

TESIS

APLIKASI METODE SUPPORT VECTOR MACHINE UNTUK KLASIFIKASI KEGAGALAN *PHOTOVOLTAIC* BERDASARKAN DATA *MAXIMUM POWER POINT*

*Application of Support Vector Machine Method for Photovoltaic Failure
Classification Based on Maximum Power Point Data*

**IMAM FARIED ASSALAM
D032211004**



**PROGRAM STUDI MAGISTER TEKNIK ELEKTRO
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2023**



PENGAJUAN TESIS

APLIKASI METODE SUPPORT VECTOR MACHINE UNTUK KLASIFIKASI KEGAGALAN *PHOTOVOLTAIC* BERDASARKAN DATA *MAXIMUM POWER POINT*

Tesis
Sebagai Salah Satu Syarat untuk Mencapai Gelar Magister
Program Studi Teknik Elektro

Disusun dan diajukan oleh

IMAM FARIED ASSALAM
D032211004

Kepada

FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2023



TESIS

APLIKASI METODE SUPPORT VECTOR MACHINE UNTUK KLASIFIKASI KEGAGALAN PHOTOVOLTAIC BERDASARKAN DATA MAXIMUM POWER POINT

IMAM FARIED ASSALAM

D032211004

Telah dipertahankan di hadapan Panitia Ujian yang dibentuk dalam rangka penyelesaian studi pada Program Magister Teknik Elektro Fakultas Teknik Universitas Hasanuddin pada tanggal 17 November 2023 dan dinyatakan telah memenuhi syarat kelulusan

Menyetujui,

Pembimbing Utama

Pembimbing Pendamping



Prof. Dr. Ir. Indar Chaerah Gunadin, S.T.,M.T. Prof. Dr. Eng. Ir. Syafaruddin, S.T.,M.Eng.,IPU.
NIP. 19731118 199803 1 001 NIP. 19740530 199903 1 003

Dekan Fakultas Teknik
Universitas Hasanuddin

Ketua Program Studi S2 Teknik Elektro



Muhammad Isran Ramli, S.T.,M.T.,IPM.
NIP. 19730926 200012 1 002

Dr. Eng. Ir. Wardi, S.T., M.Eng.
NIP. 19720828 199903 1 003



PERNYATAAN KEASLIAN TESIS DAN PELIMPAHAN HAK CIPTA

Yang bertanda tangan di bawah ini

Nama : Imam Faried Assalam

Nomor mahasiswa : D032211004

Program studi : Teknik Elektro

Dengan ini menyatakan bahwa, tesis berjudul “APLIKASI METODE SUPPORT VECTOR MACHINE UNTUK KLASIFIKASI KEGAGALAN *PHOTOVOLTAIC* BERDASARKAN DATA *MAXIMUM POWER POINT*” adalah benar karya saya dengan arahan dari komisi pembimbing (Prof. Dr. Ir. Indar Chaerah Gunadin, S.T.,M.T.,IPM dan Prof. Dr. Eng. Ir. Syafaruddin, S.T.,M.Eng.,IPU.). Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apa pun kepada perguruan tinggi mana pun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka tesis ini. Sebagian dari isi tesis ini telah dipublikasikan di Prosiding 2023 International Conference on Artificial Intelligence Robotics, Signal, and Image Processing (AIROsIP) sebagai artikel dengan judul “*Application of Support Vector Machine (SVM) Method for Photovoltaic Condition Classification Based on Characteristic Curve Indicators*”.

Dengan ini saya melimpahkan hak cipta dari karya tulis saya berupa tesis ini kepada Universitas Hasanuddin.

Gowa, 17 November 2023

Yang menyatakan



Imam Faried Assalam



KATA PENGANTAR

Segala puji syukur penulis panjatkan kepada Allah Subhanahu wata'ala, karena hanya dengan nikmat dan karunia-Nya sehingga penulis bisa menyelesaikan penulisan tesis ini. Tak lupa pula shalawat serta salam semoga tetap terlimpahkan kepada junjungan kita Nabiyullah Muhammad Shallallahu 'alaihi wasallam, sang pembawa kabar gembira dan sebaik-baiknya tauladan bagi yang mengharap rahmat dan hidayah-Nya.

Bukan hal yang mudah untuk mewujudkan gagasan-gagasan yang tertuang dalam sebuah susunan tesis, berkat bimbingan, arahan dan motivasi berbagai pihak maka tesis ini bisa disusun sebagaimana kaidah-kaidah yang dipersyaratkan, dan untuk itu penulis menyampaikan terimakasih kepada:

1. Kedua orang tua, bapak tercinta Dr. Ruslan Hamid, S.E.,M.M. dan ibunda tercinta Ir. Syerly Klara, M.T. terima kasih atas doa dan dukungannya, baik moril maupun materiil. Beliau adalah malaikat yang dikirim oleh Allah Subhanahu wata'ala serta anugrah terindah bagiku. Terima kasih atas kasih sayang yang selama ini telah dicurahkan untukku. Semoga anakmu ini bisa menjadi anak yang kelak akan membanggakan dan membahagiakanmu.
2. Prof. Dr. Indar Chaerah Gunadin, S.T.,M.T.,IPM. sebagai pembimbing utama dan Prof. Dr. Eng. Ir. Syafaruddin, S.T.,M.Eng.,IPU. sebagai pembimbing pendamping yang telah meluangkan waktu untuk memberikan bimbingan, masukan, juga tambahan referensi serta ilmunya dengan penuh sabar dan penuh perhatian dalam penyelesaian tesis ini.
3. Rektor universitas Hasanuddin dan Dekan Fakultas Teknik Universitas Hasanuddin yang telah memfasilitasi saya menempuh program magister serta para dosen dan rekan-rekan dalam tim penelitian.
4. Segenap staff PLTS Likupang 21 MWp yang telah mengizinkan saya untuk melaksanakan penelitian dan diberi kesempatan untuk menggunakan fasilitas dan peralatan di lapangan.



5. Kakak tercinta Fuad Mahfud Assidiq, S.T.,M.T. yang juga telah memberikan bimbingan, tambahan ilmu, serta masukan dan pengarahan dalam proses publikasi dan penyelesaian tesis ini.
6. Bapak dan ibu serta teman-teman seperjuangan Program Magister Teknik Elektro Universitas Hasanuddin angkatan 2021 terkhusus untuk program studi energi yang telah banyak membantu dalam hal administrasi, perkuliahan, dsb.

Akhir kata penulis mohon maaf yang sebesar-besarnya atas segala kesalahan yang penulis buat baik sengaja maupun tidak disengaja selama berkuliah di Fakultas Teknik Universitas Hasanuddin maupun selama penulisan tesis ini. Semoga Allah Subhanahu wata'ala mengampuni segala kesalahan dan menunjukkan jalan yang lurus dan benar kepada kita semua.

Penulis

IMAM FARIED ASSALAM



ABSTRAK

IMAM FARIED ASSALAM. *Aplikasi Metode Support Vector Machine untuk Klasifikasi Kegagalan Photovoltaic Berdasarkan Data Maximum Power Point* (dibimbing oleh **Indar Chaerah Gunadin, Syafaruddin**)

Persentase tingkat degradasi menjadi faktor utama dalam indikator keandalan daya pada *photovoltaic*. Untuk mengevaluasi keandalan tersebut maka dilakukan analisis kegagalan yang meliputi *hotspot*, *bypass diode failure*, dan *short circuit* dengan melakukan pengukuran Kurva I-V (arus-tegangan) sehingga mendapatkan data *Maximum Power Point* (MPP) yang merujuk pada titik operasi di mana *photovoltaic* menghasilkan daya maksimum. Penelitian ini bertujuan untuk mengaplikasikan metode Support Vector Machine (SVM) dengan variasi kernel seperti Linear, Polynomial, dan Gaussian yang diterapkan dalam proses multi-klasifikasi untuk penentuan kegagalan *photovoltaic* serta akan divalidasi dan dikombinasikan dengan metode Naïve Bayes (NB) dan K-Nearest Neighbors (KNN). Setiap metode dan kombinasi akan diterapkan proses pelatihan dan pengujian dengan megolah data MPP sebagai data latih dan data uji. Hasil penelitian menunjukkan bahwa metode Polynomial SVM memberikan tingkat akurasi dan metrik evaluasi yang sangat baik jika dibandingkan dengan metode NB dan KNN serta dengan kombinasi-kombinasi metode lainnya dalam proses multi-klasifikasi kegagalan *photovoltaic*. Tingkat akurasi Polynomial SVM tersebut mencapai 98,33% untuk proses pelatihan (*train*) dan mencapai 94,00% untuk proses pengujian (*test*).

Kata kunci: KNN, multi-klasifikasi, NB, *photovoltaic*, SVM, tingkat akurasi



ABSTRACT

IMAM FARIED ASSALAM. *Application of Support Vector Machine Method for Photovoltaic Failure Classification Based on Maximum Power Point Data* (supervised by **Indar Chaerah Gunadin, Syafaruddin**)

The degradation rate percentage is a major factor in the power reliability indicator of *photovoltaic*. To evaluate the reliability, a failure analysis is implemented which includes hotspot, bypass diode failure, and short circuit by measuring the I-V (current-voltage) Curve so as to determine the Maximum Power Point (MPP) data which refers to the operating point where the *photovoltaic* produces maximum power. This research aims to apply the Support Vector Machine (SVM) method with kernel variations such as Linear, Polynomial, and Gaussian applied in a multi-classification process for *photovoltaic* failure identification and will be validated and combined with the Naïve Bayes (NB) and K-Nearest Neighbors (KNN) methods. Each method and combination will be applied to the training and testing process by processing MPP data as training data and test data. The results show that the Polynomial SVM method provides a high level of accuracy and evaluation metrics when compared to the NB and KNN methods and with other combinations of methods in the process of multi-classification of *photovoltaic* failures. The accuracy of Polynomial SVM reached 98.33% for the train process and 94.00% for the test process.

Keywords: accuracy rate, KNN, multi-classification, NB, *photovoltaic*, SVM



DAFTAR ISI

	<u>Halaman</u>
HALAMAN JUDUL	i
PENGAJUAN TESIS.....	ii
PERSETUJUAN TESIS	iii
PERNYATAAN KEASLIAN TESIS	iv
KATA PENGANTAR.....	v
ABSTRAK	vii
ABSTRACT	viii
DAFTAR ISI.....	ix
DAFTAR TABEL	xii
DAFTAR GAMBAR.....	xiii
DAFTAR LAMPIRAN	xv
DAFTAR ISTILAH & SINGKATAN	xvi
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian.....	4
1.4 Manfaat Penelitian.....	4
1.5 Ruang Lingkup	4
BAB II LANDASAN TEORI	6
2.1 <i>Photovoltaic</i>	6
2.1.1 Spesifikasi <i>Photovoltaic</i>	6
2.2 Degradasi & Kondisi <i>Photovoltaic</i>	8
2.2.1 <i>Hotspot</i>	9
2.2.2 <i>Bypass Diode Failure</i>	10
2.2.3 <i>Short Circuit</i>	11
2.3 Kurva Karakteristik Arus-Tegangan (Kurva I-V)	13
2.4 <i>Standard Test Conditions</i> (STC)	20
2.5 Pengukuran Parameter Kurva I-V	21
Support Vector Machine	24
Metode Kernel	28
Orde Polynomial.....	29
Validasi & Kombinasi Metode.....	31



2.7.1 Naïve Bayes	31
2.7.2 K-Nearest Neighbors	32
2.8 State of Art Penelitian	33
BAB III METODE PENELITIAN	36
3.1 Tahapan Penelitian	36
3.1.1 Pengambilan Data	36
3.1.2 Seleksi Data	36
3.1.3 Kalsifikasi dengan Metode SVM	36
3.1.4 Uji Coba Akurasi Hasil Klasifikasi	37
3.1.5 Penyusunan Tesis	37
3.2 Waktu dan Tempat Penelitian	37
3.3 Diagram Proses Penelitian	38
BAB IV ANALISIS DAN PEMBAHASAN	42
4.1 <i>Preprocessing</i>	42
4.2 Model Multi-klasifikasi	43
4.2.1 Support Vector Machine (SVM)	43
4.2.2 Naïve Bayes (NB)	45
4.2.3 K-Nearest Neighbors (KNN)	45
4.2.4 Kombinasi Metode	47
4.3 Akurasi Pelatihan	47
4.4 Akurasi Pengujian	48
4.5 Evaluasi Akurasi	49
4.6 <i>Confusion Matrix</i> dan Metrik Evaluasi	50
4.7 Hasil Akurasi Multi-klasifikasi	52
4.7.1 Support Vector Machine – Linear (Linear SVM)	52
4.7.2 Support Vector Machine – Polynomial (Polynomial SVM)	53
4.7.3 Support Vector Machine – Gaussian (Gaussian SVM)	54
4.7.4 Naïve Bayes (NB)	55
4.7.5 K-Nearest Neighbors (KNN)	57
4.7.6 Linear SVM - NB	58
4.7.7 Linear SVM - KNN	59
4.7.8 Polynomial SVM - NB	60
4.7.9 Polynomial SVM - KNN	61
4.7.10 Gaussian SVM - NB	62
4.7.11 Gaussian SVM - KNN	64



4.8 Analisis Hasil Akurasi Multi-klasifikasi	65
BAB V KESIMPULAN DAN SARAN	69
5.1 Kesimpulan.....	69
5.2 Saran.....	69
DAFTAR PUSTAKA	70
LAMPIRAN.....	75



DAFTAR TABEL

	Halaman
Tabel 1 Spesifikasi photovoltaic (Trina Solar, 2017).....	6
Tabel 2 Perbedaan data MPP nominal dan STC pada <i>hotspot</i>	17
Tabel 3 Perbedaan data MPP nominal dan STC pada <i>bypass diode failure</i>	18
Tabel 4 Perbedaan data MPP nominal dan STC pada <i>short circuit</i>	19
Tabel 5 Spesifikasi STC photovoltaic (Trina Solar, 2017)	21
Tabel 6 State of art penelitian.....	33
Tabel 7 Jadwal Penelitian.....	37
Tabel 8 Hasil tingkat akurasi pada orde-n.....	44
Tabel 9 Hasil tingkat akurasi pada jenis distribusi NB	45
Tabel 10 Hasil tingkat akurasi pada jumlah neighbors KNN.....	46
Tabel 11 Persentase tingkat akurasi pada semua metode individu & kombinasi. 65	
Tabel 12 Persentase & rasio akurasi dan metrik evaluasi pengujian	68
Tabel 13 Data pelatihan algoritma	75
Tabel 14 Data pengujian algoritma	85
Tabel 15 Persentase hasil klasifikasi pada data latih.....	96
Tabel 16 Persentase hasil klasifikasi pada data uji.....	107



DAFTAR GAMBAR

	Halaman
Gambar 1 Three-diode photovoltaic.....	8
Gambar 2 Hotspot pada photovoltaic	10
Gambar 3 Kegagalan dioda bypass pada <i>photovoltaic</i>	11
Gambar 4 Short circuit pada substring sel photovoltaic.....	13
Gambar 5 Kurva I-V <i>photovoltaic</i> (Solar, 2018).....	14
Gambar 6 Kurva pengaruh radiasi matahari terhadap arus dan tegangan (Solar, 2018)	15
Gambar 7 Kurva pengaruh suhu sel terhadap arus dan tegangan (Solar, 2018)..	15
Gambar 8 Ilustrasi Kurva I-V pada hotspot	16
Gambar 9 Ilustrasi Kurva I-V pada bypass diode failure	18
Gambar 10 Ilustrasi Kurva I-V pada short circuit	19
Gambar 11 SEAWARD PV200 Complete Kit (Seaward, 2018).....	21
Gambar 12 Ilustrasi pengukuran Kurva I-V (Hossion, 2020)	22
Gambar 13 Ilustrasi pengaturan level pembeban (Ferdous et al., 2012)	23
Gambar 14 Margin besar dan kecil pada hyperlane (Meirista, 2015)	26
Gambar 15 Perbedaan ruang dimensi orde-n (Otomo et al., 2014).....	30
Gambar 16 Proses pengukuran dan pengambilan data kurva I-V	38
Gambar 17 Flowchart proses pelatihan (berlanjut)	39
Gambar 18 Flowchart proses pengujian metode individu (berlanjut)	40
Gambar 19 Flowchart proses pengujian metode kombinasi (berlanjut).....	40
Gambar 20 Flowchart analisa dan validasi hasil akurasi semua metode.....	41
Gambar 21 Confusion matrix pada pelatihan metode Linear SVM	52
Gambar 22 Confusion matrix pada pengujian metode Linear SVM	53
Gambar 23 Confusion matrix pada pelatihan metode Polynomial SVM	53
Gambar 24 Confusion matrix pada pengujian metode Polynomial SVM	54
Gambar 25 Confusion matrix pada pelatihan metode Gaussian SVM.....	55
Gambar 26 Confusion matrix pada pengujian metode Gaussian SVM.....	55
Gambar 27 Confusion matrix pada pelatihan metode NB.....	56
Gambar 28 Confusion matrix pada pengujian metode NB	56
Gambar 29 Confusion matrix pada pelatihan metode KNN	57



Gambar 30	Confusion matrix pada pengujian metode KNN	57
Gambar 31	Confusion matrix pada pelatihan metode Linear SVM-NB	58
Gambar 32	Confusion matrix pada pengujian metode Linear SVM-NB	58
Gambar 33	Confusion matrix pada pelatihan metode Linear SVM-KNN	59
Gambar 34	Confusion matrix pada pengujian metode Linear SVM-KNN	60
Gambar 35	Confusion matrix pada pelatihan metode Polynomial SVM-NB	60
Gambar 36	Confusion matrix pada pengujian metode Polynomial SVM-NB	61
Gambar 37	Confusion matrix pada pelatihan metode Polynomial SVM-KNN ..	62
Gambar 38	Confusion matrix pada pengujian metode Polynomial SVM-KNN .	62
Gambar 39	Confusion matrix pada pelatihan metode Gaussian SVM-NB	63
Gambar 40	Confusion matrix pada pengujian metode Gaussian SVM-NB	63
Gambar 41	Confusion matrix pada pelatihan metode Gaussian SVM-KNN	64
Gambar 42	Confusion matrix pada pengujian metode Gaussian SVM-KNN	64



DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Data Latih	75
Lampiran 2 Data Uji.....	85
Lampiran 3 Algoritma SVM-NB	88
Lampiran 4 Algoritma SVM-KNN	92
Lampiran 5 Hasil Klasifikasi Data Latih.....	96
Lampiran 6 Hasil Klasifikasi Data Uji.....	107



DAFTAR ISTILAH & SINGKATAN

Istilah / Singkatan	Arti / Penjelasan
I-V	Karakteristik arus-tegangan <i>photovoltaic</i>
Voc	<i>Open Circuit Voltage</i> (Tegangan rangkaian terbuka)
Isc	<i>Short Circuit Current</i> (Arus hubung singkat)
Vmp	<i>Maximum Power Voltage</i> (Tegangan daya maksimum)
Imp	<i>Maximum Power Current</i> (Arus daya maksimum)
FF	<i>Fill Factor</i> (Faktor pengisian yang merupakan nilai yang mendekati konstanta suatu sel surya tertentu)
Irr	<i>Irradiance</i> (Intesitas radiasi matahari)
Tpv	<i>Photovoltaic Temperature</i> (suhu panel surya)
Deg	<i>Degradation</i> (Persentase penurunan performa dari panel surya)
STC	<i>Standard Test Conditions</i> (Standar untuk mengukur performa maksimal suatu panel surya pada suatu kondisi seragam sehingga memungkinkan untuk melakukan perbandingan seragam pada panel surya baik pada produsen yang sama atau berbeda)
SVM	Support Vector Machine, digunakan untuk memisahkan dua kelas atau lebih dalam memprediksi nilai numerik dengan membangun hyperplane (bidang pemisah) di antara kelompok data yang berbeda
Linear	Konsep yang mengacu pada penggunaan kernel linier untuk memisahkan dan mengklasifikasikan data dengan menggunakan garis pemisah linier dalam ruang fitur.
Polynomial	Konsep yang mengacu pada penggunaan kernel polynomial untuk memisahkan dan mengklasifikasikan



ial

Istilah / Singkatan	Arti / Penjelasan
Gaussian	data dengan menggunakan kurva polynomial sebagai garis pemisah dalam ruang fitur. Konsep yang mengacu pada penggunaan kernel Gaussian untuk memisahkan dan mengklasifikasikan data dengan menggunakan permukaan tak terbatas dalam ruang fitur sebagai garis pemisah
NB	Naïve Bayes, algoritma klasifikasi probabilistik yang berdasarkan teorema Bayes. Metode ini mengasumsikan bahwa setiap fitur dalam dataset adalah independen satu sama lain, meskipun dalam kenyataannya beberapa fitur mungkin saling terkait. Meskipun asumsi ini sederhana, Naive Bayes sering kali memberikan kinerja yang baik dalam banyak tugas klasifikasi
KNN	K-Nearest Neighbors, adalah algoritma klasifikasi yang non-parametrik dan berbasis instansi. Ini berarti KNN tidak membuat asumsi tertentu tentang distribusi data dan mengambil keputusan klasifikasi berdasarkan mayoritas kelas tetangga terdekat dari data yang akan diklasifikasikan
LSVM	Linear Support Vector Machine
LSVM-NB	Kombinasi antara Linear Support Vector Machine dan Naïve Bayes
LSVM-KNN	Kombinasi antara Linear Support Vector Machine dan K-Nearest Neighbors
PSVM	Polynomial Support Vector Machine
PSVM-NB	Kombinasi antara Polynomial Support Vector Machine dan Naïve Bayes



Istilah / Singkatan	Arti / Penjelasan
PSVM-KNN	Kombinasi antara Polynomial Support Vector Machine dan K-Nearest Neighbors
GSVM	Gaussian Support Vector Machine
GSVM-NB	Kombinasi antara Gaussian Support Vector Machine dan Naïve Bayes
GSVM-KNN	Kombinasi antara Gaussian Support Vector Machine dan K-Nearest Neighbors
Multi-klasifikasi	Klasifikasi pada data yang memiliki lebih dari dua macam target
Target	Hasil yang diharapkan pada pengetesan dan pengujian algoritma multi-klasifikasi
Misprediction	Total persentase kesalahan prediksi dari semua metode multi-klasifikasi setiap titiknya
Remarks pada Confusion Matrix dan Tabel:	(1) <i>Bypass Diode Failure</i> (2) <i>Hotspot</i> (3) Normal
(1), (2), (3) & (4)	(4) <i>Short Circuit</i>



BAB I

PENDAHULUAN

1.1 Latar Belakang

Energi terbarukan menyumbang bagian yang signifikan dan terus berkembang untuk pembangkit listrik di seluruh dunia. *Photovoltaic* diharapkan menjadi sumber energi terbesar di dunia pada tahun 2025, dengan *photovoltaic* mewakili 60% dari penambahan kapasitas (Renewables, 2020). Keandalan *photovoltaic* menjadi perhatian utama dalam skenario di mana sebagian produsen *photovoltaic* memberikan garansi 25 tahun atau 30 tahun (Tsanakas et al., 2016). Para produsen *photovoltaic* menjamin penurunan daya kurang dari 20% dalam masa garansi (Virtuani et al., 2019). Dengan masa garansi yang cukup lama, tingkat degradasi *photovoltaic* harus ditentukan dengan baik dan berada di bawah 0,8% per tahun. Studi terbaru telah menuliskan tingkat degradasi sekitar 0,6% - 0,7% per tahun (Da Fonseca et al., 2020).

Degradation rate tersebut masih tinggi, karena variabilitas sampel yang diteliti dan mempertimbangkan bahwa degradasi dapat meingkatkan dari waktu ke waktu. Selain itu, data kegagalan yang tersedia saat ini tidak mencukupi untuk analisis statistik karena sebagian besar *photovoltaic* yang beroperasi belum mencapai 25 tahun beroperasi (Ishii et al., 2017). Oleh karena itu, banyak tingkat degradasi *photovoltaic* dapat melebihi 0,7% per tahun yang mengakibatkan kerugian bagi produsen karena harus memenuhi garansi.

Keandalan dan daya tahun sebuah *photovoltaic* menjadi penentu yang sangat penting untuk melihat faktor utama dari degradasi, tingkat kegagalan dan kondisi ketidaksesuaian pada *photovoltaic*. Instalasi *photovoltaic* sering terhalang oleh bayangan (*shading*) karena area, kotoran atau benda di sekitar (A. Riad et al., 2020). Hal ini dapat menyebabkan terjadinya peningkatan suhu sel *photovoltaic* yang tidak merata dan dapat menyebabkan terjadinya titik panas (*hotspot*) , 2020). Sebagaimana dibuktikan oleh referensi (Dhimish et al., 2018), sel *aic* yang ber-*hotspot* akan mengalami disipasi daya dibandingkan akan kan daya, sehingga kerugian total daya pada sistem *photovoltaic*



diperkirakan akan turun hingga 15%. Shading tidak hanya menciptakan *hotspot* tetapi menurut Dhimish dan Badran (2020) terdapat juga korelasi antara kegagalan dioda bypass (*Bypass Diode Failure*) dan hubung singkat (*short circuit*).

Data kelistrikan *photovoltaic* yang umum digunakan untuk diagnosis meliputi daya keluaran (*output power*), tegangan atau arus keluaran (*voltage or current*) dan kurva karakteristik tegangan dan arus (Kurva I-V) (Livera et al., 2019). Kurva I-V menjadi sumber penting dalam mendapatkan data-data untuk penelitian ini. Mendapatkan data-data tersebut dengan melakukan pengukuran pada satu waktu tertentu dan mengestrak indikator dari kurva yang tergabung menjadi data MPP (*Maximum Power Point*) yaitu nilai titik pada *photovoltaic* yang beroperasi dalam keadaan maksimal/puncak atau dalam kondisi STC (*Standard Test Condition*) yang meliputi V_{oc} (*Open circuit voltage*), I_{sc} (*Short circuit current*), V_{mpp} (*Maximum peak point voltage*), I_{mpp} (*Maximum peak point current*), FF (*Fill factor*).

Pada penelitian ini keseluruhan data MPP yang akan diolah merupakan data primer yang diukur secara langsung serta secara riil (Seaward, 2018) pada *photovoltaic* yang tersebar di Pembangkit Listrik Tenaga Surya (PLTS) Likupang 21 MWp di Minahasa Utara (Trina Solar, 2017), sehingga data MPP yang diolah tidak terdapat pada situs-situs manapun yang berupa data sekunder. Dengan menggunakan data primer, penelitian ini berupaya untuk menghindari adanya ketidakcocokan data parameter satu sama lain karena pengukuran data MPP memiliki sensitifitas yang sangat tinggi dan juga berupaya dalam pembaruan data untuk mendapat kondisi riil di lapangan khususnya kondisi riil di Indonesia.

Kemudian data-data MPP ini digunakan untuk mendiagnosis *photovoltaic* yang salah satunya dapat menggunakan teknik *machine learning* dengan metode Support Vector Machine (SVM). Metode SVM telah terbukti menjadi alat yang kuat dalam analisis dan klasifikasi data yang kompleks. SVM adalah metode pembelajaran mesin yang dapat membangun model klasifikasi berdasarkan pola data dalam data pelatihan. Dalam konteks aplikasi klasifikasi kondisi *photovoltaic*, SVM dapat digunakan untuk mengklasifikasikan kondisi *photovoltaic* berdasarkan indikator kurva karakteristik yang diukur. Indikator kurva



karakteristik mencerminkan kinerja dan kondisi *photovoltaic*. Dengan menggunakan SVM, model klasifikasi dapat dikembangkan untuk mengidentifikasi kondisi normal, penuaan, kerusakan fisik, atau gangguan komponen pada panel surya (Chen et al., 2018).

Dalam penelitian yang dilakukan oleh (Ghosh et al., 2020), SVM digunakan untuk mendeteksi dan mengklasifikasikan kerusakan pada *photovoltaic* dengan menggunakan data yang dikumpulkan dari berbagai kondisi. Hasil penelitian menunjukkan bahwa SVM dapat mencapai tingkat akurasi yang tinggi dalam klasifikasi kondisi *photovoltaic*. Penelitian oleh (Huang et al., 2019) juga menerapkan metode SVM dalam analisis kegagalan *photovoltaic arrays*. Mereka menggunakan sebanyak 400 data kurva IV dari panel surya yang mengalami kegagalan untuk mengklasifikasikan jenis kegagalan yang terjadi. SVM digunakan untuk memisahkan kurva-kurva karakteristik ke dalam kelas-kelas kegagalan berdasarkan pola-pola yang ada.

Pada penelitian lain (Ali et al., 2020) berhasil menggunakan metode SVM dalam mengklasifikasi kegagalan *hotspot* pada *photovoltaic* berdasarkan *infrared thermography* dan mendapatkan nilai akurasi sebesar 92% serta pada penelitian berbeda (Serfa dan Kim, 2020) juga berhasil menggunakan metode SVM berdasarkan *electroluminescence images* yang mendapatkan nilai akurasi sebesar 95%, sehingga metode SVM merupakan metode yang baik atau akurat dalam melakukan klasifikasi kegagalan *photovoltaic*. Pada penelitian ini metode SVM digunakan untuk mengklasifikasikan kondisi *photovoltaic* berdasarkan indikator kurva karakteristik yang terdiri dari kondisi normal, *hotspot*, *bypass diode failure* dan *short circuit*.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut maka dapat dirumuskan permasalahan sebagai berikut:



agaimana penerapan metode Support Vector Machine (SVM) dalam mengklasifikasikan kegagalan *photovoltaic* berdasarkan data *Maximum Power Point* (MPP)?

2. Bagaimana memvalidasi hasil tingkat akurasi dan metrik evaluasi metode Support Vector Machine (SVM) terhadap metode lain dan terhadap kombinasi metode?

1.3 Tujuan Penelitian

Dari rumusan masalah maka dapat dirumuskan tujuan penelitian ini sebagai berikut:

1. Mendapatkan hasil klasifikasi kegagalan *photovoltaic* berdasarkan data *Maximum Power Point* (MPP) dengan menggunakan metode Support Vector Machine (SVM).
2. Mendapatkan hasil validasi tingkat akurasi dan metrik evaluasi metode Support Vector Machine (SVM) terhadap metode lain dan terhadap kombinasi metode.

1.4 Manfaat Penelitian

Manfaat penelitian ini diharapkan dapat menyumbang pemikiran dan sebagai referensi dalam melakukan pengklasifikasian kegagalan *photovoltaic* dengan semua metode-metode yang telah dipaparkan dalam penelitian ini serta diharapkan menjadi rujukan dalam pengembangan metode dan konsep untuk penelitian serupa maupun penelitian yang lain.

1.5 Ruang Lingkup

Untuk membatasi kajian agar lebih spesifik dan terarah, maka analisis ini dibatasi pada pembahasan sebagai berikut:

1. Objek yang digunakan adalah *photovoltaic* yang terpasang dan beroperasi . Pembangkit Listrik Tenaga Surya (PLTS) Likupang 21 MWp, Minahasa tara.



2. *Photovoltaic* berjenis Multicrystalline Silicon (multi-c-Si) dengan daya produksi 325 Wp dan bertipe three-diode model.
3. Pengukuran data *Maximum Power Point* (MPP) memakai alat ukur SEAWARD PV 200 dan Solar Survey 200R.
4. Analisis difokuskan pada *photovoltaic* yang secara fisik masih dalam kondisi normal atau belum terdapat catat dan kerusakan.
5. Implementasi program menggunakan *software* MATLAB R2021a.



BAB II

LANDASAN TEORI

2.1 Photovoltaic

Photovoltaic adalah peralatan yang mengkonversi energi surya menjadi energi listrik. *Photovoltaic* terdiri dari beberapa sel, yang tiap sel terhubung dengan lainnya secara seri dan paralel untuk membentuk sebuah modul yang jika digabung membentuk deretan *photovoltaic* yang secara umum disebut *photovoltaic arrays*. Efisiensi operasi maksimum *photovoltaic* tergantung pada titik operasi maksimum Kurva I-V. Dalam pengoperasiannya, kinerja *photovoltaic* sangat dipengaruhi oleh kondisi klimatologi daerah setempat (suhu lingkungan dan radiasi matahari) dan parameter listriknya (*short circuit current*, *open circuit voltage*, suhu sel *photovoltaic*, dan sebagainya) (Kananda dan Nazir, 2013).

2.1.1 Spesifikasi *Photovoltaic*

Pada Tabel 1 ditampilkan mengenai spesifikasi-spesifikasi *photovoltaic* berdasarkan manufaktur yang meliputi data dimensi, elektrik dan mekanikal.

Tabel 1 Spesifikasi *photovoltaic* (Trina Solar, 2017)

Parameter	Simbol	Nilai
Data Dimensi:		
Type		Multicrystalline
Module size	$W \times L$	$0,992 \times 1,978 \text{ m}^2$
Number of cells		72 cells (6×12)
Technology		Si-poly
Rough module area		$1,96 \text{ m}^2$
Sensitive cell area		$1,75 \text{ m}^2$
Data Elektrik:		
Maximum peak power	Pmpp	325 Wp
Output tolerance		0/+5 W
Short circuit current	Isc	9,27 A



Parameter	Simbol	Nilai
Open circuit voltage	Voc	45,6 V
Maximum peak voltage	Vmpp	37,5 V
Maximum peak current	Impp	8,69 A
Module efficiency		16,6 %
Measuring tolerance		±3 %
Reference temperature	TRef	25 ⁰ C
Reference irradiance	GRef	1000 W/m ²
Isc temperature coefficient	mulsc	6,7 mA/ ⁰ C
Shunt resistance	Rshunt	427 Ω
Serie resistance	Rserie	0,32 Ω
Maximum cell current	mA	386,25 mA
Maximum cell voltage	V	0,63 V
Voc temp. coefficient	muVoc	-144 mV/ ⁰ C
Number of bypass diode per module		3
Direct voltage of bypass diode		-0,7 V
Power temp. coefficient	muPmpp	-0,35 %/ ⁰ C
Fill Factor	FF	0,772
Module efficiency	Effcells	16,6%
Operational temperature		-40 to +85 ⁰ C
Maximum system voltage		1.500 Vdc (IEC); 1000 Vdc (UL)
Max series fuse rating		15 A
Degradation	Deg	2,5% first year and 0,5% per annual


Data Mekanikal:

Weight	28 kg
Front glass	2,5 mm
EVA	White
3SS	2,5 mm
	Frameless



Parameter	Simbol	Nilai
Junction box		IP 67 rated / IP 68 rated
Cables		Cable 4,0 mm ²
Connector		MC4 EV02/UTX/TS4
Mechanical load		5400 Pa
Wind load		2400 Pa

Pada Gambar 1 merupakan rangkaian model *photovoltaic* yang menjadi objek penelitian yaitu *Three-Diode Model* yang berarti memiliki tiga dioda bypass dalam satu *photovoltaic*. Semakin banyak dioda bypass yang terpasang pada *photovoltaic* akan menghasilkan kehandalan yang lebih baik atau dapat meminimalisir gangguan eksternal seperti bayangan dan kotoran sehingga tegangan dan daya dari *photovoltaic* tidak menurun drastis.



Gambar 1 *Three-diode photovoltaic*

2.2 Degradasi & Kondisi *Photovoltaic*

Performa *photovoltaic* yang optimal biasanya terjadi pada iklim mediterania jika dibandingkan dengan iklim kemarau/gersang. Rata-rata persentase degradasi tahunan untuk *photovoltaic* berjenis crystalline silicon sekitar 1,2% pada iklim kemarau/gersang, sekitar 1,06% pada iklim panas lembab, sekitar 0,72% pada iklim dingin dan sekitar 0,15% pada iklim sedang (Bansal et al., 2021). Menurut NREL (National Renewable Energy Laboratory), persentase degradasi *photovoltaic* sekitar 4% per tahun dan rata-rata sekitar 0,8% per tahun (Jordan dan 13).



Persentase degradasi *photovoltaic* juga ditentukan oleh jenisnya, untuk jenis Monocrystalline Silicon (mono-c-Si) mengalami penurunan sebesar 0,89%/tahun, Multicrystalline Silicon (multi-c-Si) sebesar 0.81%/tahun, Amorphous Silicon (a-Si) sebesar 1,34%/tahun, Copper indium gallium selenide (CIGS) sebesar 1,86%/tahun, Cadmium telluride (CdTe) sebesar 1,70%/tahun dan Thin-film sebesar 2,24%/tahun (Alimi et al., 2022).


Ada beberapa faktor yang dapat menyebabkan degradasi pada *photovoltaic* seperti korosi (*corrosion*), perubahan warna (*discoloration*), *delemination* (deleminasi), keretakan (*ckracking*) dan kerusakan (*breakage*). Semua faktor – faktor tersebut dapat dilihat dengan kasat mata jika dilakukan inspeksi, investigasi, maupun analisis. Tetapi terdapat juga faktor – faktor penyebab degradasi *photovoltaic* juga yang tidak kasat mata seperti *hotspot*, *diode faults (bypass diode)*, dan hubung singkat (*short circuit*) (Kim et al., 2021).

2.2.1 Hotspot

Hotspot merupakan anomali atau cacat yang ditemukan pada *photovoltaic* yang berdampak negatif pada pengoperasian normal *photovoltaic*. Ada beberapa kondisi yang dapat menyebabkan terjadinya hospot. Salah satu penyebab sederhana adalah bayangan (*shading*). Bayangan dapat dihasilkan oleh cabang pohon, bukit, kotoran, maupun bangunan terdekat. Sel - sel *photovoltaic* yang tidak terkena bayangan menghasilkan tegangan yang lebih tinggi biasanya membiaskan balik ke sel yang terkena bayangan. Ketika ini terjadi, akan ada disipasi daya yang besar di sel yang terkena bayangan. Disipasi daya yang besar ini menyebabkan panas berlebih atau *hotspot* (Jain P dan Jain R, 2016).

Penyebab potensial *hotspot* lainnya adalah cacat yang ada pada *photovoltaic* seperti retak atau penyok (melengkung). Faktor ini menjadi beban sehingga arus juga terkonsentrasi ke area tersebut yang menyebabkan disipasi daya yang sangat besar. Akibatnya daya berkurang sehingga menurunkan efisiensi (Kheder et al., 2016). Pada jurnal (Salazar et al., 2016) menjelaskan bahwa dengan adanya cacat pada suatu *photovoltaic* akan mengakibatkan penurunan daya sebesar





Gambar 2 Hotspot pada *photovoltaic*


Pada Gambar 2 merupakan contoh foto termal penampakan *hotspot* pada *photovoltaic* yang salah satu sel nya memiliki tingkat suhu yang lebih tinggi dibandingkan dengan sel-sel yang lain, hal inilah menjadi dampak adanya disipasi daya sehingga akan menurunkan nilai tegangan dan mengurangi daya produksi dari *photovoltaic* tersebut.

2.2.2 Bypass Diode Failure

Untuk memahami dampak kegagalan dioda bypass, penting untuk mengetahui mengapa dioda bypass harus terdapat pada *photovoltaic*. Tujuan dari dioda bypass untuk menghilangkan fenomena *hotspot* yang dapat merusak sel *photovoltaic* dan bahkan menyebabkan kebakaran jika paparan cahaya tidak merata pada permukaan sel dalam *photovoltaic* (Freitas et al., 2019).

Meskipun peran penting dioda bypass untuk daya dan keselamatan, terdapat beberapa studi analisis kegagalan komprehensif yang mengevaluasi dioda bypass. Kegagalan dioda bypass dapat dipengaruhi dengan faktor eksternal seperti pelepasan elektrostatis, sambaran petir, kelelahan termomekanis, serta tegangan berlebih terus menerus dalam jangka waktu yang panjang. Terlepas dari faktor eksternal, kegagalan dapat terjadi akibat cacat termasuk ketidakmurnian dan cacat kristal pada *photovoltaic* tersebut. Kecacatan tersebut dapat memfokuskan aliran tertentu yang menyebabkan pelelehan dioda secara lokal (García, et al.,





Gambar 3 Kegagalan dioda bypass pada *photovoltaic*

Gambar 3 merupakan salah satu contoh foto termal penampakan kegagalan dioda bypass pada *photovoltaic* yang salah satu dioda bypass-nya memiliki tingkat suhu yang lebih tinggi jika dibandingkan dengan dua dioda bypass yang lainnya. Dengan kegagalan tersebut maka beberapa sel atau grup sel *photovoltaic* dari dioda bypass tersebut tidak membangkitkan tegangan dan menghasilkan daya produksi sehingga terdapat persentase degradasi yang diestimasi $\pm 30\%$ dalam satu *photovoltaic*.

Dalam studi kasus lain menyelidiki asal mula kegagalan dioda bypass pada *photovoltaic* saat bekerja di lapangan. Mereka menemukan bahwa ketika suhu sekitar meningkat, suhu kotak sambungan bagian dalam tempat bypass dioda berada meningkat. Pada hari - hari cerah di musim panas, suhu permukaan *photovoltaic* dan kotak sambungan meningkat dari 25% menjadi 70%. Pada dioda bypass rusak yang diperoleh dari *photovoltaic* yang beroperasi secara tidak normal, melelehnya penghalang persimpangan antara logam dan semikonduktor telah diamati sebagai akibat arus bocor yang tinggi dari dioda bypass pada suhu tinggi (Moh. Aminul et al., 2022).

2.2.3 Short Circuit

Masalah *short circuit* pada *photovoltaic* menyebabkan kehilangan daya yang signifikan. Dalam studi kasus, menyatakan bahwa *short circuit* pada *cell* di beberapa lingkungan adalah faktor tunggal terbesar yaitu 11% per lingkungan yang panas dan kering sedangkan 25% per tahun di iklim




sedang (Moh. Aminul et al., 2022). Beberapa penyebab *short circuit* pada *photovoltaic* yaitu:

- Kontaminasi atau Pencemaran: Kontaminasi seperti debu, kotoran, air, atau partikel lainnya yang masuk ke antara lapisan semikonduktor di dalam sel *photovoltaic* dapat menyebabkan jalur konduksi langsung antara lapisan tersebut.
- Cacat Produksi: Saat proses produksi *photovoltaic*, kesalahan dalam pembuatan atau manipulasi material semikonduktor dapat menciptakan jalur konduksi yang tidak diinginkan antara lapisan.
- Kerusakan Mekanis: Guncangan fisik atau tekanan yang berlebihan pada *photovoltaic* dapat merusak lapisan semikonduktor dan menciptakan jalur konduksi langsung.
- Korosi atau Oksidasi: Jika material semikonduktor atau kontak logam mengalami korosi atau oksidasi mengakibatkan lapisan yang seharusnya terisolasi dapat terhubung secara langsung sehingga menciptakan jalur konduksi yang tidak diinginkan.
- Eksposur Terhadap Suhu Ekstrem: Suhu yang ekstrem dapat merusak material dan menyebabkan perubahan dimensi yang dapat menciptakan kontak langsung antara lapisan semikonduktor.

Pada Gambar 4 salah satu contoh foto termal penampakan *short circuit* pada *photovoltaic* yang salah satu kolom *substring cell* memiliki tingkat suhu yang lebih tinggi jika dibandingkan dengan *substring cell* yang lainnya. Dengan adanya *short circuit* tersebut maka kolom *substring cell* tersebut tidak membangkitkan tegangan dan menghasilkan daya produksi sehingga terdapat persentase degradasi yang diestimasi $\pm 30\%$ - 60% dalam satu *photovoltaic*.

Kegagalan bypass dioda juga dapat berkontribusi pada masalah *short circuit*. Kegagalan bypass dioda terbuka dapat mengalirkan arus bias balik melalui *photovoltaic* dalam rangkaian string saat terkena bayangan. Masalah *hotspot* juga kontribusi terhadap penguningan enkapsulan, *short circuit* pada *substring*, dan *photovoltaic*, dan kebakaran dapat terjadi (Aneke dan Shittu, 2018).





Gambar 4 Short circuit pada substring sel *photovoltaic*

2.3 Kurva Karakteristik Arus-Tegangan (Kurva I-V)


Kurva I-V adalah representasi grafis dari karakteristik arus dan tegangan dari *photovoltaic*. Kurva ini menggambarkan hubungan antara arus listrik (I) dan tegangan listrik (V) yang dihasilkan dalam berbagai kondisi operasi. Kurva I-V adalah alat yang penting dalam pemahaman kinerja *photovoltaic*. Kurva I-V memiliki beberapa kegunaan dalam industri *photovoltaic* dan penelitian sebagai berikut:

1. Kurva I-V membantu pemahaman tentang bagaimana *photovoltaic* beroperasi dalam berbagai kondisi. Ini memungkinkan peneliti atau teknisi untuk mengevaluasi kinerja *photovoltaic* di bawah berbagai tingkat cahaya matahari dan suhu.
2. Kurva I-V digunakan untuk mengidentifikasi masalah dalam *photovoltaic*. Jika kurva tidak berperilaku seperti yang diharapkan, hal ini dapat mengindikasikan kerusakan atau masalah dalam *photovoltaic*.
3. Kurva I-V membantu dalam perencanaan sistem energi surya. Dengan mengetahui karakteristik *photovoltaic*, perencana dapat memilih *photovoltaic* yang sesuai dengan kebutuhan spesifik proyek dan lingkungan.
4. Kurva I-V digunakan dalam pengujian dan verifikasi kualitas *photovoltaic*. Produsen *photovoltaic* dapat menggunakan Kurva I-V untuk memeriksa kualitas panel surya mereka sebelum distribusi.



5. Dalam sistem energi surya, Kurva I-V digunakan dalam algoritma *Maximum Power Point Tracking* (MPPT) untuk mengoptimalkan operasi *photovoltaic* dan memaksimalkan produksi daya.

Pada Gambar 5 merupakan contoh Kurva I-V yang terdapat dua kurva yaitu arus-tegangan dan daya-tegangan. Kurva I-V memiliki beberapa indikator penting dalam merepresentasikan performa dan data karakteristik *photovoltaic* yaitu V_{oc} , I_{sc} , P_{mp} , V_{mp} , dan I_{mp} .




Gambar 5 Kurva I-V *photovoltaic* (Solar, 2018)

Open circuit voltage (V_{oc}) adalah tegangan DC maksimum pada Kurva I-V dan merupakan titik operasi untuk *photovoltaic* tanpa beban yang terhubung. V_{oc} berhubungan dengan resistansi tak terbatas atau kondisi rangkaian terbuka serta arus bernilai nol dan output daya bernilai nol. Pada Gambar 7, V_{oc} sangat berkaitan dan meningkat seiring dengan kenaikan dan penurunan suhu sel. V_{oc} juga digunakan untuk menentukan tegangan rangkaian maksimum untuk *string* dan *array*.


Short circuit current (I_{sc}) adalah arus maksimum pada Kurva I-V. I_{sc} saat kondisi resistansi nol dan kondisi hubung singkat serta pada tegangan output daya nol. Pada Gambar 6, I_{sc} berbanding lurus dengan kenaikan dan



penurunan radiasi matahari. Berbeda dengan V_{oc} , besaran I_{sc} juga berkaitan dengan kenaikan dan penurunan suhu sel tapi tidak berdampak signifikan.



Gambar 6 Kurva pengaruh radiasi matahari terhadap arus dan tegangan (Solar, 2018)




Gambar 7 Kurva pengaruh suhu sel terhadap arus dan tegangan (Solar, 2018)



Maximum power point (P_{mp}) adalah titik operasi di mana hasil kali arus dan tegangan berada pada titik maksimum/puncak atau saat *photovoltaic* beroperasi akan daya maksimal. P_{mp} terletak di puncak Kurva I-V yang mewakili

titik operasi efisiensi tertinggi untuk *photovoltaic* di bawah kondisi radiasi matahari dan suhu sel tertentu. Pada titik Pmp juga sekaligus dapat ditentukan nilai dari *Maximum power voltage* (V_{mp}) dan *Maximum power current* (I_{mp}). Setelah mendapatkan dan mengetahui data MPP *photovoltaic* berdasarkan Kurva I-V, data MPP tersebut data menjadi indikator dalam menentukan performa dan suatu kegagalan pada *photovoltaic* sehingga data tersebut saling berkaitan.



Gambar 8 Ilustrasi Kurva I-V pada *hotspot*

Dampak kegagalan pada *photovoltaic* dapat mempengaruhi kualitas dari daya produksi. Peningkatan suhu di daerah yang terkena *hotspot* akan menghasilkan peningkatan konduktivitas dan menghasilkan arus yang lebih tinggi pada rentang tegangan tertentu. Pada Gambar 8 terlihat sebagai peningkatan kurva arus dan penurunan tegangan pada kurva Kurva I-V. *Hotspot* dapat menyebabkan kerugian energi yang signifikan dalam bentuk panas. Ini dapat mengurangi efisiensi *photovoltaic* dan dalam kasus ekstrim, menyebabkan kerusakan permanen pada sel-sel yang terkena, mengurangi umur operasional dan performa sistem secara signifikan.



Pada Tabel 2 ditampilkan perbedaan data-data MPP pada Kurva I-V antara nominal dan STC. Kondisi nominal merupakan kondisi MPP *photovoltaic*

berada pada titik maksimalnya sesuai dengan standar pabrikannya sedangkan kondisi STC merupakan kondisi titik maksimal MPP *photovoltaic* secara aktual. Pada Tabel 2 ditampilkan salah satu contoh data-data MPP *photovoltaic* pada Kurva I-V saat terjadi *hotspot*. Pada saat terjadi *hotspot* pada satu atau beberapa sel semua data MPP mengalami degradasi yang mengakibatkan menurunnya performa dan daya produksi sebesar 24 Wp.

Tabel 2 Perbedaan data MPP nominal dan STC pada *hotspot*


Parameter	Nominal	STC	Degradasi
Maximum power point (Pmp)	325 Wp	301 Wp	-24 Wp
Open circuit voltage (Voc)	45,6 V	45,2 V	-0,4 V
Short circuit current (Isc)	9,27 A	8,81 A	-0,46 A
Maximum power voltage (Vmp)	37,5 V	36,0 V	-1,5 V
Maximum power current (Imp)	8,69 A	8,35 A	-0,34 A
Fill factor (FF)	0,77	0,75	-0,02

Dioda bypass adalah komponen yang terhubung paralel dengan sekelompok sel *photovoltaic*. Ini berfungsi untuk mengalihkan arus jika sel atau substring sel tidak berfungsi dengan baik, mencegah terbentuknya *hotspot*. Pada Gambar 9 dijelaskan bentuk kurva pada kegagalan dioda bypass yang dapat terjadi jika diode gagal dalam posisi terbuka atau tertutup secara permanen. Jika dioda bypass gagal dalam posisi terbuka, maka arus akan mengalir melalui jalur yang seharusnya dilewati oleh dioda. Jika dioda bypass gagal dalam posisi tertutup, maka arus dari seluruh rangkaian sel PV akan melewati sel yang bermasalah, mengurangi tegangan dan mengurangi efisiensi modul.

Pada Tabel 3 ditampilkan salah satu contoh data-data MPP *photovoltaic* pada Kurva I-V saat terjadi *bypass diode failure*. Pada saat terjadi hal tersebut semua data MPP mengalami degradasi yang mengakibatkan menurunnya performa produksi sebesar 123 Wp. Berbeda dengan *hotspot*, *bypass diode failure* degradasi yang cukup besar dikarenakan akan menyebabkan minimal bagian dari *photovoltaic* tidak dapat beroperasi untuk memproduksi daya dioda bypass bisa menjadi komponen yang kritis di mana berfungsi untuk



melindungi *photovoltaic* dari *hotspot* tetapi dapat menjadi pengurang daya jika terjadi kegagalan.



Gambar 9 Ilustrasi Kurva I-V pada *bypass diode failure*


Tabel 3 Perbedaan data MPP nominal dan STC pada *bypass diode failure*

Parameter	Nominal	STC	Degradasi
Maximum power point (Pmp)	325 Wp	202 Wp	-123 Wp
Open circuit voltage (Voc)	45,6 V	30,6 V	-15,0 V
Short circuit current (Isc)	9,27 A	9,08 A	-0,19 A
Maximum power voltage (Vmp)	37,5 V	24,2 V	-13,3 V
Maximum power current (Imp)	8,69 A	8,36 A	-0,33 A
Fill factor (FF)	0,77	0,73	-0,04

Pada Gambar 10 saat terjadi *short circuit*, arus akan mencapai nilai maksimum yang mungkin dalam sistem, sementara tegangan akan turun hingga nol. *Short circuit* dapat menyebabkan arus yang berlebihan melalui sel-sel *photovoltaic*, menghasilkan panas yang berlebihan, merusak sel, dan bahkan



berpotensi menyebabkan kebakaran. Ini juga menghasilkan kerugian energi yang besar dan mengurangi efisiensi.



Gambar 10 Ilustrasi Kurva I-V pada *short circuit*

Tabel 4 Perbedaan data MPP nominal dan STC pada *short circuit*

Parameter	Nominal	STC	Degradasi
Maximum power point (Pmp)	325 Wp	112 Wp	-213 Wp
Open circuit voltage (Voc)	45,6 V	18,3 V	-27,3 V
Short circuit current (Isc)	9,27 A	9,50 A	0,23 A
Maximum power voltage (Vmp)	37,5 V	12,8 V	-24,7 V
Maximum power current (Imp)	8,69 A	8,76 A	0,07 V
Fill factor (FF)	0,77	0,65	-0,12

Pada Tabel 4 ditampilkan salah satu contoh data-data MPP *photovoltaic* via I-V saat terjadi *short circuit*. Pada saat terjadi hal tersebut beberapa mengalami degradasi yang mengakibatkan menurunnya performa dan produksi sebesar 213 Wp. Berbeda juga dengan *hotspot* dan *bypass diode*



failure, short circuit memiliki degradasi yang lebih besar dikarenakan akan menyebabkan minimal sepertiga atau dua pertiga bagian dari *photovoltaic* tidak dapat beroperasi untuk memproduksi daya. Terjadinya *short circuit* identik dengan adanya lonjakan arus sehingga I_{sc} dan I_{mp} dari kondisi STC dapat melebihi dari kondisi nominalnya sehingga jika terdapat *short circuit* akan berdampak buruk pada sistem jika dibiarkan beroperasi terus-menerus.

2.4 Standard Test Conditions (STC)

STC pada *photovoltaic* merujuk pada kondisi standar yang digunakan untuk mengukur performa *photovoltaic*. STC adalah standar yang ditetapkan oleh industri *photovoltaic* untuk membandingkan performa panel surya secara konsisten. Kondisi standar ini terdiri dari beberapa parameter yang didefinisikan secara spesifik. Dalam konteks STC *photovoltaic*, parameter utama yang digunakan adalah sebagai berikut:

- 1) *Irradiance* (Radiasi Matahari), radiasi matahari yang digunakan dalam pengujian STC adalah 1.000 W/m^2 . Ini mewakili intensitas matahari pada permukaan bumi pada siang hari di lokasi yang terletak di garis lintang 37 derajat dan kondisi atmosfer standar,
- 2) *Photovoltaic Temperature* (Suhu Sel), suhu sel *photovoltaic* diatur pada 25°C (77°F). Suhu ini dianggap sebagai suhu standar yang memungkinkan perbandingan yang konsisten antara panel surya yang berbeda,
- 3) *Air Mass* (Massa Udara), STC mengasumsikan massa udara 1,5 (AM 1,5). Massa udara mengacu pada jumlah jalan yang dilalui sinar matahari melalui atmosfer sebelum mencapai permukaan bumi. AM 1,5 adalah kondisi standar yang digunakan untuk menggambarkan intensitas sinar matahari yang masuk pada panel surya pada permukaan bumi

Dengan menggunakan parameter-parameter ini, pengujian STC digunakan



untuk mengukur karakteristik kelistrikan dari panel surya, seperti V_{oc} , I_{sc} , P_{mpp} , V_{mp} , dan parameter-parameter lain yang relevan. Dengan menggunakan standar ini, hasil pengujian STC memungkinkan perbandingan yang konsisten antara panel surya yang berbeda dan memberikan gambaran yang jelas

tentang kinerja panel surya dalam kondisi ideal. Pada Tabel 5 ditampilkan spesifikasi STC pada *photovoltaic* yang diteliti.

Tabel 5 Spesifikasi STC *photovoltaic* (Trina Solar, 2017)

Parameter	Nilai
Maximum power point (Pmp)	325 Wp
Power output tolerance	0/+5 W
Short circuit current (Isc)	9,27 A
Open circuit voltage (Voc)	45,6 V
Maximum power voltage (Vmp)	37,5 V
Maximum power current (Imp)	8,69 A
Module efficiency	16,6 %
Measuring tolerance	±3 %

2.5 Pengukuran Parameter Kurva I-V

Pada Gambar 11 ditampilkan salah satu alat yang dapat mengukur Kurva I-V ialah SEAWARD PV200 (Complete Kit). Alat ini dapat mengukur karakteristik parameter MPP yang sudah dibahas sebelumnya yaitu Voc, Isc, Pmp, Vmp, Imp, FF dan juga dapat menentukan penurunan performa atau degradasi *photovoltaic* (Yusuf et al., 2021).



Gambar 11 SEAWARD PV200 Complete Kit (Seaward, 2018)




Untuk melakukan pengukuran Kurva I-V perlu diperhatikan bahwa radiasi harus stabil atau di dalam buku panduannya dijelaskan radiasi hanya

dibolehkan naik turun sebesar 10% dari nilai radinasi awal saat dimulai pengukuran. Selain itu, menurut standar IEC 61829:2015 saat melakukan pengukuran nilai radiasi harus minimal 700 W/m^2 sehingga diperlukan intensitas cahaya yang cukup tinggi saat menjelang siang hari (Hossion, 2020).

Pada Gambar 12 ditampilkan ilustrasi saat pengukuran Kurva I-V dilakukan dengan menggunakan *photovoltaic* yang terhubung ke SEAWARD PV200 dengan Solar Survey 200R. Alat ini berfungsi untuk mengukur kurva nilai STC arus-tegangan (I-V) dan segera membandingkan hasilnya dengan nilai nominalnya. Adapun prosesnya sebagai berikut:

- Parameter Voc, Isc, Pmp, Vmp, Imp, FF diukur menggunakan PV 200 sedangkan parameter radiasi matahari, suhu sel dan suhu sekitar dengan menggunakan Solar Survey 200R.
- Simpan data pengukuran Kurva I-V, ekstrak dan simpan semua data tersebut untuk dianalisis. Data yang diperoleh kemudian diolah dan diterjemahkan pada *standar test condition* (STC) agar sesuai dengan data nilai *photovoltaic* pada STC.




Gambar 12 Ilustrasi pengukuran Kurva I-V (Hossion, 2020)

SEAWARD PV200 pada dasarnya melakukan pemindaian (*scanning*) untuk mengukur Kurva I-V pada *photovoltaic* dengan cara mengambil sejumlah titik data. Untuk melakukan pengukuran, SEAWARD PV200 secara otomatis menaikkan level beban (*dummy load*) secara perlahan yang diterapkan pada *photovoltaic*.



sehingga secara simultan merekam arus dan tegangan yang dihasilkan. Selain mengubah level beban, SEAWARD PV200 juga melakukan *data sampling* pengukuran maksimal sebanyak 128 kali dalam satu kali pengukuran (Seaward, 2018). Pada Gambar 13 ditampilkan cara alat ukur SEAWARD PV200 dalam penentuan titik MPP pada Kurva I-V yang telah dikonversi ke bentuk nilai STC.



Gambar 13 Ilustrasi pengaturan level pembeban (Ferdous et al., 2012)

SEAWARD PV200 adalah alat ukur yang digunakan untuk melakukan pengukuran MPP pada Kurva I-V serta pengujian kinerja *photovoltaic* hanya pada suatu waktu tertentu bukan dalam durasi waktu tertentu seperti sehari atau saat jam aktif radiasi matahari. Sehingga hasil ukur yang didapatkan berupa Kurva I-V dan nilai MPP tidak sesuai dengan kondisi riilnya (*real time*) hanya berupa pengukuran dan penentuan titik-titik kritis yang dijadikan parameter data latih dan data uji untuk melakukan klasifikasi kegagalan. Sehingga hal tersebut menjadi sebuah kelemahan dalam penggunaan alat ukur SEAWARD PV200.

Selain itu, pengukuran Kurva I-V dan nilai MPP menggunakan SEAWARD PV200 hanya khususnya dilakukan pada satu kondisi radiasi matahari tertentu yang memanfaatkan jenis Radiasi Matahari Langsung (*Direct Solar Radiation*) sebagai acuan saat pengukuran sedangkan jenis matahari lainnya seperti Radiasi Terserap dan Diserap Kembali (*Absorbed and Re-radiated Solar*)



Radiation), Radiasi Matahari Difus (*Diffuse Solar Radiation*), dan Radiasi Gelombang Panjang (*Long-wave Radiation*) tidak diperhitungkan saat pengukuran yang di mana jenis-jenis radiasi matahari tersebut juga berperan dalam pembentukan daya listrik pada *photovoltaic*.

2.6 Support Vector Machine

Klasifikasi adalah sebuah proses untuk menemukan program atau fungsi yang dapat menggambarkan dan membedakan suatu atau beberapa kelas atau konsep. Model yang didapatkan berdasarkan analisis dari data latih (keterangan kelas diketahui) yang kemudian digunakan untuk memprediksi keterangan kelas yang lain atau tidak diketahui. Salah satu metode klasifikasi telah diperkenalkan oleh peneliti yaitu *machine learning*.

Metode Support Vector Machine (SVM) telah digunakan secara luas dalam klasifikasi kegagalan pada sistem *photovoltaic*. SVM adalah metode pembelajaran yang memanfaatkan teknik pemisahan linear atau non-linear untuk mengklasifikasikan data ke dalam kelas yang berbeda. SVM berupaya untuk mencari *hyperplane* yang memaksimalkan margin pemisahan antara kelas-kelas yang berbeda.

Salah satu penelitian yang menerapkan metode SVM dalam klasifikasi kegagalan *photovoltaic* adalah oleh (Huang et al., 2016). Mereka menggabungkan SVM dengan analisis komponen utama (Principal Component Analysis/PCA) untuk mengklasifikasikan kegagalan pada panel surya. Data yang digunakan meliputi parameter operasional seperti tegangan dan arus. SVM digunakan untuk memisahkan data ke dalam kelas-kelas kegagalan yang berbeda berdasarkan atribut-atribut tersebut.

Penelitian oleh (Huang et al., 2019) juga menerapkan metode SVM dalam analisis kegagalan *photovoltaic*. Mereka menggunakan data kurva karakteristik IV

el surya yang mengalami kegagalan untuk mengklasifikasikan jenis n yang terjadi. SVM digunakan untuk memisahkan kurva-kurva stik ke dalam kelas-kelas kegagalan berdasarkan pola-pola yang ada.



Selain itu, penelitian oleh (Ammar et al., 2020) mengaplikasikan metode SVM dalam klasifikasi kegagalan pada sistem *photovoltaic* yang kompleks. Mereka menggunakan data sensor yang terkait dengan parameter operasional panel surya, seperti suhu, intensitas cahaya, dan tegangan, untuk mengklasifikasikan kegagalan yang terjadi. SVM digunakan untuk memisahkan data ke dalam kelas-kelas kegagalan berdasarkan atribut-atribut tersebut.

Support Vector Machine (SVM) adalah salah satu metode dari *machine learning* berjenis *supervised* karena ketika proses latihan diperlukan target pembelajaran tertentu. SVM merupakan algoritma yang bertujuan untuk mendapatkan atau memecahkan masalah klasifikasi dengan mencari *Maximum Marginal Hyperlane* (MMH). Konsep SVM dapat dinyatakan sebagai algoritma untuk menemukan fungsi pemisah (*classifier / hyperlane*) yang optimal yang bisa memisahkan dua set data dari dua atau beberapa kelas yang berbeda.

Meirista (2015) memisalkan diberikan 2 atribut input A_1 dan A_2 , himpunan $W = \{w_1, w_2, \dots, w_d\}$; W merupakan bobot / *weight*, d adalah jumlah atribut, dan data latih $X = (x_1, x_2)$ dimana x_1 dan x_2 adalah nilai - nilai atribut A_1 dan A_2 , maka fungsi *hyperlane* dapat dituliskan sebagai berikut:

$$f(x) = W \cdot X + b \quad (2.1)$$

dimana $W, X \in^d$ (d adalah jumlah atribut) dan b adalah bias yang berupa skalar.

Hyperlane yang terletak diantara dua set objek dari kelas positif ($y_1 = +1$) dan kelas negatif ($y_2 = -1$) dapat ditulis sebagai berikut:

$$H_1: x_i w + b \geq 1 \text{ untuk } y_1 = +1 \quad (2.2)$$


$$H_2: x_i w + b \leq -1 \text{ untuk } y_2 = -1 \quad (2.3)$$

Penggabungan dari persamaan (2.2) dan (2.3) menghasilkan pertidaksamaan:

$$y_i(x_i w + b) \geq 1, \text{ untuk } \forall i = 1, 2, \dots, n \quad (2.4)$$



n merupakan jumlah data latih.



Gambar 14 Margin besar dan kecil pada hyperlane (Meirista, 2015)

Pada Gambar 14 ditampilkan margin antara dua kelas dapat dihitung dengan mencari jarak antara kedua *hyperplane* H_1 atau H_2 . Setiap pelatihan yang jatuh pada *hyperplane* H_1 atau H_2 yang memenuhi persamaan (2.2) disebut *support vector*. Jarak terdekat suatu titik di bidang H_1 terhadap pusat dapat dihitung dengan meminimalkan $x^T x$ dengan memperhatikan kendala $x_i w + b \geq 1$. Dengan menggunakan bentuk fungsi *Lagrange* dan turunan pertamanya diperoleh:

$$\min x^T x - \lambda(w^T x + b - 1)$$

$$\frac{d}{dx} (x^T x - \lambda(w^T x + b - 1)) = 0$$

$$2x - \lambda w = 0$$

$$x = \frac{\lambda}{2} w$$

Dengan mendistribusiakan x ke bidang H_1 : $x_i w + b = 1$ diperoleh:

$$\frac{\lambda}{2} w^T w + b = 1$$

$$\lambda = \frac{2(1 - b)}{w^T w}$$

Sehingga dengan mendistribusikan kembali λ pada x diperoleh:



$$\frac{-b)}{w^T w} w$$

$$x^T x = \frac{(1-b)^2}{(w^T w)^2} w^T w = \frac{(1-b)^2}{w^T w}$$

Maka jarak H_1 ke pusat adalah:

$$\|x\| = \sqrt{x^T x} = \sqrt{\frac{(1-b)^2}{w^T w}} = \frac{(1-b)}{\|w\|}$$

Untuk mencari jarak terdekat suatu titik pada bidang H_2 terhadap titik pusat dapat dihitung dengan meminimalkan $x^T x$ dengan memperhatikan kendala $x_i w + b \leq -1$. Dengan menggunakan bentuk fungsi *Lagrange* dan turunan pertamanya diperoleh:

$$\min x^T x - \lambda(w^T x + b + 1)$$

$$\frac{d}{dx} (x^T x - \lambda(w^T x + b + 1)) = 0$$

$$2x + \lambda w = 0$$

$$x = -\frac{\lambda}{2} w$$

Dengan mendistribusiakan x ke bidang H_2 : $x_i w + b = -1$ diperoleh:

$$-\frac{\lambda}{2} w^T w + b = -1$$

$$\lambda = \frac{2(b+1)}{w^T w}$$

Sehingga dengan mendistribusikan kembali λ pada x diperoleh:

$$x = \frac{(-b-1)}{w^T w} w$$

$$x^T x = \frac{(-b-1)^2}{(w^T w)^2} w^T w = \frac{(-b-1)^2}{w^T w}$$

Maka jarak H_1 ke pusat adalah:



$$\sqrt{x^T x} = \sqrt{\frac{(-b-1)^2}{w^T w}} = \frac{(-b-1)}{\|w\|}$$

Margin maksimum didapatkan dengan memaksimalkan jarak antara H_1 dan H_2 :

$$\left| \frac{(1-b)}{\|w\|} - \frac{(-b-1)}{\|w\|} \right| = \frac{2}{\|w\|}$$

Oleh karena memaksimalkan $\frac{1}{\|w\|}$ sama dengan meminimumkan $\|w\|^2$ dan untuk menyederhanakan penyelesaian ditambahkan faktor $\frac{1}{2}$. Dengan demikian, model persamaannya menjadi:

$$\text{Min } \frac{1}{2} \|w\|^2 \quad (2.5)$$

$$y_i(x_i w + b) \geq 1, \text{ untuk } \forall i = 1, 2, \dots, n \text{ (} n \text{ merupakan jumlah data latih)}$$

2.6.1 Metode Kernel

Secara umum, kasus klasifikasi di dunia nyata adalah kasus yang tidak linier sehingga digunakan metode kernel untuk mengatasi masalah tersebut. Dengan menggunakan metode kernel suatu data x di *input space* dipetakan ke *feature space* F dengan dimensi yang lebih tinggi melalui *map* φ ($\varphi: x \rightarrow \varphi(x)$). Oleh karena itu, x di *input space* menjadi $\varphi(x)$ di *feature space*. Sering kali fungsi $\varphi(x)$ tidak tersedia atau tidak dapat dihitung. Tetapi *dot product* dari dua vektor dapat dihitung, baik dalam *input space* maupun di *feature space*

$$K(X_i \cdot X_j^T) = \varphi(X_i) \cdot \varphi(X_j) \quad (2.6)$$

Fungsi Kernel yang umum digunakan adalah sebagai berikut:

$$\text{Kernel Derajat Polinomial } h: K(X_i \cdot X_j^T) = (X_i \cdot X_j^T + 1)^h \quad (2.7)$$

$$\text{Kernel Fungsi Gaussian Radial Basis: } K(X_i \cdot X_j^T) = \frac{e^{-\|x_i - x_j\|^2}}{2\sigma^2} \quad (2.8)$$

$$\text{Kernel Sigmoid: } K(X_i \cdot X_j^T) = \tanh(X_i \cdot X_j^T - \delta) \quad (2.9)$$



erdasarkan formula *langrarian*, MMH dapat didefinisikan sebagai *decision*:

$$(\sum_{i=1}^l \alpha_i y_i \varphi(X_i) \cdot \varphi(X_Z) + b) \quad (2.10)$$

Keterangan:

$\varphi(X_i) \cdot \varphi(X_Z)$ = *inner product* antara data *support vector* dengan data uji.

= fungsi *signum* yaitu nilai yang lebih besar dari 0

sign dilabelkan +1 dan semua nilai yang lebih kecil dari 0
dilabelkan -1.

X_Z = $(z_{11}, z_{12}, \dots, z_{1k})$, k adalah jumlah data uji.

2.6.2 Orde Polynomial

Fungsi kernel polynomial adalah salah satu jenis fungsi kernel yang digunakan dalam algoritma SVM. Fungsi kernel digunakan untuk mengubah data ke dalam ruang dimensi yang lebih tinggi, di mana dapat menjadi lebih mudah dipisahkan. Fungsi kernel polynomial melakukan transformasi data ke dalam ruang dimensi yang lebih tinggi dengan menggunakan polynom sebagai fungsi dasarnya (Murphy, 2012). Fungsi kernel polynomial mengambil dua vektor input dan memetakan mereka ke dalam ruang dimensi yang lebih tinggi dengan menggunakan polynom sebagai fungsi dasarnya. Fungsi kernel polynomial orde-d dinyatakan sebagai:

$$K(x, y) = (x \cdot y + c)^d \quad (2.11)$$

$$y = a^0 + a^1x + a^2x^2 + a^3x^3 + \dots + a^nx^n \quad (2.12)$$

$$\begin{pmatrix} 1 & x_1 & x_1^2 & \dots & x_1^{n-1} & y_1 \\ 1 & x_2 & x_2^2 & \dots & x_2^{n-1} & y_2 \\ 1 & x_3 & x_3^2 & \dots & x_3^{n-1} & y_3 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 1 & x_n & x_n^2 & \dots & x_n^{n-1} & y_n \end{pmatrix} \quad (2.13)$$


dengan (x) dan (y) adalah vektor input, $(\cdot)$ adalah operasi *dot product*, (c) adalah 1, dan (d) adalah orde polynomial yang menentukan derajat transformasi. Fungsi polynomial menentukan sejauh mana data akan ditingkatkan. Semakin tinggi nilai (d) semakin tinggi dimensi ruang yang dihasilkan. Nilai (d) yang lebih tinggi



akan menghasilkan transformasi ke dimensi yang lebih tinggi, tetapi dapat lebih rentan terhadap overfitting.

Nilai (d) yang rendah mungkin lebih stabil tetapi mungkin kurang mampu menangani pola yang kompleks dalam data. Pemilihan orde yang optimal perlu dilakukan berdasarkan eksperimen dan validasi silang. Dengan meningkatkan nilai (d) akan memberikan axis lebih beragam sehingga akan menghasilkan ruang *space* yang luas yang dapat membantu dalam pemisahan dan pengelompokan data yang berguna untuk proses klasifikasi data.

Pada rumus (2.12) merupakan bentuk fungsi polynomial yang akan membentuk hyperlane pada ruang space dalam proses klasifikasi. Koefisien a^0, a^1, a^2, a^3 dan x^n merupakan hasil perhitungan dengan menggunakan metode eliminasi Gauss-Jordan seperti pada rumus (2.13). Pada Gambar 15 ditampilkan proses terjadinya dan perbedaan masing-masing ruang dimensi dengan meningkatnya jumlah axis pada setiap titik sehingga memperluas ruang *space*.



Gambar 15 Perbedaan ruang dimensi orde-n (Otomo et al., 2014)



2.7 Validasi & Kombinasi Metode

2.7.1 Naïve Bayes

Selain menggunakan metode SVM untuk mengklasifikasi kondisi *photovoltaic* berdasarkan data MPP, akan juga dilakukan validasi dengan metode Naïve Bayes. Naïve Bayes merupakan pengklasifikasian dengan metode probabilitas dan statistik yang memprediksi peluang berdasarkan pengalaman sebelumnya yang dikemukakan oleh ilmuwan Thomas Bayes. Metode Naïve Bayes telah digunakan secara efektif dalam klasifikasi kegagalan *photovoltaic*. Dalam analisis keandalan sistem *photovoltaic*, penting untuk mengidentifikasi dan mengklasifikasikan kegagalan yang terjadi. Metode Naïve Bayes dapat membantu dalam mengklasifikasikan kegagalan tersebut berdasarkan indikator-indikator yang diamati pada kurva karakteristik *photovoltaic*.

Salah satu penelitian yang mengaplikasikan metode Naïve Bayes dalam klasifikasi kegagalan *photovoltaic* adalah oleh (El-Din et al., 2015). Mereka mengidentifikasi kegagalan pada sistem *photovoltaic* dengan menggunakan data kurva karakteristik IV. Metode Naïve Bayes digunakan untuk mengklasifikasikan jenis kegagalan yang terjadi berdasarkan pola kurva karakteristik yang diamati. Selain itu, penelitian oleh (Ben Abdennour et al., 2019) juga menerapkan metode Naïve Bayes dalam analisis kegagalan *photovoltaic*. Mereka menggunakan data monitoring yang terkait dengan parameter operasional panel surya, seperti suhu, tegangan, dan arus, untuk mengklasifikasikan kegagalan yang terjadi. Metode Naïve Bayes digunakan untuk mengidentifikasi pola-pola kegagalan berdasarkan data monitoring yang diamati.

Selain itu, metode Naïve Bayes juga telah diterapkan dalam klasifikasi kerusakan pada modul *photovoltaic*. Misalnya, penelitian oleh (Bui et al., 2020) mengklasifikasikan kerusakan pada modul *photovoltaic* berdasarkan data termografik yang diamati. Metode Naïve Bayes digunakan untuk mengklasifikasikan jenis kerusakan berdasarkan pola suhu yang terdeteksi. Metode

Naïve Bayes merupakan pendekatan statistik untuk melakukan inferensi induksi pada masalah klasifikasi. Metode ini menggunakan probabilitas bersyarat.



Pendekatan ini adalah cara untuk mengatasi ketidakpastian dengan menggunakan formula Bayes. Teorema Naïve Bayes dirumuskan sebagai berikut:

$$P(H|X) = \frac{P(X|H) \cdot P(H)}{P(X)} \quad (2.11)$$

Dimana:

- X : Data dengan kelas yang belum diketahui
- H : Hipotesis data yang merupakan suatu kelas spesifik
- $P(H|X)$: Probabilitas hipotesis H berdasarkan kondisi X
- $P(H)$: Probabilitas hipotesis H
- $P(X|H)$: Probabilitas X berdasarkan kondisi pada hipotesis H
- $P(X)$: Probabilitas X

Untuk atribut yang mempunyai bertipe data numerik, dinyatakan dalam formula Gaussian Naïve Bayes berikut:

$$P(H|X) = \frac{1}{\sqrt{2\pi}\sigma_{ij}} e^{-\frac{(x_i - \mu_{ij})^2}{2\sigma_{ij}^2}} \quad (2.12)$$

Dimana:

- $P(H|X)$: Merupakan probabilitas data dengan atribut X pada kelas H
- x_i : Merupakan nilai dari atribut yang dicari
- σ_{ij} : Merupakan standar deviasi dari atribut yang ditanyakan
- μ_{ij} : Merupakan mean (rata-rata) dari atribut yang ditanyakan

2.7.2 K-Nearest Neighbors



Metode K-Nearest Neighbors (KNN) telah menjadi salah satu pendekatan populer dalam klasifikasi kegagalan pada sistem *photovoltaic*. Metode KNN berdasarkan prinsip bahwa objek yang serupa cenderung berada dalam kategori yang sama dalam ruang fitur. Dalam konteks klasifikasi kegagalan

photovoltaic, metode KNN dapat digunakan untuk mengklasifikasikan jenis kegagalan berdasarkan atribut-atribut yang diamati.

Salah satu penelitian yang menerapkan metode KNN dalam klasifikasi kegagalan *photovoltaic* adalah oleh (Khedr et al., 2017). Mereka menggunakan data monitoring yang terkait dengan parameter operasional, seperti suhu, intensitas cahaya, dan arus, untuk mengklasifikasikan kegagalan yang terjadi. Metode KNN digunakan untuk mengidentifikasi tetangga terdekat dari suatu sampel kegagalan dan kemudian mengklasifikasikannya berdasarkan mayoritas label tetangga. Penelitian oleh (Malathi et al., 2019) juga menerapkan metode KNN dalam analisis kegagalan *photovoltaic*. Mereka menggunakan data kurva karakteristik IV dari *photovoltaic* yang mengalami kegagalan untuk mengklasifikasikan jenis kegagalan yang terjadi. Selain itu, penelitian oleh (Alshehri et al., 2020) mengaplikasikan metode KNN dalam klasifikasi kegagalan pada sistem *photovoltaic* yang kompleks. Mereka menggunakan data sensor yang terkait dengan parameter operasional seperti suhu, tegangan, dan kelembaban, untuk mengklasifikasikan kegagalan yang terjadi.

Metode KNN adalah sebuah algoritma klasifikasi yang sederhana namun efektif. Prinsip dasar dari metode KNN adalah dengan mengklasifikasikan sebuah data baru berdasarkan mayoritas label dari K tetangga / neighbors terdekatnya dalam ruang fitur. KNN memiliki beberapa rumus yang digunakan dalam proses pengklasifikasian, yaitu:

$$\text{Jarak Euclidean: } d(x, y) = \|x - y\| = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.13)$$

$$\text{Jarak Manhattan: } d(x, y) = \sum_{i=1}^n (|x_i - y_i|) \quad (2.14)$$

2.8 State of Art Penelitian

Tabel 6 State of art penelitian

Judul	Metode	Hasil Penelitian	Referensi
ct of the	Support Vector	Hasil terbaik pada	Ertugrul et
lust to the	Machine SVM	monocrystalline yaitu	al., 2023



Judul	Metode	Hasil Penelitian	Referensi
<i>efficiency of photovoltaic panels efficiency by SVM</i>	seperti Cubic, Quadratic, dan Fine Gaussian	menggunakan metode Cubic SVM sebesar 82,1% dan pada polycrystalline yaitu menggunakan metode Fine Gaussian SVM sebesar 88,7%	
<i>Defining the best-fit machine learning classifier to early diagnose photovoltaic solar cells hotspots</i>	Support Vector Machine SVM seperti Linear, Cubic, dan Quadratic	Kalsifikasi dengan Linear SVM sebesar 95,6%, Cubic SVM sebesar 97,9% dan Quadratic SVM sebesar 98,3%	Dhimish, 2021
<i>A Combined convolutional neural network model and support vector machine technique for fault detedtion and classification based on electroluminescence images of photovoltaic modules</i>	Kombinasi antara Neural Network dan Support Vector Machine	Persentase keakuratan metode kombinasi NN dan SVM untuk klasifikasi yaitu sebesar 99,49% untuk database ke-1 dan 99,46% untuk database ke-2	Abdelilah et al., 2022
<i>Electrical Fault diagnosis of Solar panel Using</i>	Support Vector Machine	Model terbaik dalam melakukan diagnosis yaitu Support Vector	Al-Zubaidi et al., 2023



Judul	Metode	Hasil Penelitian	Referensi
<i>Machine Learning Techniques</i>		Machine sebesar 99,7%	
<i>A machine learning framework to identify the hotspot in photovoltaic module using infrared thermography</i>	Support Vector Machine	Hasil metode SVM lebih unggul dengan akurasi pelatihan 96,8% dan akurasi pengujian 92%	Ali et al., 2020
<i>Photovoltaic Cell Defect Detection Model based-on Extracted Electroluminescence Images using SVM Classifier</i>	Support Vector Machine	Hasil metode SVM dengan akurasi sebesar 95%	Serfa dan Kim, 2020
<i>Hotspot diagnosis for solar photovoltaic modules using a Naive Bayes classifier</i>	Naïve Bayes	Klasifikasi <i>hotspot</i> dengan konsep <i>thermal imager</i> . Hasil metode Naïve Bayes dengan akurasi sebesar 94,1%	Kamran et al., 2019
<i>A Comparison of Machine Learning-Based Methods for Fault Classification in Photovoltaic</i>	Support Vector Machine & K-Nearest Neighbor	Hasil klasifikasi dengan metode SVM akurasi sebesar 98,64% dan dengan metode K-Nearest Neighbor sebesar 82,50%	Da Costa et al., 2019

