

# PENERAPAN FLASK FRAMEWORK UNTUK DEPLOYMENT MODEL MACHINE LEARNING DALAM Mendukung ANALISIS ADAPTASI MAHASISWA PADA PEMBELAJARAN DARING

Elan Suherlan<sup>1</sup>, Shindy Arti<sup>2</sup>, Siti Nabilah<sup>3</sup>, Zahwah Hazimah<sup>4</sup>

<sup>1,3,4</sup> Teknik Informatika, Fakultas Teknologi Informasi Universitas YARSI

<sup>2</sup> Sistem dan Teknologi Informasi, Fakultas Teknik, Universitas Negeri Jakarta

<sup>1</sup> [elan.suherlan@yarsi.ac.id](mailto:elan.suherlan@yarsi.ac.id), <sup>2</sup> [shindyarti@unj.ac.id](mailto:shindyarti@unj.ac.id), <sup>3</sup> [nabilasiti398@gmail.com](mailto:nabilasiti398@gmail.com), <sup>4</sup> [zahwahrs1@gmail.com](mailto:zahwahrs1@gmail.com)

---

## Abstrak

Kemampuan adaptasi mahasiswa dalam pembelajaran daring merupakan faktor penting yang memengaruhi motivasi, keterlibatan, dan keberhasilan akademik. Untuk mendukung deteksi dini tingkat adaptasi mahasiswa, penelitian ini mengusulkan pembangunan sistem prediksi berbasis *machine learning* menggunakan *framework* Flask. Model dilatih menggunakan dataset mahasiswa yang mencakup aspek demografis, teknis, dan sosial-ekonomi. Beberapa algoritma diuji untuk menentukan model terbaik dengan indikator akurasi, presisi, recall, dan F1-score. Model yang terpilih kemudian diintegrasikan ke dalam aplikasi web dengan memanfaatkan Flask sebagai *micro web framework* yang ringan dan fleksibel. Proses *deployment* dilakukan dengan membangun API yang menerima input data mahasiswa, menjalankan prediksi, dan menghasilkan keluaran berupa kategori adaptasi rendah, sedang, atau tinggi. Sistem yang dihasilkan mampu memberikan hasil dengan antarmuka sederhana sehingga mudah digunakan oleh mahasiswa maupun dosen. Hasil implementasi menunjukkan bahwa penggunaan Flask tidak hanya mempercepat proses integrasi model *machine learning* ke dalam aplikasi berbasis web, tetapi juga membuka peluang pengembangan lebih lanjut, termasuk integrasi dengan sistem manajemen pembelajaran. Penelitian ini berkontribusi dalam menghadirkan solusi praktis untuk mendukung personalisasi pembelajaran daring melalui pemanfaatan teknologi prediksi adaptasi mahasiswa.

**Kata kunci:** *machine learning*, Flask, *deployment*, adaptasi mahasiswa, pembelajaran daring

---

## 1. Pendahuluan

Perkembangan pesat teknologi informasi telah mendorong transformasi dalam dunia pendidikan, khususnya pada pembelajaran daring yang semakin menjadi kebutuhan pokok sejak pandemi COVID-19. Mahasiswa dihadapkan pada tantangan adaptasi terhadap lingkungan belajar digital yang ditandai oleh ketidakpastian, perubahan mendadak, serta keterbatasan interaksi langsung dengan dosen maupun teman sebaya. Penerapan pembelajaran daring meningkat drastis sejak pandemi COVID-19, yang memaksa perguruan tinggi beradaptasi dengan teknologi digital. Salah satu faktor penentu keberhasilan dalam pembelajaran daring adalah kemampuan adaptasi mahasiswa. Mahasiswa yang adaptif mampu menyesuaikan strategi belajar, mengelola waktu, serta memanfaatkan teknologi dengan lebih baik (She et al., 2023). Sebaliknya, mahasiswa dengan tingkat adaptasi rendah sering menghadapi hambatan dalam memahami materi dan berinteraksi dengan dosen maupun rekan belajar (Li et al., 2023).

Beberapa penelitian terdahulu telah memanfaatkan *machine learning* (ML) untuk memprediksi kemampuan adaptasi. Suzan et al. (2021) melaporkan bahwa *Random Forest* mencapai akurasi 89,63% dalam klasifikasi adaptasi mahasiswa, sementara Sree et al. (2023) menunjukkan bahwa kombinasi *SMOTE oversampling* dengan algoritme *ensemble* meningkatkan akurasi hingga 92%. Penelitian Arti et al (2025) menunjukkan ANN dapat mencapai akurasi hingga 94,6% pada prediksi adaptasi mahasiswa. Namun, model prediksi yang dibangun tidak akan optimal tanpa adanya mekanisme *deployment* yang memungkinkan hasil analisis diakses secara praktis oleh pengguna. Salah satu *framework* yang banyak digunakan untuk menjembatani pengembangan model ML dengan kebutuhan implementasi adalah Flask. Flask merupakan *microframework* berbasis Python yang ringan, fleksibel, dan mudah diintegrasikan dengan pustaka *machine learning* seperti Scikit-learn maupun TensorFlow/Keras (Kotha et al., 2021; Ningrum & Ihsanudin, 2023). Flask memungkinkan pengembang untuk membangun aplikasi

berbasis web dengan arsitektur sederhana tetapi fungsional, sehingga model prediksi dapat diakses melalui antarmuka web.

Proses *deployment* model ML dengan Flask umumnya mencakup beberapa tahap utama. Pertama, model dilatih menggunakan dataset mahasiswa yang relevan, kemudian disimpan dalam *format* serialisasi seperti *pickle* atau *joblib*. Kedua, Flask digunakan untuk membuat *endpoint* API yang dapat menerima input data dari pengguna berupa variabel prediktor (misalnya usia, perangkat yang digunakan, kualitas internet, durasi kelas daring). Data tersebut kemudian dikirimkan ke model untuk diproses dan menghasilkan output berupa kategori tingkat adaptasi. Ketiga, hasil prediksi ditampilkan pada antarmuka web yang sederhana namun *informatif*, sehingga mudah dipahami oleh pengguna akhir (Jonathan Evan & Nugraha, 2023). Melalui alur ini, *deployment* dengan Flask memberikan kemudahan akses, efisiensi pemrosesan, dan fleksibilitas integrasi dengan sistem *informasi* akademik yang sudah ada.

Penelitian ini bertujuan membangun sistem prediksi kemampuan adaptasi mahasiswa berbasis *Neural Network* dan mengimplementasikannya menggunakan Flask *framework*. Sistem ini diharapkan mampu memberikan prediksi melalui antarmuka web, sehingga dapat digunakan sebagai alat bantu dosen maupun konselor dalam mengidentifikasi mahasiswa yang membutuhkan pendampingan lebih intensif.

## 2. Dasar Teori

### 2.1 Adaptasi Mahasiswa dalam Pembelajaran Daring

Adaptasi mahasiswa dalam pembelajaran daring menjadi salah satu faktor krusial untuk memastikan keberhasilan akademik, khususnya sejak pandemi COVID-19 yang memaksa peralihan drastis dari pembelajaran tatap muka ke *format* daring. Adaptasi didefinisikan sebagai kemampuan individu untuk melakukan penyesuaian kognitif, afektif, dan perilaku dalam menghadapi situasi baru, penuh ketidakpastian, dan perubahan mendadak (Martin et al., 2013; Van den Heuvel et al., 2013). Dalam konteks pendidikan tinggi, mahasiswa dituntut untuk menyesuaikan strategi belajar, memanfaatkan teknologi digital, serta mengelola emosi ketika menghadapi tekanan akademik di lingkungan daring. Penelitian Stockinger, Rinas, dan Daumiller (2021) menunjukkan bahwa mahasiswa dengan tingkat adaptabilitas tinggi cenderung memiliki emosi positif seperti harapan (*hope*) dan kegembiraan (*joy*), serta lebih rendah tingkat kecemasan (*anxiety*) dan keputusasaan (*hopelessness*). Emosi ini terbukti memediasi hubungan antara adaptasi dan capaian akademik, baik berupa keterlibatan belajar maupun hasil tes pengetahuan.

Studi terdahulu menunjukkan bahwa tingkat adaptabilitas mahasiswa memiliki hubungan erat dengan pengalaman emosional dan prestasi belajar. Stockinger, Rinas, dan Daumiller (2021) menemukan bahwa mahasiswa dengan tingkat adaptabilitas tinggi cenderung memiliki emosi positif seperti harapan (*hope*) dan kegembiraan (*joy*), serta lebih rendah kecemasan (*anxiety*) dan keputusasaan (*hopelessness*). Kondisi emosional tersebut memediasi hubungan antara adaptabilitas dengan hasil belajar, baik dalam keterlibatan akademik maupun capaian pengetahuan. Penelitian lain menunjukkan bahwa mahasiswa dengan tingkat adaptabilitas tinggi cenderung mengalami lebih banyak emosi positif, seperti harapan dan kegembiraan, serta lebih sedikit emosi negatif seperti kecemasan dan keputusasaan (Stockinger et al., 2021). Emosi ini memiliki peran penting dalam menentukan keterlibatan belajar serta capaian akademik. Selain emosi, adaptasi juga berhubungan dengan *self-efficacy*. Martin, Ginns, dan Collie (2023) menunjukkan bahwa adaptabilitas berfungsi sebagai *personal resource* yang menjaga keyakinan mahasiswa terhadap kemampuan akademiknya, sehingga meningkatkan keterlibatan dan mengurangi kelelahan belajar.

### 2.2 Self-Regulated Learning (SRL)

*Self-Regulated Learning* (SRL) merupakan konsep yang menekankan peran aktif individu dalam mengatur proses belajarnya melalui kontrol terhadap pikiran, motivasi, emosi, dan perilaku untuk mencapai tujuan akademik tertentu. Model siklus SRL yang dikemukakan Zimmerman (2002) mencakup tiga fase utama, yaitu *forethought* (perencanaan dan penetapan tujuan), *performance* (implementasi strategi belajar dan pemantauan diri), serta *self-reflection* (evaluasi hasil belajar). Pintrich (2004) menambahkan bahwa SRL melibatkan dimensi kognitif, metakognitif, motivasi, dan perilaku yang saling berinteraksi untuk membentuk strategi belajar efektif. Penelitian menunjukkan bahwa mahasiswa dengan keterampilan SRL yang baik cenderung mampu mengelola waktu secara efisien, mengembangkan strategi kognitif yang sesuai, serta meregulasi emosi untuk menghadapi tantangan akademik (Broadbent & Poon, 2015). Dalam konteks pembelajaran daring, kemampuan ini menjadi sangat krusial karena keterbatasan kontrol langsung dari dosen serta meningkatnya kebutuhan kemandirian mahasiswa.

Sejumlah studi menegaskan bahwa SRL tidak hanya berhubungan positif dengan prestasi akademik, tetapi juga dengan motivasi intrinsik, efikasi diri, serta ketekunan mahasiswa (Arcoverde et al., 2022; Smadi et al., 2024). Berbagai intervensi telah dikembangkan untuk meningkatkan SRL, termasuk integrasi ke dalam kurikulum *formal*, lokakarya keterampilan belajar, penggunaan alat digital, serta aktivitas reflektif seperti *learning diaries* dan *peer*

*feedback* (Villamarín et al., 2024; Hadwin et al., 2022). Studi terkini menyoroti bahwa penerapan strategi berbasis teknologi seperti *learning management systems*, aplikasi *mobile*, dan modul daring yang dapat mendukung kesadaran metakognitif dan memberikan *scaffolding*, meskipun efektivitasnya tetap bergantung pada desain instruksional yang tepat dan dukungan manusia (ElSayed et al., 2024). Faktor kontekstual, seperti latar belakang demografis, disiplin ilmu, maupun mode pembelajaran, juga memengaruhi profil SRL mahasiswa, sehingga intervensi perlu disesuaikan dengan kebutuhan spesifik (Bartolo-Alemán et al., 2022; Fayda-Kınık, 2024). *Self-regulated learning* (SRL) menjadi landasan penting bagi mahasiswa dalam mengatur tujuan, memonitor kemajuan, serta merefleksikan capaian belajar mereka (Hadwin et al., 2022). Adaptabilitas berperan sebagai komponen pelengkap SRL, karena memungkinkan mahasiswa menyesuaikan strategi belajar ketika menghadapi hambatan teknis maupun psikologis.

### 2.3 Machine Learning untuk Prediksi Adaptasi

Dalam konteks pendidikan digital, model *machine learning* (ML) telah banyak digunakan untuk memprediksi kemampuan adaptasi mahasiswa dalam pembelajaran daring. Model-model tersebut meliputi algoritma klasik seperti *Logistic Regression* (LR), *Support Vector Machine* (SVM), dan *K-Nearest Neighbor* (KNN), hingga algoritma *ensemble* modern seperti *Random Forest* (RF) dan *Extreme Gradient Boosting* (XGB). Penelitian oleh Iparraguirre-Villanueva et al. (2023) menunjukkan bahwa RF dan XGB memberikan *performa* terbaik dengan akurasi mencapai 92%, mengungguli KNN (85%), SVM (76%), dan LR (67%). Hasil ini diperkuat oleh Suzan et al. (2021) yang juga menemukan bahwa RF mampu menangkap pola kompleks dari data mahasiswa sehingga lebih stabil dalam memprediksi tingkat adaptasi. Di sisi lain, pendekatan berbasis *neural networks* seperti *Artificial Neural Network* (ANN) dan *Convolutional Neural Network* (CNN) menawarkan kemampuan memproses pola non-linear yang lebih mendalam. Penelitian yang dilakukan Arti et al (2025) membandingkan tujuh algoritme diuji: *Decision Tree*, *Random Forest*, *Gradient Boosting*, *SVM*, *Logistic Regression*, *k-NN*, *Naïve Bayes*, dan *Neural Network*. Model *Neural Network* mampu memprediksi adaptasi mahasiswa dengan akurasi 94,6%. Evaluasi model ML dalam konteks prediksi adaptasi mahasiswa umumnya dilakukan menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score*, yang memberikan gambaran komprehensif mengenai kinerja model. Evaluasi ini penting karena akurasi saja tidak cukup menggambarkan *performa* model, terutama ketika terdapat ketidakseimbangan data antar kelas.

Penelitian tentang prediksi adaptasi mahasiswa semakin menegaskan relevansi teknologi ML dalam pendidikan daring. Adaptasi mahasiswa, yang mencakup dimensi kognitif, afektif, dan perilaku, terbukti memengaruhi motivasi, emosi, dan hasil belajar (Stockinger et al., 2021). Studi global oleh Martin et al. (2023) menemukan bahwa mahasiswa dengan tingkat adaptasi tinggi menunjukkan keterlibatan akademik lebih baik selama masa *lockdown* COVID-19, sedangkan mereka dengan adaptasi rendah cenderung mengalami *disengagement*. Selain itu, Tiwari et al. (2022) dalam kerangka *Education 4.0* menunjukkan kombinasi *neural network* dan *Random Forest* mampu mencapai akurasi 93% dalam klasifikasi adaptasi mahasiswa. Dengan berbagai temuan tersebut, jelas bahwa ML tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai fondasi dalam merancang intervensi pendidikan yang lebih adaptif, personal, dan responsif terhadap kebutuhan mahasiswa.

### 2.4 Framework Flask

Flask adalah *microframework* berbasis Python yang ringan dan fleksibel untuk mengembangkan aplikasi web. Flask tidak membutuhkan *library* yang besar, namun mendukung perluasan melalui banyak *extensions* sesuai kebutuhan (Ningrum & Ihsanudin, 2023). Arsitektur aplikasi Flask pada dasarnya mengikuti pola *Model-View-Controller* (MVC) secara sederhana: *view* menangani antarmuka pengguna (melalui template HTML), *controller* (rute Flask) menangani logika aplikasi dan komunikasi antara *view* dan *model*, sedangkan *model* di sini dapat berupa komponen pengolahan data atau model *machine learning* yang melakukan perhitungan prediksi. Keunggulan Flask adalah kemudahan integrasinya dengan kode Python dan pustaka *machine learning* seperti *scikit-learn* atau *TensorFlow/Keras*. Dengan Flask, model *machine learning* yang telah dilatih dapat disimpan (*serialize* dalam *format pickle* atau *h5*) dan kemudian dimuat pada aplikasi web, sehingga prediksi dapat diakses melalui *web service*.

Dalam konteks *machine learning*, tantangan utama setelah proses pelatihan model adalah tahap *deployment*. Model yang hanya berada dalam bentuk file atau notebook tidak akan memberikan manfaat praktis tanpa mekanisme distribusi yang memungkinkan pengguna mengakses fungsinya. Flask dapat berfungsi sebagai jembatan antara model dengan pengguna akhir melalui REST API. Misalnya, sebuah *endpoint* POST /predict dapat dikonfigurasi untuk menerima data masukan dalam *format* JSON, melakukan pra-pemrosesan, menjalankan model untuk menghasilkan prediksi, lalu mengembalikan hasil dalam bentuk respons JSON. Dengan pendekatan ini, model *machine learning* menjadi mudah diintegrasikan dengan aplikasi eksternal, sistem akademik, maupun dashboard analitik (DigitalOcean, 2022).

### 3. Metodologi

#### 3.1 Data Penelitian

Dataset berasal dari 675 mahasiswa perguruan tinggi (Arti & Suherlan, 2025). Variabel meliputi demografi, sosial-ekonomi, teknis, serta label tingkat adaptasi (Low, Moderate, High). Data penelitian ini diperoleh dari 675 mahasiswa perguruan tinggi, sebagaimana digunakan dalam penelitian Arti & Suherlan (2025). Dataset tersebut mencakup berbagai variabel yang dikelompokkan ke dalam tiga kategori utama, yaitu demografis (jenis kelamin, usia, jenjang pendidikan, tipe institusi), sosial-ekonomi (kondisi ekonomi keluarga, lokasi tempat tinggal, frekuensi pemadaman listrik), serta teknis (jenis perangkat yang digunakan, tipe jaringan internet, durasi kelas daring, dan ketersediaan LMS). Label tingkat adaptasi dikategorikan ke dalam tiga kelas, yaitu *Low* (rendah), *Moderate* (sedang), dan *High* (tinggi).

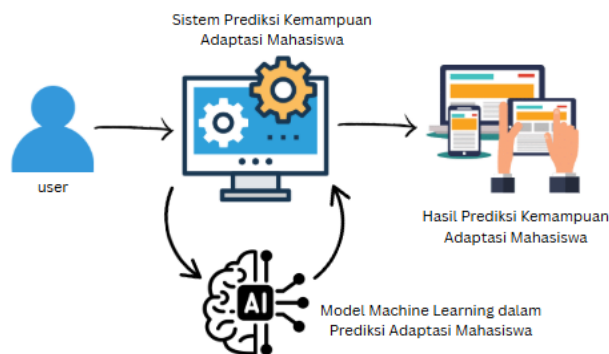
Data yang digunakan dalam penelitian ini adalah hasil model *machine learning* yang dilakukan dalam Arti et al (2025), tujuh algoritme diuji: Decision Tree, *Random Forest*, Gradient Boosting, SVM, Logistic Regression, k-NN, Naïve Bayes, dan *Neural Network*. Evaluasi menggunakan *accuracy*, *precision*, *recall*, *F1-score*, *MCC*, dan *AUC*. Model *Neural Network* dipilih karena hasil terbaik (akurasi 94,6%). Dalam penelitian tersebut, *Artificial Neural Network* (ANN) menghasilkan *performa* paling unggul dibanding algoritme lainnya. Model ini mencapai akurasi 94,6%, nilai F1-score 0,95, AUC 0,96, serta MCC 0,88, yang menandakan stabilitas dan keandalannya dalam membedakan ketiga kelas adaptasi (Low, Moderate, High). Berdasarkan hasil tersebut, ANN dipilih sebagai model utama untuk diimplementasikan ke dalam sistem prediksi berbasis Flask. Pemilihan ini bukan hanya karena nilai akurasi tertinggi, tetapi juga karena kemampuan ANN dalam menghasilkan generalisasi yang baik pada data uji, sehingga dapat diandalkan ketika digunakan pada data nyata di aplikasi web.

#### 3.2 Deployment menggunakan Flask

Setelah model terbaik diperoleh, tahap berikutnya adalah *deployment* menggunakan kerangka kerja Flask agar model dapat digunakan secara praktis dalam bentuk aplikasi web. Proses *deployment* dilakukan dengan langkah-langkah berikut:

1. Serialisasi model ANN hasil pelatihan ke dalam *format* file .pkl, sehingga dapat di-*load* ulang tanpa perlu melatih model dari awal.
2. Inisialisasi aplikasi Flask melalui file app.py, termasuk konfigurasi untuk memuat model dan pipeline *preprocessing* saat aplikasi dijalankan.
3. *Routing* Flask dibuat dengan *endpoint* utama /*predict* yang berfungsi menerima input dari pengguna baik melalui *form* HTML maupun request JSON, kemudian menjalankan proses prediksi, dan mengembalikan hasilnya.
4. Antarmuka pengguna dibangun menggunakan HTML dan CSS untuk menghasilkan tampilan *form* input yang sederhana namun responsif. Hasil prediksi ditampilkan dalam bentuk label kelas adaptasi.

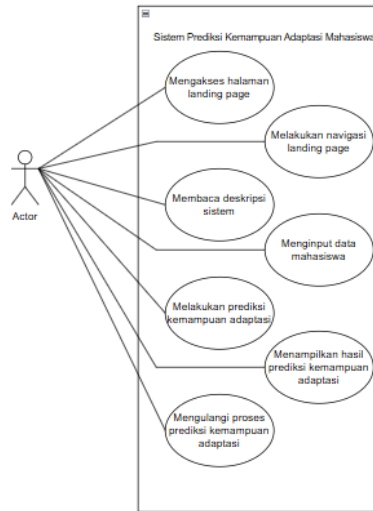
#### 3.3 Desain sistem



Gambar 3.1. Desain Arsitektur Sistem Prediksi Kemampuan Adaptasi Mahasiswa

Gambar 3.1 menjelaskan desain arsitektur dari sistem prediksi kemampuan adaptasi mahasiswa. Pada gambar tersebut, sistem dirancang untuk memungkinkan pengguna menginput data terkait karakteristik individu mahasiswa melalui antarmuka aplikasi berbasis web. Data tersebut kemudian diproses oleh sistem utama yang dibangun menggunakan *framework* Flask, dan diteruskan ke model *machine learning* yang telah dilatih untuk mengenali pola-pola yang berkaitan dengan tingkat adaptasi mahasiswa terhadap lingkungan akademik. Model ini melakukan analisis dan menghasilkan prediksi yang kemudian dikembalikan ke sistem dan ditampilkan dalam bentuk hasil visual yang mudah dipahami oleh pengguna. Alur kerja sistem ini mencakup proses input data oleh

user, pemrosesan dan prediksi oleh model *machine learning*, hingga penyajian output prediksi dalam bentuk informasi adaptasi yang dapat digunakan sebagai dasar pengambilan keputusan akademik atau intervensi psikologis.



Gambar 3.2. Use Case Diagram Sistem Prediksi Kemampuan Adaptasi Mahasiswa

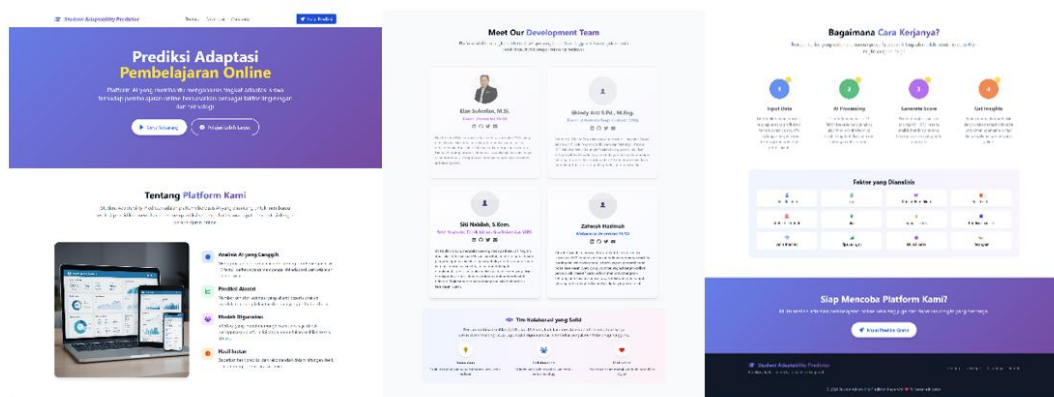
Selain desain sistem, gambar 3.2 menunjukkan bagaimana pengguna berinteraksi dengan aplikasi. Use case diagram memberikan penjelasan sederhana namun komprehensif mengenai fungsi-fungsi utama yang dapat diakses oleh pengguna, seperti membuka halaman utama, mengisi data mahasiswa, mengirimkan permintaan prediksi, hingga melihat hasil keluaran sistem. Tabel use case ditunjukkan pada tabel 3.1.

Tabel 3.1. Penjelasan Use Case Sistem Prediksi Kemampuan Adaptasi Mahasiswa

Use Case ID	Nama Use Case	Aktor	Deskripsi	Alur Utama
UC-01	Akses Landing Page	User	User membuka halaman awal sistem prediksi kemampuan adaptasi mahasiswa.	1. User membuka URL aplikasi. 2. Sistem menampilkan halaman utama (judul, deskripsi, menu).
UC-02	Navigasi ke Halaman Prediksi	User	User memilih tombol/menu untuk mengakses halaman prediksi.	1. User klik tombol "Prediksi Sekarang". 2. Sistem mengarahkan ke halaman prediksi.
UC-03	Membaca Deskripsi Sistem	User	User membaca informasi singkat tentang fungsi sistem dan manfaat prediksi adaptasi.	1. Sistem menampilkan teks deskripsi di landing page. 2. User memahami fungsi aplikasi.
UC-04	Input Data Mahasiswa	User	User mengisi <i>form</i> variabel (contoh: usia, jenis kelamin, kondisi ekonomi, perangkat, durasi kelas).	1. User isi semua field input. 2. User klik tombol submit.
UC-05	Prediksi Adaptasi	Sistem (Flask + Model)	Sistem memproses input dengan model <i>Neural Network</i> yang sudah di-compile.	1. Flask menerima request POST. 2. Model ML melakukan prediksi. 3. Sistem mengirim hasil ke UI.
UC-06	Tampilkan Hasil Prediksi	User	User melihat hasil prediksi kemampuan adaptasi mahasiswa pada layar.	1. Sistem menampilkan hasil prediksi dalam kotak output. 2. User membaca hasil prediksi.
UC-07	Ulangi Proses Prediksi	User	Jika ingin memprediksi lagi, user dapat mengulang dengan input baru.	1. User klik tombol reset/refresh. 2. Sistem mengosongkan <i>form</i> input.

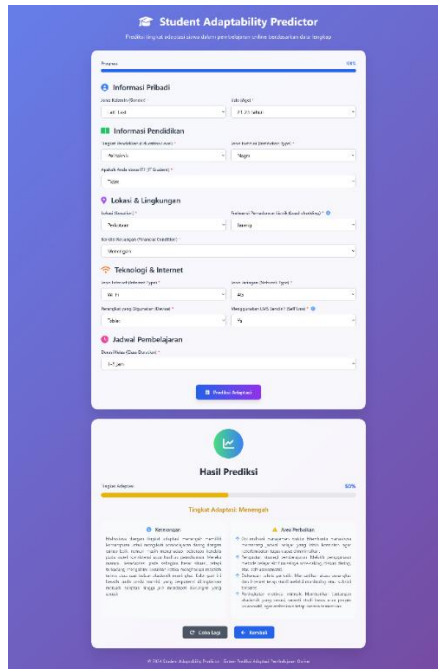
#### 4. Hasil dan Analisis

Hasil penelitian ini merupakan implementasi sistem berbasis web bernama *Student Adaptability Predictor*. Sistem ini dikembangkan menggunakan *framework* Flask yang berfungsi sebagai *backend* utama untuk menghubungkan model *machine learning* dengan antarmuka pengguna. Implementasi Flask menghasilkan aplikasi web ringan dengan *form* input 14 variabel mahasiswa. Output sistem menampilkan kategori adaptasi (*Low, Moderate, High*). Dalam arsitektur sistem prediksi kemampuan adaptasi mahasiswa, komunikasi antara antarmuka pengguna (*frontend*) dan model *machine learning* (*backend*) dijumpai melalui mekanisme *fetching*. Model prediksi yang telah dilatih disimpan di server dan dipanggil oleh backend saat menerima permintaan dari pengguna. Data yang dimasukkan melalui antarmuka web dikirim menggunakan protokol HTTP (misalnya metode POST), kemudian diproses oleh backend untuk menghasilkan prediksi kemampuan adaptasi mahasiswa. Hasil prediksi dikembalikan dalam *format* terstruktur seperti JSON agar dapat ditampilkan di frontend. Pendekatan ini menjaga beban komputasi utama tetap berada di server, sehingga frontend hanya berfungsi sebagai pengirim input dan penampil hasil. Selain itu, arsitektur berbasis Flask ini memudahkan pemeliharaan, memungkinkan pembaruan model secara berkala, dan meningkatkan keamanan sistem karena model tidak perlu diunduh ke sisi pengguna



Gambar 4.1 Halaman Landing Page Sistem Prediksi Adaptasi Mahasiswa

Gambar 4.1 menunjukkan halaman utama (*landing page*) dari platform *Student Adaptability Predictor* yang diakses melalui localhost. Sistem menampilkan informasi awal berupa judul aplikasi, deskripsi singkat, serta menu navigasi untuk menuju ke halaman prediksi. Platform ini dirancang untuk menganalisis tingkat adaptasi siswa terhadap pembelajaran daring berdasarkan berbagai faktor lingkungan dan teknologi. Halaman tersebut berfungsi sebagai halaman utama dan memberikan informasi singkat tentang tujuan platform dan manfaatnya untuk menilai seberapa akomodatif siswa terhadap pembelajaran online. Gambar 4 menunjukkan halaman prediksi kemampuan adaptasi mahasiswa. User berperan sebagai aktor tunggal yang dapat langsung mengakses halaman tanpa login. Selanjutnya, pada halaman prediksi, user mengisi form data terkait karakteristik pembelajaran daring. Setelah menekan submit, data akan diproses oleh Flask yang telah disisipi model *Machine Learning* berbasis *Neural Network*. Hasil prediksi berupa tingkat kemampuan adaptasi mahasiswa ditampilkan. Jika diperlukan, user dapat mengulang proses dengan mengisi kembali form prediksi.



**Gambar 3.2. Halaman Prediksi Kemampuan Adaptasi Mahasiswa**

Uji coba menunjukkan respons prediksi <2 detik, konsisten dengan evaluasi model offline. Sistem ini membuktikan bahwa model *machine learning* dapat dioperasionalkan menjadi alat bantu pengambilan keputusan. Dosen atau konselor dapat mengidentifikasi mahasiswa dengan adaptasi rendah dan memberikan intervensi, misalnya pelatihan literasi digital atau pendampingan intensif. Fitur inti platform terdiri dari empat aspek utama: (1) analisis AI yang canggih untuk memproses variabel input, (2) hasil prediksi yang akurat berbasis model pembelajaran mesin, (3) antarmuka yang mudah digunakan tanpa keahlian teknis mendalam, dan (4) penyajian hasil secara instan setelah data dimasukkan. Keempat aspek tersebut terintegrasi melalui arsitektur Flask, yang menghubungkan *frontend* (HTML, CSS, dan komponen UI/UX) dengan *backend* (Python-Flask dan model *machine learning*).

## 5. Kesimpulan dan Saran

Kemampuan adaptasi mahasiswa merupakan salah satu faktor penting dalam keberhasilan pembelajaran daring. Deployment dengan Flask terbukti efektif dalam mewujudkan sistem prediksi berbasis AI yang mudah diakses, instan, dan bermanfaat. Untuk memprediksi tingkat adaptasi tersebut, penelitian ini memanfaatkan hasil pemodelan *machine learning* dari penelitian sebelumnya, dimana data yang digunakan sejumlah 675 mahasiswa perguruan tinggi. Data penelitian ini mencakup tiga kategori variabel: demografis (jenis kelamin, usia, jenjang pendidikan, tipe institusi), sosial-ekonomi (kondisi ekonomi keluarga, lokasi tempat tinggal, frekuensi pemadaman listrik), serta teknis (perangkat, jaringan internet, durasi kelas daring, dan ketersediaan LMS). Label tingkat adaptasi dibagi menjadi tiga kelas, yaitu *Low*, *Moderate*, dan *High*. *Artificial Neural Network* (ANN) dipilih sebagai model utama karena menunjukkan performa paling unggul dengan akurasi 94,6%, F1-score 0,95, AUC 0,96, serta MCC 0,88. Model ini dianggap stabil dan andal dalam membedakan ketiga kategori adaptasi. Model ANN yang telah dibangun kemudian di-*deploy* menggunakan *framework* Flask, sehingga dapat digunakan secara praktis dalam bentuk aplikasi web. User dapat mengakses halaman utama (*landing page*), membaca deskripsi sistem, serta melakukan navigasi menuju halaman prediksi. Untuk pengembangan berikutnya, penelitian lainnya melakukan pembaruan dan perluasan dataset dari berbagai perguruan tinggi agar lebih representatif, serta integrasi dengan *log* aktivitas LMS (*login*, akses materi, forum, tugas) sehingga prediksi tidak hanya berbasis data statis, tetapi juga mencerminkan perilaku belajar nyata mahasiswa.

### Daftar Pustaka:

- Arti, S., & Suherlan, E. (2025). Evaluasi kinerja *machine learning* dalam memprediksi kemampuan adaptasi mahasiswa pada lingkungan pembelajaran daring. *Jurnal Pustaka AI*, 5(1), 50–57. <https://doi.org/10.55382/jurnalpustakaai.v5i1.901>
- Arcoverde, Â. R. dos R., Boruchovitch, E., Góes, N. M., & Acee, T. W. (2022). Self-regulated learning of Natural Sciences and Mathematics future teachers: Learning strategies, self-efficacy, and socio-demographic factors. *Psicologia-Reflexao E Critica*, 35(1). <https://doi.org/10.1186/s41155-021-00203-x>
- Bartolo-Alemán, M. H., Martínez-López, M., Robledo-Taboada, L. H., VÁSQUEZ-MARTÍNEZ, M., Martínez-Mendoza, S. M., & GARCÍA-MONTALVO, G. O. (2022). Self-regulated learning in first year industrial engineering students, national technological institute of mexico campus oaxaca, mexico. *Journal of Global Research in Education and Social Science*, 14–18. <https://doi.org/10.56557/jogress/2022/v16i37909>
- Broadbent, J., & Poon, W. L. (2015). Self-regulated learning strategies & academic achievement in online higher education learning environments: A systematic review. *The Internet and Higher Education*, 27, 1–13. <https://doi.org/10.1016/j.iheduc.2015.04.007>
- Chitra, E., Hidayah, N., Chandratilake, M., & Nadarajah, V. D. (2022). *Self-Regulated Learning Practice of Undergraduate Students in Health Professions Programs*. *Frontiers in Medicine*, 9. <https://doi.org/10.3389/fmed.2022.803069>
- DigitalOcean. (2022, May 10). *How to serve Flask applications with Gunicorn and Nginx on Ubuntu 22.04*. DigitalOcean. <https://www.digitalocean.com>
- ElSayed, A. A., Rodríguez, M. C., Mikic-Fonte, F. A., Lugalde-López, A., & Nistal, M. L. (2024). Measuring and Promoting *Self-Regulated Learning* Using Spaced Questionnaires. *IEEE Access*, 1. <https://doi.org/10.1109/access.2024.3457238>
- Fayda-Kımk, F. Ş. (2024). *Empowering Undergraduates: An Examination of Online Self-Regulated Learning Skills in Higher Education*. <https://doi.org/10.4995/head24.2024.17161>
- Greenberg, A., Olvet, D. M., Brenner, J. M., Zheng, B., Chess, A., Schlegel, E., & Ginzburg, S. B. (2023). Strategies to support self-regulated learning in integrated, student-centered curricula. *Medical Teacher*, 1–8. <https://doi.org/10.1080/0142159X.2023.2218538>
- Hadwin, A. F., Sukhawathanakul, P., Rostampour, R., & Bahena-Olivares, L. M. (2022). Do *Self-Regulated Learning* Practices and Intervention Mitigate the Impact of Academic Challenges and COVID-19 Distress on Academic Performance During Online Learning? *Frontiers in Psychology*, 13. <https://doi.org/10.3389/fpsyg.2022.813529>
- Jonathan Evan, D., & Nugraha, P. O. (2023). Implementasi Python *framework* Flask pada modul transfer out toko di PT XYZ. *JUPI*, 8(4), 1121–1131 <https://doi.org/10.29100/jupi.v8i4.4020>
- Kotha, A., Das, P., & Phadikar, S. (2021). Web-based *deployment* of deep learning models using Flask and Docker. *Journal of Emerging Technologies and Innovative Research*, 8(6), 421–426.
- Li, Z., et al. (2023). Students' online learning adaptability and their continuous usage intention across different disciplines. *Humanities and Social Sciences Communications*, 10(1), 1–10. <https://doi.org/10.1057/s41599-023-02376-5>
- Martin, A. J., Ginns, P., & Collie, R. J. (2023). University students in COVID-19 lockdown: The role of adaptability and fluid reasoning in supporting their academic motivation and engagement. *Learning and Instruction*, 83, 101712. <https://doi.org/10.1016/j.learninstruc.2022.101712>
- Mickwitz, Å., Londén, M., Perander, K., & Tiihonen, S. (2024). Understanding the varieties in first-year university students' experience of self-regulated learning during emergency remote teaching. *European Journal of Higher Education*, 1–18. <https://doi.org/10.1080/21568235.2024.2359107>
- Ningrum, D. S., & Ihsanudin, M. (2023). Penerapan Flask pada *deployment* model *machine learning* untuk prediksi umur transformator. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(2), 101–110. <https://doi.org/10.1234/jtiik.v10i2.1234>
- Pintrich, P. R. (2004). A conceptual *framework* for assessing motivation and self-regulated learning in college students. *Educational Psychology Review*, 16(4), 385–407. <https://doi.org/10.1007/s10648-004-0006-x>
- She, C., Liang, Q., Jiang, W., & Xing, Q. (2023). *Learning adaptability facilitates self-regulated learning at school*. *Frontiers in Psychology*, 14, 1–9. <https://doi.org/10.3389/fpsyg.2023.1162072>
- Smadi, M., Al Masri, A., Maharmah, H., & Abu-Snoubar, T. (2024). Exploring the Correlation between Self-regulated Learning Strategies and Academic Success in Higher Education. *Journal of Ecohumanism*, 3(7), 2875–2883. <https://doi.org/10.62754/joe.v3i7.4424>
- Sree, V., Ramesh, K., & Rao, P. (2023). Student adaptability level prediction in online education using *machine learning* with SMOTE. *International Journal of Emerging Technologies in Learning*, 18(5), 45–59. <https://doi.org/10.3991/ijet.v18i05.35649>

- Stockinger, K., Rinas, R., & Daumiller, M. (2021). Student adaptability, emotions, and achievement: Navigating new academic terrains in a global crisis. *Learning and Individual Differences*, *90*, 102046. <https://doi.org/10.1016/j.lindif.2021.102046>
- Suzan, M. H., Widodo, A., & Putra, H. (2021). Predicting student adaptability in online learning using supervised machine learning algorithms. *Procedia Computer Science*, *179*, 524–531. <https://doi.org/10.1016/j.procs.2021.12.067>
- Tiwari, R. G., Jain, A. K., Misra, A., Ujjwal, N., & Kukreja, V. (2022). Education 4.0: Classification of student adaptability level in e-education. In *Proceedings of ICRITO 2022* (pp. 1–6). IEEE. <https://doi.org/10.1109/ICRITO56286.2022.9964851>
- Van den Heuvel, M., Demerouti, E., Bakker, A. B., & Schaufeli, W. B. (2013). Adapting to change: The value of change information and meaning-making. *Journal of Vocational Behavior*, *83*(1), 11–21. <https://doi.org/10.1016/j.jvb.2013.02.004>
- Villamarín, P. D. C., Pillajo, M., Ocampo, P., Pillajo, A., & Tipanta, D. (2024). El aprendizaje autorregulado en el aula: Revisión de su impacto y estrategias de aplicación. *Revista Veritas de Difusão Científica.*, *5* (3), 719-730. <https://doi.org/10.61616/rvdc.v5i3.229>
- Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory Into Practice*, *41*(2), 64–70. [https://doi.org/10.1207/s15430421tip4102\\_2](https://doi.org/10.1207/s15430421tip4102_2)