




AI IN 7 DAYS

DAY 3 HANDBOOK - SELF-STUDY GUIDE

How Machine Learning Actually Works - Machine Learning එක ඇත්තටම වැඩ කරන්නේ කොහොමද?

6 VIDEOS	60 MINUTES	1 NOTEBOOK	1 EXPERIMENT RECORD
-------------	---------------	---------------	------------------------



© 2026 AI PANTHIYA

අද ඔබ ඉගෙනගන්නේ


- Machine Learning lifecycle එක මුල සිට අග දක්වා
- Learning types සහ algorithm families
- Prediction → Target → Loss → Update training loop
- Training, Validation, Cross-validation, Test සහ Inference
- Google Colab notebook එකක පළමු ML experiment එක
- Overfitting, Generalization, Interpretability සහ Reproducibility



Day 3 Main Task: Google Colab notebook එක run කර, එක controlled change එකක් compare කර, GitHub එකට සුදානම් **ML Experiment Record** එකක් සකස් කිරීම.

HOW TO USE THIS HANDBOOK

Day 3 එකේ goal එක highest score එකක් හොයන එක නොවෙයි. නිවැරදි experiment එකක් design කිරීම, models සාධාරණව compare කිරීම, result එක reproduce කළ හැකිව record කිරීම සහ limitations පැහැදිලිව කියාදීමයි.



Day 3 Learning Outcomes

- ML lifecycle එක නිවැරදි order එකට තැබීම
- Algorithm, fitted model, parameter සහ hyperparameter වෙන් කිරීම
- Regression, classification සහ අනෙක් learning types හඳුනාගැනීම
- Train / Validation / Test / Inference roles වෙන් කිරීම
- Baseline, tuning, threshold සහ leakage concepts තේරුම්ගැනීම
- fit(), predict(), Pipeline, Git, GitHub සහ README purpose පැහැදිලි කිරීම
- Underfitting, Overfitting, Generalization සහ interpretation limitations තේරුම්ගැනීම

Today's 6 Video Map

1. The Complete Machine Learning Lifecycle
2. Learning Types and the Algorithm Family Map
3. How Training Changes a Model
4. Validation, Cross-Validation and Model Selection
5. Your First ML Notebook and Modern Builder Toolkit
6. Generalization, Interpretation and the ML Experiment Record

Scientific cautions: Algorithm එක සහ fitted model එක එකම දේ නොවේ. Training score එක ඉහළ වුණා කියලා future data වලින් හොඳයි කියලා තහවුරු වෙන්නේ නැහැ. Test set එක tuning සඳහා repeatedly භාවිත කළොත් fair final test එකක් නොවේ. SHAP/LIME causality හෝ fairness prove කරන්නේ නැහැ.

The Complete Machine Learning Lifecycle

Prediction එක final output එකක්. ඒකට කලින් දිග workflow එකක් තියෙනවා.



Problem Definition First

Algorithm එක තෝරන්න කලින් මේ ප්‍රශ්න අහන්න:

- User කවුද?
- Decision එක මොකක්ද?
- Success metric එක මොකක්ද?
- Wrong prediction එකේ harm එක මොකක්ද?
- AI අවශ්‍යමද, නැත්නම් simpler rule එකක් ඇතිද?

Data Split Roles

Training: parameters ඉගෙනගන්න.

Validation: model/settings compare කර select කරන්න.

Test: development ඉවර වුණාට පස්සේ final fair evaluation.

Rule: preprocessing rules Training Data එකෙන් fit කරලා Validation/Test data වලට apply කරන්න.

Mini Task: "Student pass/fail prediction" problem එකකට user, decision, metric, harm සහ baseline එක ලියන්න.

Learning Types and the Algorithm Family Map

Problem එකට ගැළපෙන learning type එක තෝරන්නේ output එක සහ available learning signal එක බලලා.

Supervised Learning

Labeled data. Known target/label ඇත.

Regression: continuous number predict කිරීම.

Classification: category predict කිරීම - Binary, Multiclass, Multilabel.

Unsupervised Learning

Correct target එක කලින් දීලා නැහැ.

Clustering, dimensionality reduction, anomaly detection වගේ tasks.

Semi-supervised

Labeled data ටිකක් + unlabeled data ගොඩක්.

Self-supervised

Learning signal data එකෙන්ම හදනවා.

Foundation model pretraining සඳහා වැදගත්.

Active Learning

Model එකට difficult/informative examples human කෙනෙකුගෙන් label කරගන්නවා.

Online Learning

අලුත් data ලැබෙන තරමට model එක update කරන approach එක.

Reinforcement Learning

Agent → State → Action → Reward/Penalty → Policy learning.

© 2026 AI PANTHIYA
RIGHT PROTECTED • ALL RIGHTS RESERVED

Common Supervised Algorithm Families

Linear Regression

Logistic Regression

Decision Tree

Random Forest

Gradient Boosting

SVM


kNN

Naive Bayes

Selection rule: Problem First → Learning Type Second → Algorithm Third. Algorithm name එකෙන් project එක පටන්ගන්න එපා.

How Training Changes a Model

Training කියන්නේ model එක මිනිසෙක් වගේ “තේරුම්ගන්නවා” කියන එක නොවෙයි. Data වලින් parameters සකස් කරන process එකයි.



Parameter vs Hyperparameter

Parameter: training අතරතුර model එක data වලින් ඉගෙනගන්න value.
Example: weight, coefficient, intercept.

Hyperparameter: training කලින් අපි තෝරන setting. Example: learning rate, tree depth, number of neighbours, regularization strength.

Loss and Gradient

Loss: prediction එක target එකෙන් කොච්චර වැරදිද කියලා training අතරතුර මැනගන්න function එක.

Gradient: parameter වෙනස් කළොත් loss කුමන දිශාවට වෙනස් වෙනවද කියන information.

Gradient Descent: loss අඩු වන දිශාවට parameters update කරන approach එකක්. හැම algorithm එකක්ම මේක භාවිත කරන්නේ නැහැ.

Simple Manual Example

Study Hours = 6
Target Score = 48

Weight = 5
Prediction = 30
Absolute Error = 18

Weight = 7
Prediction = 42
Absolute Error = 6

Weight = 9
Prediction = 54
Absolute Error = 6

එක example එකක් විතරක් බලලා “best weight” තීරණය කරන්න බැහැ. Real training එක training examples ගොඩක් මත overall loss අඩු කරන parameter values හොයනවා.

Also know: Batch = examples කුඩා කොටසක්. Iteration = එක update step එකක්. Epoch = dataset එක සම්පූර්ණයෙන් එක වතාවක් process කිරීම.

Validation, Cross-Validation and Model Selection

Training score එක alone future performance කියන්නේ නැහැ. Fair comparison design එකක් අවශ්‍යයි.

Training Set

Model parameters සහ preprocessing rules fit කරන්න.

Validation Set

Algorithm, hyperparameters, threshold වගේ development decisions සඳහා.

Test Set

All decisions අවසන් වුණාට පස්සේ final fair check.

Cross-validation

Training data folds කිහිපයකට බෙදා validation fold එක rotate කරමින් model එක particular split එකකට පමණක් හොඳේ කියලා බලනවා.

Final Test Set: තවමත් untouched තබාගන්න.

Split Strategy Matters

Stratified: class proportions preserve කරන්න.

Group-aware: එකම person/group records Train සහ Test දෙකට බෙදී නොයන්න.

Time-aware: future prediction problems වල chronological order preserve කරන්න.

Hyperparameter Search

Grid Search: predefined combinations සියල්ල try කරනවා.

Random Search: search space එකෙන් combinations randomly sample කරනවා.

වැඩි combinations try කලා කියලා experiment automatically better නොවේ.

Decision Threshold

Classification probability එක category එකකට convert කරන cutoff එක.

Threshold එක business risk අනුව tune කරන්න පුළුවන් - Validation Data මත.

Leakage Warning: Full dataset මත scaler fit කරලා පස්සේ split කිරීම, prediction time එකේ available නොවන feature භාවිත කිරීම, Test Set එක repeatedly tuning සඳහා භාවිත කිරීම - මේවා fair evaluation එකට හානි කරයි.

Your First ML Notebook and Modern Builder Toolkit

මෙය full Python course එකක් නොවේ. Code එක workflow එකේ මොන step එකද කරන්නේ කියලා තේරුම්ගන්න.



Notebook Concepts

Google Colab: browser එකෙන් Python notebook run කරන්න.

X: feature matrix.

y: target vector.

random_state=42: same split නැවත ලබාගන්න. 42ට special scientific meaning එකක් නැහැ.

Pipeline: preprocessing + model ordered workflow එකක් ලෙස එකට තබන structure එක.

Teaching Dataset Caution

Scikit-learn built-in Breast Cancer Wisconsin Diagnostic dataset එක numerical binary classification teaching example එකක් ලෙස භාවිත කරනවා.

Important: මේ notebook එක clinical diagnosis product එකක් නොවේ.

Controlled Change Experiment

Same dataset, same split, same pipeline, same metric තබාගෙන **Logistic Regression C** value එක 1.0 සිට 0.1 දක්වා එක setting එකක් පමණක් වෙනස් කර result compare කරන්න.

Learning exercise එකේ result compare කරන්න පුළුවන්. Real model selection එකක Test Set result repeatedly බලලා tuning කරන්න එපා.

Git vs GitHub

Git: project file changes track කරන version-control system.

GitHub: Git repositories online store/share/collaborate කරන platform.

Repository Basics

Repository: project files + version history.

Commit: changes වල saved snapshot එකක්.

README: project purpose, dataset, workflow, run steps, results, limitations සහ disclaimer.

Generalization, Interpretation and the ML Experiment Record

Model score එක ලැබුණාට පස්සේ වැදගත්ම ප්‍රශ්නය: new data වලටත් model එක සාධාරණව වැඩ කරනවද?

Underfitting

Model එක වැදගත් patterns ප්‍රමාණවත් ලෙස ඉගෙනගෙන නැහැ.

Train Low + Validation Low.

Overfitting

Training Data noise/detail වැඩිපුර fit වෙලා new data performance අඩුවෙයි.

Train Very High + Validation/Test Lower.

Generalization

Training වෙලාවේ නොදුටු, target environment එකට සමාන new data වලටත් හොඳින් වැඩ කිරීම.

Bias - Variance Intuition

High Bias: model ඉතා සරල - underfitting වෙන්න පුළුවන්.

High Variance: training data ටිකක් වෙනස් වුණත් behaviour ගොඩක් වෙනස් - overfitting වෙන්න පුළුවන්.

Learning Curves

Training සහ Validation performance එක data amount/training progress සමඟ වෙනස් වෙන්නේ කොහොමද කියලා බලන graph එකක්.

Learning curve එක clue එකක් - alone final conclusion එකක් නෙවේ.

Interpretability

Global: model එක සාමාන්‍යයෙන් decisions ගන්නේ කොහොමද?

Local: particular prediction එකකට features මොනවාද බලපෑවේ?

Feature Importance, SHAP, LIME වගේ methods clues දෙයි.

Limits

Explainability method එක model relationship explain කළත් **causality, absolute truth හෝ fairness** prove කරන්නේ නැහැ.

Reproducibility: Dataset/version, split, random_state, preprocessing, model, hyperparameters, library versions, metric, results, code commit සහ environment information record කරන්න.

DAY 3 - ML EXPERIMENT RECORD WORKSHEET

Notebook එක run කළාට පස්සේ මේ worksheet එක පුරවන්න. Experiment එක repeat කරන්න සහ explain කරන්න පුළුවන් evidence එකක් හදන එක අරමුණයි.

1. Problem

Prediction task, user, decision

2. Dataset

Name, source/library, target meaning

3. Task Type

Binary classification and why

4. Algorithm Family

Baseline + Logistic Regression family

5. Features X / Target y

What are X and y?

6. Split / Validation

Train-test, stratification, random_state

7. Baseline

Method + score

8. Pipeline

Preprocessing + estimator

9. Original Result

Held-out metric + example

10. Controlled Change

Exactly one hyperparameter change

11. New Result

Result under same split

12. Error Notes

Observed errors / missing evidence

13. Interpretation

Improved, declined or similar?

14. Explainability Note

Feature importance / SHAP / LIME limits

15. Limitations

Important uncertainties

16. Reproducibility

Library version, environment, commit

17. Repository Evidence

README, notebook, result, record

18. Conclusion

What is justified / not justified?

19. Next Experiment

One controlled follow-up change:

Responsible conclusion: Teaching experiment එකක් successful run කළා කියලා clinical safety, causality, fairness හෝ production readiness prove වෙන්නේ නෑහැ.

DAY 3 QUICK SELF-CHECK

Quiz Questions

1. ML lifecycle එක order එකට ලියන්න.
2. Algorithm සහ fitted model අතර වෙනස මොකක්ද?
3. Parameter vs hyperparameter?
4. Regression, binary, multiclass, multilabel examples දෙන්න.
5. Semi-supervised vs Self-supervised?
6. Training, Validation, Test සහ Inference roles?
7. Cross-validation භාවිත කරන්නේ ඇයි?
8. Grid Search vs Random Search?
9. Data Leakage example එකක් දෙන්න.
10. fit() සහ predict() අතර වෙනස?
11. Underfitting vs Overfitting?
12. SHAP/LIME prove නොකරන දේ මොනවාද?

Answer Hints

- Problem → Data → Split → Baseline → Train → Validate → Test → Error Analysis → Deploy → Monitor.
- Algorithm = training procedure; fitted model = learned parameters සහිත prediction system.
- Parameter data වලින් learn; hyperparameter අපි කලින් තෝරන setting.
- Regression = number; classification = category.
- Semi = few labels + many unlabeled; Self = signal data එකෙන්ම.
- Validation development decisions; Test final fair check.
- CV එක one split dependency අඩු කරන්න උදව් කරයි.
- Grid all predefined combinations; Random sample combinations.
- Future information feature එකක් ලෙස training data තුළ තිබීම.
- fit learns; predict uses fitted model.
- Underfit too simple / insufficient learning; Overfit training data too closely.
- Causality, absolute truth, fairness prove නොකරයි.



Sampath Bandaranayake
Instructor - AI Panthiya

Need guided learning?

Online Zoom Classes - Contact Us on WhatsApp

WhatsApp: +81 70 2313 1981

MSc - AI and Digital Innovation (Final Year) - Tokyo International University, Japan

MBA - Cardiff Metropolitan University, UK

BSc - Applied Sciences, Sri Lanka

LinkedIn: <https://www.linkedin.com/in/sampathbandara/>

Website: <https://aipanthiya.com/>

Next step: **Day 4 - Clustering, Anomaly Detection, Recommendation Systems, Forecasting and Model Evaluation Metrics**