

BAB II

TINJAUAN PUSTAKA DAN LANDASAN TEORI

2.1 TINJAUAN PUSTAKA

Pengembangan sistem informasi monitoring surya PV menjadi isu penting dalam mendukung keberlanjutan dan efisiensi operasional sistem energi terbarukan (Deshmukh and Singh, 2020; Bhau *et al.*, 2021; Raghunath, Deshmukh and Deshmukh, 2021). Peneliti Deshmukh melakukan pemantauan berbasis IoT pada sistem surya PV *stand-alone* menggunakan platform *Conext Insight* dari Schneider Electric yang meliputi data masukan total PV, pengisian baterai, pengosongan baterai, grid masukan, dan beban keluaran. Peneliti Mudaliar (Mudaliar and Sivakumar, 2020) mengembangkan sistem monitoring menggunakan platform Raspberry Pi dan layanan awan pada surya PV. Sistem ini memungkinkan pengiriman data PV ke platform berbasis web untuk keperluan monitoring jarak jauh. Namun demikian, penelitian tersebut belum mengembangkan mekanisme pengolahan data dan analisis statistik yang komprehensif untuk mendukung fungsi sistem informasi, khususnya dalam penyediaan informasi kinerja dan prediksi produksi energi.

Peneliti (Lopez-Vargas, Fuentes and Vivar, 2019) mengembangkan platform IoT dengan memanfaatkan jaringan komunikasi seluler 3G untuk mentransmisikan data PV ke layanan awan dan direpresentasikan melalui aplikasi web. Arsitektur ini menunjukkan pentingnya integrasi antara lapisan akuisisi data, komunikasi, dan visualisasi dalam cakupan sistem informasi. Namun, ketergantungan terhadap infrastruktur komunikasi dan keterbatasan analitik menjadi faktor yang mempengaruhi keandalan sistem informasi secara keseluruhan. Peneliti Kermani mengembangkan sistem pemantauan surya PV dengan menggunakan sistem SCADA yang terdiri dari komponen perangkat keras untuk akuisisi data, komunikasi, pengontrolan dan perangkat lunak untuk optimasi, elaborasi data, visualisasi data (Kermani *et al.*, 2021). Bagaimanapun, integrasi perangkat SCADA pada microgrid tidak mudah dan kompleksitas sistem semakin meningkat ketika ada penambahan rangkaian switching dan kebutuhan sinyal PWM

frekuensi tinggi untuk keperluan pengontrolan serta kebutuhan biaya yang tinggi (Ullah *et al.*, 2022). Hal ini menunjukkan perlunya sistem informasi monitoring yang lebih ringan, adaptif, dan berbasis IoT untuk konteks Smart Microgrid.

Seiring dengan meningkatnya kompleksitas data operasional PV, penelitian mulai mengintegrasikan kecerdasan buatan ke dalam sistem monitoring. Peneliti Emamian (Emamian *et al.*, 2022) mengusulkan IMS untuk pembangkit PV dengan menggunakan protokol mini WIFI untuk komunikasi data berbasis IoT. IMS menggunakan model ansambel pada arsitektur ANN-LSTM untuk deteksi kesalahan dan prediksi daya dalam sistem PV. Pendekatan ini menandai pergeseran dari sistem monitoring pasif menuju sistem informasi yang memiliki kemampuan analitik dan prediktif. Namun, fokus penelitian tersebut masih lebih menitikberatkan pada performa algoritma, tanpa membahas peran sistem informasi secara menyeluruh dalam mendukung manajemen energi.

Proses peramalan yang dilakukan menggunakan pendekatan AI sangat diperlukan untuk pemanfaatan kinerja sistem PV. Model AI menggunakan pendekatan *Neural Network* merupakan model dasar untuk peramalan daya pada sistem PV. Model ini mempunyai keunggulan dalam memecahkan masalah nonlinier yang kompleks. Penelitian ini menggunakan renewable energy yang bersumber dari energi solar. Beberapa pendekatan telah dikembangkan untuk prediksi solar PV generation oleh peneliti sebelumnya yaitu pendekatan tradisional dengan menggunakan model time series dan pendekatan tingkat lanjut dengan menggunakan model Neural Network (NN) (Sharma *et al.*, 2011; Chen *et al.*, 2017). Beberapa metode yang digunakan pada model time series diantaranya Autorregresive (AR) (Bacher, Madsen and Nielsen, 2009), Moving Average (MA) dan Autorregresive Moving Averages (ARMA).

Pada model hybrid, kombinasi metode dilakukan dengan tujuan untuk mengatasi kelemahan pada metode NN, sebagai contoh metode NN dengan wavelet (Cao and Cao, 2005, 2006; Mellit, Benganem and Kalogirou, 2006). Hasil perbandingan yang dilakukan oleh peneliti (Reikard, 2009) menunjukkan bahwa metode ARIMA memiliki performansi yang lebih baik dari metode lainnya (regresi, UCM dan NN) tergantung pada resolusi yang diinginkan. Perbandingan lainya pada model linear (ARIMA) dengan model non-linear (NN, ANFIS). Metode ARIMA

bagus pada pemrosesan data yang sederhana begitu juga pada NN bagus pada pemrosesan yang mempunyai sedikit iterasi.

Pada pendekatan tingkat lanjut dengan menggunakan model Neural Network (NN), peneliti (Gensler *et al.*, 2016) mengembangkan metode peramalan dengan menggunakan metode deep learning dan fokus eksperimen pada penggunaan beberapa struktur jaringan neuron, seperti Auto encoder, Deep Belief Network, LSTM dan dibandingkan dengan metode ANN. Pada penelitian tersebut, deep learning memberikan hasil akurasi yang tinggi dibandingkan dengan ANN. Peneliti (Agoua, Girard and Kariniotakis, 2018) menggunakan metode statistik Spatio temporal untuk memprediksi solar generation. Hasil eksperimen menunjukkan kompleksitas komputasi rendah. Selanjutnya, untuk menangani permasalahan time-series prediction penggunaan metode deep learning dengan struktur jaringan LSTM lebih cocok dibandingkan metode lainnya (Aslam *et al.*, 2019).

Peneliti Aslam (M. Aslam *et al.*, 2021) mengembangkan model peramalan daya untuk hari kedepan dengan menggunakan metode *Deep Learning* berdasarkan mekanisme 2 tahap pada arsitektur LSTM dan metode optimasi Bayesian yang diterapkan untuk mendapatkan kombinasi optimal dari Hyperparameter pada model *Deep Learning*. Bagaimanapun, model ini memiliki komputasi yang kompleks, sehingga proses konvergensi menjadi lambat. Peneliti Succetti (Succetti *et al.*, 2020) mengembangkan model prediksi multivariat daya luaran PV dengan membandingkan 4 arsitektur DNN. Hasil pengujian membuktikan arsitektur multi-LSTM memiliki akurasi yang paling tinggi. Peneliti Agga (Agga *et al.*, 2021) mengembangkan dua model hibrida menggunakan CNN-LSTM dan ConvLSTM untuk memprediksi daya pembangkit PV. Hasil pengujian menunjukkan model CNN-LSTM memberikan hasil yang lebih akurat. Bagaimanapun, model ini memerlukan layer yang panjang sehingga meningkatkan kompleksitas komputasi dan akurasi model tersebut menurun ketika waktu perkiraan lebih panjang.

Peneliti Cervone (Cervone *et al.*, 2017) mengembangkan metode ANN dan analog Ensemble untuk memprediksi daya PV. Hasil pengujian menunjukkan kombinasi ini memberikan hasil terbaik dan komputasi yang efisien ketika diterapkan pada komputasi paralel. Bagaimanapun, pendekatan ini membutuhkan kumpulan data historis yang sesuai dengan model analog karena model dikompilasi

hanya satu kali pada pendekatan ini. Peneliti Guo (Guo *et al.*, 2020) mengembangkan metode prediksi daya PV dengan menggunakan model pembelajaran berbasis *Stacking ensemble* yang terdiri dari beberapa algoritma, diantaranya XGBoost, RF, SVR, LGBM dan *CatBoost*. Hasil pengujian menunjukkan metode ensemble yang terdiri dari XGBoost, CatBoost, LGBM, RF memberikan hasil yang paling akurat. Bagaimanapun, hasil kinerja metode pembelajaran ensemble akan dipengaruhi data kelistrikan yang mempunyai pola acak yang rumit dan sulit untuk disesuaikan secara tepat (Chen *et al.*, 2022). Sehingga memerlukan metode pembelajaran mendalam atau *Deep Learning* yang memiliki keunggulan pada analisis data non linier.

Berdasarkan tinjauan pustaka tersebut, sebagian besar penelitian sebelumnya masih berfokus pada pengembangan model prediksi atau sistem monitoring yang diteliti secara terpisah. Masih terbatas penelitian yang mengintegrasikan kemampuan monitoring, analitik prediktif, dan visualisasi informasi ke dalam satu sistem informasi yang mendukung pengambilan keputusan manajemen energi pada Smart Microgrid. Oleh karena itu, penelitian ini mengisi celah tersebut dengan mengembangkan sistem monitoring kinerja solar PV berbasis IoT dan Multi-LSTM yang dirancang sebagai artefak dengan menambahkan pengolahan hasil luaran sistem monitoring berdasarkan kecerdasan buatan Multi-LSTM pada Sistem Informasi untuk mendukung pengelolaan dan pengambilan keputusan energi secara terintegrasi.

2.2 KEASLIAN (ORISINALITAS) PENELITIAN

Berdasarkan ringkasan penelitian terdahulu yang ditunjukkan pada Tabel 2.1, dapat dilihat bahwa sebagian besar penelitian sebelumnya berfokus pada pengembangan dan perbandingan model peramalan daya solar PV dengan tujuan utama meningkatkan akurasi prediksi. Penelitian oleh (Succetti *et al.*, 2020; Agga *et al.*, 2021; M. Aslam *et al.*, 2021) mengembangkan berbagai arsitektur berbasis LSTM, CNN-LSTM, dan ConvLSTM untuk peramalan daya PV, namun pendekatan tersebut masih menempatkan model kecerdasan buatan sebagai objek utama penelitian, bukan sebagai bagian dari sistem informasi yang terintegrasi.

Tabel 2.1 Penelitian yang telah dilakukan sebelumnya.

No	Peneliti	Judul	Metode	Fokus Penelitian
1	(M. Aslam <i>et al.</i> , 2021)	Two-Stage Attention Over LSTM With Bayesian Optimization for Day-Ahead Solar Power Forecasting	LSTM dan Bayesian optimization	<ul style="list-style-type: none"> - Berfokus pada optimasi akurasi model - Belum dirancang sebagai bagian dari sistem informasi - Belum membahas pemanfaatan hasil prediksi sebagai informasi pendukung keputusan
2	(Succetti <i>et al.</i> , 2020)	Deep Neural Network for Multivariate Solar Power Forecasting on Smart Home Microgrid	C-LSTM, Conv LSTM, Multi-LSTM, Stacked LSTM	<ul style="list-style-type: none"> - Model peramalan berdiri sendiri - Belum terintegrasi dalam arsitektur sistem informasi monitoring real-time dan manajemen energi
3	(Agga <i>et al.</i> , 2021)	Short-term self consumption PV plant power production forecasts based on hybrid CNN-LSTM, ConvLSTM models	Hybrid model: CNN-LSTM, Conv LSTM	<ul style="list-style-type: none"> - Pendekatan berorientasi performa prediksi - Belum mengkaji peran sistem informasi dalam transformasi data menjadi informasi keputusan
4	(Guo <i>et al.</i> , 2020)	Study on short-term photovoltaic power prediction model based on the Stacking ensemble learning	XGboost, RF, SVR, CatBoost, LGBM	<ul style="list-style-type: none"> - Fokus pada ensemble prediction - Belum mempertimbangkan integrasi dengan sistem informasi monitoring berbasis IoT

No	Peneliti	Judul	Metode	Fokus Penelitian
5	(Cervone <i>et al.</i> , 2017)	Short-term photovoltaic power forecasting using Artificial Neural Networks and an Analog Ensemble	ANN, Analog Ensemble	<ul style="list-style-type: none"> - Ketergantungan tinggi pada data historis - Belum dirancang untuk sistem informasi operasional real-time
6	(Emamian <i>et al.</i> , 2022)	Cloud Computing and IoT Based Intelligent Monitoring System for Photovoltaic Plants Using Machine Learning Techniques	Platform IoT dan Model Ensemble LSTM	<ul style="list-style-type: none"> - Fokus pada platform monitoring dan performa model - Arsitektur sistem informasi dan dukungan keputusan belum dibahas secara terstruktur
7	Iksan, <i>et al</i>	<ol style="list-style-type: none"> 1. Arsitektur system monitoring renewable energi pada PV 2. Optimasi metode DNN untuk proses peramalan 	<ol style="list-style-type: none"> 1. Perbaikan layanan pada arsitektur 2. Bayesian optimization + Multi LSTM pada DNN 	Merancang dan mengimplementasikan sistem informasi yang mengintegrasikan IoT, analitik Multi-LSTM, untuk mendukung pengambilan keputusan

SEKOLAH PASCASARJANA

Dalam kaitanya dengan Sistem Informasi, kekurangan utama penelitian-penelitian tersebut tidak hanya terletak pada kompleksitas komputasi atau kebutuhan layer yang banyak, tetapi pada belum adanya integrasi menyeluruh antara data real-time dari perangkat fisik (IoT), pengolahan data, analitik prediktif, dan penyajian informasi untuk mendukung pengambilan keputusan manajemen energi. Sebagian besar penelitian masih mengolah data secara offline atau menggunakan kumpulan data historis tanpa mempertimbangkan arsitektur sistem informasi operasional yang berjalan secara kontinu pada lingkungan Smart Microgrid.

Penelitian berbasis ensemble dan stacking seperti yang dilakukan oleh (Cervone *et al.*, 2017; Guo *et al.*, 2020) menunjukkan peningkatan akurasi prediksi, namun dalam konteks Sistem Informasi, pendekatan tersebut memiliki keterbatasan dalam hal adaptivitas sistem, ketergantungan pada kualitas data historis, serta belum dirancang sebagai bagian dari sistem monitoring dan manajemen energi secara real-time. Hal ini menyebabkan model sulit diintegrasikan secara langsung ke dalam sistem operasional Smart Microgrid. Penelitian oleh Emamian (Emamian *et al.*, 2022) mulai mengarah pada integrasi antara IoT dan kecerdasan buatan melalui pengembangan *Intelligent Monitoring System* (IMS). Meskipun demikian, pendekatan tersebut masih menitikberatkan pada pemilihan dan performa model ensemble LSTM, tanpa membahas secara mendalam perancangan arsitektur sistem informasi, alur transformasi data menjadi informasi, serta peran sistem dalam mendukung pengambilan keputusan energi secara terstruktur.

Berdasarkan analisis tersebut, modifikasi dan kebaruan penelitian ini terletak pada pengembangan sistem informasi yang mengintegrasikan hasil luaran rekaman data IoT dengan model analitik berbasis Multi-LSTM yang dimodifikasi dan dioptimasi menggunakan Algoritma Bayesian Optimization. Multi-LSTM dirancang dengan pemrosesan multivariat melalui jalur LSTM terpisah untuk mengekstraksi pola temporal spesifik dari setiap parameter operasional PV. Bayesian Optimization diterapkan untuk mengoptimasi hyperparameter utama

model secara adaptif berdasarkan performa prediksi terhadap data operasional. Model Multi-LSTM teroptimasi selanjutnya diintegrasikan sebagai *decision support engine* dalam sistem informasi monitoring berbasis IoT, sehingga hasil peramalan tidak hanya meningkatkan akurasi prediksi, tetapi berfungsi sebagai informasi prediktif yang mendukung pengambilan keputusan manajemen energi pada Smart Microgrid.

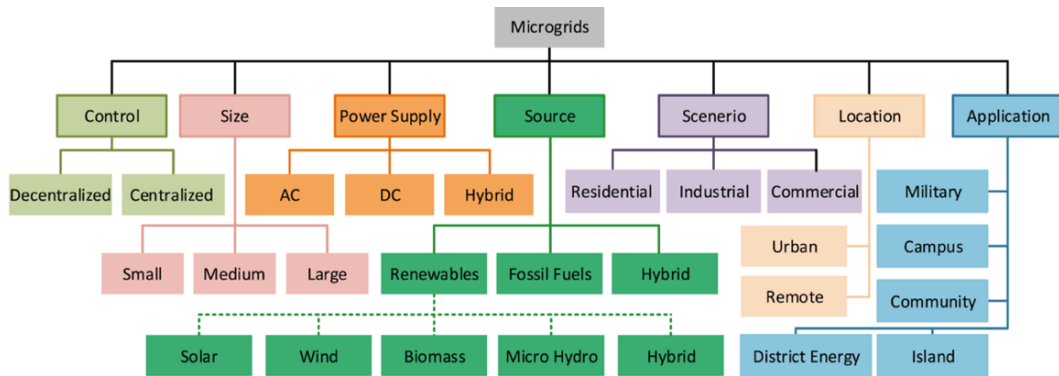
2.3 LANDASAN TEORI

2.3.1 GRID DAN MICROGRID

Grid dalam konteks kelistrikan disebut juga jaringan listrik atau *electrical grid* memiliki komponen yang terdiri dari sistem pembangkit, sistem transmisi, sistem distribusi dan konsumen (Barua *et al.*, 2021). PLN sebagai penyedia layanan energi listrik memiliki sistem pembangkitan listrik terpusat untuk menghasilkan energi listrik dan selanjutnya ditransmisikan dan didistribusikan ke pelanggan. Sistem pembangkitan listrik semakin dikembangkan dengan menerapkan model terdistribusi yang memungkinkan sumber energi listrik tersebar di banyak lokasi bahkan pada pengguna akhir. Sumber energi yang tergabung dalam model terdistribusi umumnya berupa energi terbarukan seperti energi surya, energi angin, energi air yang digabungkan dengan instalasi baterai dan generator sehingga membentuk jaringan listrik. Sumber energi terdistribusi dapat diimplementasikan pada jaringan listrik yang lebih kecil yang digunakan pada konsumen perumahan atau komersial kecil atau *microgrid*. Disamping itu juga dapat diimplementasikan pada konsumen dengan konfigurasi daya yang lebih besar misalkan untuk pedesaan, universitas, pabrik dan gerai komersial yang lebih besar yang mempunyai kapasitas 1 kW hingga 10 kW.

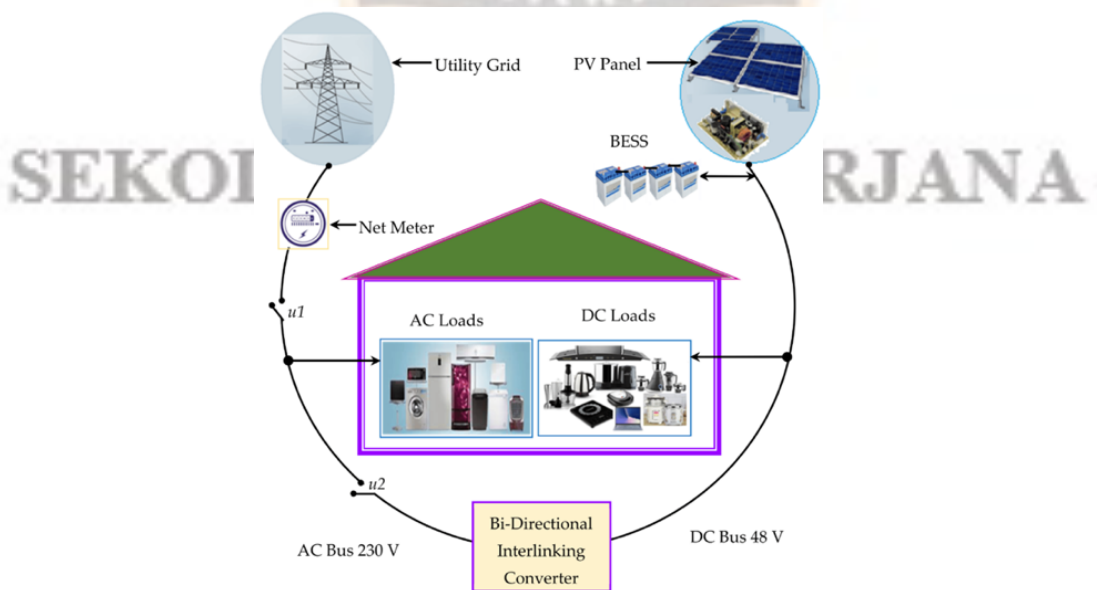
MG menerapkan sistem pembangkit terdistribusi baik dari pembangkit konvensional dan pembangkit terbarukan. MG dapat diklasifikasikan berdasarkan beberapa kategori (Uddin *et al.*, 2023) sebagaimana ditunjukkan pada Gambar 2.1. Berdasarkan sumber energinya, MG dapat bersumber dari energi terbarukan seperti energi surya, angin, biomass, mikro hidro dan hibrida. Selanjutnya MG juga dapat

bersumber dari energi fosil, serta bersumber dari gabungan antara energi terbarukan dan fosil.



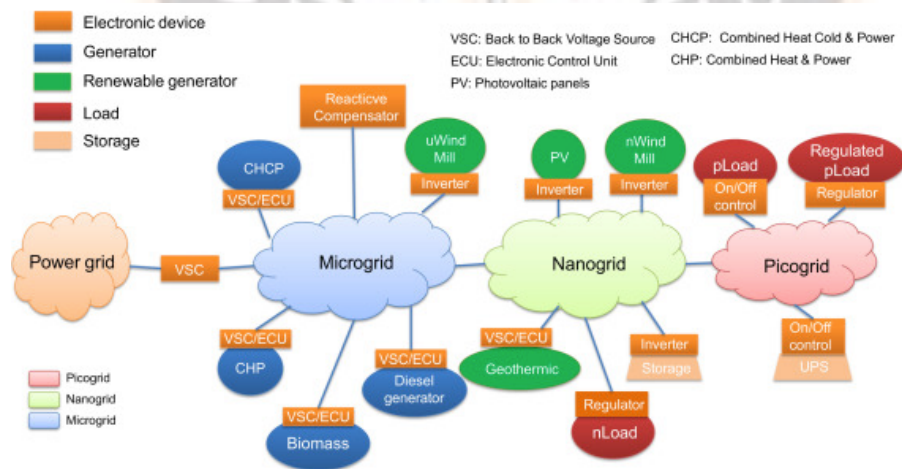
Gambar 2.1 Klasifikasi microgrid (Come Zebra *et al.*, 2021)

Pada klasifikasi MG dengan kategori sumber energi hibrida, dapat direalisasikan dengan integrasi antara sumber energi fosil dan terbarukan, sebagaimana ditunjukkan pada Gambar 2.2. Sumber energi fosil biasanya dimanfaatkan oleh jaringan listrik konvensional atau grid PLN. Beban AC dihubungkan ke bus AC dan dialiri oleh sumber AC dari grid PLN. Kemudian pada bus DC terdiri dari PV surya, baterai dan beban DC (Said, Aly and Balint, 2020; Rengasamy *et al.*, 2021).



Gambar 2.2 Microgrid dengan sumber energi hibrida (Said, Aly and Balint, 2020)

Konsep jaringan listrik pada literatur lain (Martin-Martínez, et.al, 2016) mendefinisikan konfigurasi skema hirarki dari jaringan listrik yang terdiri dari power grid, microgrid, nanogrid dan picogrid sebagaimana ditunjukkan pada Gambar 2.3. Skema hirarki ini terdapat pada area residensial yang terhubung ke jaringan distribusi daya atau ke microgrid lainnya. Power grid terkait jaringan listrik utama yang dikelola oleh perusahaan utilitas dan diatur oleh pemerintah. Jaringan ini terdiri dari pembangkit listrik, saluran transmisi, gardu induk, dan sistem distribusi. Power grid disebut juga sebagai jaringan makro atau macrogrid yang menyediakan listrik skala besar untuk ditransmisikan dan didistribusikan ke pelanggan yang jaraknya sangat jauh.



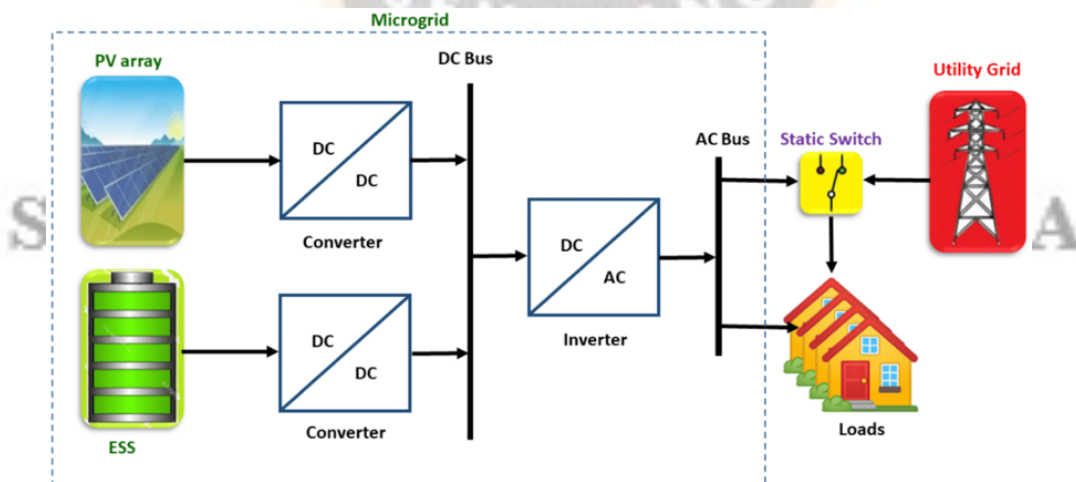
Gambar 2.3 Microgrid yang terhubung pada Power grid, Nanogrid dan Picogrid (Martin-Martínez, et.al, 2016)

MG mengintegrasikan DER dan juga terhubung langsung ke power grid melalui jaringan distribusi serta juga ke MG lainnya. Oleh karena itu, MG menjadi jaringan listrik skala mikro yang dapat beroperasi secara mandiri atau beroperasi bersama dengan jaringan listrik utama. Nano Grid merupakan versi yang lebih kecil dari microgrid yang dirancang untuk menyediakan listrik yang ditujukan untuk penggunaan pada lokasi-lokasi terpencil. Nano Grid bertujuan mengendalikan pembangkit listrik nano yang dapat berupa panel PV dan turbin angin nano, beban nano, dan grid yang lebih kecil atau pico grid. Selanjutnya, picogrid menjadi sistem kelistrikan paling kecil yang biasanya digunakan untuk kebutuhan daya yang sangat kecil. Contoh implementasi picogrid pada perangkat portabel dan perangkat IoT

yang memerlukan daya listrik yang kecil. Nanogrid dan pico grid menyediakan solusi energi untuk lokasi yang jauh dari jangkauan jaringan listrik utama.

2.3.2 MICROGRID TERHUBUNG DENGAN PV

Microgrid yang terhubung dengan utility grid dan memiliki sumber energi PV telah mengkombinasikan sumber daya terbarukan PV dengan jaringan utama untuk meningkatkan keandalan, efisiensi, dan keberlanjutan daya di tingkat lokal. Microgrid ini juga dapat beroperasi secara terhubung ke jaringan utama atau berdiri sendiri yang membuatnya lebih fleksibel dan ideal untuk wilayah-wilayah dengan akses listrik terbatas atau yang sering mengalami gangguan. Arsitektur microgrid ini terdiri dari sakelar, pemutus sirkuit, inverter, panel PV, sistem penyimpanan energi, bus DC, bus AC dan beban, seperti yang diilustrasikan dalam Gambar 2.4 (Shaban *et al.*, 2021). Konverter DC/DC yang dikontrol oleh MPPT digunakan untuk memaksimalkan hasil daya array PV. Rangkaian konverter ini dirancang untuk menyesuaikan titik operasi selalu pada titik daya maksimum karakteristik P-V array. Rangkaian konverter melacak tegangan dan arus array yang diukur oleh sensor tegangan dan arus DC. Konverter ini digunakan untuk menghubungkan array PV secara efektif ke inverter DC-AC dan/atau untuk mengisi daya array baterai.



Gambar 2.4 Arsitektur microgrid terhubung ke main grid, PV dan baterai (Shaban *et al.*, 2021)

Sistem penyimpanan energi atau ESS sangat penting untuk mengkompensasi kekurangan energi dan fluktuasi daya dalam sistem PV mandiri. Bus DC dihubungkan ke susunan baterai melalui sirkuit konverter bidirectional. Pengontrol

konverter ini tersebut bertanggung jawab untuk mempertahankan tegangan bus DC yang diatur, selain mengisi dan mengeluarkan daya susunan baterai sebagaimana diperlukan. Inverter berfungsi sebagai penghubung antara bus DC dan beban. Kontrol inverter digunakan untuk mengatur tegangan dan frekuensi di sisi beban. Karena sistem tidak terhubung langsung ke jaringan utilitas, amplitudo dan frekuensi tegangan bus AC harus diatur dengan baik.

2.3.3 SISTEM MONITORING SOLAR PV

Surya PV menjadi salah satu sumber energi berkelanjutan yang mulai banyak diterapkan dibandingkan dengan sumber energi terbarukan lainnya. Pengoperasian dan fungsi dari sistem surya PV dapat dipengaruhi oleh berbagai faktor, seperti lingkungan, suhu, penyinaran dan lain-lain sehingga akurasi dan kinerjanya dapat ditingkatkan dengan menggunakan sistem monitoring surya PV. Karena semakin meningkatnya kebutuhan energi yang berasal dari surya PV ini, teknologi monitoring surya PV menjadi perhatian yang cukup besar untuk mendukung peningkatan kinerja solar PV. Proses monitoring bertujuan untuk merekam dan mengamati parameter-parameter yang menentukan kinerja sistem surya PV dan mendeteksi gangguan/kesalahan secara realtime serta memberikan sinyal peringatan kepada pengguna untuk tujuan pemeliharaan dan perbaikan (Labrador Rivas and Abrão, 2020).

Integrasi surya PV sebagai sumber energi terbarukan dengan sumber energi dari jaringan listrik PLN dapat dilakukan dengan menerapkan teknologi smart grid. Teknologi smart grid juga dapat diterapkan pada skala mikro yang digunakan untuk pemenuhan kebutuhan kelistrikan pada rumah tangga dan gedung atau disebut *smart microgrid*. Penerapan *smart microgrid* memiliki beberapa tantangan yang meliputi ketidakstabilan pada pensuplaian energi listrik yang bersumber dari surya PV dan memerlukan peningkatan pada teknik optimasi dan peramalan pada energi yang dihasilkan sehingga dapat menjaga stabilitas pada pensuplaian dan permintaan energi pada *smart microgrid* (Marino, Chinelato and Marufuzzaman, 2022).

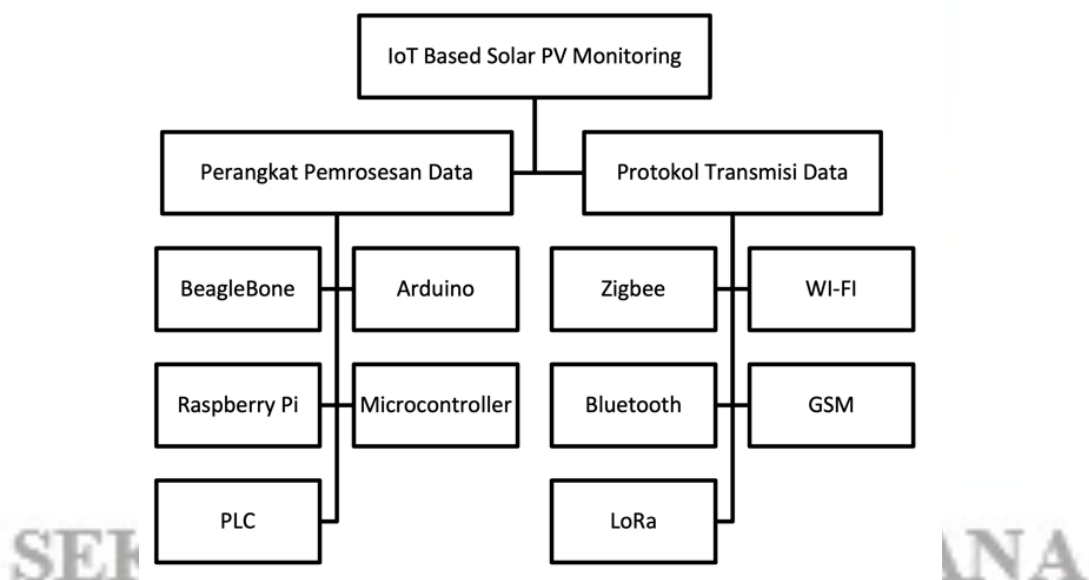
Arsitektur sistem monitoring PV dapat dibagi menjadi 3 bagian, diantaranya bagian akuisisi data, bagian pemrosesan data dan bagian visualisasi dan

penyimpanan data (Ansari *et al.*, 2021). Bagian akuisisi data digunakan untuk mengumpulkan berbagai data yang berasal dari berbagai sensor, seperti tegangan, arus, suhu, kelembaban, radiasi, dan lain-lain. Data hasil akuisisi ini kemudian dikirimkan ke bagian pemrosesan data melalui media komunikasi data baik menggunakan kabel maupun tanpa kabel seperti Zigbee, WI-FI, Bluetooth, Lora dan lain-lain. Selanjutnya, data akan disimpan pada perangkat seperti data logger, kemudian diproses dan dikirimkan ke bagian visualisasi data. Selanjutnya peneliti lain, Fernandes (de Arquer Fernández *et al.*, 2021) mengembangkan arsitektur menjadi 4 bagian seperti lapisan sensor, transmisi, pemrosesan data dan aplikasi. Penerapan arsitektur ini didasarkan pada skala pemantauan, seperti pemantauan skala besar dan kecil serta pemantauan berbasis perangkat lunak atau berbasis cloud. Klasifikasi dari berbagai parameter kelistrikan dan lingkungan dari arsitektur sistem pemantauan PV dapat ditunjukkan pada Tabel 2.2.

Tabel 2.2 Berbagai parameter kelistrikan dan lingkungan dari arsitektur sistem pemantauan PV.

Sistem monitoring PV	Parameter	
	Lingkungan	kelistrikan
Skala Besar	<ol style="list-style-type: none"> 1. Irradiance 2. Array Temperature 3. Speed of wind 4. Humidity 5. Air Presure 	<ol style="list-style-type: none"> 1. Array output voltage 2. Array output current 3. Grid voltage 4. Current to and from gri 5. Grid impedance
Skala Kecil	<ol style="list-style-type: none"> 1. Irradiance 2. Panel Temperature 3. Humidity 	<ol style="list-style-type: none"> 1. Panel output voltage 2. Panel output current 3. Inverter output voltage 4. Inverter output current 5. Load output voltage 6. Load output current


Berbagai pengembangan teknologi pada aplikasi monitoring solar PV difokuskan pada bagian pemrosesan data, protokol transmisi dan metode kecerdasan buatan sebagaimana ditunjukkan pada Gambar 2.5. Pengembangan pada bagian pemrosesan data meliputi perangkat-perangkat yang digunakan diantaranya: BeagleBone (Genevieve et al., 2015), Arduino (Lopez-Vargas et al., 2019), Raspberry Pi (Paredes-Parra *et al.*, 2018; Mudaliar and Sivakumar, 2020), PLC (Han *et al.*, 2014), dan Mikrokontrol seperti ATMEGA8 dan ATMEGA16 (Le, Tsai and Lam, 2016). Pengembangan dari protokol transmisi data seperti Zigbee (Ranhotigamage and Mukhopadhyay, 2011; Lopez, Mantinan and Moline, 2012), GSM (Tejwani, Kumar and Solanki, 2014), WI-FI (Allafi and Iqbal, 2017), Bluetooth (Guerriero *et al.*, 2016) dan LoRa (Lee and Ke, 2018).



Gambar 2.5 Perkembangan perangkat IoT pada sistem monitoring solar PV.

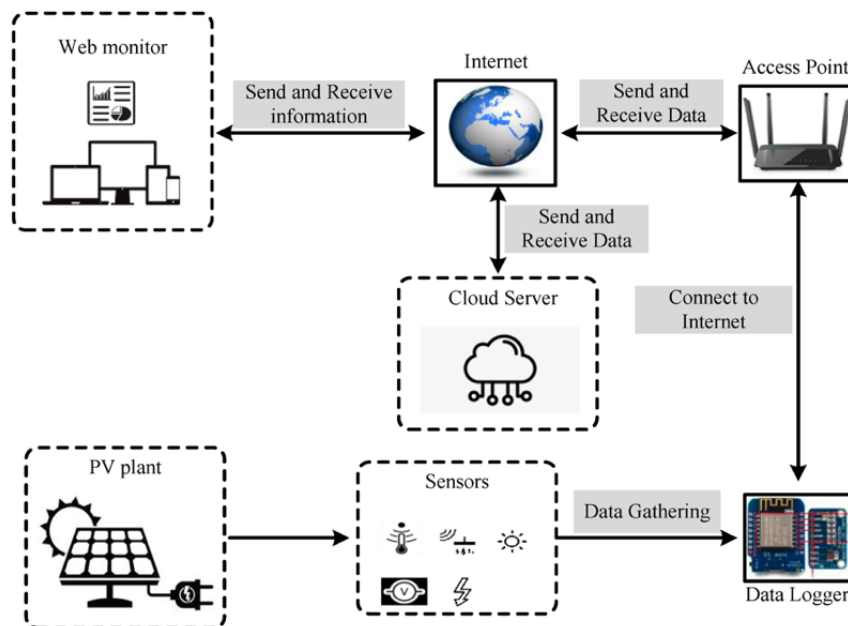
Beberapa penelitian terkait sistem monitoring PV telah dilakukan, seperti peneliti Forero (Forero et al., 2006) mengembangkan sistem monitoring PV dengan menggunakan data logger komersial untuk menyimpan dan mentransfer data dari variable output listrik solar PV berupa kurva I-V dan data dari variabel lingkungan berupa temperatur, radiasi matahari ke Lab VIEW. Peneliti Chouder (Chouder *et al.*, 2013) menggunakan akuisisi data nirkabel yang terdiri dari mikrokontroler PIC dan LAB VIEW. Namun, sistem monitoring tersebut tidak didesain sebagai paket software open source sehingga sulit untuk dikembangkan dan sistem ini

mempunyai fleksibilitas rendah. Peneliti Han (Han, Lee and Kim, 2015) menggunakan PLC untuk komunikasi data dan selanjutnya diimplementasikan untuk mendeteksi gangguan di tingkat panel PV (Han *et al.*, 2017) sebagaimana ditunjukkan pada Gambar 2.6. Bagaimanapun, penggunaan modul PLC termasuk dalam kategori perangkat yang mahal untuk digunakan pada skala mikro grid.



Gambar 2.6 Arsitektur sistem monitoring PV menggunakan PLC (Han, Lee and Kim, 2015)

Sistem monitoring solar PV juga telah dikembangkan oleh Touati (Touati *et al.*, 2016) menggunakan protokol komunikasi Zigbee ke sebuah PC untuk di proses. Pereira (Pereira *et al.*, 2018) mengembangkan sistem monitoring menggunakan platform Raspberry Pi dan layanan cloud pada solar PV. Peneliti (Lopez-Vargas, Fuentes and Vivar, 2019) mengembangkan platform IoT untuk sistem pemantauan dengan menggunakan protokol komunikasi 3G. Informasi di kirimkan ke cloud dan kemudian direpresentasikan melalui aplikasi web. Bagaimanapun, kedekatan jarak dengan posisi stasiun penyedia layanan 3G akan menjadi faktor penting untuk menentukan kinerja arsitektur ini. Emamian (Emamian *et al.*, 2022) mengusulkan arsitektur IMS untuk pembangkit PV dengan menggunakan protokol mini WIFI untuk komunikasi data, sebagaimana ditunjukkan pada Gambar 2.7.

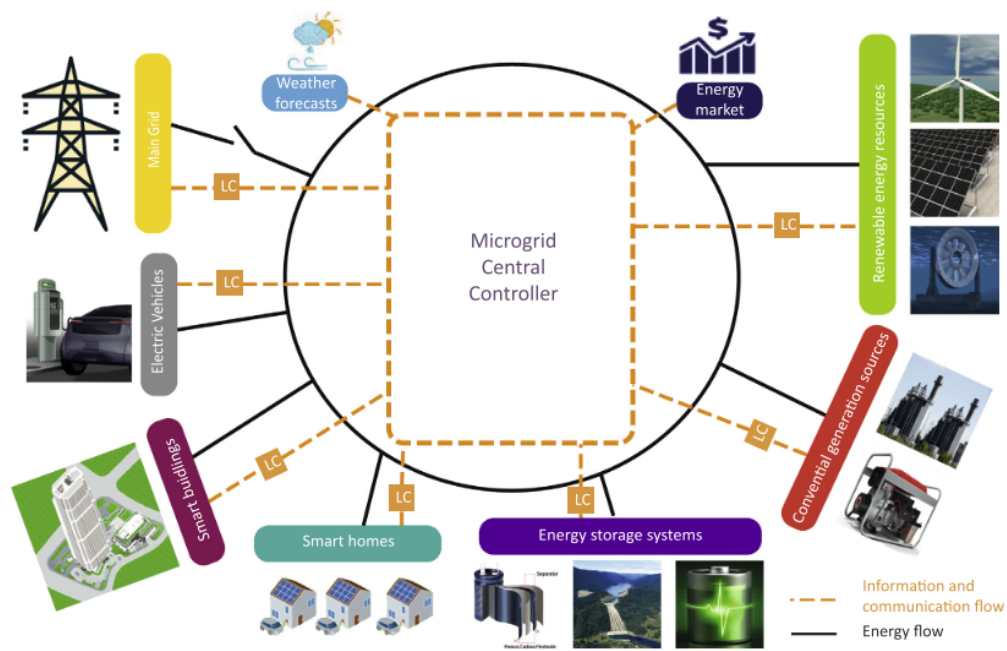


Gambar 2.7 Arsitektur *Intelligent Monitoring System* (IMS) (Emamian *et al.*, 2022)

2.3.4 SISTEM INFORMASI MANAJEMEN ENERGI

Pemanfaatan sumber energi terbarukan pada microgrid merupakan bagian dari transformasi sistem energi modern yang menuntut tidak hanya integrasi infrastruktur kelistrikan, tetapi juga pengelolaan informasi yang kompleks dan dinamis. Sistem manajemen energi pada microgrid dipandang sebagai sistem informasi terintegrasi yang berfungsi untuk mengelola data operasional, menganalisis kondisi sistem, serta mendukung pengambilan keputusan dalam pengelolaan energi terdistribusi.

Microgrid mengintegrasikan berbagai sumber energi terbarukan, seperti energi surya, angin, biomassa, dan air, yang dikombinasikan dengan pembangkit konvensional dan sistem penyimpanan energi. Integrasi sumber energi terdistribusi tersebut menghasilkan aliran data yang besar dan heterogen, sehingga diperlukan sistem manajemen energi berbasis sistem informasi yang mampu melakukan monitoring, kontrol, optimasi, serta deteksi kegagalan secara real-time. Teknologi microgrid memberikan kerangka operasional, sedangkan sistem informasi berperan sebagai lapisan manajerial dan analitik yang menghubungkan data teknis dengan keputusan operasional (Zia, Elbouchikhi and Benbouzid, 2018).

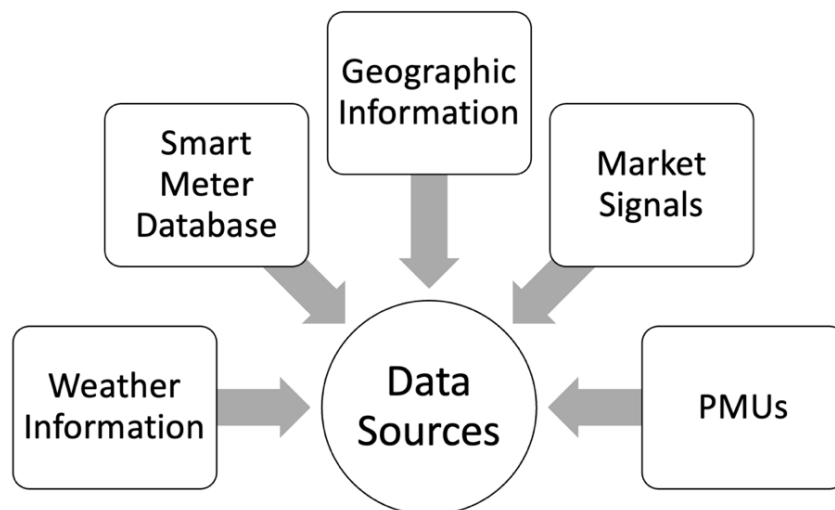


Gambar 2.8 Sumber energi terdistribusi pada microgrid (Zia, Elbouchikhi and Benbouzid, 2018)

Dalam arsitektur microgrid modern, sistem manajemen energi tidak hanya menangani aliran energi listrik, tetapi juga aliran informasi dan komunikasi. Seperti ditunjukkan pada Gambar 2.8, microgrid terhubung dengan berbagai layanan eksternal dan internal melalui dua jalur utama, yaitu jalur energi dan jalur komunikasi. Jalur komunikasi menjadi pondasi utama bagi sistem informasi manajemen energi, karena memungkinkan integrasi data dari berbagai subsistem seperti Energy Storage System, Energy Market, Smart Home, Weather Forecast, Smart Transportation, dan aplikasi berbasis mobile.

Teknologi komunikasi yang digunakan, baik nirkabel (Zigbee, Z-Wave, WiFi, 4G) maupun kabel (PLC, DSL, fiber optic), berfungsi sebagai infrastruktur sistem informasi yang menjamin ketersediaan, keandalan, dan ketepatan waktu data. Aplikasi mobile yang digunakan oleh end-user merupakan bagian dari antarmuka sistem informasi, yang memungkinkan pengguna untuk memantau kondisi energi, menerima informasi kinerja, serta melakukan kontrol dan pengambilan keputusan berbasis data secara langsung pada lingkungan microgrid. Sumber data dalam sistem informasi manajemen energi microgrid berasal dari berbagai entitas, sebagaimana ditunjukkan pada Gambar 2.9, yang meliputi smart

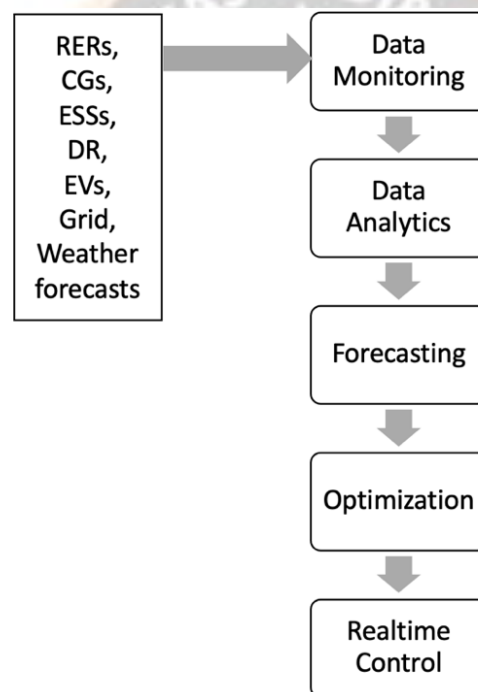
meter, sensor lingkungan, informasi cuaca, sinyal pasar energi, phasor measurement units (PMUs), serta data geografis. Keberagaman sumber data ini menuntut adanya mekanisme integrasi data (data integration) dan manajemen data (data management) agar data mentah dapat diolah menjadi informasi yang konsisten, relevan, dan dapat digunakan dalam proses pengambilan keputusan.



Gambar 2.9 Sumber data pada microgrid.

Aplikasi sistem manajemen energi pada microgrid dijalankan melalui beberapa tahapan proses informasi, sebagaimana ditunjukkan pada Gambar 2.10, yaitu data monitoring, data analytics, peramalan, optimization, dan real-time control. Tahapan ini merepresentasikan siklus pengolahan informasi dalam sistem informasi. Pada tahap data monitoring, sistem informasi melakukan akuisisi dan penyimpanan data operasional dari berbagai sumber. Data yang diperoleh masih berupa data mentah sehingga memerlukan pra-pemrosesan untuk mengurangi derau, menangani data hilang, dan menstandarkan format data. Pada tahap data analytics, data yang telah diproses dianalisis menggunakan teknik machine learning, data mining, hingga deep learning untuk mengekstraksi pola dan pengetahuan. Hasil analisis ini kemudian digunakan pada tahap peramalan untuk menghasilkan informasi prediktif, seperti peramalan produksi energi, konsumsi daya, dan harga energi. Proses peramalan ini berfungsi sebagai decision support mechanism yang menyediakan informasi prospektif bagi pengelola microgrid. Tahap optimization dan real-time control memanfaatkan informasi hasil analisis

dan peramalan untuk mendukung pengambilan keputusan operasional secara adaptif, seperti pengaturan distribusi energi, pemanfaatan sistem penyimpanan, dan respon terhadap perubahan kondisi lingkungan. Dengan demikian, sistem manajemen energi pada microgrid tidak hanya berfungsi sebagai sistem kontrol teknis, tetapi sebagai sistem informasi yang menghubungkan data, informasi, dan keputusan.



Gambar 2.10 Proses manajemen energi pada microgrid.


Pemanfaatan kecerdasan buatan dalam sistem manajemen energi memungkinkan peningkatan akurasi dan efisiensi pengambilan keputusan berbasis data cuaca dan kondisi lingkungan. Integrasi data produksi dan konsumsi energi, data geografis (GIS), serta data cuaca seperti suhu, kelembaban, kecepatan dan arah angin, serta tutupan awan, mendukung proses analitik yang lebih komprehensif. Dalam perspektif Sistem Informasi, integrasi data lintas domain ini memperkuat peran sistem manajemen energi sebagai platform informasi strategis dalam perencanaan, pengelolaan, dan optimasi energi terbarukan pada microgrid.

2.3.5 MACHINE LEARNING UNTUK PERAMALAN

ML merupakan bagian dari sistem AI yang mempunyai kemampuan dalam menganalisis pola dari data untuk mendapatkan model pengetahuan yang digunakan untuk menyelesaikan permasalahan serta membuat keputusan. Penelitian ini menggunakan ML untuk melakukan proses peramalan terhadap daya yang dibangkitkan oleh surya PV. Beberapa metode ML yang digunakan untuk eksperimen diantaranya algoritma CNN, CNN-LSTM, Stacked-LSTM, Multi LSTM.

1. Long Short-Term Memory

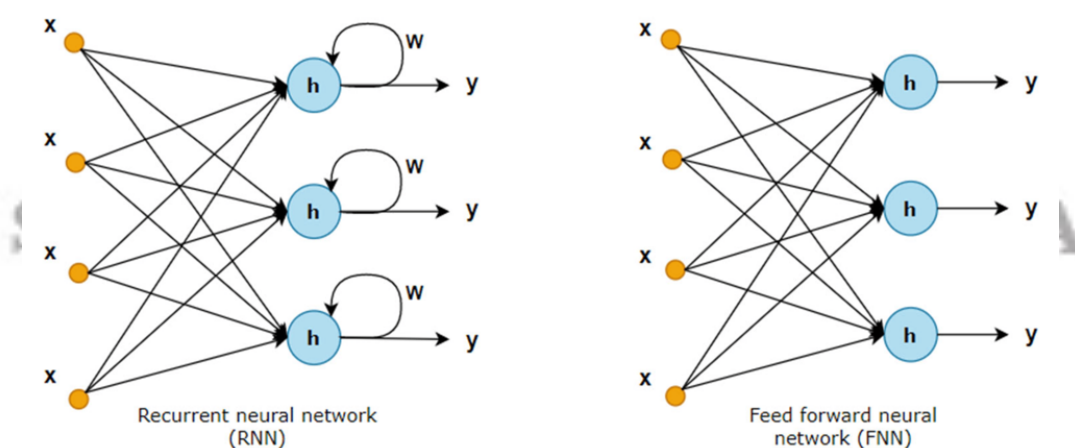
Arsitektur jaringan LSTM merupakan pengembangan teori jaringan saraf, yang dirancang untuk mengatasi keterbatasan model jaringan saraf sebelumnya dalam menangani permasalahan prediksi data deret waktu. Perkembangan LSTM dimulai dari arsitektur *Feed Forward Neural Network* (FFNN), RNN, hingga arsitektur LSTM. FFNN juga dikenal sebagai arsitektur *Multi Layer Perceptron* (MLP) merupakan arsitektur jaringan syaraf tiruan yang paling sederhana yang mempunyai siklus kerja satu arah atau arah maju yang dimulai dari *input layer*, *hidden layer* dan *output layer* sebagaimana ditunjukkan pada Gambar 2.11.



Gambar 2.11 Arsitektur *Feed Forward Neural Network* (Jailani et al., 2023)

Input layer terdiri dari neuron input yaitu X_f , X_m , X_s yang masing-masing menerima berbagai bentuk data. *Hidden layer* melakukan perhitungan pada data yang diterima oleh *input layer* dan sekaligus menerapkan fungsi aktivasi (ReLU, sigmoid, atau tanh) dan kemudian meneruskan hasilnya ke layer berikutnya. *Output layer* dapat terdiri dari satu atau lebih neuron tergantung pada dimensi output sebagai keluaran akhir dari jaringan saraf. Setiap garis koneksi antara neuron dalam lapisan yang berbeda memiliki bobot yang digunakan untuk menentukan pengaruh satu neuron terhadap neuron lainnya. Bagaimanapun, setiap masukan pada arsitektur ini diproses secara independen, tanpa memori masukan sebelumnya. Hal ini membuatnya tidak cocok untuk tugas-tugas yang konteks historis atau urutan titik datanya penting, seperti dalam prediksi deret waktu (Teso-Fz-Betoño *et al.*, 2022).


RNN dikembangkan untuk mengatasi permasalahan pada arsitektur FFNN yang memiliki keterbatasan pada memori. RNN dilengkapi dengan siklus loop yang tidak dimiliki oleh FFNN untuk menjaga informasi tetap ada pada neuron. Gambar 2.12 menunjukkan perbandingan arsitektur RNN dan FFNN dimana pada *hidden layer* RNN terdapat koneksi yang berulang beberapa kali.



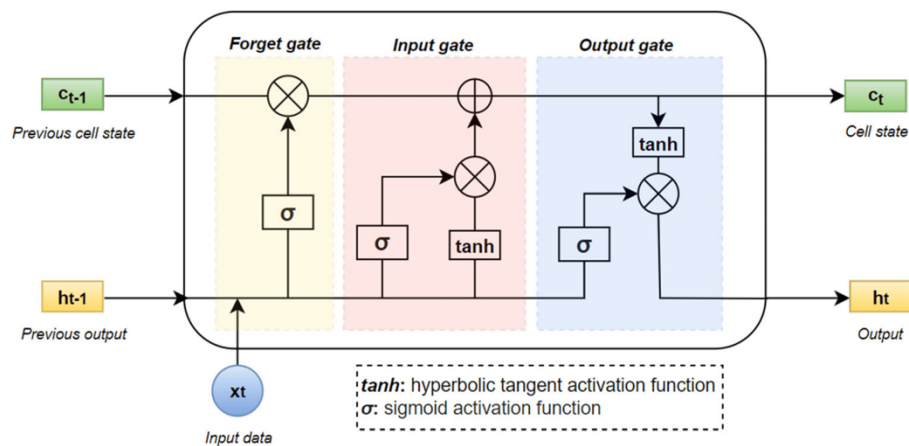
Gambar 2.12 Perbandingan arsitektur RNN dan FFNN (Jailani *et al.*, 2023)

Gambar 2.13 menunjukkan proses penanganan data dalam koneksi berulang pada arsitektur RNN. *Hidden state* (h_t) menunjukkan status tersembunyi pada waktu t , yang merupakan memori jaringan, yang membawa informasi dari input sebelumnya yang diproses oleh jaringan hingga waktu t . Status tersembunyi

diperbarui pada setiap langkah waktu. Jaringan RNN memproses urutan dari awal hingga akhir, yang menunjukkan setiap masukan diproses selama langkah waktu yang berurutan. Oleh karena itu, arsitektur ini menjadi alternatif pilihan sebagai model prediksi.



Gambar 2.13 Proses penanganan data pada arsitektur RNN (Jailani *et al.*, 2023)



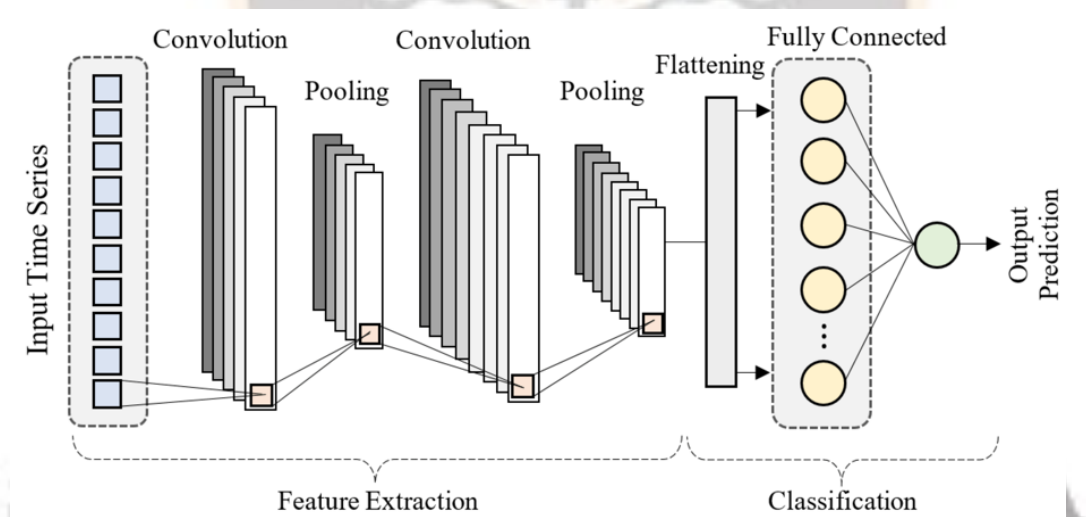
Gambar 2.14 Arsitektur LSTM Sederhana (Jailani *et al.*, 2023)

LSTM merupakan pengembangan dari arsitektur RNN yang mencakup sel memori dan beberapa gerbang. Gambar 2.14 menunjukkan struktur sel LSTM, yang terdiri dari tiga gerbang berbeda: *forget gate*, *input gate*, dan *output gate*. *Forget gate* akan memutuskan informasi apa yang dibuang dari status sel dengan menggunakan fungsi *sigmoid* (σ). *Input gate* menentukan informasi baru apa yang ditambahkan ke status sel dengan menggunakan fungsi *sigmoid* (σ) dan membuat vektor nilai kandidat baru dengan menggunakan fungsi *tanh*. *Output gate* akan menentukan status tersembunyi (*output*) berikutnya dari sel LSTM, yang berisi informasi tentang input saat ini dan memori input sebelumnya dan fungsi *sigmoid*

(σ) akan menentukan bagian mana dari status sel yang masuk ke output. Data masukan X_t terhubung dengan gerbang LSTM untuk memperbaharui status sel bersamaan dengan bagian keluaran sebelumnya (h_{t-1}). Sedangkan status sel sebelumnya (C_{t-1}) membawa informasi selama pemrosesan urutan.

2. Convolutional Neural Network

Algoritma CNN dapat digunakan pada pemrosesan gambar dan visi komputer serta pemrosesan pada peramalan deret waktu. Kemampuan CNN digunakan untuk mengekstraksi pola data spasial dan juga pada data deret waktu dalam 1 dimensi. Gambar 2.15 menunjukkan arsitektur CNN untuk prediksi data deret waktu. Model CNN umumnya menggunakan lima lapisan pemetaan, seperti *input-layer*, *convolutional-layer*, *pooling-layer*, *fully-connected-layer*, *dense-layer*, dan *output-layer*.



Gambar 2.15 Arsitektur *Convolutional Neural Network* (Rahman *et al.*, 2021)

- *Input Layer* : lapisan ini menerima *raw* data deret waktu, yang bisa berupa urutan titik data yang terukur. Masukan ini diformat ke dalam bentuk yang sesuai untuk diproses oleh CNN.
- *Convolution Layer*: Lapisan-lapisan ini menjalankan operasi konvolusi menggunakan berbagai filter (atau kernel) yang diterapkan pada data masukan.

$$Z_{i,j,k} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} X_{i+m,j+n} \times W_{m,n,k} + b_k \quad (2.1)$$

- *Pooling Layer*: mengurangi ukuran spasial (dimensionalitas) peta fitur untuk mengurangi daya komputasi yang diperlukan untuk memproses data, dan juga untuk membuat deteksi fitur tidak berubah terhadap skala dan orientasi.

$$P_{i,j} = \max_{a,b \in \text{window}} X_{i \times s+a, j \times s+b} \quad (2.2)$$

- *Flattening layer*: melibatkan transformasi seluruh kumpulan atau matriks peta fitur lapisan konvolusional menjadi satu kolom yang kemudian diumpankan ke lapisan yang terhubung sepenuhnya.

$$Y = \text{flatten}(X) \quad (2.3)$$

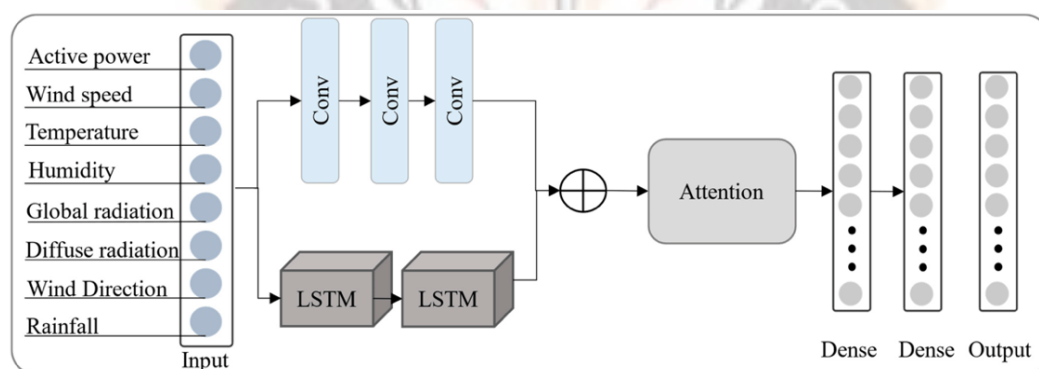
- *Fully Connected Layers*: Lapisan ini juga dikenal sebagai lapisan dense, adalah lapisan jaringan saraf yang terhubung secara mendalam, tempat neuron terhubung ke setiap neuron di lapisan sebelumnya. Lapisan ini mengintegrasikan fitur yang dipelajari dari masukan yang diberikan oleh lapisan konvolusional dan penggabungan. Untuk melakukan penalaran tingkat tinggi seperti klasifikasi berdasarkan fitur yang diekstraksi dan digabungkan oleh lapisan sebelumnya. Di sini, neuron belajar untuk aktif saat mendeteksi keberadaan fitur tertentu.

$$Y = W \cdot X + b \quad (2.4)$$

- *Output Layer*: Lapisan ini berisi keluaran untuk tugas, seperti neuron tunggal untuk klasifikasi biner atau beberapa neuron untuk klasifikasi multikelas atau tugas regresi. Untuk mengeluarkan prediksi berdasarkan fitur tingkat tinggi yang dipelajari oleh jaringan.

3. CNN-LSTM

Algoritma hybrid CNN-LSTM merupakan gabungan dari dua arsitektur jaringan saraf yaitu CNN dan LSTM. Integrasi kedua metode ini memanfaatkan kekuatan CNN dalam ekstraksi fitur spasial dan LSTM dalam pemodelan dependensi temporal atau sekuensial. Algoritma hibrida CNN-LSTM menjadi alternatif pilihan untuk aplikasi seperti peramalan pembangkitan energi PV karena kemampuannya dalam menggabungkan ekstraksi fitur spasial melalui CNN dan pemodelan dependensi temporal menggunakan LSTM (Alharkan, Habib and Islam, 2023). Gambar 2.16 menunjukkan arsitektur CNN-LSTM untuk prediksi data deret waktu.

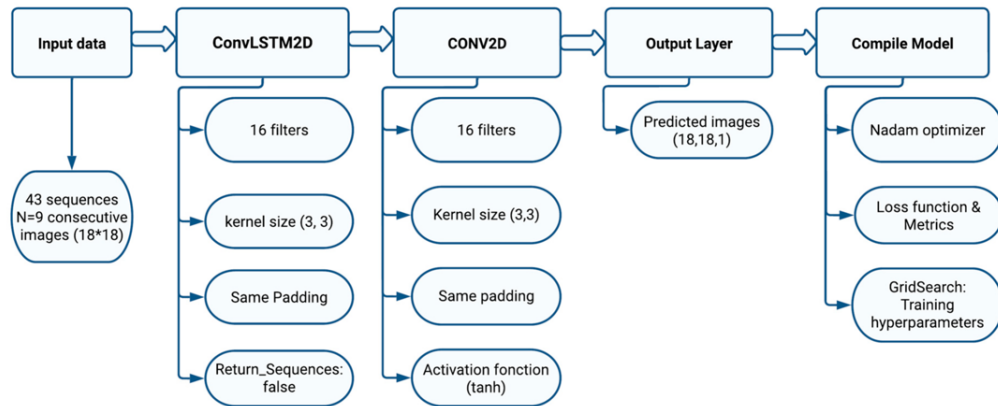


Gambar 2.16 Arsitektur CNN-LSTM (Alharkan, Habib and Islam, 2023)

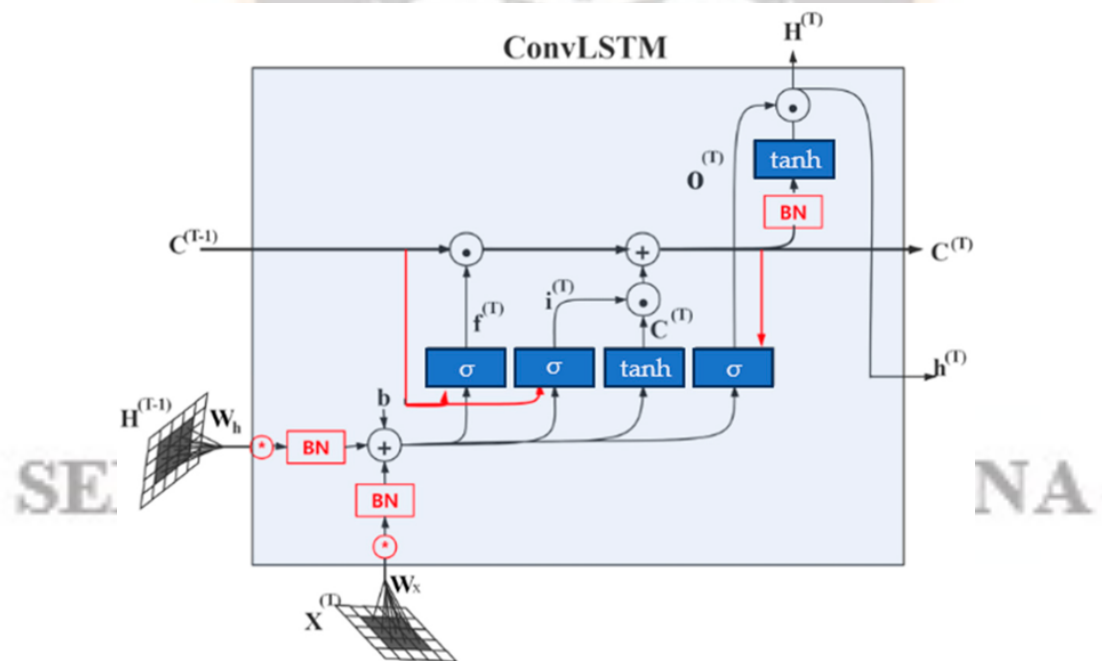
Arsitektur CNN terdiri dari layer konvolusi, layer *pooling* dan layer *fully connected*. Lapisan konvolusi termasuk kernel konvolusi didalamnya melakukan operasi konvolusi antara bobot neuron dengan masukan untuk menghasilkan fitur map. Selanjutnya, arsitektur LSTM akan menyimpan informasi waktu terkait karakteristik data daya PV. Arsitektur ini menyediakan solusi dengan mempertahankan memori jangka logaritma dengan menggabungkan unit memori yang dapat memperbarui status tersembunyi sebelumnya. Mekanisme unit tiga gerbang dapat digunakan untuk menentukan status setiap sel memori. Gerbang *input*, *output*, dan *forget* mewakili unit gerbang.

Arsitektur CLSTM atau *Convolutional LSTM* hampir mirip dengan arsitektur CNN-LSTM. Arsitektur CNN-LSTM melibatkan penggunaan lapisan Convolutional Neural Network untuk ekstraksi fitur diikuti oleh lapisan LSTM

untuk menangani prediksi sekuens (Bounoua *et al.*, 2024). Berbeda dengan arsitektur ConvLSTM mengintegrasikan operasi konvolusi secara langsung ke dalam sel LSTM itu sendiri.



Gambar 2.17 Arsitektur CONV-LSTM (Bounoua *et al.*, 2024)



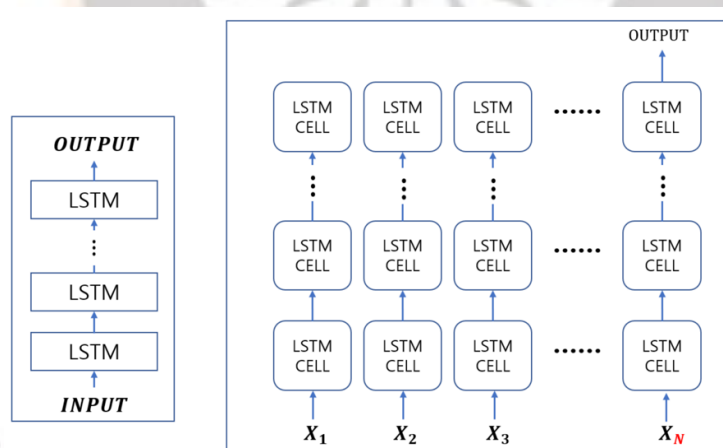
Gambar 2.18 Operasi konvolusi pada gate LSTM (Bounoua *et al.*, 2024)

Arsitektur ConvLSTM memiliki struktur konvolusional baik dalam transisi input ke status maupun status ke status sehingga operasi konvolusi merupakan bagian dari mekanisme gating LSTM sebagaimana ditunjukkan pada Gambar 2.17. Dalam ConvLSTM, gerbang *input*, *forget*, dan *output* sel LSTM melakukan operasi

konvolusi sebagaimana ditunjukkan pada Gambar 2.18. Arsitektur Conv LSTM tidak hanya menangkap dinamika temporal tetapi juga mempertahankan hubungan spasial. Karena operasi konvolusi terintegrasi ke dalam gerbang LSTM, arsitektur ini sangat cocok untuk tugas-tugas di mana data input memiliki dimensi temporal dan spasial (seperti data deret waktu yang didistribusikan secara spasial).

4. Stacked LSTM

Arsitektur Stacked LSTM merupakan bentuk pengembangan dari arsitektur LSTM, yang dirancang untuk meningkatkan kemampuan model dalam mempelajari data temporal yang lebih kompleks. Arsitektur ini memiliki beberapa lapisan LSTM yang disusun secara bertumpuk untuk menangkap pola yang kompleks dan hubungan yang lebih dalam dalam data deret waktu, yang mungkin kurang terlihat dengan model LSTM yang lebih sederhana sebagaimana ditunjukkan pada Gambar 2.19.



Gambar 2.19 Arsitektur Stacked LSTM (Kim, Lee and Jeong, 2021)

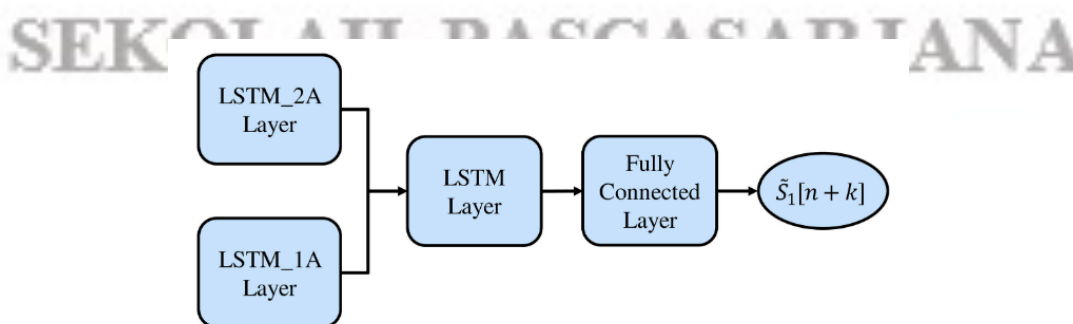
Setiap lapisan berisi sejumlah unit atau beberapa sel LSTM, yang bertanggung jawab untuk mempertahankan status dan memori di seluruh urutan (X_1 , X_2 , ..., X_n). Keluaran dari satu lapisan LSTM menjadi masukan untuk lapisan berikutnya, yang memungkinkan model untuk membangun hierarki fitur pada berbagai tingkat abstraksi. *Input Layer* menerima urutan data dari deret waktu. Setiap elemen input biasanya dikaitkan dengan *Time Stamp*, yang membentuk urutan yang diproses melalui jaringan. Setiap unit dalam lapisan LSTM berisi mekanisme yang dikenal sebagai *Gate*: *Input Gate*, *Output Gate*, dan *Forget Gate*.

Gerbang-gerbang ini mengendalikan aliran informasi. *Input Gate* mengendalikan sejauh mana nilai baru mengalir ke dalam sel, *Forget Gate* mengendalikan sejauh mana nilai tetap berada di dalam sel, dan *Output Gate* mengendalikan sejauh mana nilai dalam sel digunakan untuk menghitung aktivasi output unit LSTM.

5. Multi LSTM

Arsitektur ini disebut juga Parallel LSTM yang merupakan bentuk lain dari arsitektur *stacked* LSTM. *Stacked* LSTM terdiri dari beberapa lapisan LSTM yang ditumpuk di atas satu sama lain. Output setiap lapisan berfungsi sebagai input ke lapisan berikutnya. Sedangkan Multi LSTM melibatkan beberapa jaringan LSTM yang beroperasi secara paralel, masing-masing memproses input yang sama secara independen sebagaimana ditunjukkan pada Gambar 2.20. Multi LSTM dapat digunakan ketika fitur atau jenis data yang berbeda yang perlu diproses secara terpisah.

Asitektur Multi LSTM yang digambarkan menunjukkan model prediktif yang terdiri dari beberapa lapisan LSTM yang beroperasi secara paralel dan bersekuensial (Succetti *et al.*, 2020). Dua lapisan LSTM pertama (LSTM_1A dan LSTM_2A) mengolah data masukan secara terpisah, yang dapat diberikan input data yang berbeda. Output dari kedua lapisan ini kemudian digabungkan dan diproses oleh lapisan LSTM ketiga untuk integrasi fitur. Setelah itu, output melewati lapisan terhubung penuh (fully connected) yang melakukan transformasi akhir sebelum menghasilkan prediksi. Model ini efektif untuk tugas yang memerlukan pemahaman kontekstual dan temporal yang mendalam.



Gambar 2.20 Arsitektur Multi LSTM (Succetti *et al.*, 2020)

2.3.6 METODE EVALUASI

Metode evaluasi dalam penelitian ini bertujuan untuk menilai kinerja sistem monitoring dan peramalan energy surya PV pada Smart Microgrid sebagai sebuah rancangan Sistem Informasi. Oleh karena itu, evaluasi tidak hanya difokuskan pada akurasi model Deep Learning yang digunakan, tetapi juga pada kualitas informasi yang dihasilkan, tingkat ketidakpastian prediksi, kompleksitas sistem, serta implikasi kesalahan prediksi terhadap pengambilan keputusan manajemen energi.

1. Evaluasi Akurasi Prediksi

Evaluasi akurasi prediksi digunakan untuk mengukur kemampuan komponen analitik berbasis multi-LSTM dalam menghasilkan nilai peramalan produksi daya PV. Metrik yang digunakan meliputi: MAE, MSE, dan RMSE. Nilai MAE, MSE, dan RMSE yang lebih rendah menunjukkan kemampuan sistem informasi dalam menghasilkan prediksi yang lebih akurat

- *Mean Absolute Error* (MAE)

MAE digunakan untuk mengukur rata-rata kesalahan absolut antara nilai prediksi dan nilai aktual, sehingga memberikan gambaran tingkat kesalahan rata-rata yang dihasilkan oleh sistem.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2.5)$$

- *Mean Squared Error* (MSE)

MSE digunakan untuk mengukur rata-rata kesalahan kuadrat yang menekankan penalti lebih besar terhadap kesalahan prediksi yang ekstrem.

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (2.6)$$

- *Root Mean Squared Error* (RMSE).

RMSE merupakan akar kuadrat dari MSE yang memberikan estimasi kesalahan prediksi dalam satuan yang sama dengan data aktual, sehingga lebih mudah diinterpretasikan dalam konteks operasional.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (2.7)$$

2. Evaluasi Kualitas Informasi

Penelitian ini mengevaluasi kualitas informasi yang dihasilkan oleh sistem monitoring dan peramalan produksi daya PV berdasarkan beberapa dimensi utama, yaitu:

- Information Accuracy (IA): kesesuaian informasi prediksi dengan kondisi aktual sistem PV.

$$IA = 1 - \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{Y_i} \quad (2.8)$$

- Information Timeliness: kemampuan sistem menyajikan informasi secara tepat waktu untuk mendukung keputusan operasional.

$$IT = 1 - \frac{T_{delay}}{T_{threshold}} \quad (2.9)$$

- Information Completeness: kelengkapan informasi yang disajikan, termasuk data kinerja, tren historis, dan prediksi energi.

$$IC = \frac{N_{available}}{N_{required}} \quad (2.10)$$

3. Evaluasi Ketidakpastian Prediksi

Dalam sistem informasi manajemen energi, ketidakpastian prediksi memiliki implikasi langsung terhadap risiko pengambilan keputusan. Oleh karena itu, penelitian ini mengevaluasi tingkat ketidakpastian prediksi dengan menganalisis variasi kesalahan prediksi pada berbagai kondisi operasional dan horizon waktu. Evaluasi ini memberikan gambaran tentang stabilitas dan keandalan informasi prediktif yang dihasilkan oleh sistem, sehingga pengelola Smart Microgrid dapat mempertimbangkan tingkat risiko dalam penggunaan hasil prediksi untuk pengambilan keputusan.

4. Evaluasi Kompleksitas Sistem (*Complexity Index Evaluation*)

Sebagai sistem informasi yang berjalan secara operasional, kompleksitas komputasi menjadi faktor penting. Evaluasi kompleksitas dilakukan untuk menilai

efisiensi komputasi dan skalabilitas sistem analitik, khususnya pada penggunaan arsitektur Multi-LSTM.

- Indikator kompleksitas yang dievaluasi meliputi:
- Jumlah parameter dan layer model
- Waktu pelatihan dan inferensi
- Kebutuhan sumber daya komputasi

Evaluasi ini bertujuan untuk memastikan bahwa sistem informasi yang dikembangkan tidak hanya akurat, tetapi juga layak diimplementasikan secara real-time pada lingkungan Smart Microgrid.

5. Evaluasi Penyimpangan Terburuk (*Worst-Case Deviation Evaluation*)

Evaluasi worst-case deviation digunakan untuk mengukur penyimpangan maksimum antara nilai prediksi dan nilai aktual dalam kondisi ekstrem. Dalam konteks Sistem Informasi, metrik ini penting untuk menilai dampak kesalahan prediksi terhadap keputusan operasional, seperti pengelolaan beban, penyimpanan energi, dan stabilitas sistem. Dengan mengevaluasi kondisi terburuk, sistem informasi dapat dirancang lebih robust dan adaptif terhadap ketidakpastian lingkungan dan dinamika operasional Smart Microgrid.

SEKOLAH PASCASARJANA