

BAB I

PENDAHULUAN

1.1. Latar Belakang

Dewasa ini data merupakan penunjang pengambilan keputusan secara cepat, atau dikenal dengan istilah *Data Driven Decision Making (DDDM)* di mana kemajuan teknologi berperan besar dalam memanfaatkan data dan informasi tersebut (Aditya, Mulyana, Eka, & Widiyanto, 2020). Dalam berbagai aspek termasuk melakukan prediksi mengenai informasi curah hujan yang akurat di mana pemodelan tersebut masih memiliki kekurangan seperti penggunaan jumlah *parameter*, asumsi matematis, dan rumusan persamaan yang cenderung rumit, untuk menghasilkan sebuah model prediksi yang mendekati keakuratan optimal harus memiliki banyak *parameter* dan *variabel input* untuk memenuhi sebuah asumsi prediksi (Supriyadi, 2019).

Mengatasi perihal tersebut, dikembangkanlah sebuah *Kecerdasan Buatan (Artificial Intelligence)* yang memiliki kemampuan untuk melakukan pembelajaran untuk menganalisis berbagai macam asumsi dan aspek yang berpengaruh untuk menarik kesimpulan (Supriyadi, 2019). *Artificial Intelligence (AI) atau kecerdasan buatan* didefinisikan secara berbeda dalam konteks yang berbeda pula dalam disiplin ilmu komputer AI adalah mempelajari cara menstimulasikan untuk melakukan tugas yang biasanya membutuhkan pemahaman seperti manusia (Knowledge@Wharton, 2018). AI juga suatu cabang ilmu komputer yang menggunakan lebih banyak simbol daripada angka, dan

memproses informasi berdasarkan jumlah aturan dalam merepresentasikan pengetahuan (Swarnkar & Swarnkar, 2019).

Machine Learning adalah bagian dari AI di mana mesin digunakan untuk belajar dari pengalaman masa lalu (Aditya, Mulyana, Eka, & Widiyanto, 2020). Algoritma *Machine Learning* digunakan dalam berbagai aplikasi, seperti dalam kedokteran, pengenalan *email*, pengenalan suara, dan visi komputer, di mana sulit atau tidak mungkin untuk mengembangkan algoritma konvensional untuk melakukan tugas yang diperlukan (Hu, Niu, Carrasco, Lennox, & Arvin, 2020).

Beberapa implementasi *Machine Learning* menggunakan data dan *Neural Network (Jaringan Saraf)* dengan cara yang meniru kerja otak biologis manusia (Zhou, 2019). *Deep Learning* dapat dipahami sebagai bentuk *Neural Network layer* berganda yang merupakan bagian dari *Machine Learning* yang dapat digunakan dalam tugas termasuk *computer vision, speech recognition, natural language processing, Machine translation, bioinformatics, drug design, medical image analysis, material inspection* dan *board game programs*, di mana mereka telah menghasilkan hasil yang sebanding dan dalam beberapa kasus melebihi kinerja para pakar (Hu, Niu, Carrasco, Lennox, & Arvin, 2020).

Misalnya, sebuah komputasi yang menggunakan *Deep Learning*, mampu memahami konsep seperti garis, bentuk, tekstur, dan juga pengaruhnya dengan melihat data-data citra tanpa bantuan tambahan dari manusia (Schneiderman & Kanade, 2002). *Machine Learning* senantiasa bekerja menggunakan 1 *layer* di mana *Deep Learning* bekerja lebih dari 1 *layer*. Untuk batasan *layer* dari *Deep Learning* itu sendiri sebagai *Neural Network* biasanya memiliki 3 *layer* atau lebih,

makin banyak *layer* yang digunakan akan memengaruhi lama waktu yang terpakai untuk komputer mengalkulasi (Hinton, et al., 2012).

Layer pada *Deep Learning* dapat di gambarkan seperti lapisan *neuron* pada otak manusia *layer* itu nantinya akan menggambarkan jarak atau *vektor* menggunakan Fungsi matematika yaitu fungsi *sigmoid* (σ) (Putra J. G., 2020). Alasan fungsi *sigmoid* digunakan karena dalam fungsi ini membutuhkan perhitungan yang relatif mudah dan cepat. Selain itu, fungsi *sigmoid* dapat diartikan sebagai nilai peluang karena nilainya antara 0 dan 1 (Putra J. G., 2020).

Salah satu pendekatan *Deep Learning* yang mampu secara otomatis mempelajari fitur yang dideskripsikan dalam bentuk *vektor* adalah *Recurrent Neural Networks (RNN)* (Puspaningrum, Bunga, & Iryanto, 2020). Pada *RNN* sendiri teknik *Learning* bekerja dengan menyimpan *layer* dari *output* kembali sebagai *input* pada *hidden layer* berikutnya hingga memprediksi hasil akhir (Tarkus, Sompie, & Jacobus, 2020). Kelemahan *RNN* adalah tidak mampu lagi untuk belajar menghubungkan informasi ketika ada kesenjangan yang terus tumbuh, memori yang tersimpan akan semakin tidak relevan seiring waktu berjalan karena tertimpa dengan memori baru (Putra, Osmond, & Ansori, 2020), di sebabkan kelemahan dari *RNN* sendiri tidak dapat mempelajari informasi yang terlalu jauh atau *Long-Term Dependencies*, yang cukup jauh pada masukannya (Wibisono & Khodra, 2018).

Penelitian *Deep Learning* terdahulu yang di lakukan Juanda, Jondri, & Rohmawati, tentang *Prediksi Harga Bitcoin Dengan Menggunakan Recurrent Neural Network* menurutnya, masalah prediksi *timeseries* adalah jenis pemodelan

prediktif yang sulit, tidak seperti pemodelan prediktif regresi, *timeseries* juga menambah kompleksitas ketergantungan urutan antar *variabel input*. *Recurrent Neural Network* terbukti berhasil digunakan untuk prediksi data *timeseries* karena *RNN* mampu menggunakan informasi yang telah direkam sebelumnya yang panjang urutannya atau *sequence*-nya beragam-ragam. Oleh karena itu, pembangunan sistem ini dibuat dengan metode *Recurrent Neural Network* dengan menggunakan algoritma *Backpropagation Through Time*. Hasil akhir Prediksi harga Bitcoin dapat dilakukan menggunakan *Recurrent Neural Network*. Akurasi rata-rata terbaik yang didapatkan adalah 98.76% pada data latih dan 97.46% pada data uji, dengan *parameter* jumlah pola *input* terbaik adalah 5, jumlah *epoch* 1000, nilai *Learning rate* 0.001 dan jumlah *hidden unit* 50 (Juanda, Jondri, & Rohmawati, 2018).

Long Short-Term Memory (LSTM) merupakan sebuah pengembangan metode dari arsitektur *Recurrent Neural Network (RNN)*, Banyak peneliti yang mengembangkan metode *LSTM* di berbagai bidang seperti dalam bidang prediksi deret waktu atau *forecasting* dikarenakan metode *LSTM* mampu mengatasi kekurangan tersebut karena metode ini dapat mengatur memori pada setiap masukannya dengan menggunakan *memory cells* dan *gate units* pada setiap *neurons* yang berfungsi sebagai pengatur memori (Putra, Osmond, & Ansori, 2020). Contoh penggunaan *Deep Learning* untuk data *timeseries* yang banyak dihasilkan dari pengamatan cuaca adalah *LSTM*, *LSTM* sendiri diciptakan oleh *Hochreiter* dan *Schmidhuber* pada tahun 1997 (Supriyadi, 2019).

Penelitian *LSTM* terdahulu yang yang di teliti oleh *Poornima & Pushpalatha*, mengenai *Prediction of Rainfall Using Intensified LSTM Based Recurrent Neural*

Network with Weighted Linear Units dalam penelitian tersebut menyajikan *Long Short-Term Memory (LSTM)* berbasis *Recurrent Neural Network (RNN)* untuk memprediksi curah hujan. *Neural Network* dilatih dan diuji menggunakan kumpulan data standar curah hujan. Jaringan yang dilatih akan menghasilkan atribut prediksi curah hujan. *Parameter* yang dipertimbangkan untuk evaluasi kinerja dan efisiensi model prediksi curah hujan yang diusulkan adalah *Mean Square Error (MSE)*, *akurasi*, *jumlah epoch*, *loss*, dan *Learning rate*. Menurutny *LSTM* dapat menyimpan data besar ke dalam memorinya dan dapat menghindari *gradient* yang hilang lebih baik dari pada *RNN* dan menunjukkan akurasi lebih baik di bandingkan *RNN*, *LSTM* pun juga mempertahankan akurasi di masa depan seiring dengan mempertimbangkan nilai *Mean Square Error (MSE)*, *akurasi*, *jumlah epoch*, *loss*, dan *Learning rate* (Poornima & Pushpalatha, 2019).

Penelitian *LSTM* terdahulu yang juga di lakukan oleh Supriyadi, mengenai metode *Deep Learning LSTM* untuk memprediksi *parameter* cuaca, seperti suhu udara, kelembaban, kecepatan angin, dan tekanan udara. Metode ini bekerja dengan memanfaatkan fungsi matematika seperti fungsi *tanh* dan *sigmoid* yang berada dalam *layer LSTM*. Adapun jumlah *layer* yang digunakan sebanyak 200 buah. Sedangkan jumlah datanya dibagi dua menjadi *training* data dan test data dengan rasio 9:1. Pada bulan Januari 2019. Diperoleh *MSE parameter* suhu udara, kelembaban, kecepatan angin, dan tekanan udara nilainya semakin baik ketika menggunakan *Deep Learning LSTM* dengan update dibandingkan *LSTM* tanpa update. Diperoleh hasil prediksi suhu udara, kelembaban, kecepatan angin, dan tekanan udara 1 hari ke depan memiliki *MSE* yang baik. Dari *parameter* cuaca tersebut hanya *parameter* suhu dan kelembaban udara yang mengalami

pertambahan *MSE* seiring bertambahnya waktu. Sedangkan *parameter* kecepatan angin dan tekanan udara mengalami penurunan di hari ketiga dan meningkat secara kontinu hingga 1 bulan ke depan (Supriyadi, 2019).

Berdasarkan rincian penjelasan sebelumnya, sangat dimungkinkan untuk menggunakan *Deep Learning* dengan metode *LSTM* dikarenakan mendukung kegiatan proyeksi curah hujan. Karena data pengamatan meteorologi umumnya berupa *vektor* dan *timeseries*, untuk itu peneliti membuat Penelitian dalam bentuk skripsi dengan judul **“OPTIMALISASI DEEP LEARNING METHOD DENGAN LONG SHORT-TERM MEMORY DALAM MEMPROYEKSI CURAH HUJAN”**.

1.2. Perumusan Masalah

Berdasarkan uraian pada latar belakang masalah maka yang menjadi perumusan masalah pada skripsi ini adalah sebagai berikut :

1. Bagaimana melakukan proses prediksi curah hujan dengan menggunakan pendekatan *Deep Learning* menggunakan metode *Long Short-Term Memory* dapat menghasilkan alternatif dalam pengambilan sebuah keputusan ?
2. Bagaimana penerapan *Deep Learning* menggunakan metode *Long Short-Term Memory* dapat melakukan prediksi curah hujan.
3. Bagaimana pengujian *Deep Learning* dengan metode *Long Short-Term Memory* di implementasikan ke dalam sebuah sistem yang dibangun untuk memprediksi curah hujan di daerah padang Pariaman ?

1.3. Hipotesis

Berdasarkan rumusan masalah yang telah ditentukan maka dapat diambil kesimpulan sebagai berikut :

1. Dengan melakukan proses prediksi curah hujan dengan menggunakan pendekatan *Deep Learning* diharapkan dapat menghasilkan alternatif dalam pengambilan sebuah keputusan.
2. Dengan menggunakan konsep pendekatan *Deep Learning* metode *Long Short-Term Memory* diharapkan dapat melakukan prediksi curah hujan.
3. Penerapan *Deep Learning* dengan metode *Long Short-Term Memory* diharapkan dapat di implementasikan ke dalam sebuah sistem yang dibangun untuk memprediksi curah hujan di daerah padang Pariaman.

1.4. Batasan Masalah

Adapun batasan masalah pada penelitian ini adalah sebagai berikut :

1. Data yang digunakan adalah data *Stasiun Klimatologi Kelas II Sicincin Padang Pariaman* dari tahun 1985 sampai tahun 2021.
2. Metode yang digunakan dalam penelitian ini *Long Short-Term Memory*.
3. Menggunakan Bahasa Pemograman *Python*.
4. Fungsi Aktivasi yang digunakan adalah fungsi *Sigmoid* (σ) dan *Tanh*.
5. Untuk fitur *variabel* yang digunakan dalam penelitian ini hanya terdiri dari curah hujan (rr).
6. Data dibagi menjadi dua bagian, yaitu data *training* dan data *testing* dengan rasio 9:1 di mana 9 untuk *training* dan 1 untuk *testing*.

1.5. Tujuan Penelitian

Adapun Tujuan dari penelitian ini adalah sebagai berikut :

1. Menerapkan *Deep Learning* menggunakan metode *Long Short-Term Memory* untuk melakukan proses prediksi curah hujan dalam menghasilkan alternatif dalam pengambilan sebuah keputusan.
2. Menerapkan pendekatan *Deep Learning* menggunakan metode *Long Short-Term Memory* untuk melakukan prediksi curah hujan.
3. Melakukan pengujian *Deep Learning* dengan metode *Long Short-Term Memory* di implementasikan ke dalam sebuah sistem yang dibangun untuk memprediksi curah hujan di daerah padang Pariaman.

1.6. Manfaat Penelitian

Hasil dari penelitian di harapkan dapat memberikan manfaat sebagai berikut :

1. Menambah pengetahuan peneliti dalam memprediksi / memproyeksi data berbentuk *timeseries* yang di selesaikan dengan cara *Deep Learning* dengan menggunakan metode *Long Short-Term Memory*.
2. Membuktikan keakuratan metode *Long Short-Term Memory* dalam melakukan peramalan khususnya curah hujan.
3. Memberikan informasi tambahan mengenai peramalan curah hujan di daerah padang Pariaman yang akan terjadi pada masa mendatang.

1.7. Gambaran Umum Objek Penelitian

Stasiun Klimatologi Kelas II Sicincin Padang Pariaman merupakan BMKG Stasiun Klimatologi Padang Pariaman yang terletak di daerah *Jalan Raya Padang*

– *Bukittinggi KM. 51 Kapalo Hilalang Sumatera Barat*. Berikut ini adalah gambaran umum tentang Objek Penelitian :

1.7.1. Sejarah BMKG

Pengamatan meteorologi dan geofisika di Indonesia dimulai pertama kali pada tahun 1841 diawali dengan pengamatan yang dilakukan secara individual oleh Dr. Pieter Loth Onnen, Kepala Rumah Sakit di Bogor. Dari tahun ke tahun kegiatannya berkembang seiring dengan meningkatnya kebutuhan akan data hasil pengamatan cuaca dan geofisika. Pada tahun 1866, pemerintah Hindia Belanda meresmikan kegiatan pengamatan *perorangan* sebagai lembaga pemerintah dengan nama Observatorium Magnetisch en Meteorologisch atau Observatorium Magnetik dan Meteorologi yang dipimpin oleh Dr. Pieter Adrian Bergsma.

Pada tahun 1879, 74 jaringan alat pengukur hujan dibangun di Jawa. pengamatan medan magnet bumi dipindahkan dari Jakarta ke Bogor Pada tahun 1902. Pada tahun 1908 pemantauan gempa dimulai dengan pemasangan komponen horizontal seismograf Wiechert di Jakarta, sedangkan pemasangan komponen vertikal dilakukan pada tahun 1928. Pada tahun 1912, pengamatan meteorologi ditata ulang dengan menambahkan jaringan sekunder. Sedangkan pada tahun 1930 jasa meteorologi mulai digunakan untuk penerangan.

Pada masa pendudukan Jepang antara tahun 1942 dan 1945, nama badan meteorologi dan geofisika diubah menjadi Kisho Kauso Kusho atau Lembaga Meteorologi. Pada tahun 1945 Setelah proklamasi kemerdekaan Indonesia, badan tersebut dibagi menjadi dua: Di Yogyakarta dibentuk Badan Meteorologi yang berkedudukan di lingkungan Mabes TNI khusus untuk melayani kepentingan

Angkatan Udara. Di bawah Kementerian Pekerjaan Umum dan Energi Badan Meteorologi dan Geofisika dibentuk Di Jakarta.

Pada tanggal 21 Juli 1947 Biro Meteorologi dan Geofisika diambil alih oleh Pemerintah Belanda dan namanya diubah menjadi Meteorologisch en Geofisiche Dienst. Badan Meteorologi dan Geofisika yang dikelola oleh Pemerintah Republik Indonesia berada di Jl. Gondangdia, Jakarta. Pada tahun 1949, setelah penyerahan kedaulatan Republik Indonesia dari Belanda, Meteorologisch en Geofisiche Dienst diubah menjadi Biro Meteorologi dan Geofisika di bawah Departemen Perhubungan dan Pekerjaan Umum. Selanjutnya pada tahun 1950 Indonesia resmi masuk sebagai anggota Organisasi Meteorologi Dunia dan Kepala Badan Meteorologi dan Geofisika menjadi Wakil Tetap Indonesia dengan WMO.

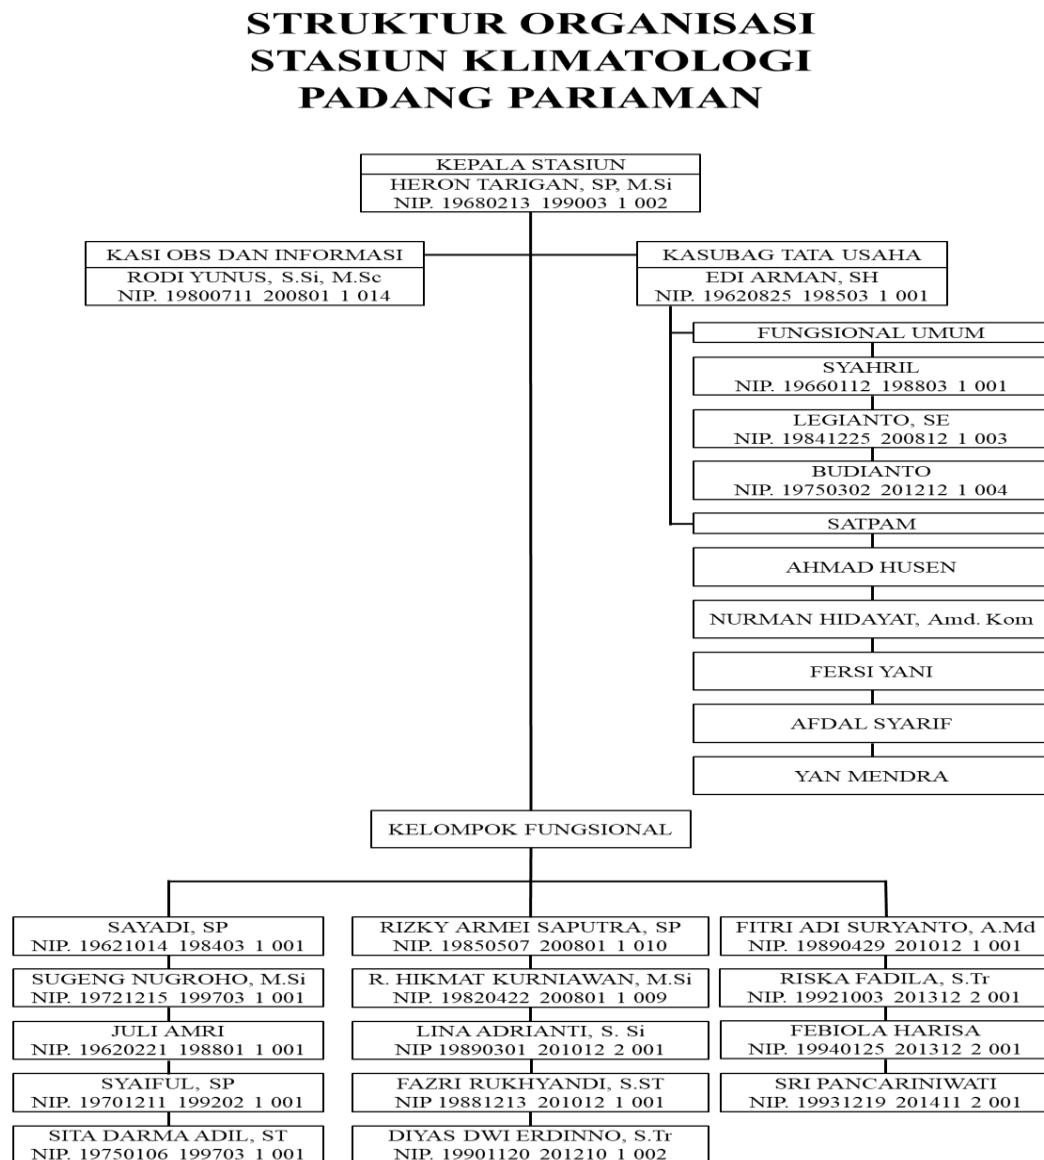
Pada tahun 1955 Biro Meteorologi dan Geofisika beubah nama menjadi Lembaga Meteorologi dan Geofisika di bawah Kementerian Perhubungan, dan pada tahun 1960 namanya dikembalikan menjadi Biro Meteorologi dan Geofisika di bawah Kementerian Perhubungan Udara.

Pada tahun 1965, namanya diubah menjadi Direktorat Meteorologi dan Geofisika, posisinya tetap di bawah Kementerian Perhubungan Udara. statusnya dinaikkan menjadi lembaga setingkat eselon I dengan nama Badan Meteorologi dan Geofisika, dengan jabatan tetap di bawah Kementerian Perhubungan. Badan Meteorologi dan Geofisika.

Melalui Peraturan Presiden Nomor 61 Tahun 2008, BMG berganti nama menjadi Badan Meteorologi, Klimatologi, dan Geofisika dengan status tetap sebagai Lembaga Pemerintah Non Departemen.

1.7.2. Struktur Organisasi

Berikut adalah bentuk struktur organisasi BMKG Padang Pariaman :



(Sumber : Sta. Klim. Kelas II Padang Pariaman, 2021)

Gambar 1.1. Struktur Organisasi BMKG Padang Pariaman

Stasiun Klimatologi Kelas II Sicincin Padang Pariaman dipimpin oleh Kepala Stasiun Klimatologi (Kaslim) bertanggung jawab terhadap seluruh bidang

yang ada pada instansi BMKG, Staf yang membantu Kaslim dalam menjalankan aktivitas di kantor adalah sebagai berikut :

1. Tata usaha yang bertanggung jawab terhadap *administrasi* kantor.
2. Bagian analisa yang bertanggung jawab terhadap pengolahan data dan analisis data-data yang dikirim ke Balai Wilayah I.
3. Tenaga teknis yang bertanggung jawab terhadap data-Data Klimatologi yang ada di *Stasiun Klimatologi Kelas II Sicincin Padang Pariaman*.
4. Tim pengamat yang bertanggung jawab terhadap pengaturan jadwal pengamatan di *Stasiun Klimatologi Kelas II Sicincin Padang Pariaman*.
5. Tim komunikasi dan peralatan yang bertanggung jawab terhadap pengiriman informasi kondisi peralatan yang ada di *Stasiun Klimatologi Kelas II Sicincin Padang Pariaman*.

1.7.3. Visi

Mewujudkan BMKG yang handal, tanggap dan mampu dalam rangka mendukung keselamatan masyarakat serta keberhasilan pembangunan nasional, dan berperan aktif di tingkat Internasional.

Terminologi di dalam visi tersebut dapat dijelaskan sebagai berikut :

1. Pelayanan informasi meteorologi, klimatologi, kualitas udara, dan geofisika yang handal ialah pelayanan BMKG terhadap penyajian data, informasi pelayanan jasa meteorologi, klimatologi, kualitas udara, dan geofisika yang akurat, tepat sasaran, tepat guna, cepat, lengkap, dan dapat dipertanggungjawabkan.

2. Tanggap dan mampu dimaksudkan BMKG dapat menangkap dan merumuskan kebutuhan *stakeholder* akan data, informasi, dan jasa meteorologi, klimatologi, kualitas udara, dan geofisika serta mampu memberikan pelayanan sesuai dengan kebutuhan pengguna jasa.

1.7.4. Misi

Dalam rangka mewujudkan Visi BMKG, maka diperlukan visi yang jelas yaitu berupa langkah-langkah BMKG untuk mewujudkan Misi yang telah ditetapkan yaitu :

1. Mengamati dan memahami fenomena meteorologi, klimatologi, kualitas udara dan geofisika.
2. Menyediakan data, informasi dan jasa meteorologi, klimatologi, kualitas udara dan geofisika yang handal dan terpercaya.
3. Mengkoordinasikan dan memfasilitasi kegiatan di bidang meteorologi, klimatologi , kualitas udara dan geofisika.
4. Berpartisipasi aktif dalam kegiatan internasional di Bidang meteorologi, klimatologi, kualitas udara dan geofisika.