

TESIS
IMPLEMENTASI *DEEP LEARNING* UNTUK PENDETEKSIAN
***SNAIL TRAILS* PADA MODUL SEL SURYA**

Disusun dan Diajukan oleh:

FITRIYANTY DWI LESTARY

D032 20 1 007



PROGRAM PASCA SARJANA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA

2023

UJIAN TUTUP TESIS

**IMPLEMENTASI *DEEP LEARNING* UNTUK PENDETEKSIAN
SNAIL TRAILS PADA MODUL SEL SURYA**

*Deep Learning Implementation for Snail Trails Detection in Photovoltaic
Module*

FITRIYANTY DWI LESTARY

D032201007



**PROGRAM PASCA SARJANA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA**

2023

PENGAJUAN TESIS

**IMPLEMENTASI *DEEP LEARNING* UNTUK PENDETEKSIAN
SNAIL TRAILS PADA MODUL SEL SURYA**

Tesis

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

Disusun dan diajukan oleh

FITRIYANTY DWI LESTARY

D032201007

Kepada

**FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN**

GOWA

2023

TESIS

IMPLEMENTASI *DEEP LEARNING* UNTUK PENDETEKSIAN *SNAIL TRAILS* PADA MODUL SEL SURYA

FITRIYANTY DWI LESTARY
D032201007

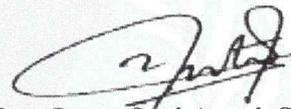
Telah dipertahankan dihadapan Panitia Ujian Tesis yang dibentuk dalam rangka penyelesaian studi Program Magister Teknik Elektro Fakultas Teknik Universitas Hasanuddin.
Pada tanggal 13 Januari 2023
dan dinyatakan telah memenuhi syarat kelulusan

Pembimbing Utama



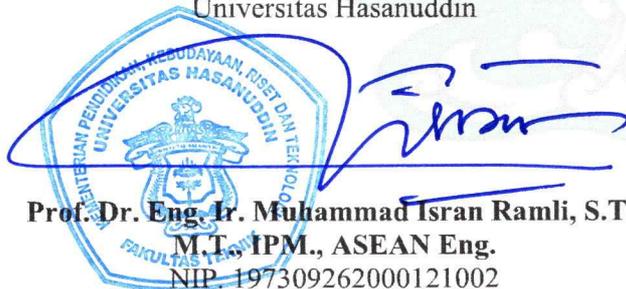
Prof. Dr. Eng. Ir. Syafaruddin, S.T., M.Eng., IPU
NIP. 197405301999031003

Pembimbing Pendamping



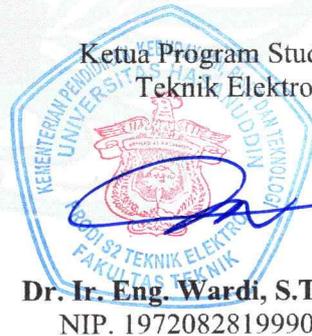
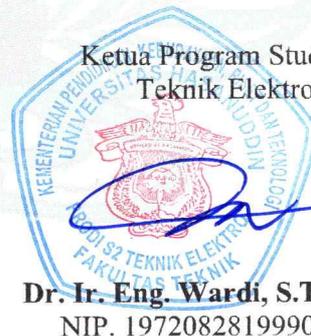
Dr. Eng. Intan Sari Areni, S.T., M.T.
NIP. 197502032000122002

Dekan Fakultas Teknik
Universitas Hasanuddin



**Prof. Dr. Eng. Ir. Muhammad Isran Ramli, S.T.,
M.T., IPM., ASEAN Eng.**
NIP. 197309262000121002

Ketua Program Studi S2
Teknik Elektro



Dr. Ir. Eng. Wardi, S.T., M.Eng
NIP. 197208281999031003

PERNYATAAN KEASLIAN TESIS DAN PELIMPAHAN HAK CIPTA

Yang bertanda tangan dibawah ini

Nama : Fitriyanty Dwi Lestary

Nomor Mahasiswa : D032201007

Program Studi : Teknik Elektro

Dengan ini menyatakan tesis bahwa, yang berjudul “IMPLEMENTASI *DEEP LEARNING* UNTUK PENDETEKSIAN *SNAIL TRAILS* PADA MODUL SEL SURYA” adalah benar karya saya dengan arahan dari komisi pembimbing Prof. Dr. Eng. Ir. Syafaruddin, S.T., M.Eng., IPU dan Dr. Eng. Intan Sari Areni, S.T., M.T. Karya ilmiah ini belum diajukan atau tidak sedang diajukan dalam bentuk apapun kepada perguruan tinggi manapun. Sumber informasi yang dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks yang dicantumkan dalam Daftar Pustaka tesis ini. Sebagian dari tesis ini telah dipublikasikan di Jurnal/Prosiding (2022 FORTEI-International Conference on Electrical Engineering (FORTEI-ICEE) DOI: 10.1109/FORTEI-ICEE57243.2022.9972952) sebagai artikel dengan judul *Deep Learning Implementation for Snail Trails Detection in Photovoltaic Module*.

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

Gowa, 17 Januari 2023

Yang menyatakan



Fitriyanty Dwi Lestary

KATA PENGANTAR

Puji dan syukur penulis panjatkan kepada Tuhan Yang Maha Esa karena berkat rahmat dan karunia-Nya sehingga tugas akhir yang berjudul “Implementasi *Deep Learning* untuk Pendeteksian *Snail Trails* pada Modul Sel Surya” ini dapat diselesaikan sebagai salah satu syarat dalam menyelesaikan jenjang Magister pada Departemen Teknik Elektro Fakultas Teknik Universitas Hasanuddin.

Penulis menyadari bahwa dalam penyusunan dan penulisan laporan tugas akhir ini tidak lepas dari bantuan, bimbingan serta dukungan dari berbagai pihak, dari masa perkuliahan sampai dengan masa penyusunan tugas akhir. Oleh karena itu, penulis dengan senang hati menyampaikan terima kasih kepada:

1. Tuhan Yang Maha Esa yang telah memberikan rahmat dan hidayah-Nya kepada penulis untuk bisa menyelesaikan tesis ini dengan baik.
2. Kedua orang tua penulis, yang selalu menjadi motivasi penulis dari kecil hingga berada pada tahap ini dan menyelesaikan penyusunan tugas akhir ini;
3. Bapak Prof. Dr. Eng. Ir. Syafaruddin, S.T., M.Eng., IPU selaku pembimbing I yang senantiasa memberikan saran-saran serta bantuan selama proses pengambilan data hingga selesainya sistem ini dibuat, dan Ibu Dr. Eng Intan Sari Areni, ST., M.T selaku pembimbing II yang selalu menyediakan waktu untuk mengingatkan penulis untuk selalu semangat menyelesaikan penulisan penyusunan tugas akhir ini.
4. Bapak Dr. Eng. Ir. Wardi, S.T., M.Eng. selaku Ketua Departemen Teknik Elektro Fakultas Teknik Universitas Hasanuddin yang telah membimbing penulis selama masa perkuliahan.
5. Bapak dan Ibu tenaga pengajar Departemen Teknik Elektro Fakultas Teknik Universitas Hasanuddin yang telah memberikan bimbingan dan ilmunya kepada penulis selama masa perkuliahan.
6. Saudara saya Rizky Eka Liyanty, S.T., M.T yang menjadi panutan saya, dalam setiap mengambil langkah saat menempuh masa studi, juga sebagai penasihat saya terbaik bagi diri saya.

7. Teman teman saya, Inggi Ramadhani, S.T., Begita Wahyuningtyas, S.T, Gloria Mariance, S.T, yang selalu memotivasi saya, dan menemani saya dalam mengkoreksi setiap penyusunan dalam tesis ini.
8. Teman saya, Muh. Arief Wicaksono, S.T. yang telah meluangkan waktu untuk mengajari saya mengenai materi *deep learning* baik secara luring maupun daring.
9. Mentor saya, Muh. Fajar B., S.Pd., M.cs. yang sudah meluangkan waktu mengajari, dan membantu penulis pada setiap sharing session dan proses submit artikel ilmiah.
10. Teman saya Moh. Amiruddin Haryana Rahman, Amd.T. yang telah menemani saya dalam perjalanan pengambilan dataset untuk penelitian ini.
11. Kakak tingkat saya A. Najiah Nurul Afifah Ibrahim, S.T yang sedang menempuh studi S3 dan telah meluangkan waktu untuk berbagi ilmu dan pengalaman tentang *image processing*.
12. Teman teman kantor saya yang sudah memahami dan mendukung masa perkuliahan saya, walaupun disisi lain saya harus memenuhi kewajiban saya sebagai seorang karyawan.
13. Orang-orang berpengaruh lainnya yang tanpa sadar telah memotivasi dan membantu penulis.

Penulis menyadari bahwa tesis ini masih jauh dari sempurna. Untuk itu saran beserta kritikan yang membangun sangat diharapkan. Semoga karya ini dapat bermanfaat bagi kita semua.

Wassalam
Makassar, Januari 2023

Penulis

ABSTRAK

FITRIYANTY DWI LESTARY. Implementasi *Deep Learning* untuk Pendeteksian *Snail Trails* pada Modul Sel Surya (dibimbing oleh, **Syafaruddin, Intan Sari Areni**).

Penurunan cadangan bahan bakar fosil serta antusiasme yang meningkat pada pengembangan sumber daya terbarukan telah membuat dunia mencari dan menciptakan sumber daya alternatif yang bersih dan terbarukan. Diantara sumber energi alternatif yang tersedia, energi surya diklaim sebagai pilihan utama yang dapat menggantikan sumber daya fosil untuk menghadapi tuntutan kebutuhan konsumsi daya pada saat ini karena persediaan energi surya yang tak terbatas. Namun kesadaran untuk memeriksa kondisi PV dalam dekade pemakaiannya masih sangat rendah, sehingga deteksi *snail trails* ini diperlukan untuk mengetahui peformansi *snail trails* sebagai langkah awal pencegahan kerusakan yang berkelanjutan. Penelitian ini bertujuan untuk mengembangkan sistem dektesi *snail trails* pada citra modul fotovoltaik menggunakan metode deep learning dengan algoritma YOLO (*You Only Look Once*) versi ke 3. Ada beberapa proses penting yang diperlukan pada metode YOLOv3 yaitu anotasi citra, dan pelatihan data dan pengujian data. Hasil *mean average precision* pada simulasi pelatihan dalam mengenali dan mendeteksi objek *snail trails* pada modul fotovoltaik sebesar 89,29%. Nilai ini menunjukkan bahwa metode ini dapat diusulkan untuk kontribusi dalam implementasi pengembangan penelitian pendeteksian kerusakan yang efektif sejak dini pada modul panel surya.

Kata Kunci: *Photovoltaic module; Snail trails detection; Image processing; YOLOv3*

ABSTRACT

FITRIYANTY DWI LESTARY. *Deep Learning Implementation for Snail Trails Detection in Photovoltaic Module* (supervised by, **Syafaruddin, Intan Sari Areni**).

The decline in fossil fuel reserves as well as the growing enthusiasm for the development of renewable resources have led the world to seek out and create clean and renewable alternative resources. Among the alternative energy sources available, solar energy is claimed to be the top choice that can replace fossil resources to face the demands of power consumption needs at this time due to the unlimited supply of solar energy. However, awareness of checking the condition of PV in the decades of use is still very low, so the detection of these snail trails is necessary to know the formation of snail trails as the first step in continuous damage prevention. This study aims to develop a snail trails detection system on photovoltaic module imagery using the deep learning method with the 3rd version of the YOLO (You Only Look Once) algorithm. There are several important processes required in the YOLOv3 method, namely image annotation, and data training and data testing. The mean average precision result in the training simulation in recognizing and detecting snail trails objects on the photovoltaic module was 89.29%. This value indicates that this method can be proposed for contribution in the implementation of the development of effective damage detection research early on solar panel modules.

Kata Kunci: *Photovoltaic module; Snail trails detection; Image processing; YOLOv3*

DAFTAR ISI

HALAMAN JUDUL	ii
PENGAJUAN TESIS.....	iii
PERSETUJUAN TESIS	iv
PERNYATAAN KEASLIAN TESIS	v
KATA PENGANTAR.....	vi
ABSTRAK	viii
ABSTRACT	ix
DAFTAR ISI.....	x
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL.....	xiv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan Masalah.....	5
1.4 Manfaat Penelitian	5
1.5 Batasan Masalah.....	5
1.6 Penelitian Terkait	6
1.7 Sistematika Penulisan	14
BAB II	16
TINJAUAN PUSTAKA	16
2.1 Panel Surya	16
2.2 Kerusakan Panel Surya.....	17
2.3 Teknik Inspeksi Panel Surya.....	22
2.4 <i>Artificial Intelligence</i>	24
2.3 <i>Featuring Learning</i>	25
2.4 <i>Convolutional Neural Network</i>	27
2.5 <i>Yolov3</i>	31
2.6 <i>Intersection over Union (IoU)</i>	33
2.7 <i>Mean Average Precision (mAP)</i>	34

2.8	<i>F-Measure</i>	34
2.9	<i>Precision</i>	35
2.10	<i>Recall</i>	35
2.11	<i>Confusion Matrix</i>	35
2.12	<i>Fill Factor</i>	35
BAB III		37
METODE PENELITIAN		37
3.1	Tahap Penelitian	37
3.2	Waktu dan Tempat Penelitian	38
3.3	Jenis Penelitian	40
3.4	Perancangan Sistem	40
3.4.1	Pengambilan Data.	41
3.4.2	Blok Diagram <i>Processing Data</i>	42
BAB IV		49
HASIL DAN PEMBAHASAN		49
4.1	Tahap Penelitian dan Perancangan Data.	49
4.1.4	Kebutuhan Perangkat.	49
4.1.2	Tahap Pra-pemrosesan Data.	50
4.1.3	<i>Training Stages.</i>	51
4.2	Evaluasi Hasil <i>Training</i>	57
4.3	Proses <i>Testing</i>	61
4.4	Hasil Analisa Pengujian	64
4.4.1	Hasil Analisa Pengaruh Penambahan <i>Max Batches</i> pada <i>Training.</i>	64
4.4.2	Hasil Analisa Pengaruh Jarak Terhadap Deteksi Objek.	65
4.4.3	Analisa Dampak Pengaruh Kemunculan <i>Snail Trails.</i>	68
BAB V		72
5.1	KESIMPULAN	72
5.2	SARAN	73
DAFTAR PUSTAKA		74
LAMPIRAN		78
	Dokumentasi Pengambilan Data	78

<i>Source Code Training YOLOv3 dengan Framework Darknet.....</i>	80
<i>Source Code Testing Snail Trails dengan YOLOv3</i>	83

DAFTAR GAMBAR

Gambar 3. 1 Lokasi pengambilan dataset citra di PLTS Pulau Karanrang.....	38
Gambar 3. 2 Rangkain panel surya yang terpasang di PLTS Pulau Karanrang....	40
Gambar 3. 3 Blok diagram perancangan sistem deteksi snail trails.....	41
Gambar 3. 4 Protokol pengambilan Citra.	41
Gambar 3. 5 Hasil gambar yang ditangkap oleh kamera drone UAV	42
Gambar 3. 6 Proses training pada dataset citra	43
Gambar 3. 7 Proses konvolusi pada dataset citra.....	45
Gambar 3. 8 Proses pengujian pada dataset citra.....	47
Gambar 4. 1 Contoh dataset yanga kan diolah pada proses training	49
Gambar 4. 2 Proses anotasi pada citra, dengan cara melabel dataset citra secara manual.....	51
Gambar 4. 3 Hasil anotasi citra yang telah dilabel, yang berbentuk file txt	51
Gambar 4. 4 Arsitektur Darknet 53.....	52
Gambar 4. 5 Proses menghubungkan ke open CV dan GPU.....	55
Gambar 4. 6 Proses untuk membangun jaringan dakrnet53	55
Gambar 4. 7 Proses duplikasi data ke folder darknet yang telah dibangun agar sistem dapat membaca data yang akan di training	56
Gambar 4. 8 Proses training citra.....	56
Gambar 4. 9 Proses training dengan max batches 1000.....	57
Gambar 4. 10 Proses training dengan max batches 2000.....	58
Gambar 4. 11 Proses training dengan max batches 4000.....	59
Gambar 4. 12 Proses training dengan max batches 5000.....	60
Gambar 4. 13 Area pada panel surya yang terpapar snail trails.....	69

DAFTAR TABEL

Tabel 1. 1 State of The Art.....	6
Tabel 3. 1 Spesifikasi Panel Surya	39
Tabel 3. 2 Spesifikasi Alat	39
Tabel 3. 3 Struktur Jaringan Darknet53	44
Tabel 3. 4 Tabel perhitungan confusion matrix	47
Tabel 4. 1 Spesifikasi perangkat lunak untuk penggunaan proses training	50
Tabel 4. 2 Confusion matrix hasil training 2 objek class.	61
Tabel 4. 3 Hasil Pengujian citra untuk deteksi objek snail trails	62
Tabel 4. 4 Perbandingan hasil mAP proses training	64
Tabel 4. 5 Nilai confidence dataset pengujian dari perbedaan jarak pengambilan gambar.....	65
Tabel 4. 6 Pengaruh snail trails terhadap daya yang dihasilkan	70

BAB I

PENDAHULUAN

1.1 Latar Belakang

Penurunan cadangan bahan bakar fosil dan peningkatan risiko pemanasan global telah membuat dunia khawatir untuk mencari sumber energi berkelanjutan yang bersih dan terbarukan. Penggunaan bahan bakar fosil secara ekstensif telah mempercepat terjadinya pencemaran lingkungan [1]. Akibatnya, kondisi tersebut telah menyebabkan beberapa situasi yang mengkhawatirkan seperti efek rumah kaca, *global warming*, penipisan lapisan ozon, hingga hujan asam dan perubahan iklim. Untuk mengurangi dampak pencemaran lingkungan tersebut, maka pembangunan berkelanjutan seperti, pengurangan tingkat emisi dengan meningkatkan kualitas bahan bakar fosil, memilih bahan energi terbarukan untuk bakar fosil dengan energi alternatif yang tersedia di alam serta ramah lingkungan, terbarukan dan bersih menjadi solusi utama yang sedang dilakukan [2].

Di antara sumber energi alternatif yang tersedia, energi surya diklaim sebagai pilihan utama untuk menghadapi tuntutan konsumsi daya saat ini. Pembangkit listrik berbasis energi surya telah mendapatkan perhatian yang luar biasa dan telah mencapai perkembangan yang fenomenal di seluruh dunia. Penggunaan langsung energi matahari untuk produksi energi listrik dalam menghadapi perkembangan yang intens terkait kebijakan pengurangan emisi karbon dioksida (CO_2) yang sedang berlangsung dan perkembangan teknis yang signifikan dari teknologi fotovoltaik. Modul fotovoltaik (PV) digunakan di bidang pembangkit listrik berbasis energi surya yang nantinya energi matahari disintesis dan diubah menjadi listrik dengan bantuan modul fotovoltaik (PVM). Dalam dekade terakhir ini, dan peningkatan yang terjadi sangat signifikan dalam pengembangan energi PV yang mendukung transisi dari fosil ke masyarakat hijau. Konversi semacam itu kemungkinan akan berlangsung dalam jangka panjang yang menghasilkan pengurangan emisi karbon dan peningkatan produksi energi hijau [3]. Pengurangan biaya awal dan pasokan listrik yang tidak terputus adalah alasan utama untuk mengadopsi pembangkit listrik berbasis energi surya. Laporan

terbaru oleh *International Energy Agency* (IEA) memprediksi bahwa total produksi listrik dunia berdasarkan sumber energi terbarukan akan meningkat lebih dari 50% antara 2019 dan 2024 di mana pembangkit listrik berbasis surya menyumbang sekitar 60%. Selain itu, biaya keseluruhan pembangkit listrik melalui PVM telah menurun sekitar 81% dalam 10 tahun terakhir. Faktor-faktor ini telah mempercepat pemasangan PLTS besar di seluruh dunia dan diharapkan total instalasi dapat mencapai 740 GW pada tahun 2022. Karena permintaan untuk pembangkit listrik dan peningkatan fasilitas terpasang melibatkan fungsi peformansi fotovoltaik modul yang efektif [4].

Namun, selama beberapa dekade terakhir, biaya produksi sel PV telah turun, membuat biaya listrik akan mendekati biaya bahan bakar konvensional. Penurunan peformansi tersebut karena adanya kejadian kesalahan tidak dapat dihindari dalam fotovoltaik modul karena operasinya di bawah kondisi eksternal yang tidak menguntungkan. Kejadian kesalahan tersebut mempengaruhi masa pakai dan keandalan fotovoltaik modul. Untuk memastikan operasi masa pakai fotovoltaik modul yang berkelanjutan, pemantauan yang sering dan deteksi kesalahan sistem PV secara tepat waktu sangat penting. Terjadinya gangguan pada fotovoltaik modul disebabkan karena tiga faktor utama, yaitu kerusakan fisik (kerusakan yang sering terjadi pada tahap pengangkutan dan pemasangan), kerusakan akibat korsleting listrik, dan kerusakan akibat lingkungan seperti kondisi (tekanan termal, kelembaban, awan, dll.). Di antara faktor-faktor tersebut diatas, gangguan akibat kerusakan fisik dan kondisi lingkungan merupakan kerusakan yang paling sering terjadi mengikuti masa usia pemakaian modul sel surya. Berbagai patahan yang terjadi akibat kerusakan fisik dan kondisi lingkungan antara lain pecahan kaca, bekas terbakar, delaminasi, perubahan warna dan jejak siput atau *snail trails* ini menyebabkan potensi degradasi yang diinduksi atau *potential induced degradation* (PID) yang dapat menyebabkan penurunan yang signifikan dalam output daya PVM (lebih dari 30%) [5]. Salah satu kerusakan fisik akibat lingkungan yaitu menyebabkan munculnya patahan dan *snail trails* pada permukaan modul fotovoltaik [6]. Bentuk *snail trails* seperti garis gelap kecil yang sempit dan perubahan warna yang berada di permukaan sel [7].

Fenomena *snail trails* ini muncul sebagai jari kontak bewarna keputihan sedikit kecoklatan pada permukaan sel surya terutama di tepi sel atau disekitar area retakan mikro. Pengaruh adanya retakan mikro pada permukaan panel surya merupakan penyebab awal terjadi munculnya *snail trails* [8].

Pada penelitian yang telah dilakukan sebelumnya oleh Sinaga, R., Tanesab, J., & Beily, M. (2019, December 12) dengan judul *The Impact of Snail Trails and Cracks to Energy Output of Photovoltaic Modules at Lotas Off-Grid PV System*, mengenai pengaruh kemunculan *snail trails* terhadap daya yang dihasilkan panel surya yang menunjukkan bahwa, efek jejak siput pada permukaan panel surya memberikan penurunan kinerja sekitar 46% dari total area luar sebesar 84,69%. Pengukuran pengaruh *snail trails* dilakukan dengan mengukur total daya dan arus yang dihasilkan oleh panel surya dan mengidentifikasi objek snail pada permukaan panel surya secara manual.

Pada penelitian lain yang telah dilakukan untuk menganalisis kemunculan *snail trails*, telah diselidiki menggunakan metode Spektroskopi Raman dan mikroskop elektron transmisi. Dengan menggunakan metode tersebut ditemukan bahwa jari-jari perak berwarna kecoklatan atau gelap disebabkan oleh pembentukan perak asetat serta reaksinya dengan enkapsulan yang berasal dari reaksi ion Ag dengan karbon dioksida dan asam asetat [9].

Dan pada penelitian yang telah dilakukan oleh Kontges dan kawan kawan, menggunakan radiasi fluoresensi untuk menyelidiki retakan mikro pada sel PV, untuk menentukan jumlah, posisi/orientasi, dan frekuensi dari *snail trails* [10]. Pada studi tersebut berlanjut kepada pengujian daya pada modul PV dengan mensimulasikan daya yang dipengaruhi oleh jenis retakan yang berbeda. Penulis memperkirakan bahwa retakan mengisolasi bagian sel yang menyebabkan hilangnya daya rangkaian modul sekitar 6-22%. [11].

Dari beberapa penelitian yang telah dilakukan terhadap dampak yang ditimbulkan dari kemunculan *snail trails* sangat berpengaruh pada daya yang dihasilkan oleh panel surya. Sehingga perlunya metode yang efisien, mudah di

aplikasikan untuk dapat memantau dalam mendeteksi *snail trails* yang muncul pada permukaan panel surya. Dan juga pengelolaan energi yang efektif merupakan salah satu transformasi utama yang diperlukan untuk mencapai tujuan pembangunan berkelanjutan. Tenaga matahari merupakan salah satu sumber pembangkit listrik non-konvensional terbesar. Untuk penghematan biaya, semua negara sekarang berinvestasi besar-besaran dalam instalasi yang sangat besar dari sumber daya terbarukan ini. Instalasi semacam itu membutuhkan sistem pemeliharaan dan pemantauan yang canggih terutama pada bagian struktural dan permukaan untuk terus menghasilkan jumlah energi yang diharapkan secara teratur. Dibandingkan dengan metode pemeriksaan yang membutuhkan biaya cukup besar dan ketersediaan alat untuk melakukan inspeksi masih terbatas dan belum memadai di berbagai laboratorium, pemantauan berbasis gambar bisa menjadi salah satu solusi yang paling menjanjikan karena efektivitasnya dan juga mekanismenya yang murah. Dalam pemantauan berbasis gambar drone, pembangkit terbarukan skala besar dapat dipantau secara teratur berdasarkan data yang diperoleh dan analisis yang sesuai untuk membuat keputusan yang tepat tentang pemeliharaan yang memastikan pasokan energi tidak terputus. Sehingga perlunya metode yang efisien, mudah di aplikasikan untuk dapat memantau dalam mendeteksi *snail trails* yang muncul pada permukaan panel surya.

Sehubungan dengan kondisi latar belakang yang telah dijelaskan, penulis tertarik mengusulkan metode jaringan saraf convolutional sebagai metode untuk melakukan sistem deteksi *snail trails* pada permukaan panel surya sebagai langkah pencegahan dini kerusakan yang berkelanjutan pada panel surya.

1.2 Rumusan Masalah

Berdasarkan dari latar belakang masalah, maka dirumuskan masalah yang di hadapi terkait dengan penelitian ini diuraikan sebagai berikut:

1. Bagaimana membangun model *You Only Look Once (YOLO)* dengan algoritma *Convolutional Neural Network (CNN)* untuk klasifikasi objek *snail trails* pada citra?

2. Bagaimana unjuk kerja dari sistem deteksi *snail trails* pada panel surya dengan model *You Only Look Once (YOLO)*?

1.3 Tujuan Masalah

Tujuan penelitian ini adalah:

1. Membangun model *You Only Look Once (YOLO)* dengan algoritma *Convolutional Neural Network* yang dapat melakukan klasifikasi dan mendeteksi pola *snail trails* pada permukaan panel surya.
2. Menguji akurasi sistem kerja pendeteksian *snail trails* dengan metode *You Only Look Once (YOLO)* versi 3.

1.4 Manfaat Penelitian

Dari rumusan masalah dan tujuan dari penelitian yang telah dijabarkan, maka diharapkan hasil dari penelitian ini memberi manfaat untuk analisa otomatis dari gambar inspeksi yang dikumpulkan melalui citra, sehingga dapat secara signifikan mengurangi biaya inspeksi, menyediakan mekanisme deteksi yang efektif, dan mempersingkat waktu pelaporan, sehingga mengurangi biaya perawatan secara keseluruhan, dan meningkatkan langkah-langkah keselamatan.

1.5 Batasan Masalah

Dalam penelitian ini, perancangan yang akan dibuat dibatasi pada hal-hal sebagai berikut:

- a. Penelitian yang dilakukan hanya untuk mengetahui deteksi cacat *snail trails* yang terjadi pada permukaan modul sel surya.
- b. Sample data yang digunakan untuk penelitian ini diambil hanya data citra permukaan panel surya menggunakan kamera UAV dan kamera ponsel.
- c. Penelitian ini menggunakan metode *YOLOv3*.

1.6 Penelitian Terkait

Berikut ini merupakan penelitian – penelitian yang terkait dengan masalah:

Tabel 1. 1 *State of The Art*

No	Peneliti	Judul	Tahun	Tujuan Penelitian	Metode	Hasil
1.	JiafanYu, dkk	<i>DeepSolar: A Machine Learning Framework to Efficiently Construct a Solar Deployment Database in the United States.</i>	2018	Untuk mengidentifikasi lokasi GPS dan ukuran panel fotovoltaik surya menggunakan deep solar.	Menggunakan metode CNN dalam mengelola data citra yang ditangkap dari satelit.	Dapat mendeteksi keberadaan solar panel yang ada di seluruh wilayah dengan akurasi SolarForest mencapai $R^2 = 0,722$ dan SolarNN mencapai $R^2 = 0,717$, yang merupakan akurasi mutakhir tertinggi [12].
2.	Chao Zhang,	<i>Mask-MRNet: A</i>	2020	Untuk mengurangi	Menggunakan	DenseNet-121 dipilih

No	Peneliti	Judul	Tahun	Tujuan Penelitian	Metode	Hasil
	Dkk	<i>deep neural network for wind turbine blade fault detection.</i>		i waktu inferensi saat melakukan deteksi objek besar seperti kesalahan blade pada turbin angin.	metode Mask-MRNet diusulkan untuk mendeteksi patahan sudut turbin angin berdasarkan gambar yang diambil oleh kendaraan udara tak berawak.	sebagai model klasifikasi untuk Mask-MRNet karena memiliki akurasi pelatihan dan pengujian, skor f1, dan efisiensi deteksi[13].
3.	Shihavuddin A.	<i>Wind Turbine Surface Damage Detection by Deep Learning</i>	2019	Untuk mendeteksi kerusakan pada permukaan turbin,	Sistem deteksi kerusakan permukaan pada turbin	Menggunakan arsitektur Inception-ResNet-v2 di dalam R-CNN yang

No	Peneliti	Judul	Tahun	Tujuan Penelitian	Metode	Hasil
		<i>Aided Drone Inspection Analysis</i>		sehingga dapat mengefisienkan waktu pengecekan dan mempersingkat waktu pemberhentian operasi turbin pada saat perbaikan.	angin dilatih menggunakan R-CNN	lebih cepat, MAP 81,10% dicapai pada empat jenis kerusakan yang berbeda, yaitu, erosi LE, panel generator vortex, panel generator vortex dengan gigi yang hilang, dan reseptor petir [14].
4.	Zefri Y., dkk	<i>Thermal Infrared and Visual Inspection of Photovoltaic</i>	2018	Membuktikan keunggulan UAV dalam mendeteksi	Menggunakan beberapa perbandingan jenis kamera,	UAV telah membuktikan nilai dan efisiensinya dalam inspeksi PV. Karena

No	Peneliti	Judul	Tahun	Tujuan Penelitian	Metode	Hasil
		<i>Installations by UAV Photogrammetry—Application Case: Morocco</i>		kerusakan panel surya.	yaitu infrared kamera, thermal kamera, dan kamera UAV biasa.	dapat mengenali kerusakan fisik secara efektif pada permukaan panel surya [15].
5.	Aghaei, dkk.	<i>PV power plant inspection by image mosaicing techniques for IR real-time images</i>	2016	Tujuan utama dari makalah ini adalah untuk mengembangkan algoritma pemrosesan citra digital untuk menyediakan Image Mosaicing (IM) untuk deskripsi tanaman yang lebih	Penelitian eksperimental ini dibuat untuk mengusulkan suatu algoritma untuk menggabungkan banyak gambar IR untuk memberikan IM dengan menggunakan	Hasilnya telah membuktikan bahwa algoritma pengolahan citra digital yang diusulkan mampu memberikan informasi yang dapat diandalkan seperti IM, deteksi cacat dan kegagalan dan juga

No	Peneliti	Judul	Tahun	Tujuan Penelitian	Metode	Hasil
				kaya dengan menggabungkan banyak citra inframerah (IR).	akan algoritma mosaik berdasarkan metode detektor sudut Harris untuk perencanaan pembangunan kit listrik PV. Selain itu, algoritma lain berdasarkan teknik pemrosesan citra digital dikembangkan di Matlab untuk menghitung	penghitungan modul selama inspeksi pembangkit listrik PV. Namun, penelitian dan pengembangan lebih lanjut akan diperlukan untuk meningkatkan algoritma untuk perencanaan pembangunan kit listrik PV [16].

No	Peneliti	Judul	Tahun	Tujuan Penelitian	Metode	Hasil
					ng jumlah modul PV, serta jumlah modul sehat dan cacat dalam string PV dengan menggunakan metode deteksi tepi.	
6.	Yap, dkk.	<i>Quantitative Analysis of Dust and Soiling on Solar PV Panels in the Tropics Utilizing Image-Processing Methods</i>	2015	Membandingkan metode tercepat dan terakurat untuk memproses citra pendeteksi debu pada panel	Makalah ini menyajikan metodologi <i>non-evasive</i> dalam mengukur jumlah debu dan kekotoran	Hasil menunjukkan bahwa algoritma binarisasi menunjukkan pembacaan tercepat dan paling akurat pada uji gambar

No	Peneliti	Judul	Tahun	Tujuan Penelitian	Metode	Hasil
				surya.	n pada PV surya dengan menyelidiki lima teknik pemrosesan gambar yang berbeda. Lima metodenya yaitu penelitian ini dengan mengadopsi teknik binerisasi, model histogram, model statistik, pencocokan citra dan pencocok	terkontrol dan algoritma pencocokan gambar menunjukkan akurasi tertinggi pada uji gambar yang sebenarnya. Metode analisis debu dan kekotoran panel PV terbukti akurat, berbiaya rendah, mudah diterapkan dan kritis, memberikan informasi yang diperlukan pengguna

No	Peneliti	Judul	Tahun	Tujuan Penelitian	Metode	Hasil
					an tekstur.	akhir dalam mempertah ankan efisiensi sistem PV [17].
7.	Chen, dkk	<i>Solar cell surface defect inspection based on multispectra l convolution al neural network</i>	2018	Untuk mengatasi masalah pemantaua n kerusakan modul panel surya yang masih dilakukan dengan cara manual dengan mengandal kan penglihatan n manusia.	Penelitian ini menggun akan metode deteksi cacat visual berbasis multi- spektral deep convoluti onal neural network (CNN)	Beberapa hasil eksperimen dan validasi silang K- fold menunjukk an bahwa model CNN dalam multi- spektral dapat secara efektif mendeteksi cacat permukaan sel surya dengan akurasi yang lebih

No	Peneliti	Judul	Tahun	Tujuan Penelitian	Metode	Hasil
						tinggi dan kemampuan beradaptasi yang lebih besar. Keakuratan pengenalan cacat mencapai 94,30% [18].

Mengacu pada kajian literatur yang telah dipaparkan, maka penelitian tentang mengidentifikasi pola *snail trail* pada panel surya penting dilakukan untuk mempermudah terkait pendeteksian pola *snail trail* yang ditangkap menggunakan kamera UAV.

1.7 Sistematika Penulisan

Sistematika yang digunakan dalam penulisan tesis ini menggambarkan secara garis besar isi dan sistematika penulisan tesis yang akan dilakukan sesuai dengan kerangka - kerangka yang telah ditetapkan dengan tahapan – tahapan yang disusun sebagai berikut:

BAB I PENDAHULUAN

Pada bab ini berisikan mengenai latar belakang alasan penulis mengangkat *snail trails* sebagai topik penelitian, rumusan masalah yang akan diteliti dari tema yang telah ditentukan dengan menggunakan metode *deep*

learning, tujuan penulisan, batasan masalah dari penelitian deteksi objek *snail trails*, dan sistematika penulisan yang tersusun pada penelitian ini.

BAB II LANDASAN TEORI

Pada bab ini menjelaskan tentang teori teori yang berhubungan dengan panel surya, jenis kerusakan panel surya, kerusakan yang lebih spesifik mengenai objek *snail trail* yang akan di deteksi dan jenis metode *deep learning* yang digunakan pada penelitian ini.

BAB III PERANCANGAN SISTEM

Pada bab ini menjelaskan berupa rancangan alur proses penelitian dari metode YOLOv3, lokasi dan waktu pelaksanaan penelitian, alat yang digunakan dalam proses pengambilan dataset, serta alat yang digunakan dalam proses pelatihan dan pengujian dataset.

BAB IV HASIL DAN ANALISA

Pada bab ini berisi hasil simulasi training dan hasil pengujian dari deteksi objek *snail trails* menggunakan metode YOLOv3. Pada bab ini jg menjelaskan analisa mengenai data-data, parameter, hasil proses pelatihan dan pengujian sistem.

BAB V PENUTUP

Pada bab ini berisi tentang kesimpulan dari pembahasan hasil analisa penggunaan metode *deep learning* dengan algoritma YOLOv3 sebagai deteksi *snail trails* pada salah satu jenis kerusakan panel surya. Yang kemudian dilanjutkan dengan saran perbaikan untuk penelitian kedepannya yang lebih baik.

BAB II

TINJAUAN PUSTAKA

2.1 Panel Surya

Panel surya merupakan perlengkapan yang terdiri dari sel surya yang mengganti sinar matahari mejadi listrik. Energi matahari yang berasal dari matahari dalam bentuk penyinaran matahari dapat langsung diubah menjadi listrik dengan menggunakan teknologi *photovoltaic* (PV). Teknologi PV memakai sel surya yang dibuat dari semikonduktor berfungsi untuk meresap radiasi dari matahari serta mengubahnya jadi tenaga listrik [19].

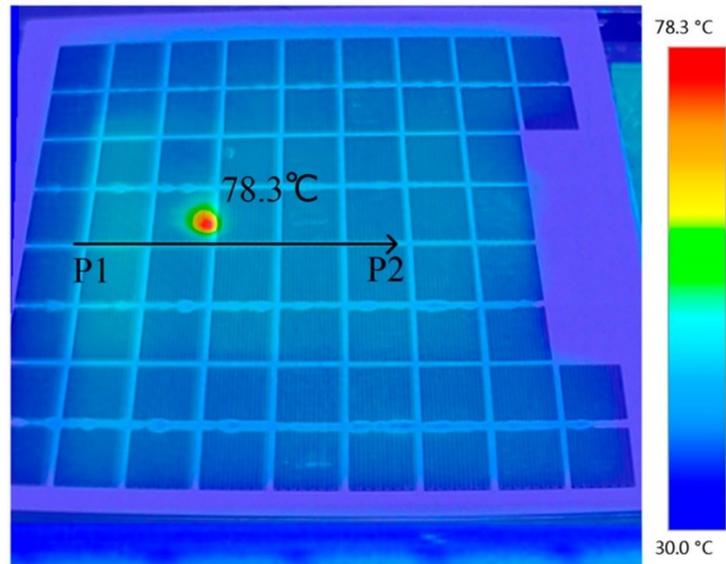
Fotovoltaik beroperasi dengan menghasilkan arus listrik searah dari penyerapan foton, atas dasar mengeksploitasi sifat elektronik dari kelas bahan khusus yang disebut semi-konduktor [20] Semikonduktor pada dasarnya merupakan suatu komponen yang sederhana. Semikonduktor memiliki kapasitas untuk menangkap dan menyerap sinar matahari lalu mengirimkannya sebagian energi dari foton yang diterima ke pembawa arus listrik – elektron dan lubang. Dioda semikonduktor akan memisahkan dan mengumpulkan dari pembawa lalu menghantarkan arus listrik yang dihasilkan ke arah tertentu. Proses konversi dilakukan oleh sel. Arus searah yang dihasilkan dikonversi oleh inverter untuk mendapatkan arus bolak-balik [21] Kebanyakan sel PV terbuat dari semi-konduktor tetapi ada juga yang terbuat dari bahan seperti silikon, germanium, kadmium telluride, gallium arsenide, tembaga indium deselenide, dll. Namun yang terbuat dari semi-konduktor adalah yang paling banyak digunakan karena ketersediannya yang berlimpah di kerak bumi. Ada tiga kategori sel surya silikon tersedia di pasaran, yaitu Monokristalin (dengan rentang efisiensi 12–16% dengan luas permukaan yang dibutuhkan sekitar 1 m²/kW), polikristalin (dengan rentang efisiensi 11–15% dengan luas permukaan yang dibutuhkan sekitar 8 m²/kW) dan amorf (dengan rentang efisiensi 6–8% dengan luas permukaan yang dibutuhkan sekitar 16 m²/kW) [22].

2.2 Kerusakan Panel Surya

Modul PV yang sering digunakan di seluruh dunia juga memiliki keterbatasan atau kekurangan salah satunya yaitu penurunan peformansi dikarenakan faktor eksternal yang tidak dapat dihindari seperti lingkungan, cuaca, kelembaban, suhu. Ini membuat mereka rentan terhadap berbagai cacat, yang menyebabkan kerugian hasil yang signifikan [23] Cacat PV dapat didefinisikan sebagai segala sesuatu kondisi yang berbeda dari bentuk kondisi normal PV dalam menghasilkan daya maksimum [24]. Untuk mendeteksi, menemukan, dan mengidentifikasi cacat yang terjadi, berbagai teknik digunakan. Namun, untuk instalasi yang sulit dijangkau dan berskala besar, penggunaan teknik klasik secara manual menghadapi tantangan yang masih perlu ditangani. Beberapa cacat yang umum diketahui disajikan secara singkat sebagai berikut.

- *Mismatches*

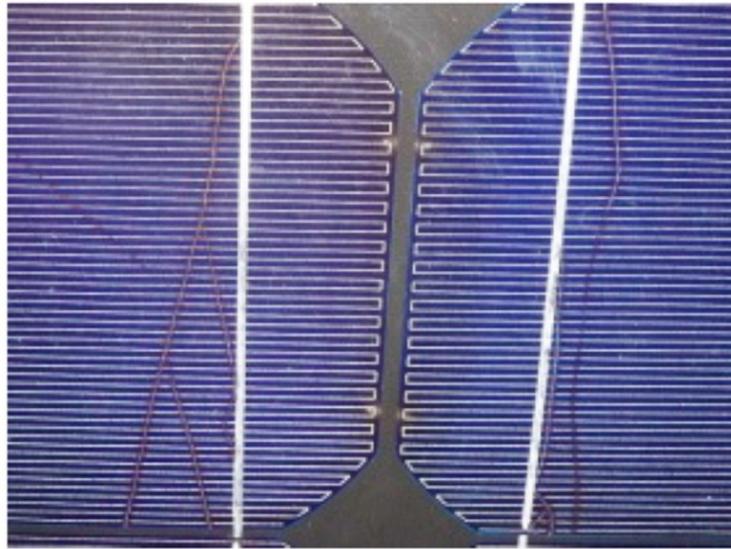
Cacat mismatches dihasilkan dari perbedaan radiasi matahari yang diterima sel surya sehingga menimbulkan perbedaan penerimaan hasil daya yang dihasilkan sel surya yang dapat mengganggu interkoneksi dan mengakibatkan hilangnya daya keluaran dan berdampak pada seluruh modul sel surya. Ketidaksamaan dengan cara kerja dibawah perbedaan kondisi lingkungan tersebut membuat dioda bypass yang rusak, dapat mengembangkan hotspot seperti yang terdapat pada gambar 2.1 yang dapat menyebabkan kecoklatan, bekas luka bakar atau dalam kasus yang parah, menyebabkan kebakaran.



Gambar 2. 1 Hotspot yang diamati pada gambar termal modul PV [25].

- Retakan (*Crack*)

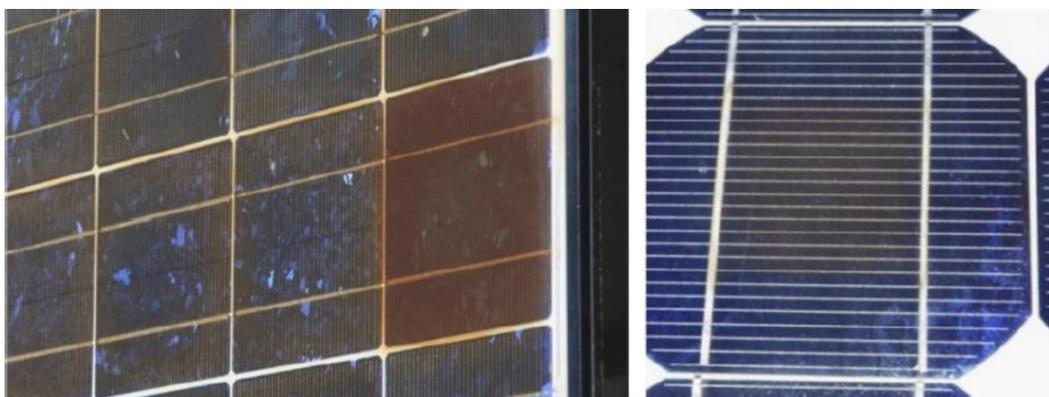
Retakan adalah salah satu cacat yang paling sering mempengaruhi modul PV. Bentuknya seperti yang terdapat pada gambar 2.2. Mereka dapat memiliki panjang dan orientasi yang berbeda dan dapat muncul pada berbagai tahap masa pemakaian modul, selama pembuatan karena penyolderan, proses stringing, dan penanganan, setelah menyelesaikan produksi karena pengemasan, transportasi, dan pemuatan ulang, dan akhir-akhir ini di lapangan, sebagai akibat dari beban mekanis karena angin, salju, dan hujan es.



Gambar 2. 2 Retakan yang terdapat pada panel surya [24].

- Perubahan Warna (*Discolorations*)

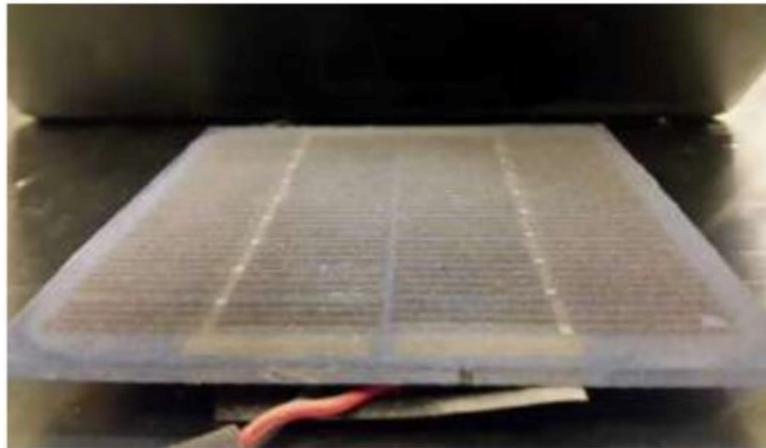
Perubahan warna seperti yang terdapat pada gambar 2.3, berupa perbedaan warna pada permukaan panel surya yang disebabkan oleh faktor internal, seperti penggunaan polimer berkualitas buruk dalam perakitan sel, atau polimer eksternal, seperti suhu dan kelembaban panas. Area yang berubah warna mengurangi jumlah sel penembus sinar matahari, dan dengan demikian, dapat mengakibatkan kehilangan produksi daya.



Gambar 2. 3 Perubahan warna yang menyebabkan terjadinya perbedaan warna pada panel surya [24].

- Debu atau Kotoran (*Soiling*)

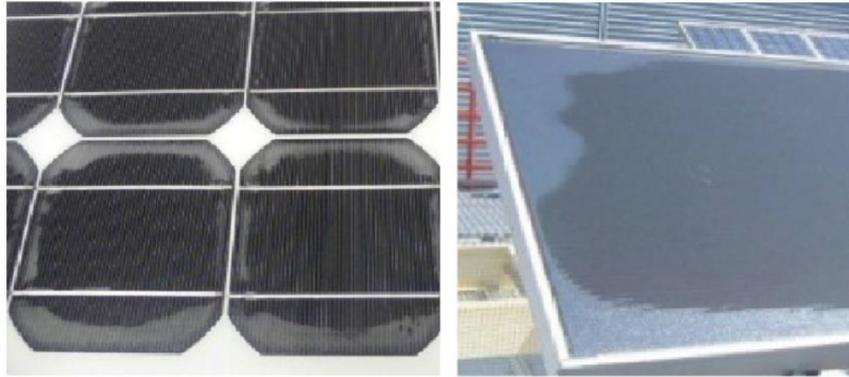
Soiling mengacu pada akumulasi kotoran pada permukaan modul PV pada gambar 2.4. Ini dapat diakibatkan oleh berbagai penyebab seperti debu, polusi, kotoran burung, dll. Literatur menunjukkan kehilangan hasil PV tahunan karena akumulasi pengendapan sedimen pada permukaan panel surya dengan rentan nilai mulai dari 1-7% di wilayah negara, seperti Spanyol, hingga lebih dari 10% di zona kering, seperti Siprus dan Kuwait. Namun, prediksi kerugian yang akurat tetap sulit karena adanya beberapa parameter yang berkorelasi untuk dipertimbangkan seperti kondisi lingkungan dan cuaca, sudut kemiringan modul PV, jenis partikel kotoran, dan juga tekstur material kaca permukaan sel.



Gambar 2. 4 Penumpukan kotoran debu pada permukaan panel surya [26].

- Delaminasi (*Delaminations*)

Kerusakan ikatan antara lapisan material yang mengatur laminasi modul. Delaminasi mengganggu pembuangan panas yang efisien sehingga mengakibatkan kemungkinan pemanasan sel bias balik. Penyebab utama delaminasi adalah pergerakan sel dan interkoneksi sel karena tekanan lingkungan. Juga proses, penuaan fisik yang terkait dengan penerapan suhu tinggi dapat memicu delaminasi suhu modul panel surya.



Gambar 2. 5 Delaminasi pada permukaan panel surya [24].

- Jejak Siput (*Snail Trails/Tracks*)

Jejak siput adalah efek perubahan warna abu-abu/hitam dari garis kisi perak pada permukaan sel silikon kristal pada gambar 2.5. Ini terjadi pada retakan mikro dan/atau di sepanjang tepi sel. Jejak siput dapat dengan mudah diidentifikasi dengan penglihatan. Mereka biasanya terjadi tiga bulan hingga satu tahun setelah pemasangan modul PV dan menyebar tergantung pada kondisi lingkungan. Tes eksperimental menunjukkan penurunan lebih dari 20% output PV listrik pada modul yang dipengaruhi oleh jejak siput.



Gambar 2. 6 Penomena jejak siput atau *snail trails* yang terjadi pada permukaan panel surya [24].

2.3 Teknik Inspeksi Panel Surya

Modul PV dapat dilakukan inspeksi dengan cara diperiksa menggunakan berbagai teknik. Masing-masing menyajikan beberapa kelebihan dan keterbatasan, dan tampaknya disesuaikan dengan cacat tertentu atau konfigurasi tertentu. Berikut ini, teknik yang umum digunakan disajikan secara singkat dalam inspeksi pemantau permukaan panel surya.

- Inspeksi visual (*Visual Inspection*)

Inspeksi visual umumnya merupakan tes pertama yang harus berhasil dilalui modul. Inspeksi secara visual biasa dapat dilakukan dengan menggunakan panca indra kita sendiri. Cacat yang umumnya dapat dideteksi dengan teknik ini adalah debu kotor, beberapa retakan, perubahan warna, delaminasi, dan *snail trails*.

- Pengukuran I-V (*I-V Measurements*)

Pengukuran I-V digunakan untuk menetapkan kurva I-V modul PV. Pengukuran ini dapat mengungkapkan perubahan kondisi operasi PV, seperti cuaca, adanya beberapa cacat, seperti delaminasi, ketidakcocokan, dioda bypass yang rusak, dll. Operasi pengukuran arus dan daya ini selanjutnya akan dianalisis penyimpangan antara kurva I-V modul yang diperiksa menyajikan dampak iradiasi dan suhu sekitar pada kurva I-V dari modul PV, sedangkan pengukuran yang disebabkan cacat yang dapat dideteksi berdasarkan penyimpangan kurva I-V, dengan karakteristik listrik yang dihasilkan tercantum secara rinci. Namun, kekurangan dari teknik ini adalah kurang dapat mendeteksi variasi kecacatan modul yang muncul. Selain itu, pengukuran dengan melihat kurva I-V tidak memuat informasi detail kondisi lokasi cacat yang berada pada panel surya, oleh karena itu teknik dengan metode lain seringkali digunakan untuk mengimbangi penggunaan metode pengukuran I-V.

- Elektroluminesensi (*Electroluminescence*)

Modul PV dirancang untuk mengoptimalkan penyerapan sinar matahari dan konversinya menjadi arus listrik. Oleh karena itu, berdasarkan prinsip timbal balik, metode ini dapat memancarkan foton setelah dirangsang,

dan ini adalah prinsip electroluminescence. Teknik ini menerapkan arus searah ke modul dan mengukur fotoemisi yang dihasilkan menggunakan kamera inframerah. Pada prinsipnya, area gelap sesuai dengan zona yang rusak oleh berbagai cacat, sedangkan yang terang dan jernih sesuai dengan zona utuh. Pencitraan elektroluminesensi dilakukan di lingkungan gelap. Ini khusus digunakan untuk mendeteksi retakan yang muncul sebagai garis gelap. Dalam kasus modul surya multi-kristal, orang yang bereksperimen diperlukan untuk membedakan retakan dari cacat kristalografi. Di sisi lain, *electroluminescence* memiliki beberapa kelemahan praktis seperti inspeksi dalam jumlah besar, metode ini kurang cocok dilakukan di bawah operasi pembangkit listrik PV. Selain itu, mereka membutuhkan catu daya yang besar dan hanya memberikan diagnosis kualitatif.

- Termografi (*Infrared Thermography*)

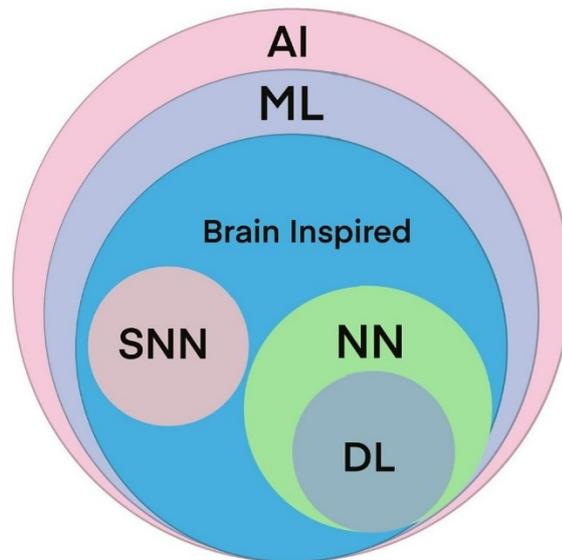
Pada suhu yang lebih tinggi dari 0K (suhu nol mutlak), setiap benda memancarkan radiasi panas dalam bentuk gelombang elektromagnetik. Radiasi yang dipancarkan sebanding dengan suhu tubuh. Menyebar dengan kecepatan cahaya, tanpa perlu kontak material atau gradien suhu menengah. Menggunakan kamera termal, termografi inframerah terdiri dari menangkap radiasi ini, mengubahnya menjadi sinyal listrik dan menyediakan gambar raster (termogram) di mana piksel berisi nilai suhu. Bagian terpenting dari kamera termal (atau pencitra termal) adalah susunan detektor.

- UAV untuk Inspeksi Panel Surya (*UAV for PV Inspection*)

Dengan kesadaran yang menyebar luas secara bertahap mengenai fotovoltaik, kecenderungan sekarang bergerak terutama ke tanaman besar. Pada skala ini, teknik pemeriksaan konvensional menjadi memakan waktu dan mahal untuk diterapkan. Inspeksi visual dan termal dapat dilakukan oleh kamera udara. Ini menghemat waktu dan sumber daya manusia. Ini juga memungkinkan cakupan area yang luas, pengumpulan data yang cepat, serta inspeksi instalasi yang sulit dijangkau. Penggunaan UAV dapat mengurangi hingga 85% waktu yang dihabiskan untuk melakukan inspeksi termografi di pabrik fotovoltaik besar.

2.4 Artificial Intelligence

Sejak 1950-an, sebagian kecil *Artificial Intelligence* (AI), sering disebut *Machine Learning* (ML), telah merevolusi beberapa bidang dalam beberapa dekade terakhir. *Neural Networks* (NN) adalah sub bidang ML, dan sub bidang inilah yang melahirkan *Deep Learning* (DL). Sejak awal, DL telah menciptakan gangguan yang semakin besar, menunjukkan kesuksesan luar biasa di hampir setiap domain aplikasi. Gambar 2.6 menunjukkan taksonomi AI. DL yang menggunakan arsitektur pembelajaran yang mendalam atau pendekatan pembelajaran hierarkis). *Deep Learning* adalah prosedur yang terdiri dari memperkirakan parameter model sehingga model yang dipelajari (algoritma) dapat melakukan tugas tertentu. Misalnya, dalam Jaringan Syaraf Tiruan (JST), parameternya adalah matriks bobot. DL, di sisi lain, terdiri dari beberapa lapisan di antara lapisan input dan output yang memungkinkan banyak tahap unit pemrosesan informasi non-linier dengan arsitektur hierarkis hadir yang dieksploitasi untuk pembelajaran fitur dan klasifikasi pola [27], [28]. Literatur terbaru menyatakan bahwa pembelajaran representasi berbasis DL melibatkan hierarki fitur atau konsep, dimana konsep tingkat tinggi tersebut dapat didefinisikan dari yang tingkat rendah dan konsep tingkat rendah dapat didefinisikan dari yang tingkat tinggi. Dalam beberapa artikel, DL telah digambarkan sebagai pendekatan pembelajaran universal yang mampu menyelesaikan hampir semua jenis masalah dalam domain aplikasi yang berbeda [29].



Gambar 2. 7 Klasifikasi dari *Artificial Intelligent*, ML yaitu *Machine Learning*, NN yaitu *Neural Network*, DL yaitu *Deep Learning*, SNN yaitu *Spiking Neural Network* [29].

2.3 *Featuring Learning*

Pada *machine learning* umumnya yang digunakan adalah *feature engineering*, *feature learning* merupakan metode dimana proses *feature extraction* diolah secara otomatis dan adaptif oleh model. *Feature learning* muncul karena keterbatasan kemampuan pada *feature engineering* dalam mengelolah setiap kasus data yang berbeda dan memerlukan *feature extraction* yang berbeda. Hal tersebut menyebabkan *feature engineering* tidak memiliki kemampuan generalisasi kepada keberagaman jenis data seperti yang selalu diperlukan dalam studi kasus klasifikasi objek pada citra [30].

Pada pengolahan yang lebih kompleks seperti klasifikasi citra dan suara, umumnya diperlukan ekstraksi fitur untuk mengubah data tersebut menjadi data yang dapat dimengerti oleh metode *learning*. Namun dalam proses perubahan datanya diperluka waktu yang cukup panjang dan cenderung kurang dapat menggambarkan dari keseluruhan nilai informasi data. *Feature learning* akan membantu mengatasi kekurangan tersebut dengan membuat proses ekstrasi fitur

menjadi adaptif yang penyesuaian otomatis dapat dilakukan terhadap data yang akan dijalankan [30].

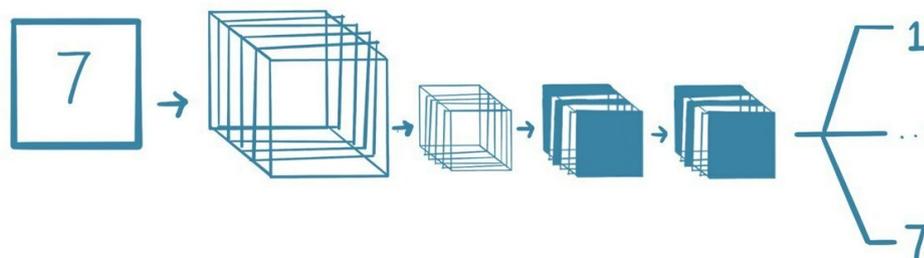
Dalam beberapa dekade tahun ini perkembangan dari *feature learning* terdapat beragam jenis metode yang dikembangkan. Secara garis besar dibagi menjadi dua yaitu *unsupervised featurizing learning* dan *unsupervised featurizing learning*. Metode *unsupervised learning* merupakan metode dari *feature learning* yang berkembang terlebih dahulu dan memiliki tujuan transformasi data menjadi representasi lain yang lebih mudah dipahami oleh komputer. Dalam modelnya metode *unsupervised learning* tidak menggunakan data latih dalam melakukan pembelajaran. Algoritma ini tidak memiliki variable target dan bertujuan mengelompokkan objek yang serupa dalam suatu area tertentu. Metode *unsupervised learning* biasa digunakan untuk klasifikasi secara *clustering*. Diantaranya terdapat *autoencoder*, *Deep Belief Network*, *Gaussian Mixture Model*, dan juga metode *K-Mean* [31].

Pada awal perkembangannya, klasifikasi objek pada citra menggunakan metode tersebut, namun kemudian berkembang metode *featurizing learning* yang bersifat *supervised* sehingga metode *unsupervised* mulai ditinggalkan karena performa yang masih banyak kekurangan. Metode *supervised featurizing learning* menggunakan data latih untuk pembelajaran, tujuannya agar mesin mampu mengidentifikasi label input yang baru dengan menggunakan fitur yang ada untuk melakukan prediksi dan klasifikasi. Karena keunggulan tersebut membuat metode tersebut banyak perkembangan salah satunya adalah *deep learning featurizing learning* yang dimana menggunakan *deep network* yang melakukan proses ekstraksi fitur dan klasifikasi menggunakan *learning*.

Model *deep learning* yang paling sering digunakan pada pengolahan citra yaitu *Convolutional Neural Network (CNN)*. Pada kasus penanganan citra tersebut, *featurizing learning* dilakukan oleh CNN pada kumpulan *convolution layer* di dalamnya. Karena adanya proses tersebut, CNN tidak memerlukan ekstraksi fitur khusus dan pada umumnya proses yang terjadi hanya memerlukan pra-proses dasar untuk normalisasi data.

2.4 Convolutional Neural Network

Convolutional Neural Network (CNN) adalah salah satu jenis *neural network* yang digunakan untuk mengekstraksi fitur-fitur dari sebuah citra. CNN pertama kali dikenal dengan sebutan NeoCognitron oleh seorang peneliti NHK *Broadcasting Science Research Laboratories Tokyo*, di Jepang bernama Kunihiko Fukushima [32]. CNN dikenal memiliki performansi yang baik dalam pengolahan ekstraksi pada citra. CNN terdiri dari beberapa layer dan salah satu layernya merupakan layer *convolutional*, yang terdapat kernel untuk mengkonvolusi sebuah citra. Layer-layer lainnya selain *convolutional* yaitu, *rectified linear unit*, *pooling*, dan *fully connected layer* yang memiliki fungsi tersendiri. Ketika lapisan-lapisan ini saling terhubung, maka arsitektur CNN telah terbentuk seperti gambar dibawah ini.



Gambar 2. 8 Arsitektur CNN

Fungsi dasar dari setiap layer pada contoh skema CNN di atas dapat dipecah menjadi empat bagian, yaitu:

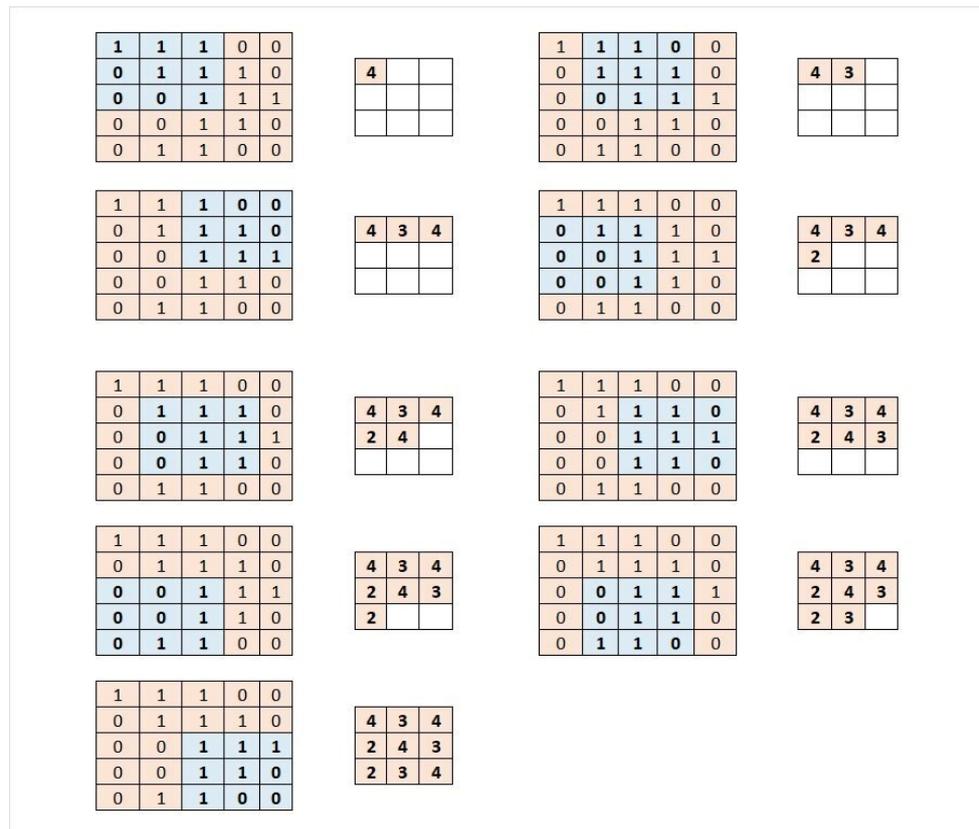
1. Lapisan input, yang telah di labeling akan dimasukkan sebagai data input.
2. Lapisan konvolusional akan menentukan nilai output neuron yang terhubung ke daerah lokal input melalui perhitungan produk skalar antara bobotnya dan wilayah yang terhubung ke volume input. Unit linier yang diperbaiki (biasanya disingkat menjadi ReLu) bertujuan untuk diterapkan fungsi aktivasi 'elementwise' seperti sigmoid ke output aktivasi yang dihasilkan oleh lapisan sebelumnya. Pada proses konvolusi akan terjadi perkalian dari dua matriks yang kemudian dijumlahkan atau dioperasikan dengan dot product. Misalnya ada sebuah data input berukuran 5×5 , dan

sebuah filter atau kernel yang berukuran 3×3 , nanti akan akan mengkonvolusi inputan tersebut secara beraturan vertical menurun kebawah ke seluruh pixel data inputan seperti gambar 2.9 dibawah ini:

1	1	1	0	0	*	1	0	1
0	1	1	1	0		0	1	0
0	0	1	1	1		1	0	1
0	0	1	1	0				
0	1	1	0	0				

Gambar 2. 9 Perkalian matriks input dan matriks kernel

Pada gambar 2.9 Kernel ini akan menempel melintasi setiap pixel dari data input dengan ukuran yang sama yang nantinya akan menghasilkan sebuah konvolusi yang disebut *feature map*. Salah satu bentuk dari konvolusi yang dihasilkan yaitu *bluring*, *smoothing*, *sharpen*, *edge detection*. Tujuan dari konvolusi layer ialah untuk menjaga hubungan antar pixel agar tidak terpisah dengan cara mempelajari ciri pada citra input melalui perkalian matriks. Berikut contoh operasi matematis perkalian matriks pada proses konvolutional layer:

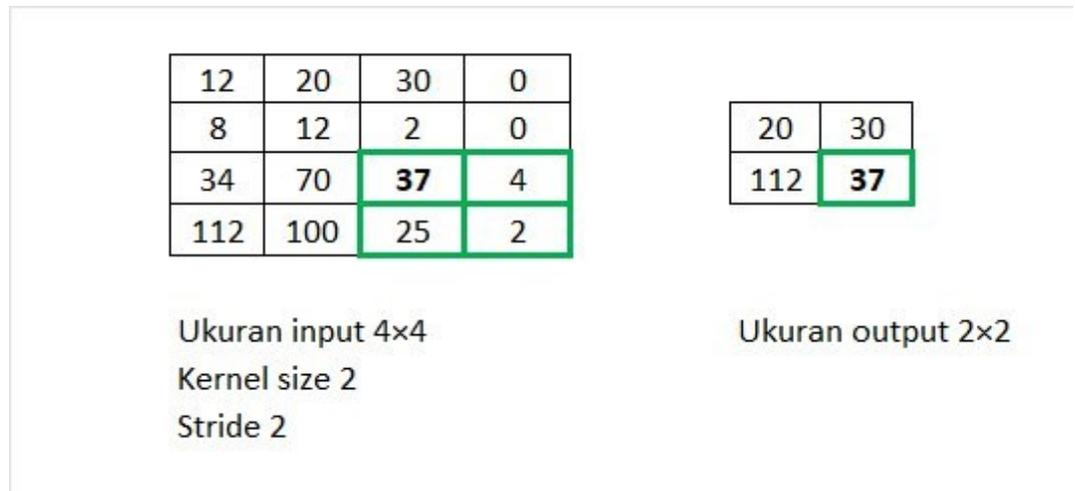


Gambar 2. 10 Proses menghasilkan *feature map* dengan perkalian matriks

Dari 2.10 terlihat bahwa kernel akan bergeser secara vertical, dan menurun sesuai dengan jumlah stride. Dari stride ini akan menentukan jumlah pergeseran pixel. Penentuan jumlah stride yang digunakan akan berdampak pada pengurangan jumlah spasial pada suatu citra. Jika jumlah stride yang digunakan lebih banyak maka, dapat membantu mengurangi jumlah spasial pada citra yang berukuran besar.

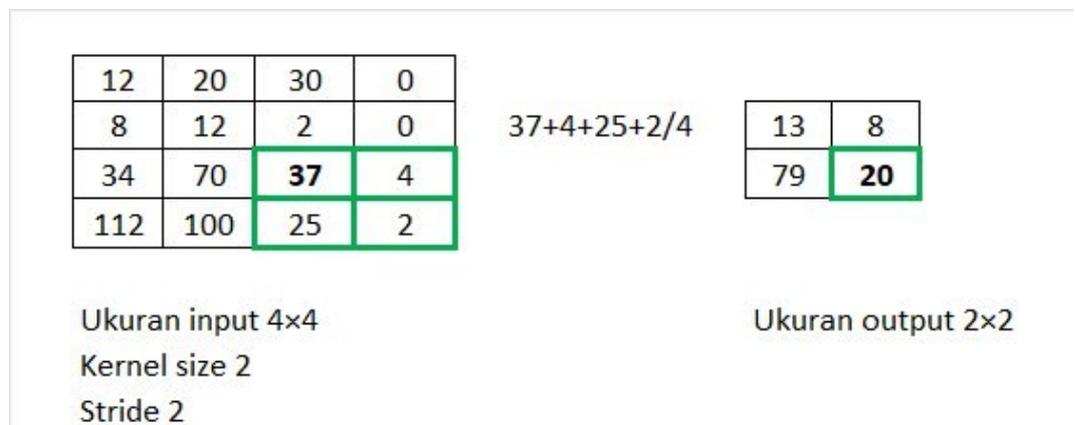
3. Lapisan pooling selanjutnya akan melakukan downsampling pada proses dimensi spasial dari input yang memiliki ukuran yang besar, sehingga layer berikutnya tidak memerlukan komputasi terlalu banyak. Selanjutnya akan dilakukan pengurangan dari jumlah parameter pada proses aktivasi. Layer ini akan memproses chanel input secara terpisah, sehingga output yang dihasilkan pada proses pooling akan memiliki ukuran chanel output yang sama. Pada *pooling* layer ini juga memiliki *kernel size*, *stride*, dan *padding* seperti *convolutional layer*, namun pada

pooling layer tidak memiliki *weight*. Ada dua jenis *pooling*, yaitu *max pooling* dan *average pooling*. *Max pooling* akan memilih nilai maximum dari setiap area *local*, dapat dilihat pada gambar 2.11.



Gambar 2. 11 Proses *max pooling*

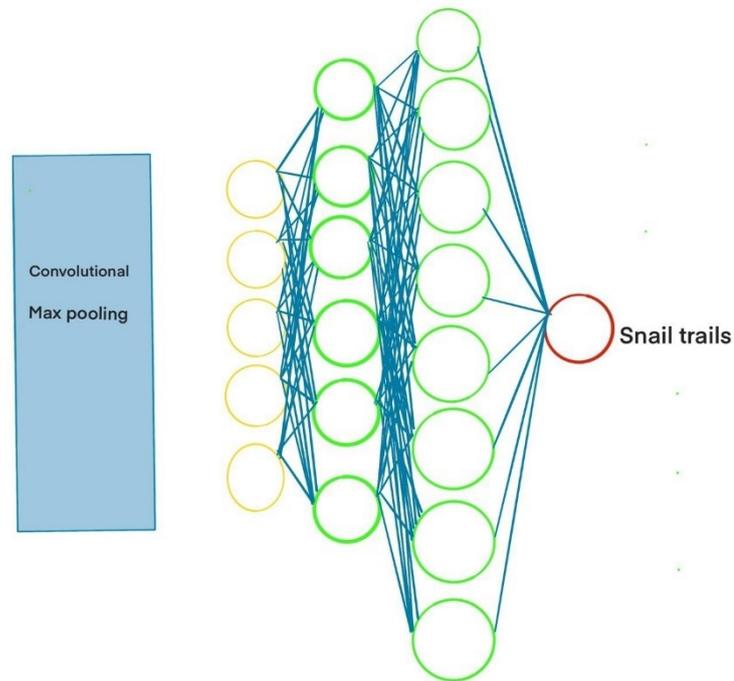
Dengan proses *max pooling* tersebut, selanjutnya akan meneruskan bagian yang penting dari input dengan mengambil nilai output tertinggi. Sedangkan *average pooling* akan merata-rata semua nilai dari area *local* tersebut, sehingga sistem akan meneruskan semua bagian dari input secara sama rata. Gambar 2.12 merupakan ilustrasi *average pooling*.



Gambar 2. 12 Proses *average pooling*

4. Lapisan *fully connected layer*, merupakan lapisan yang terhubung sepenuhnya akan menghasilkan skor kelas dari aktivasi, yang digunakan

untuk klasifikasi. Pada proses ini Layer ReLU akan berperan pada lapisan untuk meningkatkan kerja. Input ke lapisan yang terhubung sepenuhnya merupakan *output* dari *pooling* akhir atau lapisan konvolusional, yang diratakan dan kemudian dimasukkan ke dalam lapisan yang terhubung sepenuhnya. Sedangkan *flatenned* merupakan output dari lapisan *pooling* dan konvolusional akhir yang membentuk matriks 3 dimensi. Dari gabungan fitur-fitur tersebut akan menghasilkan sebuah *activation map* yang akan mengklasifikasikan *snail trails*. Gambar 2.13 merupakan ilustrasi dari lapisan *fully connected layer*.



Gambar 2. 13 Cara kerja *fully connected layer*

Melalui metode transformasi sederhana ini, CNN mampu mengubah input asli lapis demi lapis menggunakan teknik konvolusional dan downsampling untuk menghasilkan skor kelas untuk tujuan klasifikasi.

2.5 YOLOv3

Metode YOLOv3 menganggap deteksi objek sebagai masalah regresi. Ini secara langsung memprediksi probabilitas kelas dan offset kotak pembatas dari

gambar penuh dengan jaringan saraf konvolusi umpan ke depan tunggal. Ini sepenuhnya menghilangkan pembuatan proposal wilayah dan resampling fitur, dan merangkum semua tahap dalam satu jaringan untuk membentuk sistem deteksi ujung ke ujung yang sebenarnya. Metode YOLOv3 akan membagi dataset citra menjadi sel kisi kecil $S \times S$. Jika pusat objek terdeteksi tepat di dalam sel kisi, sel kisi bertanggung jawab untuk mendeteksi objek. Setiap sel kisi memiliki tugas memprediksi informasi posisi kotak pembatas B dan menghitung skor objeksi yang sesuai dengan kotak pembatas ini. Setiap skor objeksi dapat diperoleh sebagai berikut:

$$C_j^i = P_{ij}(Object) \times IOU_{pred}^{truth} \quad (2.1)$$

Dimana C_j^i adalah skor objeksi kotak pembatas jth di sel kisi ith . $P_{ij}(Object)$ adalah sebuah fungsi objek. IOU_{pred}^{truth} mewakili persimpangan atas persatuan (IOU) antara kotak prediksi dan kotak kebenaran dasar. Metode YOLOv3 menggunakan entropi silang biner dari skor objektivitas yang diprediksi dan skor objeksi kebenaran sebagai salah satu bagian dari fungsi loss. Ini dapat dinyatakan pada persamaan 2.2 sebagai berikut:

$$E_1 = \sum_{i=0}^{S^2} \sum_{j=0}^B W_{ij}^{obj} [\hat{C}_j^i \log(C_j^i) - (1 - \hat{C}_j^i) \log(1 - C_j^i)] \quad (2.2)$$

Dimana S^2 adalah jumlah sel kisi gambar, dan B adalah jumlah kotak pembatas. C_j^i dan \hat{C}_j^i adalah prediksi kesalahan dan skor prediksi kebenaran. Posisi setiap kotak pembatas didasarkan pada empat prediksi t_x, t_y, t_w, t_h . Dengan asumsi bahwa (C_x, C_y) adalah offset sel kisi dari sudut kiri atas gambar. Posisi tengah kotak pembatas akhir yang diprediksi diimbangi dari sudut kiri atas gambar dengan (b_x, b_y) . Dan dihitung pada persamaan 2.3 dan 2.4 sebagai berikut:

$$b_x = \sigma(tx) + c_x \quad (2.3)$$

$$b_y = \sigma(ty) + c_y \quad (2.4)$$

Dimana σ merupakan fungsi sigmoid. Lebar dan tinggi kotak pembatas yang diprediksi dihitung dengan persamaan 2.5 dan 2.6

$$b_w = p_w e^{t_w} \quad (2.5)$$

$$b_h = p_h e^{t_h} \quad (2.6)$$

Dimana $p_w p_h$ adalah lebar dan tinggi kotak pembatas sebelumnya. Mereka diperoleh dengan pengelompokan dimensi. Kotak kebenaran dasar terdiri dari empat parameter (g_x, g_y, g_w, g_h) yang sesuai dengan parameter yang diprediksi $b_x b_y t_w, t_h$. Berdasarkan rumus yang ada dari diatas, maka nilai kebenaran dari $\hat{t}_x, \hat{t}_y, \hat{t}_w, \hat{t}_h$ dapat diperoleh sebagai berikut :

$$\sigma(\hat{t}_x) = g_x - c_x \quad (2.7)$$

$$\sigma(\hat{t}_y) = g_y - c_y \quad (2.8)$$

$$\hat{t}_w = \log(g_w/p_w) \quad (2.9)$$

$$\hat{t}_h = \log(g_h/p_h) \quad (2.10)$$

Metode YOLOv3 menggunakan kesalahan kuadrat dari prediksi koordinat sebagai salah satu bagian dari fungsi kehilangan. Ini dapat dinyatakan dengan persamaan 2.11 sebagai berikut:

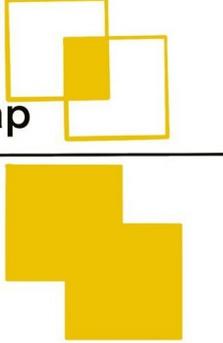
$$E_2 = \sum_{i=0}^{S^2} \sum_{j=0}^B W_{ij}^{obj} [(\sigma(t_x)_i^j - \sigma(\hat{t}_x)_i^j)^2 + [(\sigma(t_y)_i^j - \sigma(\hat{t}_y)_i^j)^2] \quad (2.11)$$

$$+ \sum_{i=0}^{S^2} \sum_{j=0}^B W_{ij}^{obj} [(\sigma(t_w)_i^j - \sigma(\hat{t}_w)_i^j)^2 + [(\sigma(t_h)_i^j - \sigma(\hat{t}_h)_i^j)^2]$$

2.6 Intersection over Union (IoU)

Intersection over Union (IoU) adalah suatu evaluasi metrik untuk mengukur keakuratan kotak pembatas *ground truth* dengan kotak pembatas prediksi. Intersection merupakan luas bagian yang overlap antara *ground truth* dan kotak pembatas prediksi. Sedangkan *union* merupakan luas gabungan *ground truth*

dengan kotak pembatas prediksi. Kondisi perbandingan tersebut dapat di ilustrasikan sebagai berikut:

$$\text{IoU} = \frac{\text{Area of Overlap}}{\text{Area of Union}}$$


Gambar 2. 14 Persamaan untuk mendapatkan nilai IOU

Dari gambar diatas IoU memiliki nilai *range* dari 1 hingga 0. Nilai 1 merupakan nilai apabila posisi antara *ground truth* dan kotak pembatas prediksi memiliki posisi sama. Dan nilai 0 merupakan nilai apabila posisi antara *ground truth* dan kotak pembatas prediksi tidak memiliki kesamaan letak posisi dan cenderung semakin menjauh setiap antar kotak.

2.7 Mean Average Precision (mAP)

Mean average precision merupakan evaluasi nilai rata rata dari AP (*Average Precision*) untuk menghitung performa object detection. Pada objek deteksi ada sebuah kategori objek, dan masing masing memiliki AP. Dan untuk menghitung *average precision*, kita perlu batas *threshold IOU*. Dari perhitungan tersebut akan dihasilkan nilai dari *average precision* masing masing kategori objek yang nantinya akan membentuk sebuah rata rata seperti perhitungan pada persamaan 2.12 [33].

$$AP = \sum (recall_{n+1} - recall_n) \times precision_{interp} \times (recall_{n+1}) \quad (2. 12)$$

2.8 F-Measure

F-Measure merupakan gabungan dari *recall* dan *precision*. Untuk mendapatkan *F1 score* yang tinggi diperlukan nilai *recall* dan *precision* yang tinggi. Nilai *F1 score* dihitung menggunakan persamaan 2.13 [33].

$$F - measure = \frac{2 \times recall \times precision}{recall \times precision} \quad (2.13)$$

2.9 Precision

Nilai presisi dihitung dengan cara membagi total sampel positif yang diklasifikasikan dengan benar dibagi dengan total sampel *false positive* ditambah dengan sampel *true positive* yang diperlihatkan pada rumus seperti pada persamaan 2.14 [33].

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \quad (2.14)$$

2.10 Recall

Recall adalah rasio dari total keseluruhan hasil positif yang diklasifikasikan dengan benar kemudian dibagi dengan total sampel *false negative* ditambah dengan sampel *true positive*. Nilai recall yang tinggi menunjukkan bahwa kelas dideteksi dengan benar. Berikut merupakan persamaan *recall* 2.15 [33].

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \quad (2.15)$$

2.11 Confusion Matrix

Confusion matrix atau *error matrix* adalah ringkasan hasil prediksi pada permasalahan klasifikasi untuk mengidentifikasi jumlah klasifikasi benar dan salah dan memiliki nilai yang kemudian akan dipecah setiap kelas.

2.12 Fill Factor

Fill Factor (FF) adalah nilai perbandingan tegangan dan arus pada keadaan daya maksimum dengan tegangan rangkaian terbuka (V_{oc}) dan arus hubung singkat (I_{sc}). Formulasi disajikan dalam persamaan (2.16). P_{max} adalah salah satu variabel kelistrikan penting dari modul PV yang sering digunakan oleh pabrikan untuk menunjukkan penurunan kinerja dan digunakan untuk mengukur persentase penurunan daya (DoP) pada kinerja modul PV yang terdegradasi menggunakan persamaan (2.17) [34].

$$FF = \frac{P_{max}}{V_{oc} \times I_{sc}} \quad (2.16)$$

$$FF = \frac{P_{nmax} - P_{cmax}}{P_{nmax}} \times 100\% \quad (2.17)$$

Dimana, P_{nmax} merupakan daya maksimal dari modul baru, sedangkan P_{cmax} merupakan daya maksimal dari modul yang telah terpasang.