

BAB 1 PENDAHULUAN

1.1. Latar Belakang

Data spektral yang dihasilkan dari proses spektroskopi memiliki peran penting dalam menganalisis karakteristik dan perilaku objek langit, termasuk bintang. Beberapa parameter utama seperti **metalitas** (M/H), **temperatur efektif** (T_{eff}), **gravitasi permukaan** ($\log g$) dan **kecepatan rotasi equatorial** ($v_e \sin i$) dapat diperoleh melalui analisis spektrum hasil observasi. Akan tetapi, peningkatan signifikan dalam volume data observasi menyebabkan proses analisis spektrum menjadi semakin kompleks dan memakan banyak waktu. Untuk mengatasi tantangan ini, beberapa penelitian telah menerapkan metode *machine learning*. Yossry menggunakan *Artificial Neural Network* (ANN) untuk memprediksi parameter seperti temperatur efektif dan gravitasi permukaan^[1]. Sementara itu W.Liu merancang arsitektur **1D Stellar Spectra Convolutional Neural Network (1DSSCNN)** untuk melakukan klasifikasi berdasarkan data spektrum bintang^[2]. Berbagai pendekatan lainnya juga terus diajukan untuk menyelesaikan permasalahan ini.

Convolutional Neural Network (CNN) merupakan salah satu metode *machine learning* yang banyak digunakan dalam kasus klasifikasi maupun regresi dengan data masukan berupa gambar, termasuk data spektral. Secara umum, penerapan CNN pada data spektral menunjukkan performa yang cukup baik. Misalnya penelitian yang dilakukan oleh W.Liu berhasil merancang arsitektur **1D Stellar Spectra Convolutional Neural Network (1DSSCNN)** yang mampu meningkatkan akurasi model CNN hingga **90%** dalam klasifikasi spektrum bintang^[2]. Pada kasus regresi, arsitektur CNN **Starnet** yang dirancang oleh S. Fabbro, juga mempunyai performansi yang baik dalam memprediksi parameter stellar^[3]. Namun, efektifitas CNN sangat bergantung pada pemilihan *hyperparameter* yang optimal agar model machine learning

dapat bekerja secara maksimal. Menentukan kombinasi *hyperparameter* yang optimal bukanlah tugas yang mudah karena proses ini seringkali memakan waktu dan sumber daya yang signifikan. Bahkan setelah serangkaian percobaan dilakukan dan di temukan *hyperparameter* yang terlihat optimal, tidak ada jaminan bahwa nilai tersebut adalah solusi terbaik atau telah mencapai optimum global. Oleh karena itu, diperlukan metode pencarian otomatis yang mampu memastikan *hyperparameter* berada dalam kondisi optimal untuk meningkatkan kinerja model.

Berbagai metode pencarian telah digunakan untuk mengoptimalkan *hyperparameter* pada CNN, termasuk metode tradisional seperti *grid search* dan *random search*, serta metode metaheuristik seperti genetic algorithm dan *ant colony optimization (ACO)*. Salah satu metode tradisional yang sering digunakan adalah *grid search*, seperti yang dilakukan Marwan^[4] dalam penelitiannya. Penelitian tersebut memanfaatkan *grid search* untuk menemukan kombinasi *hyperparameter* optimal pada setiap parameter stellar^[4]. Sementara itu metode metaheuristik yang populer adalah *genetic algorithm*. Gomez, misalnya, menerapkan *genetic algorithm* untuk mengoptimalkan *hyperparameter* pada *artificial neural network (ANN)*^[5]. Meskipun kedua pendekatan ini mampu menghasilkan performa model yang baik, namun metode tersebut masih memiliki kelemahan, yakni rentan terjebak dalam *local optimum*.

Menindaklanjuti kelemahan dari metode pencarian yang telah disebutkan sebelumnya, penelitian ini mengusulkan sebuah metode pencarian metaheuristik yang relatif baru yaitu *komodo mlipir algorithm (KMA)*, untuk mengoptimalkan *hyperparameter* pada CNN. Metode ini terinspirasi dari perilaku komodo, hewan endemik dari pulau komodo di Nusa Tenggara Timur, Indonesia, dalam berburu mangsa. Berdasarkan hasil penelitian, *Komodo Mlipir Algorithm* menunjukkan performa yang lebih baik dibandingkan metode pencarian metaheuristik lainnya^[6]. Keunggulan utama KMA terletak pada

kemampuannya menjaga keseimbangan antara eksplorasi dan eksploitasi, sehingga mampu mendekati solusi yang lebih optimal.

Pada penelitian tugas akhir ini, model CNN akan dilatih menggunakan data spektral dengan pengoptimalan hyperparameter melalui *Komodo Mlipir Algorithm* (KMA). Model hasil pelatihan tersebut kemudian akan dievaluasi menggunakan *Mean Square Error* (MSE), *Root Mean Square Error* (RMSE) dan dibandingkan dengan model CNN dengan *hyperparameter* standarnya.

Dengan menerapkan KMA untuk mengoptimalkan *hyperparameter* CNN, diharapkan diperoleh model CNN yang lebih kuat dan optimal dalam memprediksi parameter stellar fundamental dari bintang.

1.2. Rumusan Masalah

Berdasarkan indentifikasi masalah yang sudah dijabarkan di latarbelakang, rumusan masalah dalam penelitian ini adalah sebagai berikut :

1. Bagaimana cara mengimplementasikan *Algoritma komodo mlipir algorithm* (KMA) untuk optimasi *hyperparameter* dari CNN ?
2. Bagaimana pengaruh *hyperparameter* yang sudah dioptimalkan menggunakan KMA terhadap performa CNN dalam memprediksi parameter stellar (T_{eff} , $\log g$, $[M/H]$, dan $v_e \sin i$) ?

1.3. Tujuan dan Manfaat

Penelitian ini bertujuan untuk mengembangkan metode optimasi *hyperparameter Convolutiona neural network* (CNN) dalam konteks analisis data spektral. Dengan memanfaatkan kelebihan dari KMA, penelitian ini diharapkan mampu meningkatkan akurasi model CNN dalam memprediksi parameter stellar seperti **temperatur efektif (T_{eff})**, **gravitasi permukaan ($\log g$)**, **metalistas ($[M/H]$)** dan **kecepatan rotasi ekuatorial ($v_e \sin i$)**.

Tujun utama dari penelitian ini adalah sebagai berikut:

1. Mengimplementasikan KMA untuk mencari kombinasi *hyperparameter* CNN yang optimal

2. Meningkatkan akurasi model CNN untuk memprediksi parameter stellar

Adapun Manfaat dari penelitian ini adalah :

- Manfaat praktis:
 1. Menghasilkan model CNN yang lebih akurat dalam memprediksi parameter stellar dari dataset spektral skala besar
 2. Meningkatkan efisiensi waktu dalam pencarian *hyperparameter* CNN yang optimal
- Manfaat ilmiah:
 1. Berkontribusi dalam pengembangan metode optimasi metaheuristik, khususnya algoritma KMA, untuk aplikasinya di bidang astronomi dan pembelajaran mesin
 2. Menjadi acuan untuk penelitian selanjutnya yang ingin mengembangkan pencarian *hyperparameter* pada berbagai model *machine learning* yang diterapkan pada bidang astronomi maupun bidang lainnya

1.4. Batasan Masalah

Penelitian ini memiliki beberapa batasan-batasan supaya penelitian bisa berjalan dengan efisien dan mempunyai ruang untuk perbaikan. Adapun batasan masalah dalam penelitian ini adalah sebagai berikut :

1. Data yang digunakan

Penelitian ini menggunakan **data spektrum bintang** dari hasil pengamatan teleskop **APOGEE** diameter 2,5m, dengan panjang gelombang tertentu yang mencakup spektrum resolusi rendah ($R \sim 1800$). Data spektrum ini terbatas pada spektrum bintang kelas G,K,F dan tidak mencakup kelas bintang A,B,M dan O karena keterbatasan data pada kelas-kelas tersebut.

2. Parameter Stellar

Fokus penelitian ini adalah pada prediksi parameter stellar utama yaitu :

- **Temperatur efektif (T_{eff})**
- **Gravitasi permukaan ($\log g$)**
- **Metalitas ($[M/H]$)**
- **Kecepatan rotasi ekuatorial ($v_e \sin i$)**

parameter lain, seperti unsur kelimpahan spesifik ($[\alpha/Fe]$) , tidak menjadi bagian dari penelitian ini.

3. Arsitektur dan Hyperparameter CNN

Arsitektur CNN pada penelitian ini menggunakan arsitektur yang di bangun oleh S.Fabbro^[3] yaitu **Starnet** . Penggunaan arsitektur ini dikarenakan adanya tujuan yang sama pada perancangan arsitektur **Starnet** yaitu untuk memprediksi parameter stellar utama kecuali kecepatan rotasi ekuatorial.

Sedangkan untuk hyperparameter yang akan dioptimalkan terbatas pada beberapa hyperparameter berikut ini :

- **Kernel size** dengan range [16, 24, 32, 40,48,52,64]
- **Activation Function** dengan list [relu, tanh, sigmoid, elu dan selu]
- **Kernel Initializer** dengan list [zeros, ones, random_normal, random_uniform, truncated_normal, variance_scaling, orthogonal, lecun_normal, lecun_uniform, glorot_normal, glorot_uniform, he_normal, he_uniform]
- **learning rate** dengan range [10^{-6} , 10^{-5} , 10^{-4} , 10^{-3} , 10^{-2} , 10^{-1}]
- **epoch** dengan range 50 - 100

- **batch** dengan range 2^n dimana n 0-6
- **pool_sizes** dengan range 2 - 9

4. Hyperparameter Komodo mlipir Algorithm

Karena keterbatasan waktu dan kondisi lingkungan komputasi, sehingga perlu dibatasi untuk beberapa hyperparameter dari *komodo mlipir algorithm*. Diantara hyperparameter yang dibatasi antara lain:

- p (**presentase konodo jantan besar**) dibuat tetap di 0.5
- d (**mlipir rate**) dibuat tetap 0.1
- jumlah iterasi di buat tetap 10
- n (**jumlah populasi komodo**) berada pada list range 5, 10 dan 15

1.5. Metode Penelitian

Pekerjaan penelitian dilakukan dengan pendekatan: studi teoritis/studi literatur, pengukuran empirik, analisis statistik, simulasi, perancangan, dan implementasi. Tahapan penelitian meliputi langkah-langkah berikut :

1. Studi literatur

Penelitian diawali dengan dengan mengkaji literatur terkait untuk memahami :

- Pentingnya parameter stellar seperti **temperatur efektif (T_{eff})**, **gravitasi permukaan ($\log g$)**, **metalitas ($[M/H]$)** dan **kecepatan rotasi ekuatorial ($v_e \sin i$)**
- Penerapan CNN pada analisis data spektral, termasuk arsitektur CNN seperti **Starnet** dan **1DSSCNN**.
- Mempelajari **Algoritma Komodo mlipir (KMA)** dan algoritma optimasi hyperparameter lain seperti **Grid Search** dan **Random Search**

2. Pengumpulan Data

Data spektral bintang diperoleh dari dataset publik **APOGEE**. Dataset ini mencakup :

- Spektrum resolusi rendah dengan panjang gelombang tertentu
- Parameter stellar sebagai label untuk pelatihan model CNN

3. Preprocessing Data

Data spektral melalui proses preprocessing, yang meliputi:

- Normalisasi spektrum
- Mengisi titik spektrum yang bolong

4. Perancangan Model CNN

- Arsitektur CNN yang digunakan dirancang khusus untuk analisis data spektral.
- Model difokuskan untuk prediksi parameter stellar (regresi) seperti T_{eff} , $\log g$, $[M/H]$, dan $v_e \sin i$.
- Hyperparameter awal ditentukan sebelum dioptimalkan menggunakan KMA

5. Implementasi Algoritma Komodo Mlipir (KMA)

- Algoritma KMA diterapkan untuk mengoptimalkan hyperparameter model CNN
- KMA dijalankan dalam simulasi untuk mencari kombinasi hyperparameter optimal yang meningkatkan performa model.

6. Simulasi dan evaluasi model

- Model CNN dilatih dan diuji dengan kombinasi hyperparameter yang dihasilkan oleh KMA
- Performa model diukur menggunakan metrik seperti *Mean Squared Error* (MSE) dan *Root Mean Squared Error* (RMSE)

7. Analisis Statistik

- Hasil simulasi dianalisis secara statistik untuk mengevaluasi keefektifan KMA dan kualitas performa dari CNN yang sudah di optimasi

1.6. Jadwal Pelaksanaan

Berikut ini adalah jadwal pelaksanaan dari penelitian tugas akhir ini:

Tabel 1.1. Jadwal Pelaksanaan Tugas Akhir.

No.	Deskripsi Tahapan	Bulan 1	Bulan 2	Bulan 3	Bulan 4	Bulan 5	Bulan 6
1	Studi Literatur						
2	Pengumpulan Data						
3	Pre-processing data						
4	Pembuatan model						
5	Analisis hasil						
6	Penyusunan Laporan/Buku TA						