



DIGITAL
TALENT
SCHOLARSHIP



THEMATIC ACADEMY

Data Scientist: Artificial Intelligence untuk Dosen dan Instruktur

Pertemuan #3 : Metodologi Data Science



KOMINFO



#JADIJAGOANDIGITAL

Badan Penelitian dan Pengembangan Sumber Daya Manusia

Deskripsi Pelatihan

Tujuan utama dari modul pelatihan ini adalah untuk membahas metodologi data science secara umum untuk mengembangkan suatu aplikasi AI dengan menjelaskan langkah-langkah utama yang diperlukan untuk menyelesaikan suatu masalah organisasi/ bisnis dengan melakukan tugas-tugas yang umumnya terkait dengan data science.

Capaian Pembelajaran

Pada topik ini, kita akan mempelajari:


- Metodologi *Data Science*
- Langkah-langkah utama dalam metodologi data science

Agenda

- **Mengapa Metodologi diperlukan**
 - Mengapa Mayoritas Projek AI Gagal
- **Berbagai Metodologi Data Science**
 - Tak semua metodologi sama lengkap
- **Langkah Pengembangan**
 - Dari Masalah Bisnis menjadi Aplikasi AI

Mengapa Metodologi diperlukan

Sistem AI berbasis (Big) Data




Data

Menjadi

Sistem Intelijen
(berbasis Pengetahuan)

Sistem AI berbasis (Big) Data dikembangkan dalam 2 tahap

1. Pengembangan (Pelatihan)



2. Penggunaan



Tujuan Tugas/ Task yang Biasa Dikembangkan

01

Descriptive:

Menjelaskan keadaan bisnis saat ini melalui data historis.

02

Diagnostic:

Menjelaskan mengapa suatu masalah terjadi dengan melihat data historis.

03

Predictive:

Memproyeksikan atau memprediksi hasil masa depan berdasarkan data historis.

04

Prescriptive:

Menggunakan hasil analitik prediktif dan pengetahuan lain dengan menyarankan upaya terbaik di masa depan.

Jenis Task yang Dikembangkan

Regression /
Estimation

Classification

Clustering

Association

Anomaly
Detection

Sequence
Mining

Recommendation
Systems

Mayoritas Proyek Pengembangan AI/DS Gagal

GARTNER
ESTIMATED

85%

of big data projects fail (2017). The initial estimation was 60% (GARTNER 2016)

THROUGH 2020

80%

of AI projects will remain alchemy, run by wizards whose talents will not scale in the organization. (GARTNER 2018)

THROUGH 2022

20%

of analytic insights will deliver business outcomes. (GARTNER 2018)

EXECUTIVE
SURVEY

77%

respondents say that “business adoption” of big data and AI initiatives continues to represent a challenge for their organizations (NEWVANTAGE PARTNERS 2019)

<https://www.slideshare.net/PMI-Montreal/symposium-2019-gestion-de-projet-en-intelligence-artificielle>

Mayoritas Proyek Pengembangan AI/DS Gagal

- **PROBLEM** yang akan diselesaikan
 - Tidak Jelas; Problem salah; Over promising
- **DATA**
 - Tidak cukup (jumlah) atau tidak tepat (variabel)
 - Kualitas, tidak mencukupi
 - Tidak mengerti arti (semantic) data
 - Berbagai bias, hubungan antar variabel tidak dipikirkan (sampling, Fairness)
- **MODEL** yang dikembangkan
 - Terlalu kompleks; Tidak dimengerti
 - Metriks pengukuran tidak tepat
- **ALGORITHMS**
 - Terlalu sophisticated; Tidak dimengerti secara teknis
 - Tidak tepat
- **SUMBER DAYA MANUSIA**
 - One man show
 - Dukungan pemangku kepentingan kunci kurang

Perlu Metodologi Pengembangan

Pengembangan Sistem AI berdasar data

≠

Data + Machine Learning (ML) Algorithms

Metodologi Pengembangan

Metoda iterative yang dipakai untuk menyelesaikan masalah dengan menggunakan data dan data science melalui urutan langkah yang ditentukan


Berbagai Metodologi Data Science

Jenis Metodologi

- Metodologi kegiatan Teknis
- Metodologi kegiatan bisnis (dan teknis)

Metodologi Teknis: Kegiatan DS/AI dianggap Kegiatan Teknikal


- Knowledge Discovery and Data Mining



<https://www.kdnuggets.com/gspubs/ai-mag-kdd-overview-1996-Fayyad.pdf>

Metodologi Teknis: Kegiatan DS/AI dianggap Kegiatan Teknikal


- SEMMA dari SAS Institute



<https://documentation.sas.com/?docsetId=emref&docsetTarget=n061bzurmej4j3n1jn8bbijm1a2.htm&docsetVersion=14.3&locale=en>

Metodologi Lengkap: Kegiatan DS/AI dianggap Kegiatan Bisnis: Masalah Bisnis menjadi Masalah DS/AI


- CRISP-DM



<https://documentation.sas.com/?docsetId=emref&docsetTarget=n061bzurmej4j3n1jnjbijm1a2.htm&docsetVersion=14.3&locale=en>

Metodologi Lengkap: Kegiatan DS/AI dianggap Kegiatan Bisnis: Masalah Bisnis menjadi Masalah DS/AI


- IBM Data Science Methodology



<https://www.slideshare.net/JohnBRollinsPhD/foundational-methodology-for-data-science>

Metodologi Lengkap: Kegiatan DS/AI dianggap Kegiatan Bisnis: Masalah Bisnis menjadi Masalah DS/AI


- Microsoft's Team Data Science Process



<https://docs.microsoft.com/en-us/azure/machine-learning/team-data-science-process/overview>

Metodologi Lengkap: Kegiatan DS/AI dianggap Kegiatan Bisnis: Masalah Bisnis menjadi Masalah DS/AI

- Domino DataLab Methodology



Bagaimana di Indonesia?

Standard Kompetensi Kerja Nasional: KepMen Ketenagakerjaan No 299 thn 2020



MENTERI KETENAGAKERJAAN
REPUBLIK INDONESIA

KEPUTUSAN MENTERI KETENAGAKERJAAN
REPUBLIK INDONESIA
NOMOR 299 TAHUN 2020
TENTANG

PENETAPAN STANDAR KOMPETENSI KERJA NASIONAL INDONESIA
KATEGORI INFORMASI DAN KOMUNIKASI GOLONGAN POKOK AKTIVITAS
PEMROGRAMAN, KONSULTASI KOMPUTER DAN KEGIATAN YANG
BERHUBUNGAN DENGAN ITU (YBDI) BIDANG KEAHLIAN *ARTIFICIAL
INTELLIGENCE* SUBBIDANG *DATA SCIENCE*

| TUJUAN UTAMA | FUNGSI KUNCI | FUNGSI UTAMA | FUNGSI DASAR |
|---|--|-------------------------------|--|
| Menemukan pengetahuan, <i>insight</i> atau pola yang bermanfaat dari data untuk berbagai keperluan (orang mengambil keputusan atau sistem memproses lebih lanjut) | Menganalisis Kebutuhan (Requirements) Organisasi | <i>Business Understanding</i> | <ol style="list-style-type: none"> Menentukan objektif bisnis Menentukan tujuan teknis Membuat rencana proyek |
| | | <i>Data Understanding</i> | <ol style="list-style-type: none"> Mengumpulkan data Menelaah data Memvalidasi data |
| | Mengembangkan model | <i>Data Preparation</i> | <ol style="list-style-type: none"> Memilah data Membersihkan data Mengkonstruksi data Menentukan Label Data Mengintegrasikan data |
| | | <i>Modeling</i> | <ol style="list-style-type: none"> Membangun skenario pengujian Membangun model |
| | | <i>Model Evaluation</i> | <ol style="list-style-type: none"> Mengevaluasi hasil pemodelan Melakukan review proses pemodelan |
| | Menggunakan model yang dihasilkan | <i>Deployment</i> | <ol style="list-style-type: none"> Membuat rencana deployment model Melakukan deployment model Melakukan rencana pemeliharaan Melakukan pemeliharaan |
| | | <i>Evaluation</i> | <ol style="list-style-type: none"> Melakukan review proyek Membuat laporan akhir proyek |

Tim Pengembang: Kegiatan Bersama

01

Data Scientist

Mengembangkan model terbaik dari data untuk menjawab permasalahan bisnis

02

Data Engineer

Menyiapkan (big) data untuk diolah/ dimodelkan

03

Data Analyst

Menganalisis/ mencari insight dari data (dan menampilkannya dalam dashboard)

04

Project/ Product Manager

Mengelola projek/ produk berbasis data.

05

Domain Expert

Memberi arahan tentang domain permasalahan

06

IT People

Menyiapkan infrastruktur IT (terutama deployment)

Langkah Pengembangan

1. Business Understanding: Menentukan Masalah Bisnis

Kasus: Kegagalan Kredit



Problem:

Bagaimana menurunkan NPL suatu bank

Pertanyaan:


Bagaimana memperbaiki perhitungan Credit score

Measurable outcomes:

% Penurunan kredit gagal bayar

1. Business Understanding: Menentukan Tugas Analytics

Apa Tugas Analitiks yang perlu diselesaikan untuk menjawab permasalahan bisnis?




A. Regresi/Estimasi: Memprediksi nilai kontinyu dari kasus

- Prediksi harga rumah berdasar karakteristik tertentu
- Prediksi harga saham besok

1. Business Understanding: Menentukan Tugas Analytics

Apa Tugas Analitiks yang perlu diselesaikan untuk menjawab permasalahan bisnis?



B. Klasifikasi: Memprediksi kelas/ kategori dari kasus

- Prediksi kolektibilitas suatu pinjaman
- Prediksi kebangkrutan suatu perusahaan di tahun depan

1. Business Understanding: Menentukan Tugas Analytics

Apa Tugas Analitiks yang perlu diselesaikan untuk menjawab permasalahan bisnis?



C. Klustering: Mengelompokkan kasus berdasar kemiripan

- Segmentasi nasabah perbankan
- Pengelompokkan pasien yang mirip kasusnya

1. Business Understanding: Menentukan Tugas Analytics

Apa Tugas Analitiks yang perlu diselesaikan untuk menjawab permasalahan bisnis?



D. Asosiasi: Memprediksi kumpulan item/ kejadian yang biasa terjadi bersama

- Mencari barang jualan yang biasa dibeli bersama
- Menyusun portofolio saham

1. Business Understanding: Menentukan Tugas Analytics

A. Apa Tugas Analitiks yang perlu diselesaikan untuk menjawab permasalahan bisnis?



E. Anomali Detection: Menemukan kasus abnormal/
tidak biasa terjadi

- Pendeteksian transaksi ilegal penggunaan kartu kredit
- Pendeteksian penerobosan jaringan

1. Business Understanding: Menentukan Tugas Analytics

Apa Tugas Analitiks yang perlu diselesaikan untuk menjawab permasalahan bisnis?



F. Sequence Mining: Memprediksi apa yang akan terjadi dari keadaan saat ini

- Prediksi apakah nasabah akan berhenti berlangganan
- Menentukan alur pada transaksi e-commerce

1. Business Understanding: Menentukan Tugas Analytics

Apa Tugas Analitiks yang perlu diselesaikan untuk menjawab permasalahan bisnis?



G. Rekomendasi: Memberikan rekomendasi pengguna berdasar asosiasi preferensi dengan pengguna lain yang memiliki 'taste' yang sama

- Rekomendasi film untuk ditonton
- Rekomendasi saham untuk dibeli

1. Business Understanding: Menentukan Tugas Analytics

Pengukuran Performansi tergantung Jenis Task Analytics

Metriks Performansi: Ukuran keberhasilan dari proses data science yang dilakukan

Contoh: Root Mean Squared Error (RMSE)

R-Square

Jackard Index

Log-loss

Precision

Recall

F1-Score

1. Business Understanding: Menentukan Tugas Analytics

Kasus: Kegagalan Kredit

Apa Tugas Analitiks yang perlu diselesaikan untuk menjawab permasalahan bisnis tersebut?



Problem:

Bagaimana menurunkan NPL suatu bank

Pertanyaan:

Bagaimana memperbaiki perhitungan Credit score

Tugas Analitik:

Klasifikasi

Performance Metrics:

F1-Score

1. Business Understanding: Menentukan Kebutuhan Data

Data apa yang diperlukan?
Dari mana bisa diperoleh?

Struktur Data: Bagaimana deskripsi data (atribut) yang diperlukan

Jumlah Data: Berapa banyak (record) data yang diperlukan

Sumber Data: Darimana data bisa diperoleh? Apakah sudah tersedia?

- Internal: Sistem Informasi/ ERP, Excel, dokumen
- Eksternal: Web API, Web Scraping
- Dataset via public data
- Dataset via open data

1. Business Understanding: Merencanakan Manajemen Proyek

Bagaimana rencana pelaksanaan proyeknya?

Cost Benefit Analysis: Apakah menguntungkan untuk melakukannya?

Situation Assessment: Analisa keadaan organisasi

Project Plan: Scope (WBS), Time, Schedule, Tim Pengembang

2. Data Understanding : Mengenali/ mendalami data yang dimiliki

01

Mengumpulkan Data

Mengumpulkan Data yang Diperlukan

Jumlah Data (Baris dan Kolom)
Deskripsi data

02

Menelaah data

Menganalisa data secara eksploratif

Karakteristik atribut/ fitur
Keterkaitan antar data

03

Memvalidasi Data

Menilai kesesuaian kualitas data dengan masalah yang akan dipecahkan

Kualitas Data

Python Libraries

Scientific Computing

Visualization

Algorithmic

Pandas (Data structure and tools)

Numpy (Array and matrices)

Scipy (Integrals, solving differential equations, optimization)

Matplotlib (plots & graphs, most popular)

Seaborn (plots : heat maps, time series, violin plots)


Scikit-learn (Machine learning : regression, classification, etc)

Statsmodels (Explore data, estimate statistical models, perform statistical test)

2. Data Understanding :

Mengapa Perlu Mengenali/ mendalami data yang dimiliki

- The United States armed forces faced a dilemma during the war, because returning bomber planes were riddled with bullet holes and they needed better ways to protect them
- “Where should they put it?”
- When they plotted out the damage these planes were incurring, it was spread out, but largely concentrated around the tail, body and wings.
- Should they upgrade these sections?



2. Data Understanding : Mengumpulkan Data

Mengumpulkan Data yang Diperlukan

Jumlah Data: Berapa banyak yang dapat diperoleh



Deskripsi Data: Penjelasan arti atribut/ fitur

2. Data Understanding : Menelaah Data

Menganalisa data secara eksploratif (EDA)

Karakteristik Atribut: Deskripsi data (atribut) yang diperoleh

Keterkaitan antar Data: Analisis statistik korelasi, Anova, Chi-Squared,...



Copyright © MachineLearningMastery.com

2. Data Understanding : Memvalidasi Data

Menilai kesesuaian kualitas data dengan masalah yang akan dipecahkan

Laporan Kualitas Data:

- Ukuran Data (Atribut/ fitur dan Jumlah record)
- Deskripsi statistical atribut
- Relasi antar atribut (dan label)
- Visualisasi data

3. Data Preparation :

Memperbaiki kualitas data untuk Pemodelan

01

Memilih dan memilah data

Memilih data yang akan dipergunakan

Rekord terpakai
Atribut terpakai

02

Membersihkan Data

Meminimalkan noise (tidak lengkap, salah)

Data lengkap
Data yang diperbaiki
Data Pecilan

03

Mengkonstruksi data

Menambahkan fitur dan transformasi data

Fitur tambahan (Feature Engineering)
Transformasi data (standardisasi, transformasi)

04

Integrasi Data

Menggabungkan data

Gabungan data

4. Modeling : Mengembangkan Model (Pengetahuan)

01

Membangun Skenario Pemodelan

Membuat strategi pencarian model terbaik

Pemilihan Algoritma Machine Learning (ML)
Pembagian Data
Penentuan Langkah Eksperimen

02

Membangun model

Mengembangkan model dengan Teknik ML

Eksekusi Algoritma
Pengaturan Parameter
Pengukuran Performance Metrics

4. Modeling : **Membangun Skenario Pemodelan**

Membuat strategi pencarian model terbaik

Pemilihan Algoritma Machine Learning (ML)
Pembagian Data
Penentuan Langkah Eksperimen

4. Modeling : Membangun Skenario Pemodelan

Membuat strategi pencarian model terbaik

A. Memilih Algoritma: Disesuaikan dengan Tugas Analytics yang dipilih


1. k-Nearest Neighbor (k-NN)
2. Naïve Bayes
3. Regression Techniques
4. Support Vector Machines (SVMs)
5. Decision Trees
6. Random Forests
7. Deep Learning Algorithms
8. ...

4. Modeling : Membangun Skenario Pemodelan

Membuat strategi pencarian model terbaik

B. Membagi data: Sesuai dengan ketersediaan data


1. Data Latih: Untuk mengembangkan model
2. Data Uji: Untuk Mengukur performansi model



4. Modeling : Membangun Skenario Pemodelan

Membuat strategi pencarian model terbaik

C. Menentukan Langkah Eksperimen: Untuk mendapatkan model terbaik secara efisien dan efektif



4. Modeling : **Membangun model**



Mengembangkan model dengan Teknik ML

Pemilihan Algoritma Machine Learning (ML)
Pembagian Data
Penentuan Langkah Eksperimen

4. Modeling : Membangun model


Mengembangkan model dengan Teknik ML

A. Proses Pelatihan : Untuk mendapatkan model



1. k-Nearest Neighbor (k-NN)
2. Naïve Bayes
3. Regression Techniques
4. Support Vector Machines (SVMs)
5. Decision Trees
6. Random Forests
7. Deep Learning Algorithms
8. ...



| Variable | Type | Definition |
|----------|------|---|
| BAD | Num | BAD: 1 = applicant defaulted on loan or seriously delinquent; 0 = applicant paid loan |
| LOAN | Num | LOAN: Amount of the loan request |
| MORTDUE | Num | MORTDUE: Amount due on existing mortgage |
| VALUE | Num | VALUE: Value of current property |
| REASON | Char | REASON: DebtCon = debt consolidation, Homelmp = home improvement |
| JOB | Char | JOB: Occupational categories |
| YOJ | Num | YOJ: Years at present job |
| DEROG | Num | DEROG: Number of major derogatory reports |
| DELINQ | Num | DELINQ: Number of delinquent credit lines |
| CLAGE | Num | CLAGE: Age of oldest credit line in months |
| NNQ | Num | NNQ: Number of recent credit inquiries |
| CLNO | Num | CLNO: Number of credit lines |
| DEBTINC | Num | DEBTINC: Debt-to-income ratio |



4. Modeling : Membangun model

Mengembangkan model dengan Teknik ML

B. Proses Pengujian : Untuk mengukur Performansi



TP = True Positives
 TN = True Negatives
 FP = False Positives
 FN = False Negatives

| | p' (Predicted) | n' (Predicted) |
|------------|----------------|----------------|
| p (Actual) | True Positive | False Negative |
| n (Actual) | False Positive | True Negative |

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$\text{F1-score} = \frac{2 * \text{precision} * \text{recall}}{\text{precision} + \text{recall}}$$

5. Model Evaluation

Mengevaluasi Performansi Model Yang Dihasilkan

01

Mengevaluasi Model

Mengukur performansi model

Performansi Capaian vs Target
Memilih Model terbaik

02

Mengevaluasi Proses

Menilai apakah proses sudah maksimal

Review Proses untuk mencari
batasan atau kekurangan model

Summary

Pada topik ini, kita sudah mempelajari:

- Langkah-langkah utama dalam menggunakan data untuk membuat suatu aplikasi AI berdasar metodologi data science
- Pengembangan sistem AI berdasar data bukan hanya masalah teknis (terkait data) namun merupakan masalah bisnis/ organisasi
- Pengembangan sistem melibatkan Pakar Domain, Pakar Data Science/ AI, Pakar Manajemen Projek, dan Pakar TI dalam satu Tim

Tools / Lab Online

o

Referensi

- Standard Kompetensi Kerja Nasional Indonesia Bidang AI sub bidang Data Science
 - <https://skkni.kemnaker.go.id/tentang-skkni/dokumen>
- CRISP-DM
 - <http://crisp-dm.eu/>
- IBM Data Science Methodology
 - <https://www.slideshare.net/JohnBRollinsPhD/foundational-methodology-for-data-science>
- Microsoft Methodology
 - <https://docs.microsoft.com/en-us/azure/machine-learning/team-data-science-process/overview>
- Domino Methodology
 - <https://www.dominodatalab.com/>

Team Teaching

- Windy Gambetta, Ir., MBA (Institut Teknologi Bandung)
 - Email: windy@staff.stei.itb.ac.id

Quiz / Games

- Quiz dapat diakses melalui LMS (<https://lms.kominfo.go.id/>)

#JADIJAGOANDIGITAL
TERIMA KASIH



digitalent.kominfo



DTS_kominfo



digitalent.kominfo



digital talent scholarship