

SAS VDMML / SAS IML wprowadzenie i warsztaty dla UFG SA

[Łukasz.Chojak@sas.com](mailto:Lukasz.Chojak@sas.com)

Mariusz.Dzieciatko@sas.com

Piotr.Kaczynski@sas.com

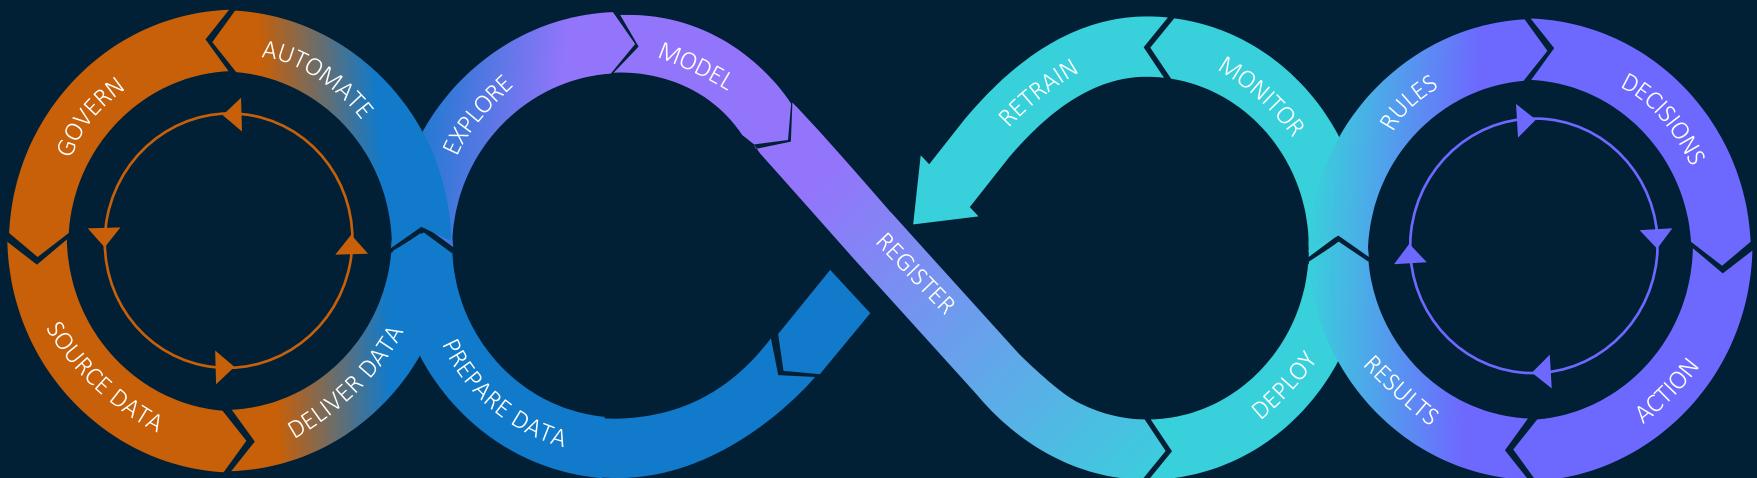
Mariusz.Zychowicz@sas.com

12.01.2021 Warszawa

Agenda spotkania:

- Wprowadzenie do SAS VDMML i SAS IML
- Demo VDMML + demo koncepcja Open Modeling Platform (HUB dla zarządzania modelami SAS i open source).
- Dyskusja / Pytania

Pełny cykl analityczny



Jeden interfejs

SAS® IML

- Programowe podejście do operacji i analizy zorientowanych na macierz
- Tak jak PROC IML jest samotną procedurą w SAS/IML, akcja iml jest jedynym członkiem zestawu działań IML w SAS IML
- Za pomocą akcji iml można wykonać większość kodu PROC IML
- Możliwe jest przetwarzanie równoległe i rozproszone
- Interfejs:
 - Z poziomu SAS (SAS Studio)—PROC CAS wywołuje akcję iml
 - Języki Python, Lua , Java, R — Bezpośredni dostęp do akcji iml

SAS® IML funkcjonalności

High-level programming language

- Translate mathematical formulas into programs.
- Matrices and vectors are treated as high-level objects.
- Data structures such as lists and in-memory tables.
- Iterative loops, IF-THEN/ELSE logic, etc.
- More than 300 built-in functions.
- Define new functions and subroutines.
- In the iml action: Functions can execute in parallel on multiple threads.

Matrix computations

- Read from a data table into a matrix.
- Multithreaded matrix operations: addition, multiplication, raise to power, etc.
- Solve linear systems.
- Matrix decompositions: Cholesky, eigenvalues, SVD, etc.
- Send matrices to functions.
- In the iml action: additional multithreaded matrix computations.

Numerical analysis

- Linear algebra.
- Root-finding algorithms.
- Integrals and derivatives.
- Differential equations (DEs).
- Interpolation.
- In the iml action: Find multiple roots, solve multiple DEs, in parallel.

Optimization

- Linear programming.
- Mixed-integer linear programming.

Simulation

- Simulate from dozens of built-in distributions.
- Univariate: Normal, lognormal, exponential, etc.
- Multivariate: Normal, multinomial, Wishart, etc.
- Time series models: ARIMA and multivariate variations.
- Program custom simulations.
- Regression models.
- Spatial models.
- In the iml action: Generate independent samples in multiple threads.

Statistics & data analysis

- Means and standard deviations.
- Correlation and covariance matrices.
- Tabulate categorical data.
- Implement hypothesis tests.
- Multivariate data analysis.
- In the iml action: bootstrap methods and permutation tests in parallel.

SAS® Visual Data Mining and Machine Learning

Interfejs wizualny
"drag & drop"



Interfejs
programistyczny



Przygotowanie
danych



Wizualna
eksploracja



Modelowanie



Wdrożenie



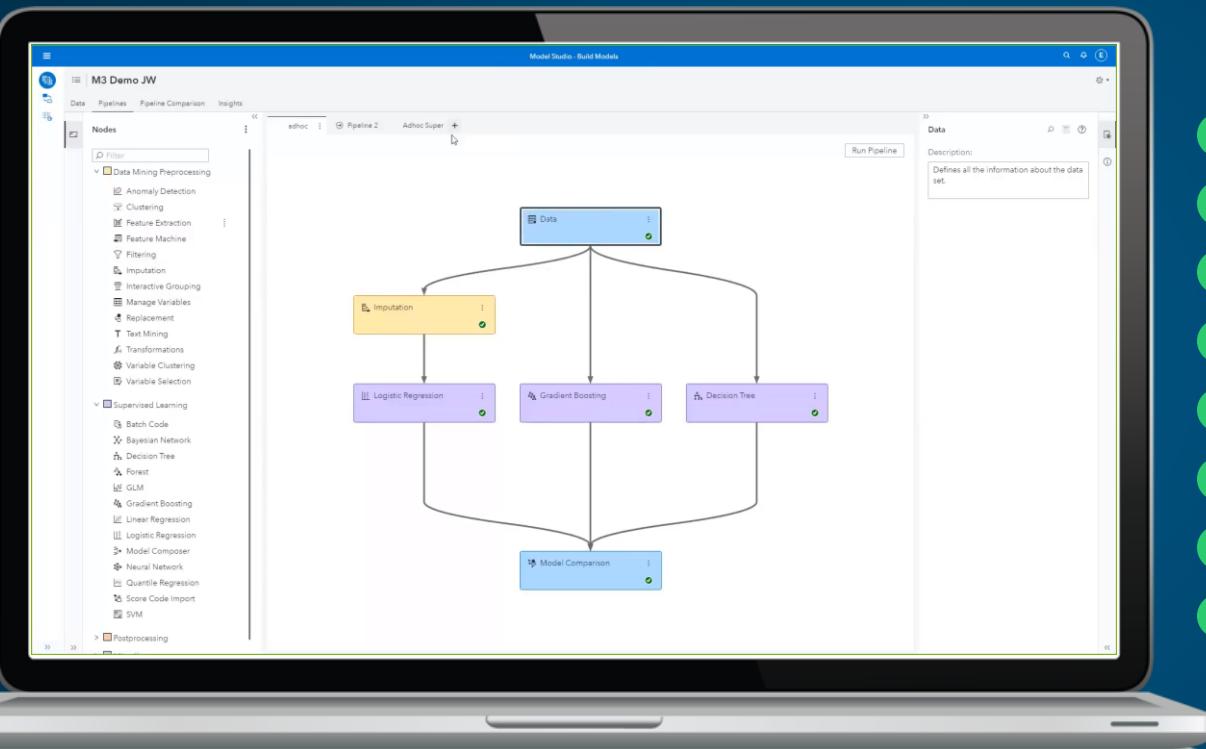
Uczenie
maszynowe



Otwarte API



Zautomatyzowane potoki



- ✓ Repository of best practice pipelines
- ✓ Models by SAS or by end-user
- ✓ Dynamically reads thru data
- ✓ Fixes data quality issues w/ ML
- ✓ Performs Data transformations
- ✓ Recommends & builds models
- ✓ Optimizes across models
- ✓ Fully editable, no black-box

Automatyzacja za pośrednictwem interfejsu GUI lub wywołań interfejsu API

`http://{host:port}/mlPipelineAutomation/projects`

- ✓ Budowa modeli
- ✓ Retrenowanie modeli
- ✓ Skoring modeli
- ✓ Rejestracja modelu w repozytorium
- ✓ W pełni edytowalne

Dokumentacja do API SAS MLPA
developer.sas.com

Wytłumaczalność i możliwości NLP

The screenshot shows the SAS Model Studio interface. At the top, there's a navigation bar with tabs for Data, Pipelines, Pipeline Comparison, and Insights. The main area displays several dashboards:

- Project Summary:** Shows the champion model is Forest Auto, chosen based on Average Squared Error for the validate partition (0.6925097683). It lists five important factors: Transformed Three-year cohort default rate, Transformed Predominant degree, Transformed Imputed Three-year cohort default rate, Transformed Median family income, and Transformed % aid students whose family income \$0-\$30K.
- Report for Bakoff College Scorecard VDMML:** A note from the champion states: "The auto-transformed Forest, using Genetic Hyper Tuning was the best model I could build. I recommend trying additional methods to reduce the dimensionality of the data." It also encourages looking at other best practice pipelines.
- Assessment for All Models:** A horizontal bar chart comparing Average Squared Error for different models: Best Transform and Varius and GBM (lowest error), Forest Auto, GBM Auto, Linear regression, and Open Source Python (highest error).
- Actual vs. Predicted for Champion Model:** A scatter plot showing Actual vs. Predicted values for the champion model.
- Most Important Variables for Champion Model:** A bar chart showing the number of models for each variable: Transformed Predominant degree (highest count).
- Most Common Variables Selected Across All Models:** A bar chart showing the number of models for various variables, including Impaired % students financially dependent and have family income, Transformed Median original amount of the loan principal upon entry, Transformed Imputed Median original amount of the loan principal, Transformed % Not working and not enrolled 10 years after entry, Transformed Imputed % aid students whose family income \$0-\$30K, PCS, Transformed Average cost of attendance academic year institution, Transformed Predominant degree, and Impaired In-state tuition and fees.

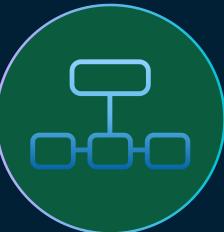
- ✓ Model Interpretability Tab
- ✓ Explain models in plain language
- ✓ Project summaries using NLG
- ✓ PD – Partial Dependency
- ✓ LIME – Lcl. Interpret. Model-Ag. Expl.
- ✓ ICE – Individual Conditional Expl.
- ✓ SHAP – SHapley Additive exPlanations
- ✓ Collaboration w/ Project Notes



Analityka	Statystyka	Uczenie maszynowe
<p>Analytic Astore Scoring</p> <p>Data Step</p> <p>Data Transpose</p> <p>DS2</p> <p>Function Compiler</p> <p>FedSQL</p> <p>Frequency / Crosstab</p> <p>Imputation</p> <p>Model Assessment</p> <p>Sampling and Partitioning</p> <p>Sentiment Analysis</p> <p>Sequencing/Pathing Analysis</p> <p>Text Mining</p> <p>Variable Binning</p> <p>Variable Cardinality Analysis</p> <p>Variable Clustering</p> <p>Variable Selection</p> <p>Variable Summary</p>	<p>Cox Proportional Hazards</p> <p>Decision Trees</p> <p>Design Matrix</p> <p>General Additive Models</p> <p>Generalized Linear Models</p> <p>Independent Component Analysis</p> <p>Clustering</p> <p><i>K-means and K-modes</i></p> <p>Linear Regression</p> <p>Linear Mixed Models</p> <p>Logistic Regression</p> <p>Model-Based Clustering</p> <p>Model Scoring</p> <p>Nonlinear Regression</p> <p>Ordinary Least Squares Regression</p> <p>Partial Least Squares Regression</p> <p>Pearson Correlation</p> <p>Principal Component Analysis</p> <p><i>Kernel Principal Comp. Analysis</i></p> <p>Quantile Regression</p> <p>Shewhart Control Chart Analysis</p>	<p>Automated ML</p> <p><i>Data Science Pilot</i></p> <p><i>Model Composer</i></p> <p>Audio Data Processing</p> <p>Bayesian Networks</p> <p>Boolean Rules</p> <p>Cross Validation ML</p> <p>Deep Learning</p> <p><i>Convolutional NN</i></p> <p><i>Deep Forward NN</i></p> <p><i>Recurrent NN</i></p> <p><i>Transfer Learning</i></p> <p>Factorization Machine</p> <p>Frequent Item Set Mining</p> <p>Gaussian Mixture Model</p> <p>Gaussian Process Regression</p> <p>Gradient Boosting</p> <p>Hyperparameter Auto-tuning</p> <p>K Nearest Neighbor</p> <p>Image Processing (<i>incl. Biomedical</i>)</p> <p>Market Basket Analysis</p>



Computer Vision (CV)



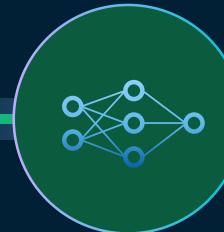
Nowe możliwości
segmentacji



Wsparcie dla obrazów DICOM oraz
DICOM RT



Poprawiona dokładność
wykrywania obiektów—
YOLOv2, TinyYOLO,
R-CNN



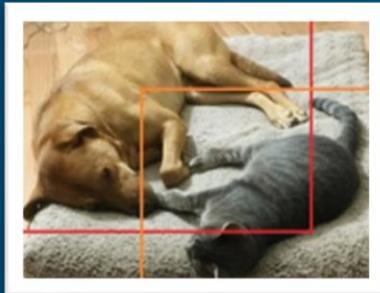
CV na urządzenia
mobilne—
MobileNet,
ShuffleNet

Cztery zadania CV pokrywają ponad 90% przypadków użycia

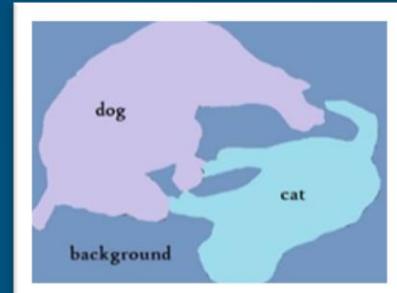
Klasyfikacja obrazów



Detekcja obiektów



Segmentacja obiektów



Detekcja kluczowych punktów



Zastosowanie:
Wykrywanie
defektów na linii
produkcyjnej

Convolutional Neural Network
models for image classification
such as VGG, ResNet, and
Darknet, MobileNet,
ShuffleNet

Zastosowanie :
Monitorowanie
zajętości miejsc
parkingowych

YOLO-v1, YOLO-v2,
Faster R-CNN

Zastosowanie :
Monitorowanie guza pod
kątem zmiany kształtu,
rozmiaru, koloru

UNET for semantic segmentation
Mask R-CNN for instance segmentation

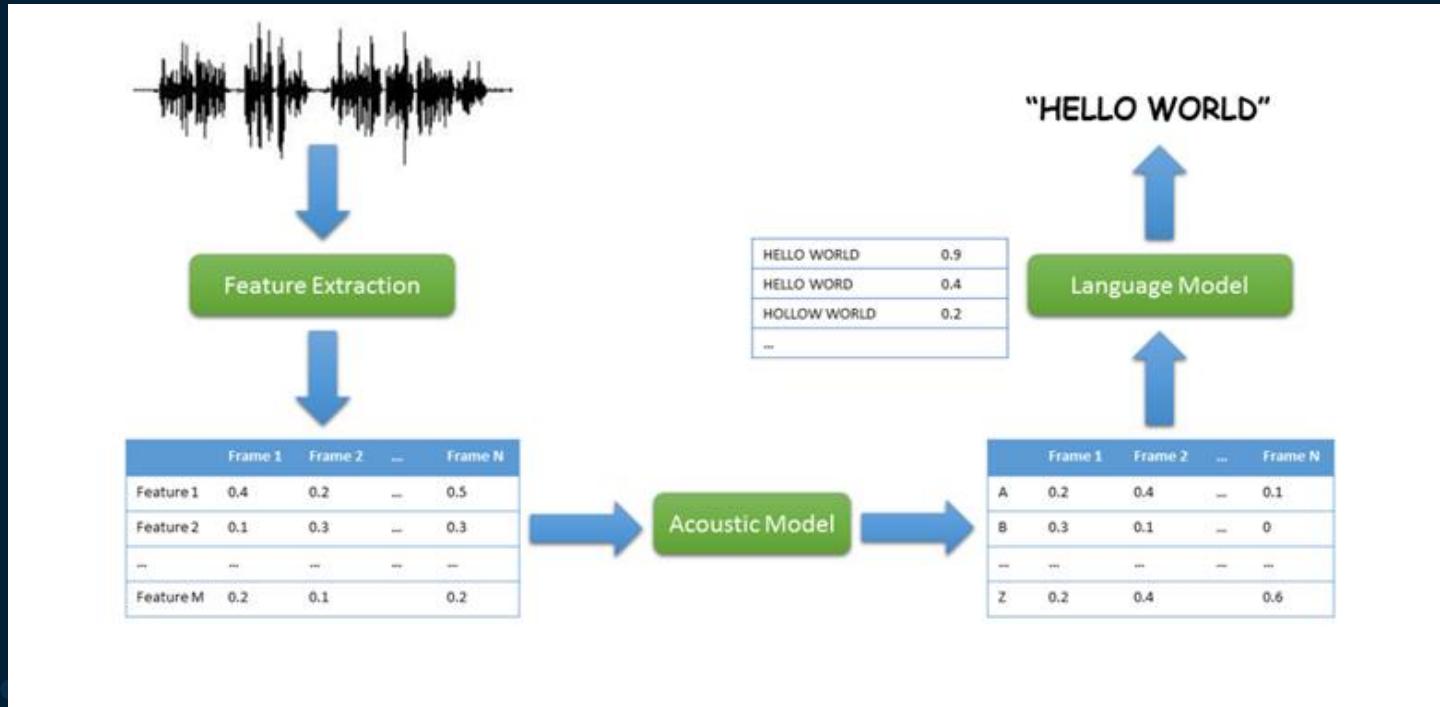
Zastosowanie :
Ruch produktu na liniach
produkcyjnych

Image regression & multi-task
learning for keypoints detection



Voice to text

Architektura



Nowe możliwości analityczne

VDMML vs. Miner

Nowe techniki analityczne

Automatyzacja i autotunning

Nowe typy danych
(obraz i mowa)

Wydajność,
skalowalność
(in-memory)

Otwartość środowiska
(OS + API)

SAS® Visual Data Mining and Machine Learning

Otwartość dla nie SASowych programistów



Języki SAS

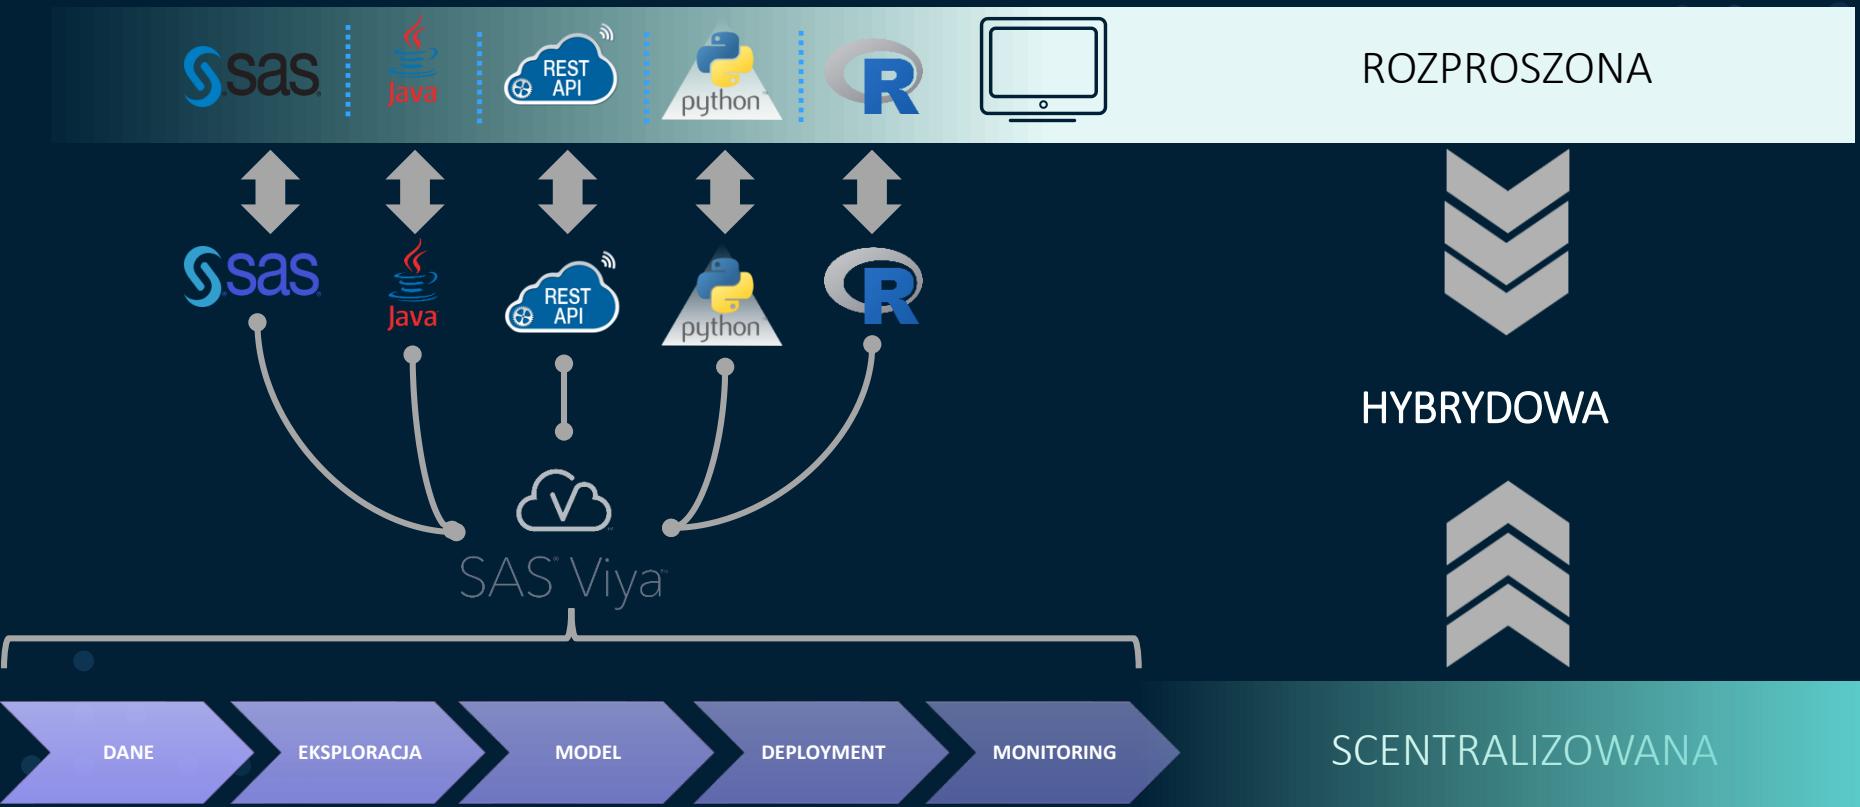


Python, R, Lua &
Java

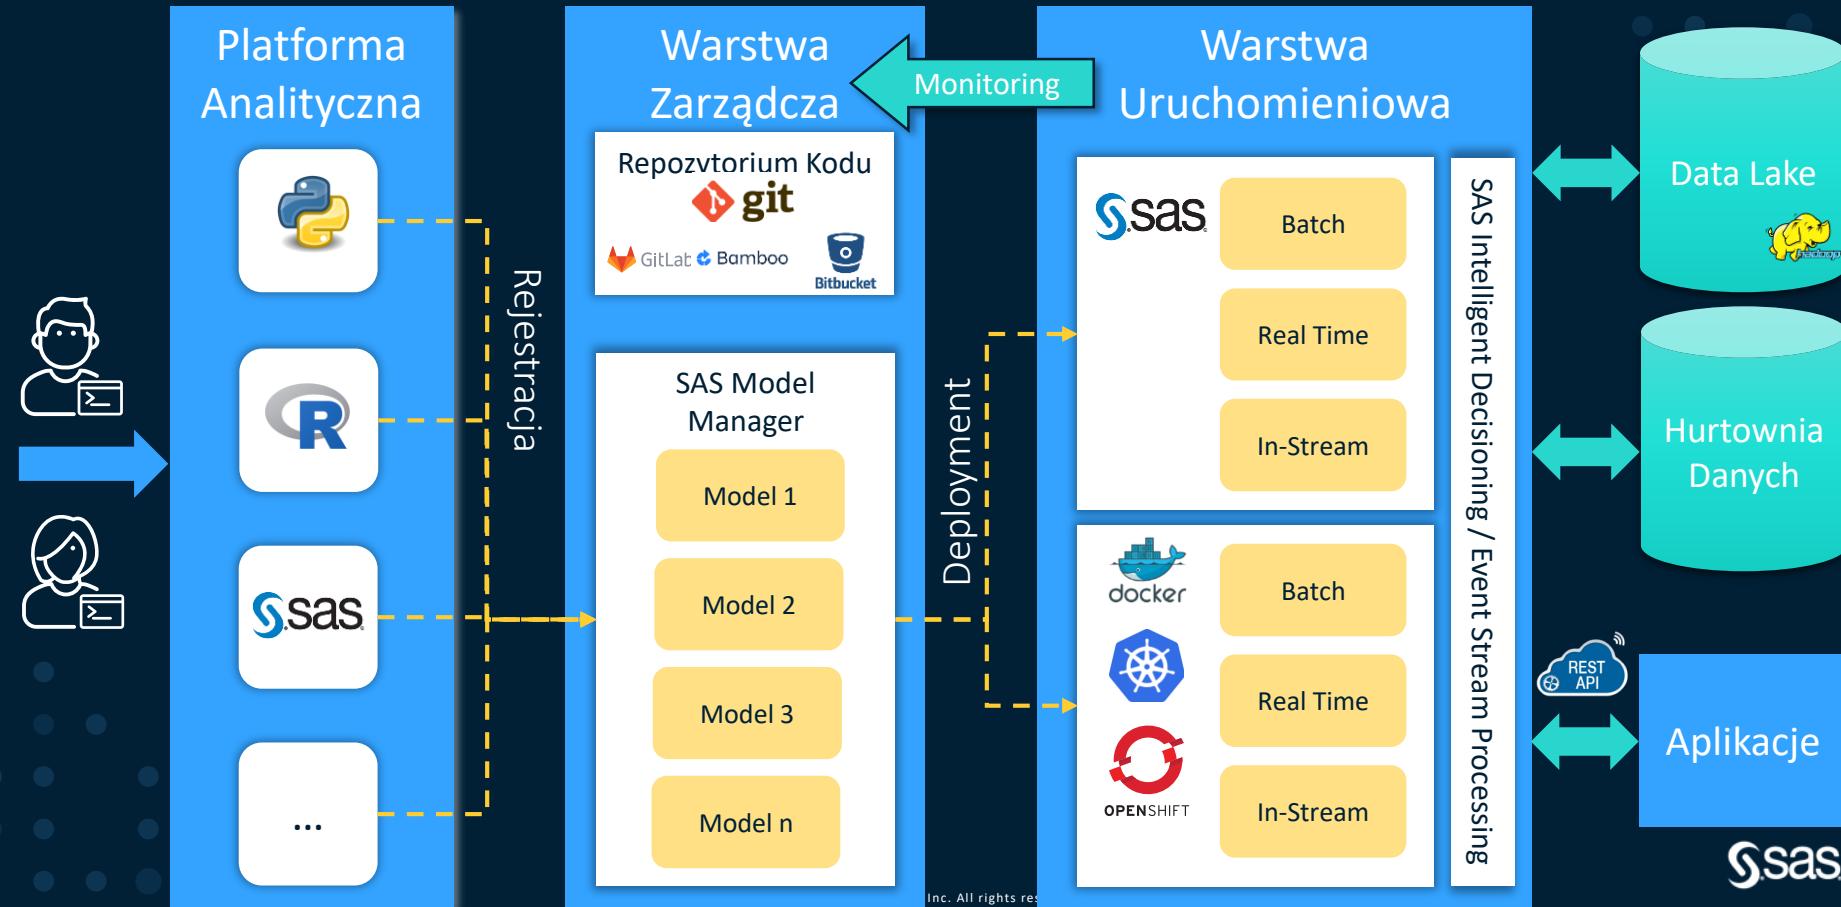


REST APIs

Otwarty System Analityczny

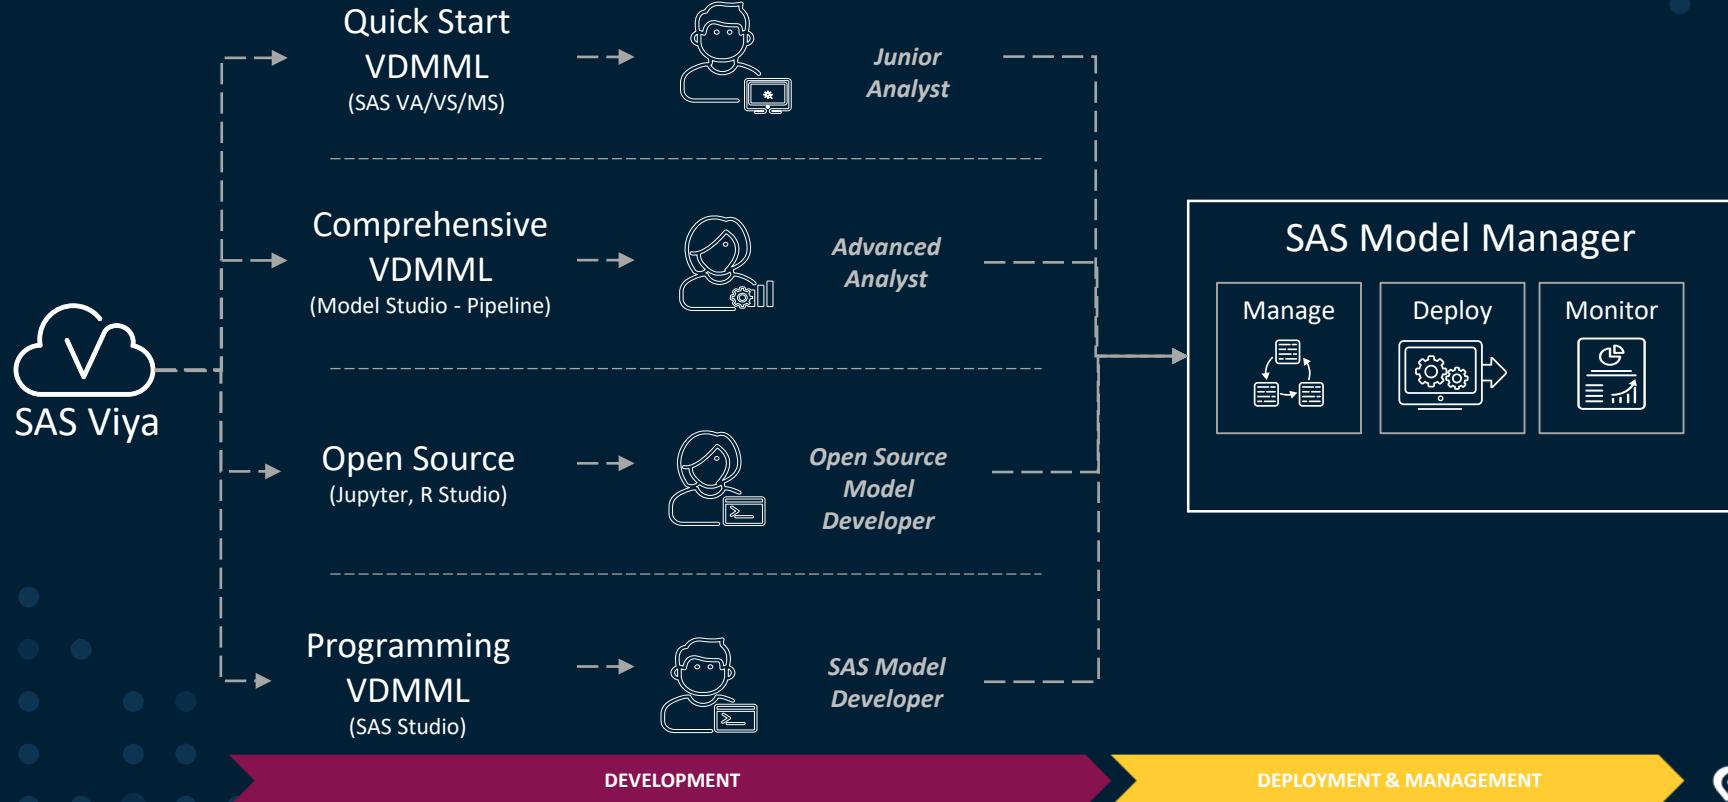


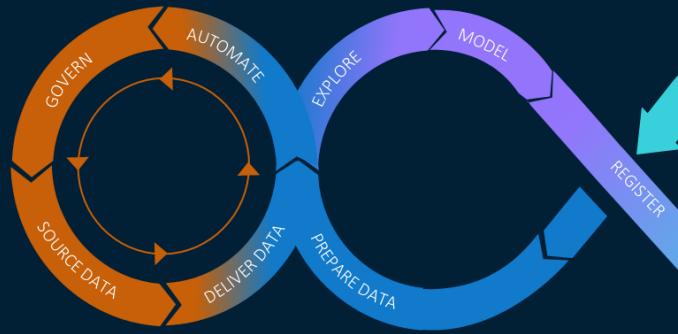
Architektura logiczna



Wykorzystanie SAS Viya

Możliwe podejścia





[DEMO]

Tworzenie i orkiestracja modeli:

- VDMML – prezentacja narzędzia, cykl analityczny na modelach SASowych + integracja kodu OS.
- VDMML z wykorzystaniem interfejsu Python'a
- Tworzenie i rejestracja modeli OS w SAS Model Manager.

Korzyści z wdrożenia Open Modeling Platform

Perspektywa analityka



Elastyczność

- Środowisko na żądanie
- Dowolna technologia
- Dostępność danych



Skuteczność

- Techniki analityczne
- Autotuning
- Automatyzacja procesów



Wygoda

- Wizualny interfejs
- Gotowe zadania
- Wydajne przetwarzanie

Korzyści z wdrożenia Open Modeling Platform

Perspektywa architekta/IT



Bezpieczeństwo

- Dane w centralnym silniku
- Nadzór nad modelami
- Uprawnienia



Skalowalność

- Przetwarzanie in-memory
- Architektura rozproszona
- Łatwość zarządzania



Nowoczesność

- Konteneryzacja
- Best-practice (Git, Rest API, itd.)
- Gotowość na chmurę

Korzyści z wdrożenia Open Modeling Platform

Perspektywa kierownictwa



Ograniczenie ryzyka

- Dane w jednym miejscu
- Rejestr modeli
- Nadzór nad cyklem analitycznym



Wzrost efektywności

- Skuteczniejsze modele
- Krótki time-to-market
- Automatyzacja procesów



Strategiczny kierunek

- Gotowość na chmurę

Dziękujemy!