

SLECARE: APLIKASI MENGKLASIFIKASIKAN SISTEMIK LUPUS ERYTHEMATOSUS BERASASKAN PENDEKATAN PEMBELAJARAN MESIN

Muhammad Izzul Islam, Shahnorbanun

Fakulti Teknologi & Sains Maklumat,
43600 Universiti Kebangsaan Malaysia

Abstrak

Systemic Lupus Erythematosus (SLE) adalah penyakit autoimun heterogen dengan variasi simptom, respons rawatan, dan komplikasi yang berbeza antara pesakit. Lupus Nephritis (LN), manifestasi serius SLE, sering membawa kepada penyakit buah pinggang kronik (CKD) dan kelewatan remisi. Projek ini membangunkan SLECare, sebuah sistem ramalan berasaskan pembelajaran mesin yang menggunakan data pesakit LN Malaysia dari Hospital Canselor Tuanku Muhriz (2000–2020) untuk meramal risiko CKD dan kelewatan remisi. Data telah melalui proses pembersihan, imputasi nilai hilang, pemilihan ciri, dan pembahagian set latihan serta ujian. Model CatBoost bersama interpretasi SHAP digunakan, manakala model lain (Random Forest, MLP, SVM) dibangunkan sebagai perbandingan. Hasil penilaian menunjukkan bahawa model CatBoost Baseline memberikan prestasi paling seimbang (F1-score tertinggi), menjadikannya pilihan utama untuk antaramuka klinikal. SLECare berpotensi menjadi alat sokongan keputusan bagi meningkatkan ketepatan rawatan pesakit LN di Malaysia.

Kata Kunci: Lupus Nephritis, Systemic Lupus Erythematosus, Pembelajaran Mesin, CatBoost, SHAP

Abstract

Systemic Lupus Erythematosus (SLE) is a heterogeneous autoimmune disease with variations in symptoms, treatment responses, and complications across patients. Lupus Nephritis (LN), a severe manifestation of SLE, often leads to chronic kidney disease (CKD) and delayed remission. This project developed SLECare, a machine learning-based prediction system utilizing data from Malaysian LN patients treated at Hospital Canselor Tuanku Muhriz (2000–2020) to predict the risks of CKD and delayed remission. The dataset underwent cleaning, missing value imputation, feature selection, and train-test splitting. The CatBoost model with SHAP interpretation was employed, while other models (Random Forest, MLP, SVM) were built for comparison. Evaluation results showed that the Baseline CatBoost model achieved the most balanced performance (highest F1-score), making it the optimal

choice for clinical interface deployment. SLECare has the potential to serve as a decision support tool to enhance treatment accuracy for LN patients in Malaysia.

Keywords: Lupus Nephritis, Systemic Lupus Erythematosus, Machine Learning, CatBoost, SHAP

1.0 PENGENALAN

Systemic Lupus Erythematosus (SLE) ialah penyakit autoimun kompleks dengan variasi simptom dan hasil rawatan yang berbeza antara pesakit mengikut jantina, bangsa dan lokasi. Di Malaysia, SLE dilaporkan sekitar 40–60 kes bagi setiap 100,000 populasi, dengan 40–60% daripada pesakit ini mengalami Lupus Nephritis (LN), iaitu manifestasi serius yang sering membawa kepada kerosakan organ buah pinggang, iaitu penyakit buah pinggang kronik (CKD), dan kegagalan buah pinggang peringkat akhir (ESRD). Walaupun kadar mortaliti LN telah menurun, risiko ESRD kekal tinggi, dilaporkan mencapai 3–11% dalam 5 tahun dan kadar tersebut meningkat sehingga 19–25% dalam 15 tahun selepas diagnosis. Dalam konteks kesihatan awam, prognosis awal amat penting bagi meningkatkan peluang rawatan yang berjaya dan mengurangkan komplikasi jangka panjang seperti CKD dan ESRD. Hal ini kerana remisi dalam tempoh masa 3 tahun dikaitkan dengan pengurangan kerosakan organ dan kadar suar yang lebih rendah. Syahrul Sazliyana et al. (2021).

Walau bagaimanapun, kaedah konvensional dalam mendiagnosis dan meramal perjalanan penyakit sering gagal mengesan faktor risiko dengan tepat. Variasi gejala mengikut etnik dan individu menyebabkan proses ini mencabar, terutamanya bagi kohort pesakit di Malaysia yang berbilang bangsa.

Projek ini membangunkan **SLECare**, sebuah sistem ramalan berasaskan pembelajaran mesin (ML) yang dibina untuk mengklasifikasikan pesakit dan mencari faktor penyakit buah pinggang kronik (CKD) dan kelewatan remisi dalam kalangan pesakit LN di Malaysia menggunakan model penerangan **Shapley Additive Explanations** (SHAP).

SLECare memanfaatkan data klinikal Hospital Canselor Tuanku Muhriz (HCTM) dan model CatBoost yang sering digunakan dalam bidang kesihatan besertakan dengan interpretasi SHAP. Dengan itu, aplikasi ini berfungsi sebagai alat sokongan keputusan klinikal bagi membantu pakar perubatan membuat keputusan rawatan yang lebih tepat dan proaktif.

2.0 Kajian Literatur

Kajian oleh AlShareedah et al. (2023) telah menunjukkan keberkesanan penggunaan pembelajaran mesin dalam mendiagnosis penyakit autoimun seperti Systemic Lupus Erythematosus (SLE). Penyelidikan tersebut menggunakan aliran kerja yang hampir serupa dengan projek ini dari segi pra-pemprosesan data, pemilihan ciri, dan pembangunan model ramalan. Walau bagaimanapun, kajian tersebut terhad kepada populasi Oman dan hanya menumpukan pada aspek diagnosis SLE, tanpa melibatkan ramalan hasil klinikal jangka panjang seperti penyakit buah pinggang kronik (CKD) atau kelewatian remisi.

Kajian oleh Syahrul Sazliyana et al. (2021) pula dijalankan menggunakan kohort pesakit Lupus Nephritis (LN) Malaysia antara tahun 2000 hingga 2020, iaitu dataset yang sama digunakan dalam projek ini. Melalui kaedah Generalized Estimating Equations (GEE), kajian tersebut mengenal pasti faktor klinikal yang berkait dengan perkembangan CKD dan kelewatian remisi. Dapatkan ini memberikan asas klinikal yang kukuh mengenai kepentingan faktor risiko tertentu dalam menentukan hasil rawatan. Namun begitu, kajian ini hanya terhad kepada analisis hubungan faktor (association) dan tidak menyediakan alat ramalan yang boleh digunakan secara langsung untuk penilaian risiko individu. Bukan itu sahaja, ML juga sering lebih tepat berbanding kaedah statistik seperti GEE dalam melakukan analisis terhadap data berdimensi tinggi seperti data-data dari hospital.

Berdasarkan kajian-kajian lepas, jelas wujud jurang dalam penyelidikan sedia ada, khususnya dari segi pembangunan sistem ramalan klinikal yang dapat mengklasifikasikan hasil rawatan pesakit LN di Malaysia. Sehubungan itu, projek ini memperkenalkan SLECare, sebuah sistem ramalan berasaskan pembelajaran mesin yang memanfaatkan data klinikal tempatan untuk mengklasifikasikan risiko CKD dan kelewatian remisi. Dengan menggunakan model CatBoost serta interpretasi SHapley Additive Explanations (SHAP), SLECare bertujuan untuk menyediakan alat sokongan keputusan yang lebih tepat, proaktif, dan relevan kepada keperluan klinikal di Malaysia.

3.0 METODOLOGI

Metodologi bagi pembangunan sistem SLECare adalah rangka kerja **CRISP-DM**, iaitu sebuah rangka kerja piawai bagi projek ML dan data sains.

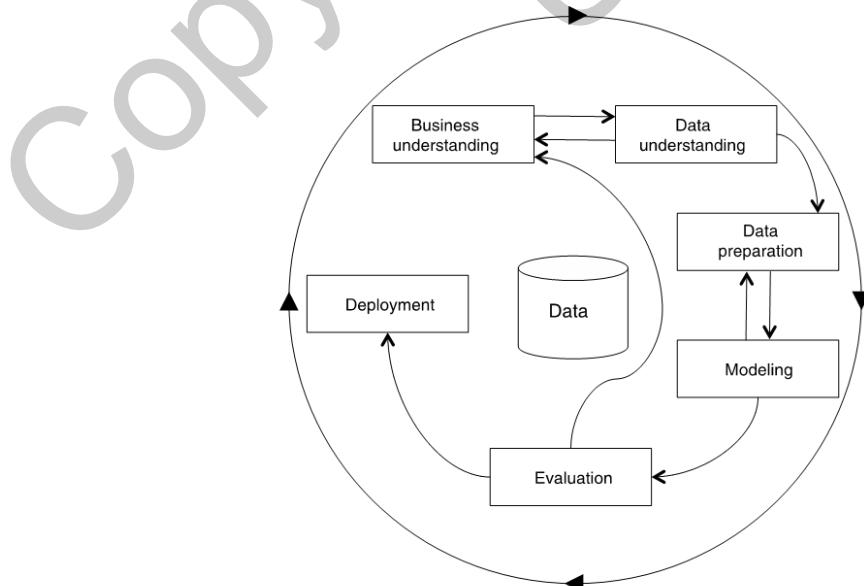
3.1 Data

Dataset yang digunakan dalam projek ini diperoleh daripada pesakit Lupus Nephritis (LN) yang dirawat di Hospital Canselor Tuanku Muhriz (HCTM) dalam tempoh tahun 2000 hingga 2020. Data ini merangkumi maklumat demografik, klinikal, biopsi, dan rawatan yang direkodkan semasa tempoh rawatan pesakit.

Bagi tujuan pemodelan, dua pemboleh ubah sasaran telah ditentukan iaitu:

- Penyakit buah pinggang kronik (CKD), yang menunjukkan sama ada pesakit mengalami kerosakan buah pinggang dalam tempoh susulan.
- Kelewatan remisi (CR 12 MTH PRED 10), yang menunjukkan sama ada pesakit gagal mencapai remisi lengkap dalam tempoh 12 bulan.

Penggunaan dataset ini adalah dengan kelulusan etika penyelidikan yang diperoleh daripada pihak berkuasa hospital dan universiti.



Rajah Error! No text of specified style in document. Rangka kerja CRISP-DM (Chapman, Clinton,

Kerber, et al. 1999).

3.2 Pra-Pemprosesan Data

Proses pra-pemprosesan data dilaksanakan bagi memastikan kualiti dan kebolehgunaan set data yang bersih sebelum pembangunan model. Langkah pertama melibatkan penyingkiran ciri yang tidak relevan serta ciri yang berpotensi menyebabkan kebocoran sasaran (target leakage), selaras dengan Pelan Kualiti Data yang ditetapkan.

Seterusnya, pengesanan dan pengendalian data terpencil (outlier) dilakukan mengikut panduan pelan kualiti terhadap beberapa ciri bagi memastikan data berada dalam julat yang munasabah. Beberapa ciri numerik didapati perlu dikendalikan pembersihan data terpencil kerana ia mempunyai taburan sangat condong (skewed) dan nilai pencilan yang ekstrem, transformasi logaritma digunakan untuk menstabilkan varians dan mengurangkan kesan pencilan tanpa membuang data. Nilai hilang bagi ciri numerik diimputasi secara manual menggunakan kaedah median, disertakan dengan penanda (flag) untuk mengekalkan maklumat tentang ketiadaan nilai asal. Bagi ciri kategori, nilai hilang diisi dengan 0 bagi ciri nominal dan 2 bagi ciri binari untuk menandakan bahawa pesakit tersebut tidak melalui ujian tersebut. walau bagaimanapun, terdapat ciri kategori ANA hanya diimputasi menggunakan nilai mod sahaja kerana kedua-dua cara tidak boleh digunakan terhadapnya dan kadar nilai hilangnya yang rendah.

Selain itu, satu ciri baharu iaitu ONSET_LN_FROM_DIAGNOSIS telah dibentuk dengan mengira perbezaan antara tahun LN aktif dan tahun diagnosis asal, bagi memperkayakan maklumat yang diberikan kepada model. Kedua-dua ciri asal telah digugurkan selepas pembentukan ciri ini.

Akhir sekali, data dibahagikan kepada set latihan (80%) dan set ujian (20%) menggunakan stratified split bagi memastikan taburan kelas sasaran kekal seimbang antara kedua-dua set. Semua langkah pra-pemprosesan dilaksanakan secara konsisten sebelum proses pembangunan model dan telah disahkan Dr Syahrul Sazliyana.

```

# == 1. Drop Irrelevant Columns ==
data_cleaned = drop_columns(data)

# == 2. Get Feature Columns ==
numeric_cols, categorical_cols = get_feature_columns()

# == 3. Impute Missing Values ==
data_imputed = impute_missing_values(data_cleaned, numeric_cols, categorical_cols)

# == 4. Apply Log Transformation (UPCI only for CatBoost)
log_features = [
    'UPCI PRE TX'
]
data_log_transformed = log_transform_features(data_imputed, log_features)

# == 5. Feature Engineering ==
data_engineered = feature_engineering(data_log_transformed)

# == 6a. Stratified split for CatBoost - CKD objective ==
X_cb_ckd, X_cb_ckd_test, y_cb_ckd, y_cb_ckd_test = perform_stratified_split(
    data_engineered,
    target_column='CKD'
)

# == 6b. Stratified Split for CatBoost - Delayed Remission objective ==
X_cb_remission, X_cb_remission_test, y_cb_remission, y_cb_remission_test = perform_stratified_split(
    data_engineered,
    target_column='CR 12 MTH PRED 10'
)

# Step 7: Only include columns that are categorical
cat_features_cb = [
    col for col in categorical_cols
    if col in data_engineered.columns and data_engineered[col].dtype == 'object'
]

```

Rajah 2 pipeline 1 untuk model CatBoost

3.3 Pembangunan Model

Bagi projek ini, dua pendekatan pemodelan telah dibangunkan untuk menilai keberkesanan kaedah ramalan bagi pesakit Lupus Nephritis (LN) di Malaysia. Pendekatan pertama menggunakan Pipeline 1 seperti yang ditunjukkan pada rajah 2, ia berdasarkan model **CatBoost**, manakala pendekatan kedua menggunakan Pipeline 2 yang melibatkan model **Random Forest (RF)**, **Multilayer Perceptron (MLP)**, dan **Support Vector Machine (SVM)**. Model-model tersebut pula dibahagikan kepada 3 jangka masa, iaitu *Baseline*, *6M* dan *12M*. Jangka masa Baseline hanya menggunakan ciri sebelum rawatan, *6M* menggunakan ciri baseline dan fitur 3 MTH, *12M* pula menggunakan fitur baseline, 3 MTH dan 6 MTH.

a. Pipeline 1 – CatBoost

Model CatBoost dipilih kerana keupayaannya mengendalikan ciri kategori secara natif tanpa memerlukan pengekodan tambahan. Algoritma ini juga tidak memerlukan penskalaan data, sekali gus memudahkan proses pemodelan. Untuk ketidakseimbangan kelas dalam ramalan CKD, *class_weights* digunakan bagi memberikan penekanan lebih pada kelas minoriti. SMOTE tidak digunakan dalam pipeline ini untuk mengelakkan penggandaan sintetik data klinikal.

b. Pipeline 2 - Random Forest, MLP, dan SVM

Pipeline kedua melibatkan model bukan CatBoost yang memerlukan pengkodan untuk proses latihan dan penskalaan ciri numerik menggunakan MinMaxScaler supaya semua nilai berada dalam julat 0–1. Bagi ramalan CKD, ketidakseimbangan kelas ditangani menggunakan **SMOTE** (Synthetic Minority Oversampling Technique) yang diaplikasikan hanya pada set latihan untuk mengelakkan kebocoran data. Oleh itu, `class_weights` tidak digunakan bagi model-model yang melalui pipeline ini.

Semua model dibangunkan menggunakan set latihan (80%), manakala prestasi model dinilai pada set ujian (20%). Proses pemilihan ciri (feature selection) dilakukan menggunakan metod Recursive Feature Elimination (RFE) pada set latihan untuk mengurangkan dimensi data agar latihan model lebih efisien, prestasi model ditingkatkan dan isu overfitting dielakkan. Model akhir yang terpilih bagi antaramuka klinikal adalah model CatBoost dengan ciri **Baseline sahaja**, manakala model lain digunakan hanya untuk tujuan perbandingan prestasi.

```
# === 1. Drop Irrelevant Columns ===
data_cleaned = drop_columns(data)

# === 2. Get Feature Columns ===
numeric_cols, categorical_cols = get_feature_columns()

# === 3. Impute Missing Values ===
data_imputed = impute_missing_values(data_cleaned, numeric_cols, categorical_cols)

# === 4. Log Transformation ===
log_features = [
    'C3 PRE TX', 'C4 PRETX',
    'UPCT PRE TX'
]
data_log_transformed = log_transform_features(data_imputed, log_features)

# === 5. Feature Engineering ===
data_engineered = feature_engineering(data_log_transformed)

# === 6. Encoding (Label + One-Hot) ===
data_encoded, encoders = encode_categorical_features(data_engineered, categorical_cols)

# === 7. Scaling ===
data_scaled, scaler = scale_numerical_features(data_encoded, numeric_cols)

# === 8a. Stratified Split for CKD objective ===
X_ckd, X_ckd_test, y_ckd, y_ckd_test = perform_stratified_split(
    data_scaled,
    target_column='CKD'
)

# === 8b. Stratified Split for Delayed Remission objective ===
X_remission, X_remission_test, y_remission, y_remission_test = perform_stratified_split(
    data_scaled,
    target_column='CR 12 MTH PRED 10'
)
```

Rajah 3 pipeline 2 untuk model bukan CatBoost

3.4 Penilaian Model

Prestasi model dinilai menggunakan set ujian (20%) yang diasingkan semasa proses pra-pemprosesan. Penilaian dilakukan menggunakan metrik Recall, Precision, F1-score, dan Confusion Matrix bagi memberikan gambaran yang menyeluruh tentang keupayaan model mengklasifikasikan kelas sasaran, khususnya dalam data tidak seimbang.

Mengikut pandangan penyelia, model yang seimbang antara precision dan recall adalah lebih penting berbanding model yang hanya mengutamakan satu metrik semata-mata. Oleh itu, nilai F1-Score adalah metrik terpenting bagi memastikan model yang paling cemerlang. Walau bagaimanapun, Recall masih digunakan sebagai rujukan tambahan, penilaian utama memberi tumpuan kepada keseimbangan prestasi keseluruhan model.

Bagi konteks sasaran khusus:

- **CKD:** kelas positif ialah kelas 1 (risiko tinggi), maka recall kelas 1 tetap diperhatikan bagi memastikan pesakit berisiko tidak terlepas daripada pengesanan.
- **Kelewatan remisi:** kelas positif yang diperhatikan ialah kelas 0, kerana model perlu mengenal pasti pesakit yang berpotensi mengalami kelewatan dalam mencapai remisi lengkap.

Selain itu, analisis interpretabiliti dilakukan menggunakan SHapley Additive Explanations (SHAP) bagi model CatBoost kerana ia adalah model terbaik dari segi prestasi. Kaedah ini membolehkan pengenalpastian ciri yang paling mempengaruhi keputusan model, sekali gus meningkatkan kebolehpercayaan dalam aplikasi klinikal.

3.5 Pembangunan Antaramuka

Antaramuka pengguna sistem SLECare dibangunkan menggunakan Streamlit untuk memudahkan pakar klinik membuat penilaian risiko pesakit secara interaktif. Aplikasi ini hanya menggunakan model CatBoost dengan ciri baseline.

Antaramuka ini menerima input ciri klinikal pesakit melalui borang yang mesra pengguna. Selepas data dimasukkan, sistem akan menghasilkan ramalan risiko bagi dua hasil utama iaitu penyakit buah pinggang kronik (CKD) dan kelewatan remisi. Selain itu, aplikasi turut memaparkan plot interpretasi SHAP untuk menjelaskan faktor yang menyumbang kepada

keputusan ramalan bagi setiap pesakit.

Bagi kemudahan pakar klinik, aplikasi ini juga menyediakan fungsi eksport untuk memuat turun keputusan ramalan dalam bentuk fail CSV. Reka bentuk ini membolehkan SLECare berfungsi bukan sahaja sebagai alat ramalan, tetapi juga sebagai alat sokongan keputusan klinikal yang boleh digunakan dalam amalan harian.

The screenshot displays the SLECare application's user interface for baseline risk prediction. It features a sidebar with model selection ('Pilih Model Ramalan: CKD / Remission') and demographic information ('GENDER: Lelaki', 'RACE: Melayu'). The main area contains numerous input fields for clinical parameters, each with a dropdown menu and a numerical value. These include 'MUCOCUTANEOUS: 0', 'SEROSITIS: 0', 'ALBUMIN BASELINE: 0.00', 'CRESCENT: 0.00', 'ACTIVE INDEX: 0.00', 'AC KIDNEY INJURY INITIAL (AKI): 0', 'LA: Negatif', 'API POSITIVE: 0', 'MSK: 0', 'NPSLE: 0', 'CREAT BASELINE: 0.00', 'C4 PRETX: 0.00', 'CHRONIC INDEX: 0.00', 'ACE/ARB: 0', 'GLOBAL SCLEROSIS MISSING: 0', 'ANTIDNA PRE TX: Negatif', and 'ANTIBZ GP1 IGG: Negatif'. At the bottom are two buttons: 'Masukkan Data Pesakit Baseline' and 'Ramal'.

Rajah 4 Antaramuka model CKD SLECare

4.0 HASIL

Hasil ujian menunjukkan bahawa ketiga-tiga senario model (Baseline, 6M, dan 12M) berjaya menghasilkan prestasi yang memuaskan dalam meramal risiko penyakit buah pinggang kronik (CKD) dan kelewatkan remisi. Walau bagaimanapun, prestasi berbeza mengikut algoritma yang digunakan.

4.1 Ringkasan Prestasi Model

Jadual 1 Prestasi Kesemua Model CKD (Class 1)

Model	Precision	Sensitiviti	F1-score
CatBoost	0.67	0.83	0.74

Random Forest	0.56	0.42	0.48
MLP	0.83	0.42	0.56
SVM	0.47	0.58	0.52

Jadual 1 menunjukkan bahawa model Catboost adalah model paling seimbang kerana nilai F1-Score 0.74 jauh lebih tinggi berbanding model lain bagi target fitur CKD.

Jadual 2 Prestasi Kesemua Model-CR (Class 0)

Model	Precision	Sensitiviti	F1-score
CatBoost	0.71	0.65	0.68
Random Forest	0.67	0.61	0.64
MLP	0.62	0.57	0.59
SVM	0.67	0.70	0.68

Jadual 2 menunjukkan bahawa model SVM dan Catboost mempunyai nilai F1-Score yang sama bagi Class 0. Walau bagaimanapun, model Catboost turut dipilih sebagai model terbaik kerana ia menunjukkan nilai F1-score lebih tinggi bagi class (F1-score = 0.68) berbanding SVM (F1-score = 0.63).

Jadual 3 Bandingan Model Baseline, 6M dan 12M CKD (Class 1)

Model	Precision	Sensitiviti	F1-score
Baseline	0.67	0.83	0.74
6M	0.75	0.75	0.75
12M	0.75	0.75	0.75

Jadual 3 menunjukkan bahawa prestasi model Catboost CKD meningkat dengan penambahan ciri yang berkait dengan masa, tetapi peningkatan prestasi ini tidak drastik. Ini kerana fitur sasaran CKD mempunyai peramal yang kuat pada data Baseline. Walaupun prestasi model

tidak melonjak naik, model 6M dan 12M lebih stabil semasa latihan dan pengesahan (validation) berbanding model Baseline.

Jadual 4 Bandingan Model *Baseline*, 6M dan 12M CR 12 MTH PRED 10 (Class 0)

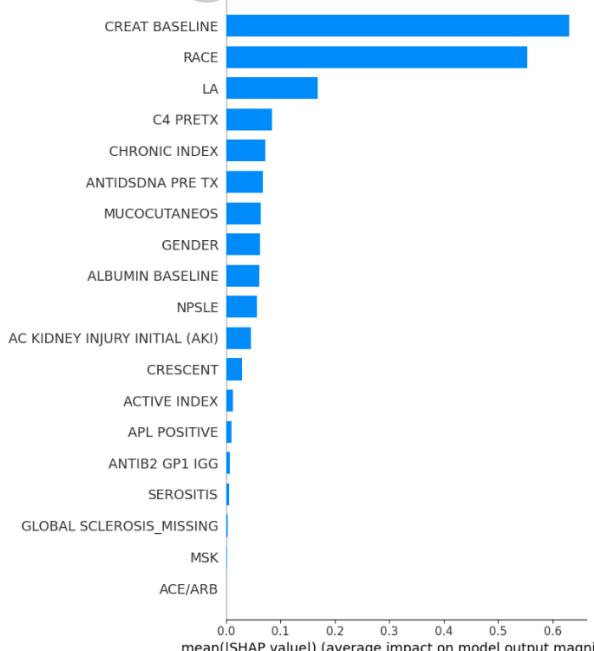
Model	Precision	Sensitiviti	F1-score
Baseline	0.71	0.65	0.68
6M	0.71	0.74	0.72
12M	0.81	0.74	0.77

Jadual 4 menunjukkan bahawa prestasi model remisi lewat melonjak naik dengan penambahan ciri atau fitur yang berkait dengan masa. Hal ini kerana ciri sasaran 12M CR 12 MTH PRED 10 tidak mempunyai peramal yang kuat seperti CKD bagi data Baseline.

4.2 Hasil Interpretasi SHAP

Analisis menggunakan SHapley Additive Explanations (SHAP) terhadap model CatBoost memberikan gambaran tentang ciri-ciri yang paling mempengaruhi keputusan ramalan bagi kedua-dua sasaran.

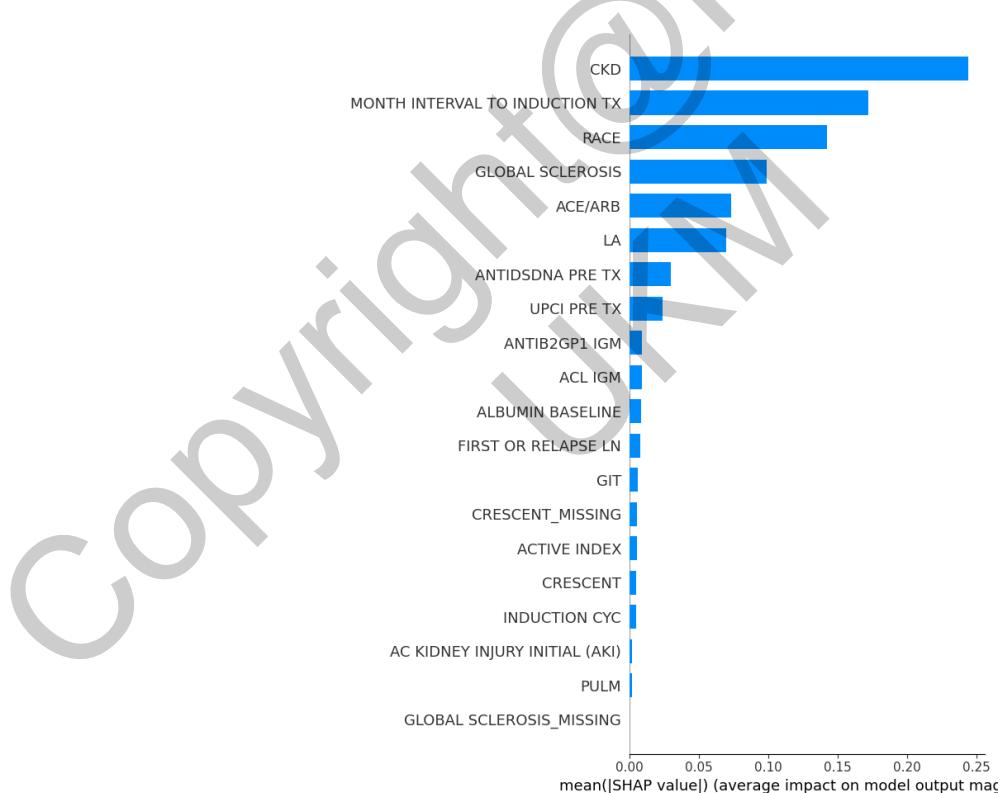
1. Model CKD



Rajah 5 Plot Bar-Shap (CKD)

Rajah 5 untuk model CKD menunjukkan bahawa CREAT BASELINE (kreatinin baseline) merupakan ciri yang mempunyai pengaruh terbesar terhadap ramalan risiko CKD. Ini adalah selari dengan pemahaman klinikal bahawa tahap kreatinin awal mencerminkan fungsi buah pinggang pesakit. RACE muncul sebagai faktor kedua paling penting, menunjukkan adanya perbezaan etnik dalam risiko CKD dalam kalangan pesakit Malaysia. Ciri LA (Lupus Anticoagulant) turut memberi sumbangan besar, diikuti oleh C4 PRETX dan CHRONIC INDEX, yang berkaitan dengan tahap kerosakan tisu pada diagnosis. Faktor lain seperti ANTIDSDNA PRE TX, ALBUMIN BASELINE, dan manifestasi klinikal seperti MUCUTANEOUS atau NPSLE turut mempengaruhi keputusan model, walaupun dengan kesan yang lebih rendah.

2. Model CR 12 MTH PRED 10



Rajah 6 Plot Bar-Shap (CR 12 MTH PRED 10)

Bagi model kelewatian remisi, graf SHAP menunjukkan bahawa ciri CKD merupakan ciri paling dominan yang mempengaruhi ramalan, diikuti oleh MONTH INTERVAL TO INDUCTION TX yang menunjukkan kepentingan masa permulaan rawatan. Faktor etnik (RACE) sekali lagi memainkan peranan penting dalam model ini, selari dengan dapatan kajian Dr. Syahrul Sazliyana mengenai perbezaan etnik

dalam tindak balas rawatan. GLOBAL SCLEROSIS dan penggunaan ACE/ARB turut memberikan kesan ketara terhadap ramalan. Ciri imunologi seperti LA, ANTIDSDNA PRE TX, dan UPCI PRE TX juga mempengaruhi keputusan, walaupun dengan magnitud yang lebih sederhana.

5.0 KESIMPULAN

Projek ini telah berjaya membangunkan SLECare, sebuah sistem ramalan berasaskan pembelajaran mesin yang bertujuan untuk mengklasifikasikan risiko penyakit buah pinggang kronik (CKD) dan kelewatan remisi dalam kalangan pesakit Lupus Nephritis (LN) di Malaysia melalui penggunaan dataset kohort pesakit HCTM, kaedah pra-pemprosesan yang teliti, serta pemilihan ciri yang konsisten, model yang dibangunkan telah menunjukkan prestasi yang memuaskan.

Hasil penilaian menunjukkan bahawa model CatBoost memberikan prestasi paling seimbang berbanding model lain, dengan nilai F1-score yang konsisten tinggi bagi kedua-dua sasaran. Walaupun model 6M dan 12M memperlihatkan sedikit peningkatan prestasi dengan penambahan ciri susulan, model Baseline CatBoost dipilih sebagai model akhir kerana prestasinya yang terbaik, lebih praktikal, dan bersesuaian untuk kegunaan klinikal sebenar.

Analisis SHAP mengesahkan bahawa model ini membuat keputusan selaras dengan pengetahuan klinikal, di mana ciri seperti kreatinin baseline, faktor etnik, dan beberapa penanda imunologi memainkan peranan dominan dalam ramalan. Keupayaan ini meningkatkan kebolehpercayaan SLECare sebagai alat sokongan keputusan untuk pakar klinik.

Secara keseluruhannya, SLECare membuktikan bahawa penggunaan pembelajaran mesin dapat meningkatkan ketepatan ramalan klinikal berbanding pendekatan konvensional. Dengan reka bentuk antaramuka mesra pengguna, sistem ini berpotensi untuk digunakan dalam amalan harian bagi membantu pakar perubatan membuat keputusan rawatan yang lebih tepat dan proaktif, sekali gus meningkatkan hasil kesihatan pesakit LN di Malaysia.

6.0 PENGHARGAAN

Alhamdulillah, segala Puji dipanjangkan kepada Allah SWT atas limpahan rahmat, hidayah dan kekuatan yang diberikan sepanjang perjalanan penyelidikan ini. Saya juga ingin merakamkan setinggi-tinggi penghargaan kepada Prof. Madya Dr. Shahnorbanun Binti Sahran, selaku penyelia projek ini, atas segala tunjuk ajar, bimbingan, serta sokongan yang telah diberikan sepanjang tempoh pelaksanaan projek. Panduan dan nasihat beliau amat bernilai dalam memastikan kejayaan projek ini.

Ucapan terima kasih juga ditujukan kepada Dr. Syahrul Sazliyana Shaharir, selaku pakar klinikal dan pemilik data kajian, atas sumbangan ilmu, bimbingan dalam pemahaman konteks klinikal, serta pengesahan dalam proses pra-pemprosesan data.

Seterusnya, penghargaan diberikan kepada pihak Fakulti Teknologi & Sains Maklumat (FTSM) dan Hospital Canselor Tuanku Muhriz (HCTM) atas kemudahan penyelidikan yang disediakan. Tidak lupa juga, ribuan terima kasih kepada keluarga, rakan-rakan, dan semua pihak yang telah memberikan sokongan moral serta bantuan teknikal sepanjang perjalanan projek ini.

Semoga segala jasa dan sokongan yang telah diberikan mendapat ganjaran yang setimpal.

RUJUKAN

AlShareedah, A., et al. (2023). Machine Learning-Based Diagnosis of Systemic Lupus Erythematosus: A Comparative Study on Autoimmune Disease Prediction. *Journal of Autoimmune Research*, 15(3), 112–124.

Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (1999). CRISP-DM 1.0: Step-by-Step Data Mining Guide. SPSS Inc.

Syahrul Sazliyana, S., Mohd, R., Kamaruzaman, L., Wan Daud, W. R., Abu Shamsi, Y., Lim, K. Y., Mustafar, R., & Abdul Gafor, A. H. (2021). Ethnic Disparities in Renal Response Among Proliferative Lupus Nephritis Patients: A Single-Centre Study from Malaysia. *Lupus Science & Medicine*, 8(1), e000500.

Muhammad Izzul Islam bin Faisal (A200363)

prof. Madya dr. Shahnorbanun binti Sahran

Fakulti Teknologi & Sains Maklumat

Universiti Kebangsaan Malaysia