting tool*. SLD ini berfungsi untuk memilih parameter pemesinan yang sesuai agar tidak terjadi kondisi yang tidak stabil (*chatter*) ketika dilakukan proses pemesinan milling. SLD dapat diperoleh secara analitik menggunakan model stabilitas chatter dengan metode 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 gaya potong tangensial dan normal, dan  $a$  adalah kedalaman potong. Setelah itu, gaya potong 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 terhadap waktu" dengan koefisien yang diselesaikan sebagai;

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

Nilai Eigen dari persamaan karakteristik dari ekspresi di atas menghasilkan;

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

Kecepatan spindle yang bergantung pada frekuensi dan berkesesuaian ditentukan oleh persamaan berikut;

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

dimana hal ini 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,  $a_{lim}$  yang memplot SLD dapat dihitung sebagai;

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

## 2.2. Continuous wavelet transform dan Wavelet-based synchrosqueezing transform (WSST)

Dalam penelitian ini awal mulanya 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 pemesinan milling. Koefisien wavelet CWT, dari sinyal  $f(t)$  ini kemudian direpresentasikan oleh persamaan (8) 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 envelope 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 fungsi morlet wavelet digunakan untuk menganalisis perilaku getaran non-linier dan non-stasioner dari sinyal yang dihasilkan oleh proses pemesinan milling.

Seiring dengan jalannya penelitian ini telah diketahui bahwa tingkat ketajaman citra yang dihasilkan oleh koefisien wavelet CWT sangat mempengaruhi keakuratan

input citra bagi model *deep learning*, sehingga diperlukan suatu metode yang mampu mempertajam kualitas citra sehingga dapat meningkatkan keakurasian input citra. *Synchrosqueezing transform* (SST) berbasis wavelet (WSST) awalnya diperkenalkan dalam konteks analisis sinyal pendengaran [20] dan dipelajari lebih lanjut secara matematis pada [21]. Prinsipnya adalah mempertajam representasi "kabur" yang diberikan oleh CWT dengan menggunakan estimasi IF pada waktu  $t$  dan skala  $a$ :

$$\widehat{\omega}_f(t, a) = \Re \left\{ \frac{1}{i2\pi} \frac{\partial_t W_f^\psi(t, a)}{W_f^\psi(t, a)} \right\}, \quad (9)$$

dimana  $\Re\{Z\}$  adalah bagian nyata dari bilangan kompleks  $Z$  dan  $\partial_t$  adalah bagian turunan parsial terhadap  $t$ . Memang,  $W_f(t, a)$  dipindahkan ke posisi baru  $(t, \widehat{\omega}_f(t, a))$  menggunakan operator sinkronisasi yang mendefinisikan WSST, sebagai berikut:

$$S_{W_f^\psi}^\gamma(t, \omega) = \int_{|W_f^\psi(t, a)| > \gamma} W_f^\psi(t, a) \delta(\omega - \widehat{\omega}_f(t, a)) \frac{da}{a}, \quad (10)$$

Dengan beberapa parameter ambang. Karena koefisien CWT dipindahkan sepanjang sumbu "skala", WSST mempertahankan sifat kausalitasnya, sehingga membuat mode  $k^{\text{th}}$  kira-kira direkonstruksi kembali dengan mengintegrasikan  $S_{W_f^\psi}^\gamma(t, \omega)$  di sekitar punggung yang sesuai  $(t, 1k(t))$  pada bidang skala waktu ( $T_s$ ):

$$f_k(t) \approx \frac{1}{C_\psi'} \int_{\{\omega, |\omega - \varphi_k(t)| < d\}} S_{W_f^\psi}^\gamma(t, \omega) d\omega, \quad (11)$$

dimana  $1k(t)$  adalah perkiraan  $0 k(t)$ , yang sering dihitung dengan teknik ekstraksi ridge [22, 23]. Parameter  $d$  memungkinkan untuk mengkompensasi perkiraan yang tidak akurat  $1k(t)$  dari  $0 k(t)$  dan kesalahan yang dibuat dengan memperkirakan IF dengan menggunakan  $\omega(t, a)$ .

### 2.3. Variational Mode Decomposition (VMD)

Akuisisi sinyal getaran proses pemesinan milling melalui akselerometer menghasilkan suatu kebisingan yang bersumber dari komponen mekanis yang berputar seperti bantalan dan roda gigi, selain itu kebisingan juga dapat bersumber dari sistem pengukuran [24]. Untuk menghilangkan kebisingan ini, teknik pemrosesan sinyal digunakan untuk mendapatkan sinyal asli dengan lebih baik [25, 26].

VMD menjadi versi perbaikan dari *empirical mode decomposition* (EMD) dan digunakan secara luas dalam beberapa aplikasi, serta memungkinkan dalam dekomposisi nonstasioner sinyal menjadi satu set sinyal stasioner, hal ini membuatnya mungkin untuk mengisolasi pemantauan komponen pembawa informasi dan menghilangkan kebisingan [27-30]. Penguraian dari sinyal kompleks dilakukan secara independen dari sumbernya, berdasarkan pada filter Wiener [31].

$$x_n(t) = \sum_{i=1}^k u_k(t) + res(t), \quad (12)$$

Di mana  $x_n$  adalah sinyal yang diperoleh,  $\{u_k\} = \{u_1, u_2, \dots, u_n\}$  adalah mode dekomposisi, dan  $res(t)$  adalah sisa sinyal setelahnya pengoptimalan.

Proses dekomposisi terdiri dari pemecahan optimasi masalah yang dirumuskan sebagai:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\}, \quad (13)$$

Dimana  $f$  adalah sinyal asli,  $\{k\}$  pusat frekuensi masing-masing  $\{u_k\}$ ,  $(t)$  adalah fungsi impuls, dan  $k$  adalah komponen modal nomor. Rumusan baru dari masalah kendala variasional adalah persamaan Lagrangian ditambah dirumuskan sebagai berikut [32]:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (14)$$

dimana adalah faktor penalti kuadrat adalah faktor pengali Lagrange.

Penyelesaian dilakukan dengan teknik iteratif yang memungkinkan pendugaan mode  $u_k$  dan frekuensi pusatnya  $k$  serta Operator Lagrangian ( $t$ ), dirumuskan secara iteratif dalam persamaan 15, 16, dan 17, masing-masing [33].

$$\hat{u}_k^{n+1}(\omega) \leftarrow \frac{\hat{f}(\omega) \sum_{i < k} \hat{u}_k^{n+1}(\omega) - \sum_{i > k} \hat{u}_k^n(\omega) + \frac{\lambda^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (15)$$

$$\omega_k^{n+1} \leftarrow \frac{\int_0^\infty \omega \left| \hat{u}_k^{n+1}(\omega) \right|^2 d\omega}{\int_0^\infty \left| \hat{u}_k^{n+1}(\omega) \right|^2 d\omega} \quad (16)$$

Dimana,  $\hat{u}_k^{n+1}$  diperoleh dengan penyaringan Wiener.

$$\lambda^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau \left( \hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (17)$$

Kriteria berhenti dirumuskan sebagai berikut:

$$\sum_k \frac{\left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2}{\left\| \hat{u}_k^n \right\|_2^2} < \varepsilon \quad (18)$$

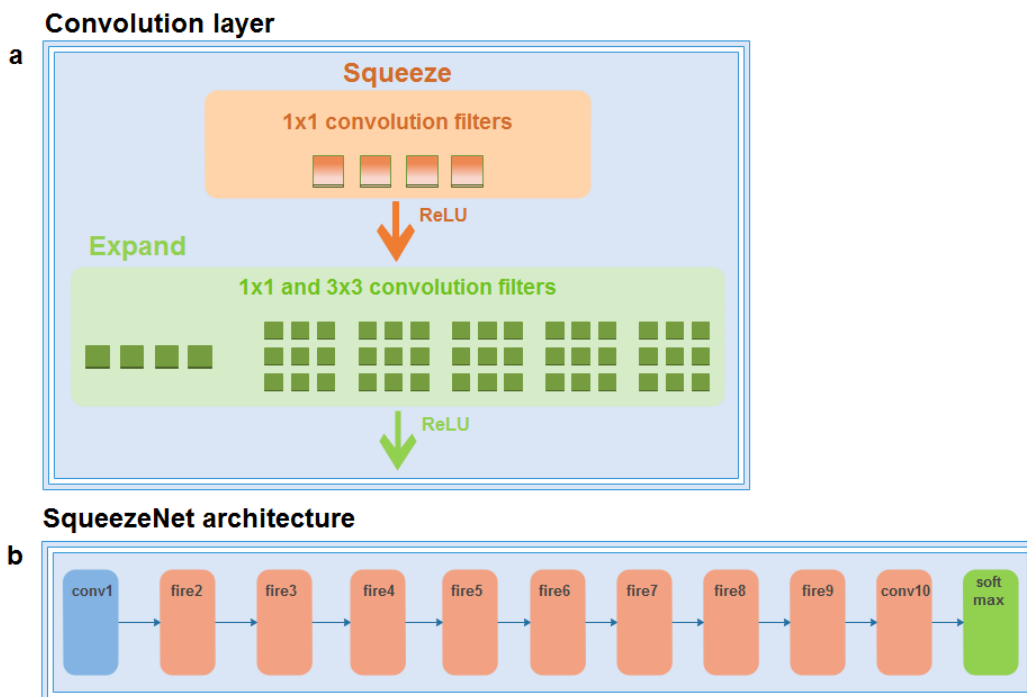
Dimana, toleransi kebisingan, dan kesalahan telah konvergen.

## 2.4. Transfer Learning via – 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 secara 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 latih. Ada beberapa 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. Telah ditemukan bahwa Squeeze-Net memiliki beberapa keunggulan diantaranya adalah model pretrained ini memiliki ukuran 510x yang lebih kecil dan parameter yang lebih sedikit jika dibandingkan dengan model Alex-Net, sehingga mengurangi sumber daya atau resource model komputasi [16]. Oleh karena itu, pada penelitian ini digunakan model pretrained Squeeze-Net untuk membangun model smart machining yang mampu mendeteksi dan memprediksi terjadinya kondisi chatter pada proses pemesinan milling.

*Transfer Learning* DeepCNN-Squeeze-Net bentuk strukturnya dimulai dengan lapisan konvolusi mandiri (conv-1), diikuti oleh 8 modul api (fire-2- fire-9), diakhiri dengan lapisan konvolusi akhir (conv-10). Model yang digunakan 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 3.a modul api terdiri dari lapisan konvolusi penyaringan (yang hanya memiliki filter 1x1), diumpankan ke lapisan perluasan yang memiliki campuran filter konvolusi 1x1 dan 3x3, hal ini seperti yang ilustrasikan pada Gambar 3.a.



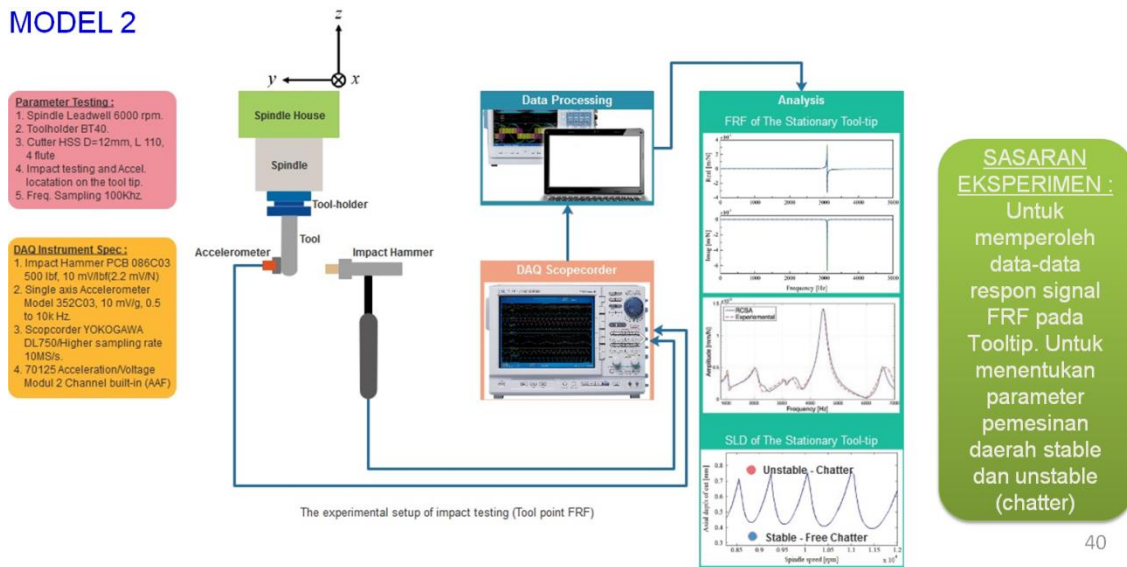
Gambar 3. (a) Each of convolution layer; (b) Squeeze-Net- DCNN architecture.

## Bab III Data dan Metodologi

### III.1 Data persiapan eksperimen

Mesin milling CNC dengan tiga sumbu (type Leadwell-V30), daya maksimum 10 HP dan kecepatan spindel maksimum 8000-rpm digunakan dalam percobaan pemotongan logam baja *stainless steel* SUS 400 dengan proses *side milling* (*shoulder milling*). Pahat potong jenis *end-mill, carbide*, empat flute dengan panjang 110 mm, diameter 12 mm, dan sudut heliks  $30^\circ$  dengan dudukan pahat tipe BT40 digunakan selama percobaan. Model keseluruhan dari prosedur eksperimental tahap 2 ini ditunjukkan pada Gambar. 4.

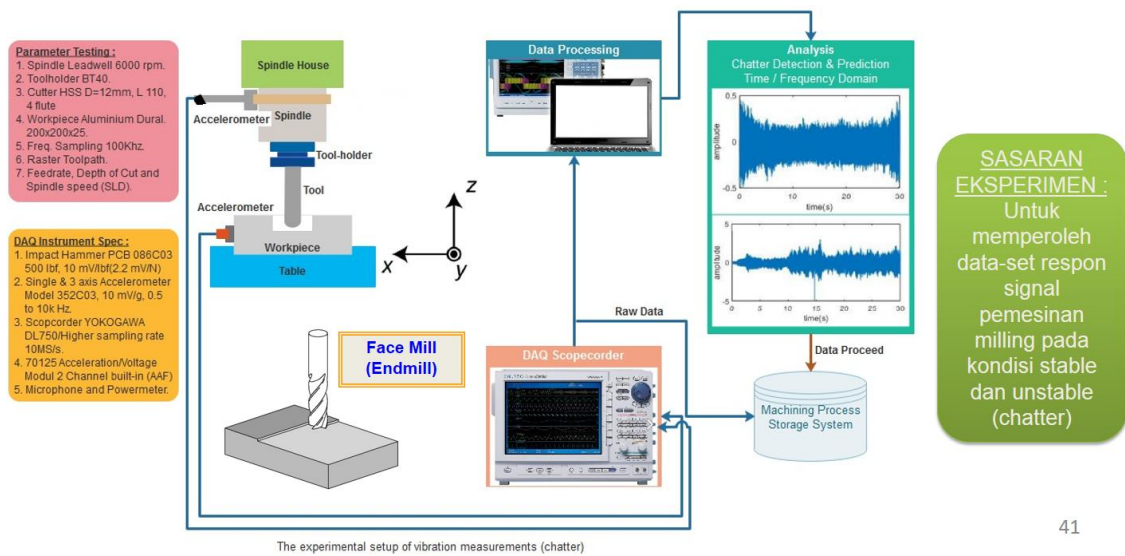
#### MODEL 2



40

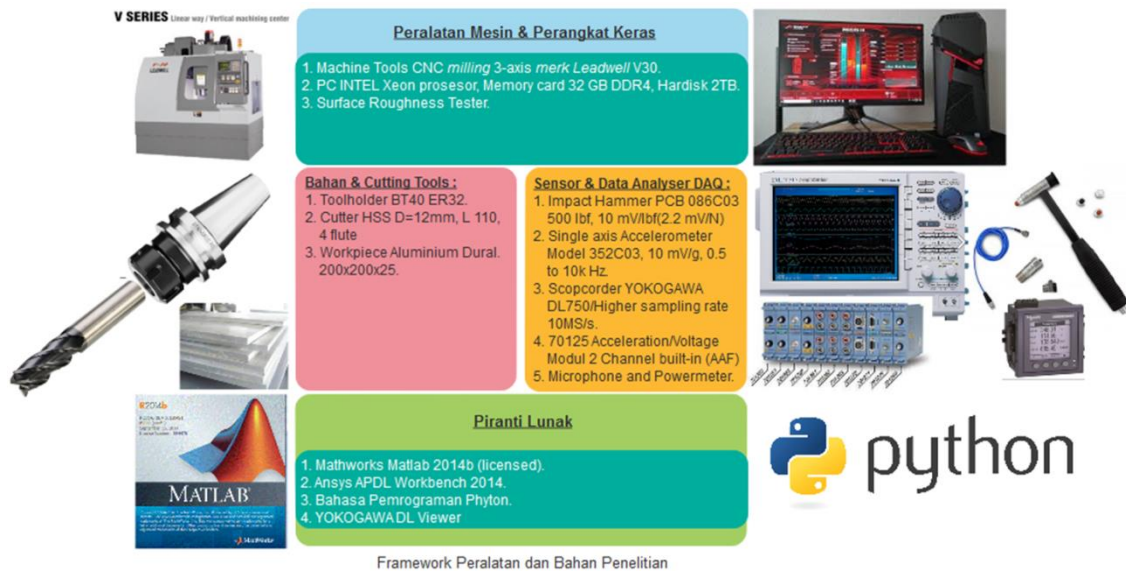
(a) Setup eksperimen *impact hammer testing*.





Gambar 4. (b) Setup eksperimen proses pemesinan milling.

Kebutuhan peralatan dan bahan penelitian yang diperlukan selama pelaksanaan pada tahap 2 ini ditunjukkan pada Gambar 5.

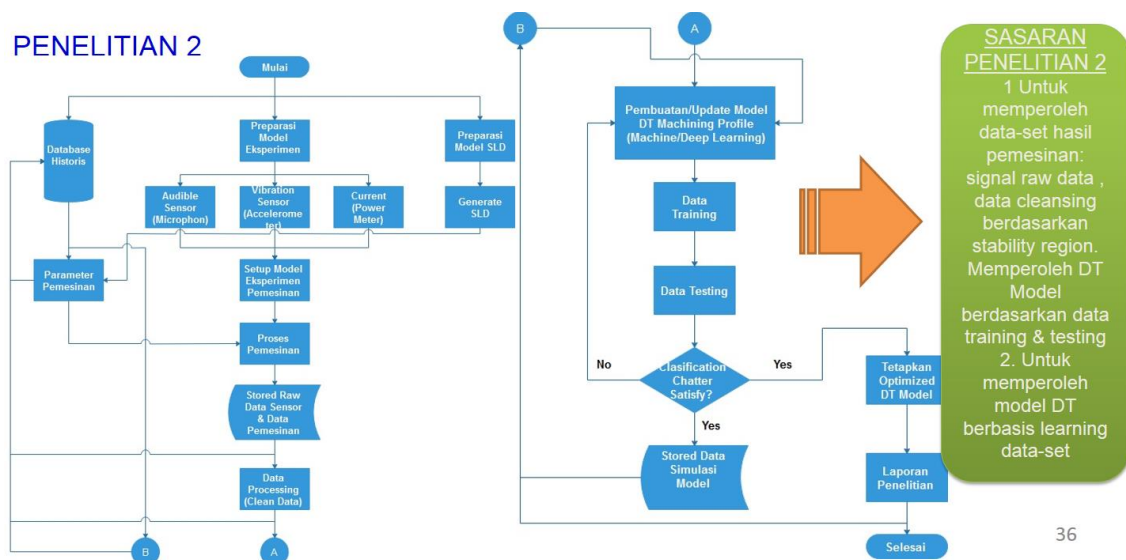


Gambar 5. Framework peralatan dan bahan penelitian.

### III.2 Metodologi

Sasaran yang ingin dicapai pada penelitian tahap 2 ini adalah untuk menggenerasi data-set hasil proses pemesinan *side milling* (memperoleh, mengumpulkan *signal raw data*, mem-processing data dan *cleansing data*) dengan parameter pemesinan yang berdasarkan pada *stability region* yang telah ditentukan

sebelumnya. Kedua, membangun serta menghasilkan model *smart machining* untuk mendeteksi kondisi pemesinan *chatter* berdasarkan metode transfer learning convolution neural network dengan data set (*training & testing*) yang diperoleh. Diagram alir dari penelitian tahap 2 ditunjukkan pada Gambar 6.

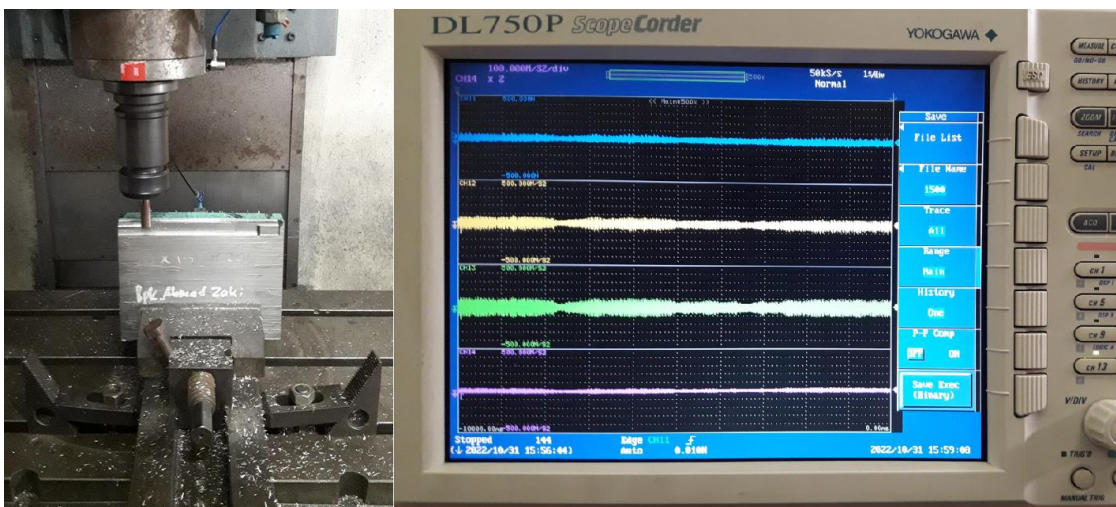
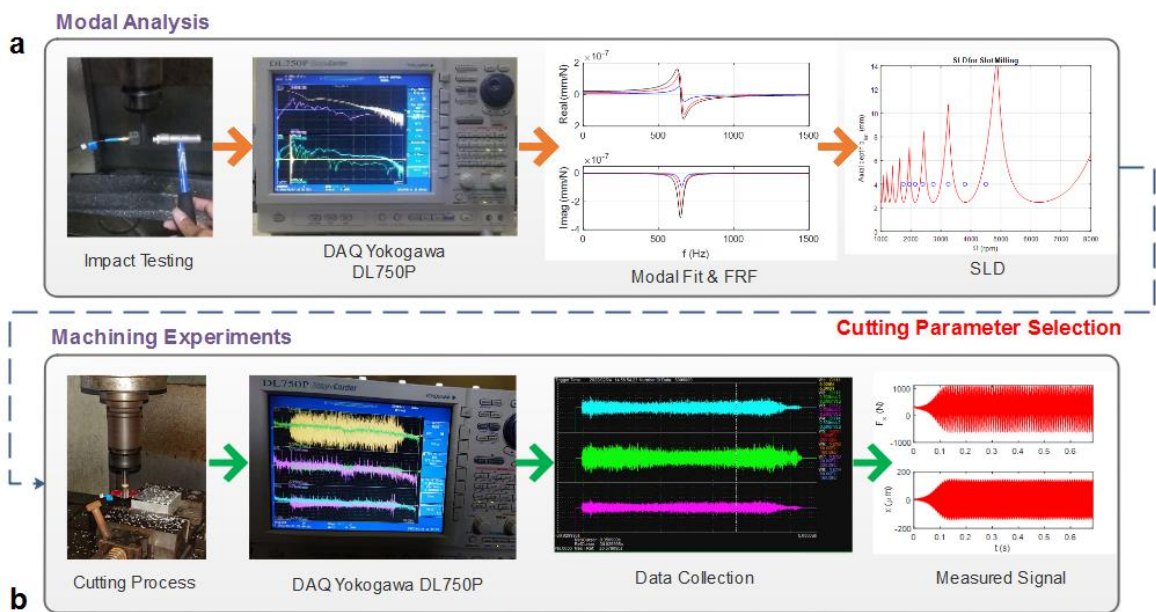


Gambar 6. Diagram alir penelitian tahap 2.

Pada penelitian tahap 2 ini, langkah awal yang dilakukan adalah seperti apa yang ditunjukkan dalam gambar diagram percobaan analisis modal. Pengujian *tap testing* dilakukan terlebih dahulu untuk menentukan karakteristik dinamis sistem spindle tool tip (FRF tooltip) sebagai parameter untuk menghasilkan diagram kestabilan SLD. Pahat potong jenis end-mill, carbide, dengan panjang overhang 45 mm, sensor jenis akselerometer dengan 3-sumbu (type Dytran3413A2) yang dipasang di ujung pahat potong (tooltip), hammer impuls (type Dytran5800B3) dan Scopocoder data akuisisi type Yokogawa DL750 digunakan selama eksperimen analisis modal. Model detail rinci dari setup pengujian impact tap testing ditunjukkan pada Gambar. 7.a.

Kemudian selanjutnya adalah tahapan *capturing* signal vibrasi untuk percobaan pemesinan *side milling cutting*, beberapa parameter pemotongan dipilih berdasarkan SLD, kemudian percobaan *milling cutting* dilakukan dalam kondisi pemotongan kering (*dry cutting*) atau tanpa coolant. Proses pemotongan dengan model *shoulder milling* dilakukan untuk memotong blok baja *stainless* berukuran 25x25x20 mm (SUS402).

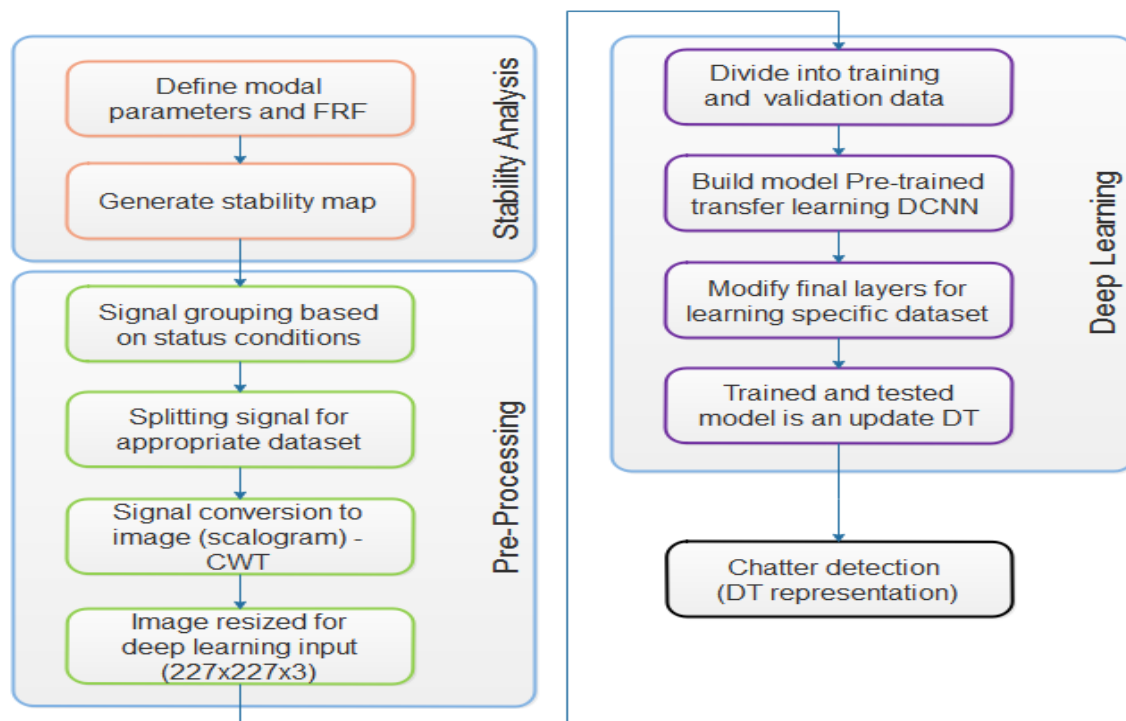
Dalam percobaan ini 2 jenis sensor akselerometer digunakan untuk mengcapture signal vibrasi dengan beberapa penempatan yaitu yang pertama, sensor akselerometer jenis 3-sumbu (type Dytran3413A2) dipasang pada sisi benda kerja, dan yang kedua, sensor akselerometer jenis 1-sumbu (type PCB3413A2) dipasang pada sisi *outerhouse* dari spindle pada arah sumbu-X, dan data akusisi Yokogawa DL750 juga digunakan selama eksperimen pemotongan. Akhirnya, seluruh sinyal mentah (*signal raw data*) yang dikumpulkan dari setiap kondisi pemotongan kemudian dikelompokkan sesuai kondisi *stable* dan *chatter* dan setelah itu ditransfer ke MATLAB™ untuk dilakukan pengkondisian sinyal seperti yang ditunjukkan pada Gambar 7.b.



Gambar 7. (a) Modal analysis experiment; (b) Machining experiments.

## Bab IV Hasil dan Pembahasan


Gambar 8 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 pemotongan 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 Deep CNN. (4) Konversi sinyal ke citra dilakukan dengan menggunakan metode VMD-WSST dan CWT-Scalogram untuk setiap sampel. (5) Data pembelajaran diperoleh dengan membagi dataset menjadi data latih, data validasi, dan data testing. (6) Model Transfer learning melalui Squeeze-Net-DCNN dibandingkan dengan AlexNet dibangun untuk mendeteksi adanya *chatter*. (7) Model DT-Smart machining dari proses pemesinan milling bertujuan untuk mengklasifikasikan kondisi pemesinan stabil/tidak stabil akhirnya dapat diperoleh.



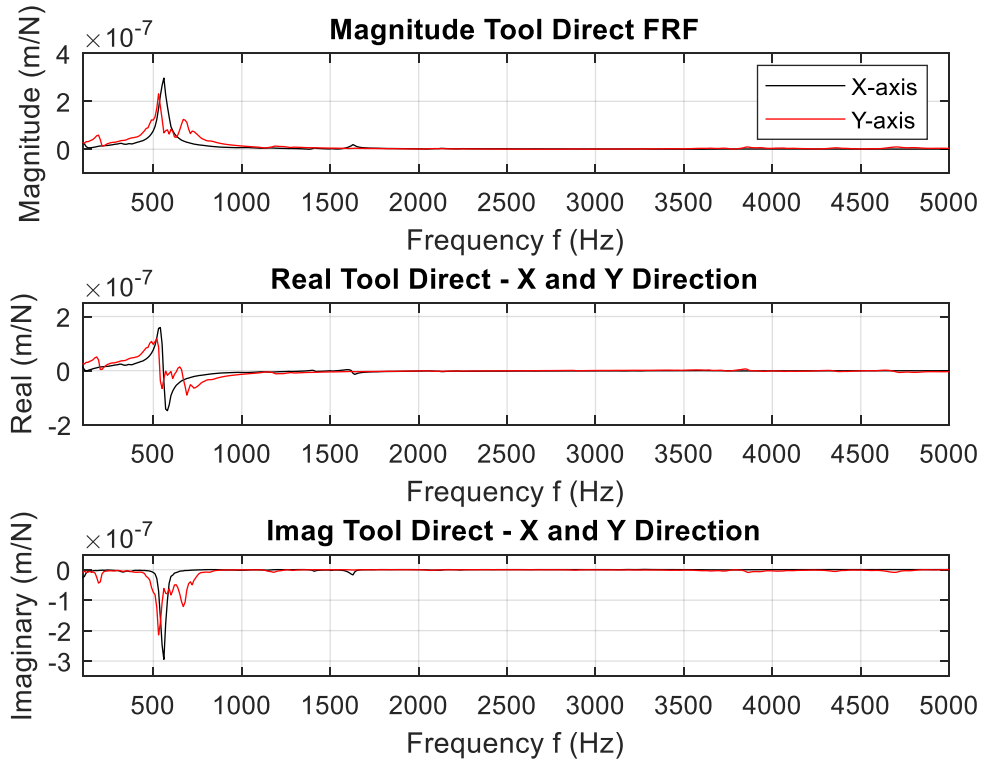
Gambar 8. The schematic of building models using deep learning.

#### 4.1. Stability map analysis

Seperti yang dapat dilihat pada Gambar 7.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 ujung tooltip dan sinyal diperoleh dengan laju pengambilan sampel 20 kHz oleh sistem penyimpanan data Yokogawa DL750. Gambar 9 dan 10 menunjukkan fungsi respons frekuensi eksperimental (FRF) dari seluruh sistem spindle dan benda kerja. 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 dan 2 menunjukkan parameter modal yang diperoleh dalam seluruh pengujian ini.



Gambar 9. Frequency response function (FRF) of the entire spindle system.



Gambar 10. Frequency response function (FRF) of the entire workpiece system.

Table 1. Modal parameters of the entire spindle system.


Axis	Natural frequency $f_n$ (Hz)	Damping ratio $\zeta$ (%)	Stiffness $k$ (N/m)
X	569	1.76	$1.79 \times 10^7$
Y	582	1.18	$-6.49 \times 10^9$

Table 2. Modal parameters of the entire workpiece system.

Axis	Natural frequency $f_n$ (Hz)	Damping ratio $\zeta$ (%)	Stiffness $k$ (N/m)
X	559	2.5	$7.6 \times 10^7$
Y	529	3.2	$4.9 \times 10^7$

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 11. Dalam studi ini, SLD dengan radial immersion sebesar 20% (2.4 mm) terhadap diameter pahat potong (12 mm) dipilih, sehingga jenis

proses pemotongan termasuk kedalam jenis *side milling* (*shoulder milling*) dipertimbangkan. Kedalaman potong (DOC) dimulai dari kedalaman pemotongan yang stabil (0.5 mm) hingga terjadi *chatter* (5 mm) pada setiap kecepatan spindle (1000 – 3500 rpm), sehingga semua parameter pemotongan tersebut menjadi objek pengamatan terjadinya *chatter* pada proses pemotongan. Tabel 3 menunjukkan daftar parameter pemotongan yang digunakan dalam penelitian ini.



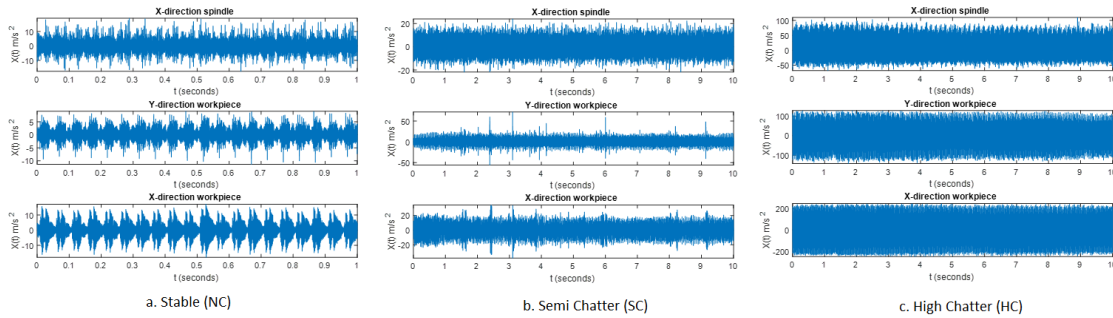
Gambar 11. Plot SLD model side milling.

Table 3. Machining parameters.

Feed (mm/min)	60							
Spin speed(rpm)	1200	1500	1800	2280	2700	3600	4500	4500
Axial depth(mm)	0.5- 5	0.5- 5	0.5-5	0.5-5	0.5-5	0.5-5	0.5-5	0.5-5
Number of tests	6	6	6	6	6	6	6	6

Sebanyak 42 percobaan proses pemotongan milling logam baja stainless SUS402 dilakukan dengan rentang kecepatan spindle 1200 rpm (pada kecepatan rendah) hingga 4500 rpm (kecepatan tinggi) dan rentang DOC dari 0.5 hingga 5 mm, dan dengan laju feed konstan 60 mm /menit. Bentuk sinyal getaran yang terukur untuk setiap kondisi pemotongan ditunjukkan pada Gambar 12. Akselerometer 3-sumbu dipasang pada sisi benda kerja dan 1-sumbu dipasang pada bagian *spindle house*, kedua tipe sensor ini seluruhnya digunakan untuk memperoleh sinyal getaran baik pada benda

kerja maupun pada spindle. Sinyal getaran dalam arah X, Y, dan Z diperoleh melalui modul data akuisisi jenis 70125, dengan sensitivitas 1.02, 50.8, 51.96 dan 50.01 mV/g dengan laju sampling 50 kHz. Gambar 12 menunjukkan sinyal getaran pada kondisi pemotongan stabil (NC), semi stabil (SC), dan tidak stabil (HC).



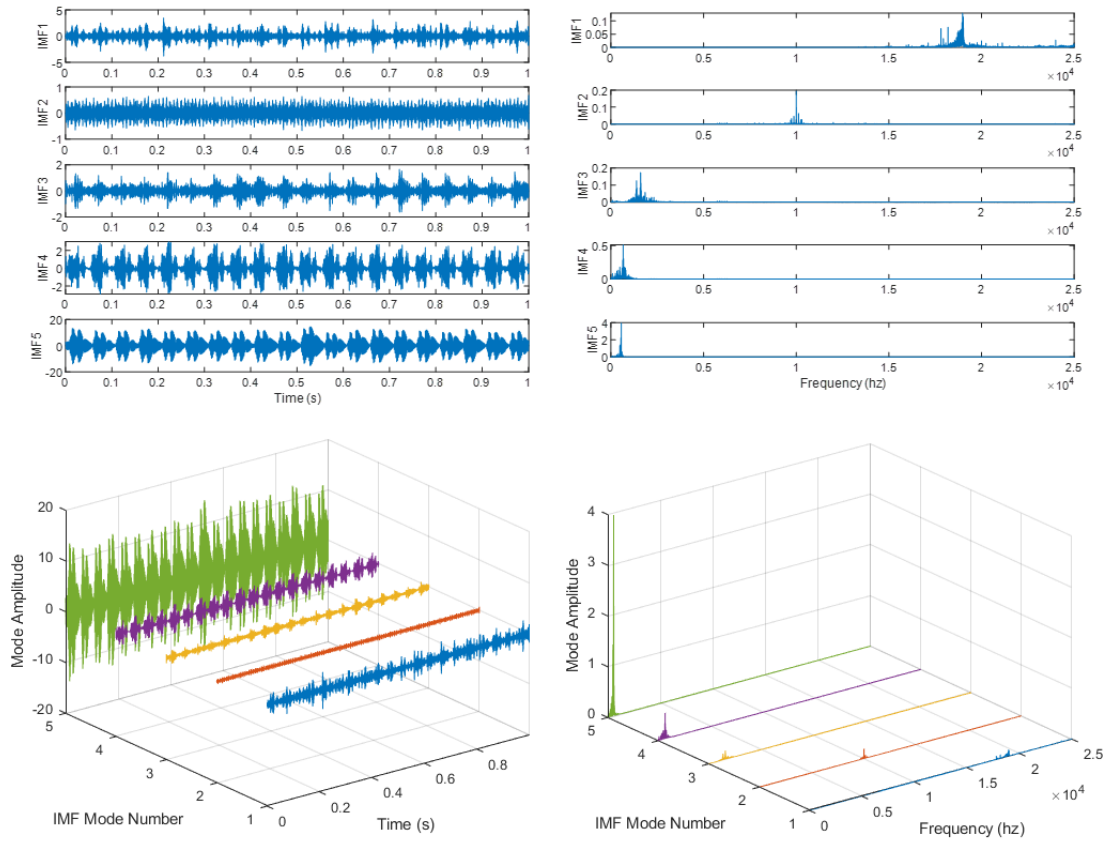
Gambar 12. The vibration signals are (a) NC; (b) SC; (c) HC.

#### 4.2. Dataset pre-processing



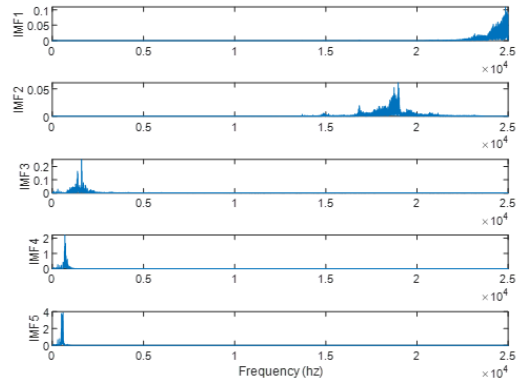
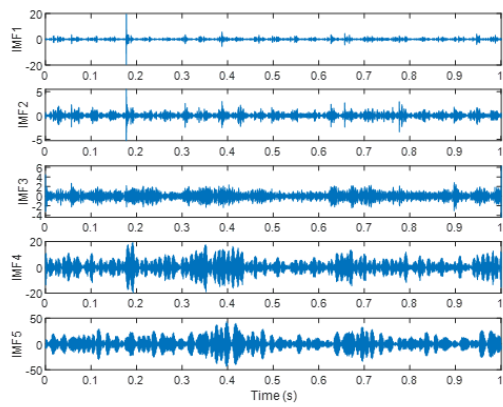
Setelah semua sinyal getaran ini terkumpul, semua sinyal tersebut dilakukan *pre-processing signal* untuk didekomposisi dengan menggunakan metode VMD. Tujuan dari dekomposisi sinyal ini adalah untuk memisahkan sinyal yang berkaitan dengan sinyal *stable cutting* dan sinyal *chatter* terhadap sinyal-sinyal pengotor ataupun sinyal komponen lainnya, sehingga dapat meningkatkan keakurasian dari sinyal yang akan digunakan sebagai input *deep learning*. Berdasarkan pada Gambar 13.a dan 13.c terlihat bahwa sinyal *stable cutting* dan sinyal akibat *chatter* terjadi pada IMF 4 dan IMF 5. Sinyal-sinyal terpilih tersebut pada akhirnya dianalisis dan dikonversikan menjadi sinyal 2-dimensi dengan menggunakan metode CWT dan *Synchrosqueeze transform WSST*. Pada Gambar 14 terlihat bahwa hasil citra dari CWT dengan VMD menghasilkan citra yang lebih baik bila dibandingkan dengan tanpa VMD. Begitu juga perbandingan hasil gambar citra dari CWT dengan WSST terlihat bahwa tingkat ketajaman atau fokus entropy energy pada WSST lebih baik bila dibandingkan dengan CWT dan tentunya ini juga dapat berkontribusi meningkatkan keakurasian dari sinyal sebagai untuk membentuk sebuah dataset. Dataset dibuat sebagai struktur array dengan dua bidang: data dinamis dan statis, serta data label. Bidang Data adalah matriks 42 x 50050 dimana setiap baris adalah proses pemotongan *side milling* yang diambil



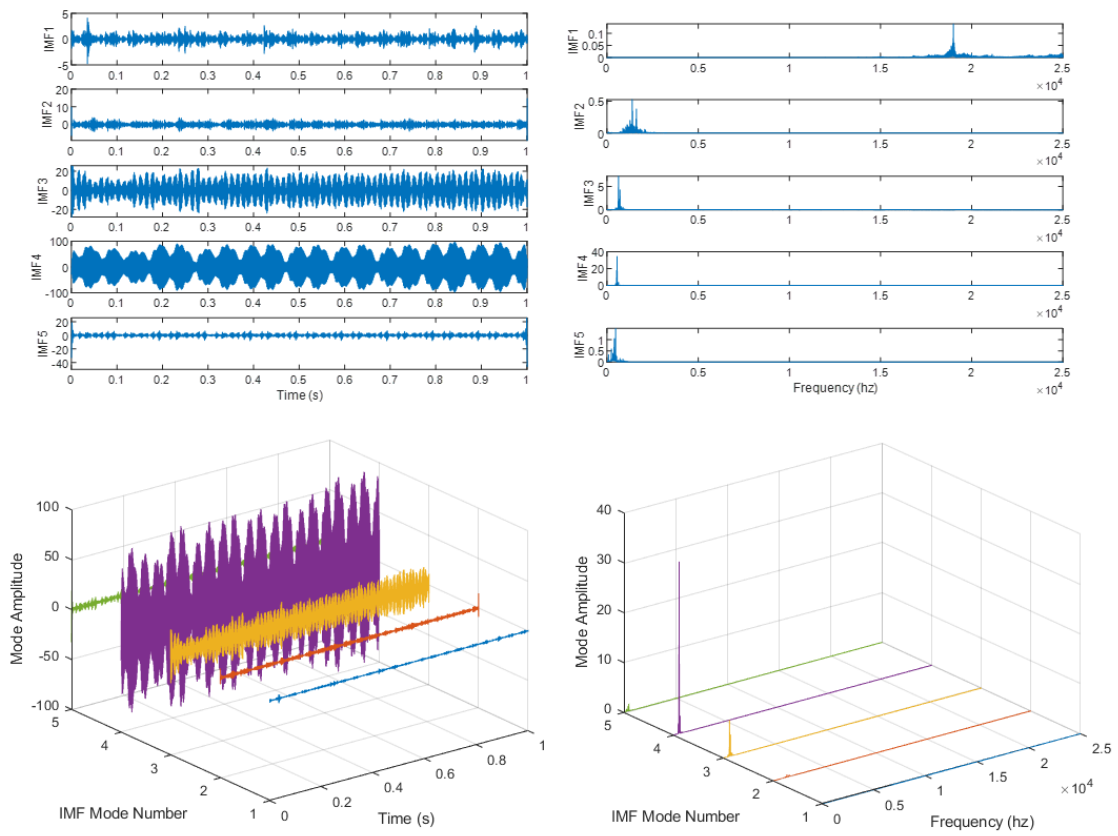
sampelnya pada 50 kHz. Label adalah larik sel 42 x 1 dari label status kondisi, satu untuk setiap baris Data. Tiga kategori status kondisi adalah: NC, SC, dan HC.



a. Stable condition (NC)

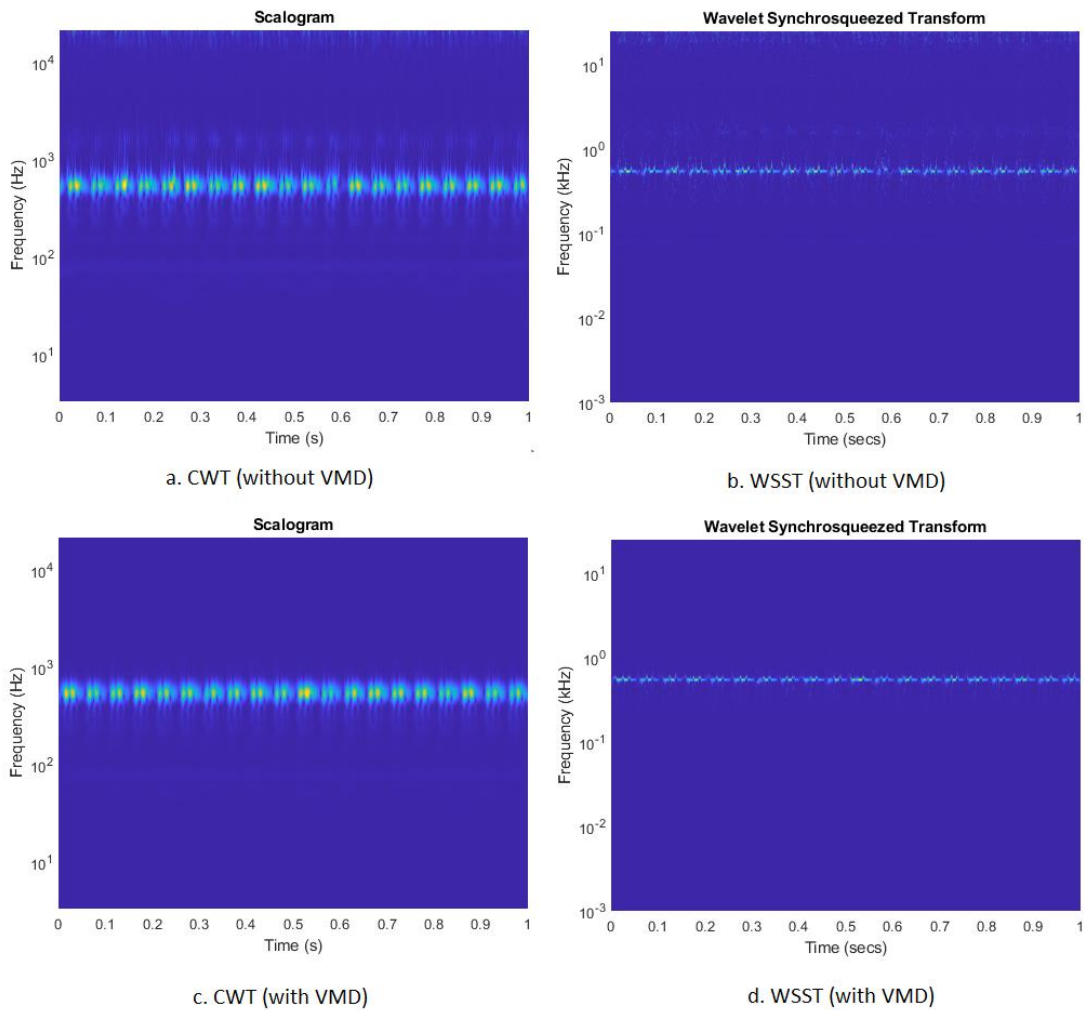


b. Semi Chatter (SC)



c. High Chatter (HC)

Gambar 13. The pre-processing vibration signals are (a) NC; (b) SC; (c) HC.



Gambar 14. Time frequency analysis of vibration signals are (a) CWT; (b) WSST; (c) CWT-VMD; (d) WSST-VMD

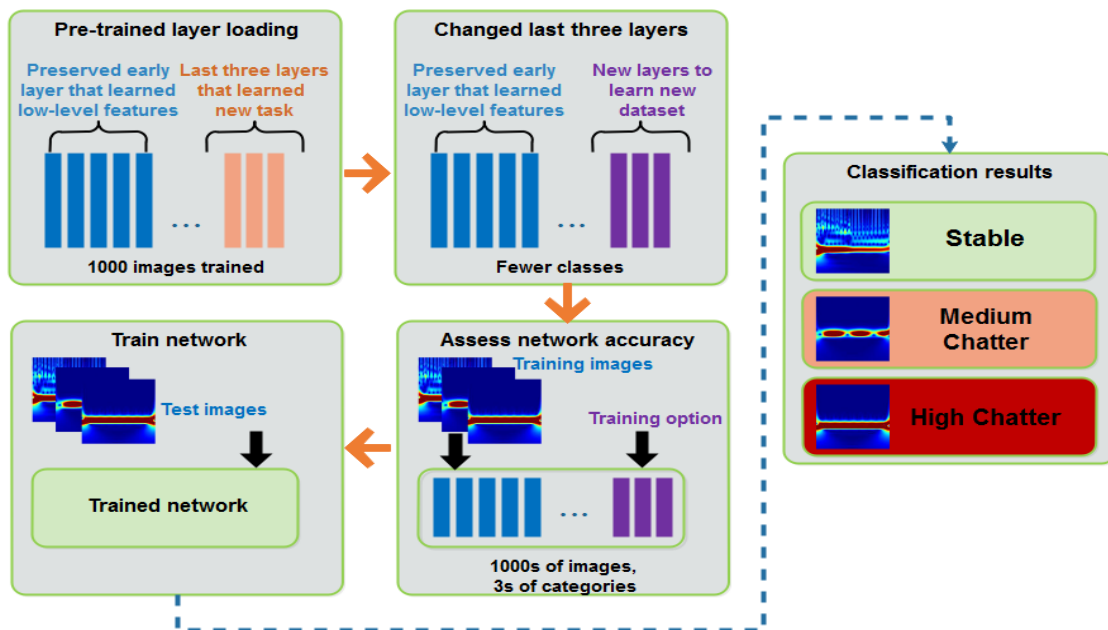
Dalam hal ini, kami melakukan pra-proses setiap sinyal dengan panjang sampel 50050, yang dapat dipecah menjadi sinyal yang lebih kecil dengan panjang sampel 2500 untuk meningkatkan ukuran dataset dan membuatnya cocok untuk melatih algoritma CNN. Untuk keperluan ini, kami mengambil sebanyak 340, 160, dan 340 sinyal masing-masing kondisi (NC, SC, dan HC), masing-masing sinyal dibagi menjadi 20 buah panjang kelompok data. Oleh karena itu, setiap kategori akan menyediakan sebanyak 340, 160, 340-sinyal dan totalnya akan menjadi 840 sinyal.

Setelah itu, semua (840 sinyal) sinyal getaran 1-D ini diubah menjadi gambar sinyal 2-D menggunakan CWT dan WSST dimana koefisien CWT direpresentasikan sebagai gambar scalogram. Untuk tujuan ini, kami mengambil CWT dan WSST sinyal 1-D dan semua koefisien disusun untuk membentuk scalogram CWT dan WSST.

Setiap scalogram dan WSST image direpresentasikan dalam peta warna tipe jet 128 warna. Semua scalogram dan WSST diubah menjadi gambar augmented dan disimpan dalam folder yang sesuai dengan masing-masing kategori. Karena model Squeeze-Net dan AlexNet hanya menerima 227 x 227 gambar masukan, semua gambar scalogram dan WSST diubah ukurannya menjadi 227 x 227 x 3 gambar berwarna RGB.

### 4.3. Transfer Learning via Squeeze-Net for chatter detection

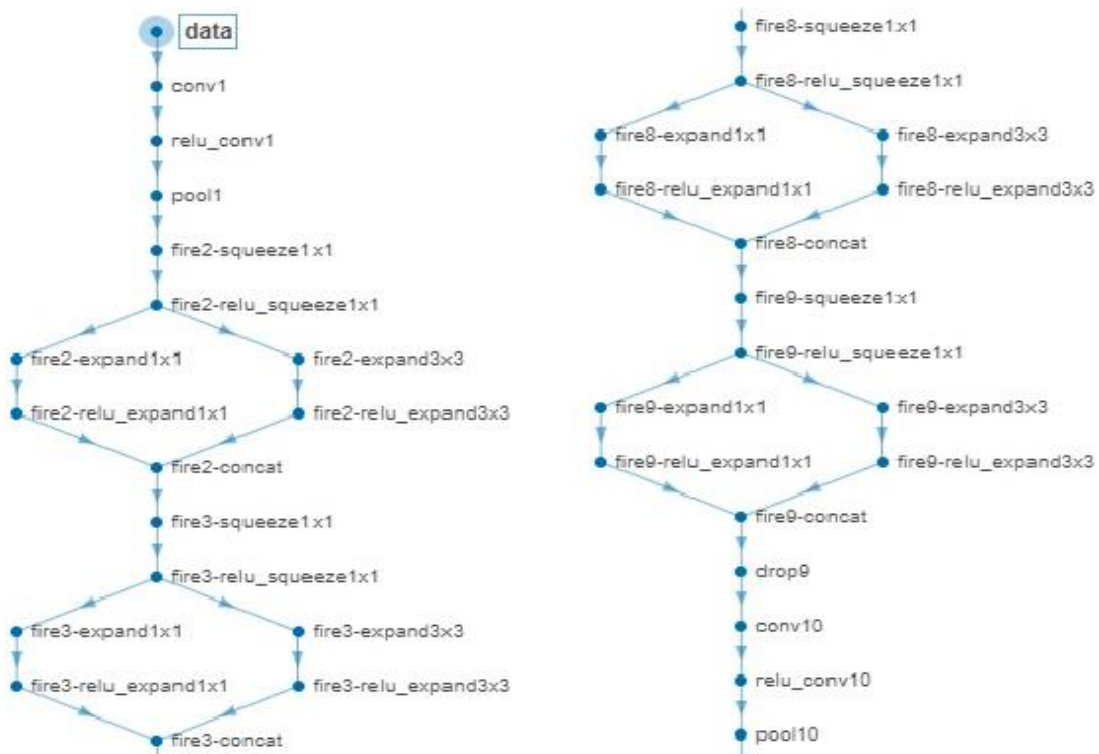
Gambar 15 menunjukkan bentuk Transfer Learning-DCNN yang diusulkan menggunakan Squeeze-Net dan AlexNet, jaringan saraf konvolusi yang telah dilatih sebelumnya, untuk mengklasifikasikan kumpulan gambar baru. Jadi, setelah semua gambar scalogram dan WSST sinyal getaran diubah ukurannya dan disimpan dalam tiga folder yang sesuai dengan masing-masing kategori NC, SC, dan HC, dari 840 dataset gambar ini, 60% akan digunakan untuk data latih dan 20% akan digunakan untuk data validasi dan 20% sisanya lagi sebagai data testing.



Gambar 15. Architecture Transfer Learning via Alex-Net dan Squeeze-Net.

Seperti terlihat pada Gambar 15, semua scalogram dan WSST dimasukkan sebagai input ke lapisan awal jaringan Squeeze-Net dalam hal ini. 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 dibekukan (*pre-trained*), lapisan yang sepenuhnya terhubung, layer soft-max dan layer klasifikasi. Konfigurasi rinci dari lapisan-lapisan ini ditunjukkan pada Gambar 16. 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. 16. Karena Squeeze-Net asli dirancang untuk membuat 1000 klasifikasi gambar yang berbeda, maka 3 lapisan terakhir harus dimodifikasi untuk prediksi (NC/SC/HC) dalam kasus kita ini. 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 (NC/SC/HC).




Gambar 16. Layer conv-1 to conv-10 process Squeeze-Net.

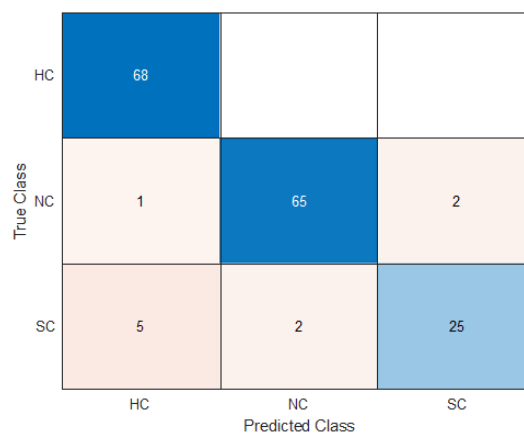
Setelah 3 lapisan terakhir ini diubah dan disetel dengan baik, kami melatih jaringan ini kepada kumpulan gambar baru dengan parameter

('WeightLearnRateFactor',50,'BiasLearnRateFactor',50),('MiniBatchSize',42,'MaxEpochs',15),and('Shuffle','everyepoch','ValidationData',TestImages,'ValidationFrequency',12,'InitialLearnRate',7e-5), kemudian setelah tahapan pelatihan dan validasi selesai maka siap untuk digunakan mengklasifikasikan masalah kondisi (NC, SC, dan HC).

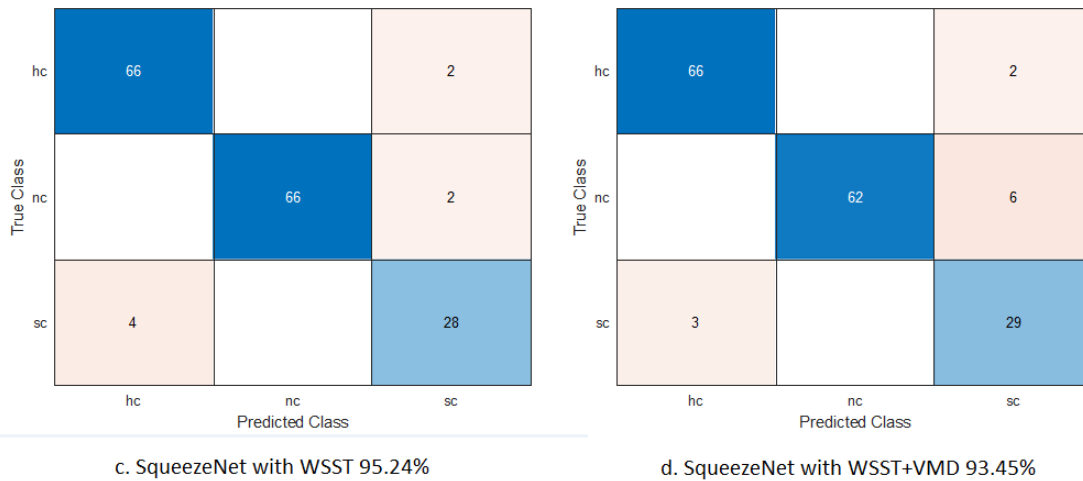
Gambar 17 menunjukkan matriks konfusi untuk melihat keakurasian klasifikasi dataset model latih Squeeze-Net jika dibandingkan dengan jaringan pra-latih Alex-Net. Diperoleh bahwa secara umum penggunaan metode WSST terhadap metode CWT mampu meningkatkan keakurasian model sebesar 2-3%. Kemudian kombinasi penerapan metode VMD dengan metode WSST dan CWT secara umum relative juga meningkatkan keakurasian model sebesar 1-2% dengan perlakuan parameter yang Sama antara Squeeze-Net dan Alex-Net. Sehingga akurasi tingkat klasifikasi dan waktu iterasi secara umum sangat berhasil dicapai (96.42%) oleh Alex-Net dan sangat cocok untuk membangun suatu model awal sistem. Rincian perbandingan capaian hasil model latih, validasi dan uji kedua model jaringan dapat dilihat pada Tabel 4.



a. Alex-Net with WSST 95.24%



b. Alex-Net with WSST+VMD 94.04%



Gambar 17. Classification accuracy validation matrix (a&b) Alex-Net; (c&d) Squeeze-Net.

Table 4. Classification accuracy result.

Network models	Alex-Net	Squeeze-Net
Classification Accuracy (%) CWT	92.85% (Validation)	92.26% (Validation)
	92.85% (Testing)	94.05% (Testing)
Time Convergence	8 min 32 sec	13 min 20 sec
Classification Accuracy (%) WSST	95.24% (Validation)	95.24% (Validation)
	94.64% (Testing)	93.45% (Testing)
Time Convergence	8 min 22 sec	14 min 22 sec
Classification Accuracy (%) CWT+VMD	94.64% (Validation)	92.26% (Validation)
	96.42% (Testing)	94.05% (Testing)
Time Convergence	8 min 22 sec	13 min 27 sec
Classification Accuracy (%) WSST+VMD	94.04% (Validation)	93.45% (Validation)
	92.26% (Testing)	92.26% (Testing)
Time Convergence	8 min 30 sec	13 min 20 sec



## Bab V Kesimpulan

Laporan ini menyajikan studi keterbaruan penerapan teknologi khusus tentang pengembangan model *DT-Smart/Intelligent machining* dari proses pemesinan milling untuk mendeteksi adanya chatter. Dalam studi ini, pendekatan baru berdasarkan analisis peta stabilitas (SLD), metode *Variational Mode Decomposition* (VMD), *Synchrosqueeze* yang berbasis *wavelet transform* (WSST) dan aplikasi *Transfer Learning* via *Deep Convolution Neural Network* (DCNN) berbasis pada data driven diusulkan. Tahapan dalam membangun model dimulai dengan menentukan FRF, membangun peta kestabilan SLD untuk memilih parameter pemotongan, kemudian data sinyal getaran diproses menggunakan CWT dan WSST yang dikombinasikan dengan metode VMD untuk meningkatkan akurasi proses pembelajaran model. Dengan menerapkan metode transfer learning yang merupakan upaya untuk mengurangi kebutuhan penggunaan dataset yang jumlahnya sangat banyak dan mempercepat proses pembelajaran tanpa harus melatih jaringan dengan bobot yang diinisialisasi secara acak dari awal. Diperoleh bahwa keakurasian model latih menjadi meningkat sebesar 2-3% ketika menggunakan metode WSST bila dibandingkan dengan metode CWT sebagai pengekstraksian fitur pada image input. Hal yang Sama juga terjadi peningkatan keakurasian model sebesar 1-2% pada penerapan metode VMD dengan metode WSST dan CWT. Tingkat akurasi klasifikasi maksimum (96.42%) dan waktu iterasi  $\pm 8$  menit 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. A novel chatter detection method for milling 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.
- [20] I. Daubechies and S. Maes, "A nonlinear squeezing of the continuous wavelet transform based on auditory nerve models," *Wavelets in medicine and biology*, pp. 527–546, 1996.

- [21] I. Daubechies, J. Lu, and H.-T. Wu, "Synchrosqueezed wavelet transforms: an empirical mode decomposition-like tool," *Applied and Computational Harmonic Analysis*, vol. 30, no. 2, pp. 243–261, 2011.
- [22] R. Carmona, W. Hwang, and B. Torresani, "Characterization of signals by the ridges of their wavelet transforms," *IEEE Transactions on Signal Processing*, vol. 45, no. 10, pp. 2586–2590, Oct 1997.
- [23] D.-H. Pham and S. Meignen, "High-order synchrosqueezing transform for multicomponent signals analysis - with an application to gravitational-wave signal," *IEEE Transactions on Signal Processing*, vol. 65, no. 12, pp. 3168–3178, June 2017.
- [24] Dibaj A, Ettefagh MM, Hassannejad R, Ehghaghi MB (2020) A hybrid fine-tuned VMD and CNN scheme for untrained compound fault diagnosis of rotating machinery with unequal-severity faults. *Expert Syst Appl* p. 114094.
- [25] Sharma V, Parey A (2020) Extraction of weak fault transients using variational mode decomposition for fault diagnosis of gearbox under varying speed. *Eng Fail Anal* 107:104204.
- [26] Benbouzid M (Ed.) (2020) *Signal processing for fault detection and diagnosis in electric machines and systems*. Institution of Engineering and Technology.
- [27] Dragomiretskiy K, Zosso D (2014) Variational mode decomposition. *IEEE Trans Signal Process* 62(3):531–544.
- [28] Chen X, Yang Y, Cui Z, Shen J (2019) Vibration fault diagnosis of wind turbines based on variational mode decomposition and energy entropy. *Energy* 174:1100–1109.
- [29] Wang Z, He G, Du W, Zhou J, Han X, Wang J, He H, Guo X, Wang J, Kou Y (2019) Crude oil risk forecasting: New evidence from multiscale analysis approach. *IEEE Access* 7:44871–44882.
- [30] Jiang F, Zhu Z, Li W (2018) an improved VMD with empirical mode decomposition and its application in incipient fault detection of rolling bearing. *IEEE Access* 6:44483–44493.
- [31] Ali JB, Saidi L, Harrath S, Bechhoefer E, Benbouzid M (2018) Online automatic diagnosis of wind turbine bearings progressive degradations under

real experimental conditions based on unsupervised machine learning. *Appl Acoust* 132:167–181.

- [32] Li Y, Cheng G, Liu C, Chen X (2018) Study on planetary gear fault diagnosis based on variational mode decomposition and deep neural networks. *Measurement* 130:94–104.
- [33] Gu R, Chen J, Hong R, Wang H, Wu W (2020) Incipient fault diagnosis of rolling bearings based on adaptive variational mode decomposition and teager energy operator. *Measurement* 149:106941.