

Zwiększanie wyjaśnialności systemów decyzyjnych: nowe rozszerzenie teorii zbiorów przybliżonych Pawlaka do oceny ważności cech

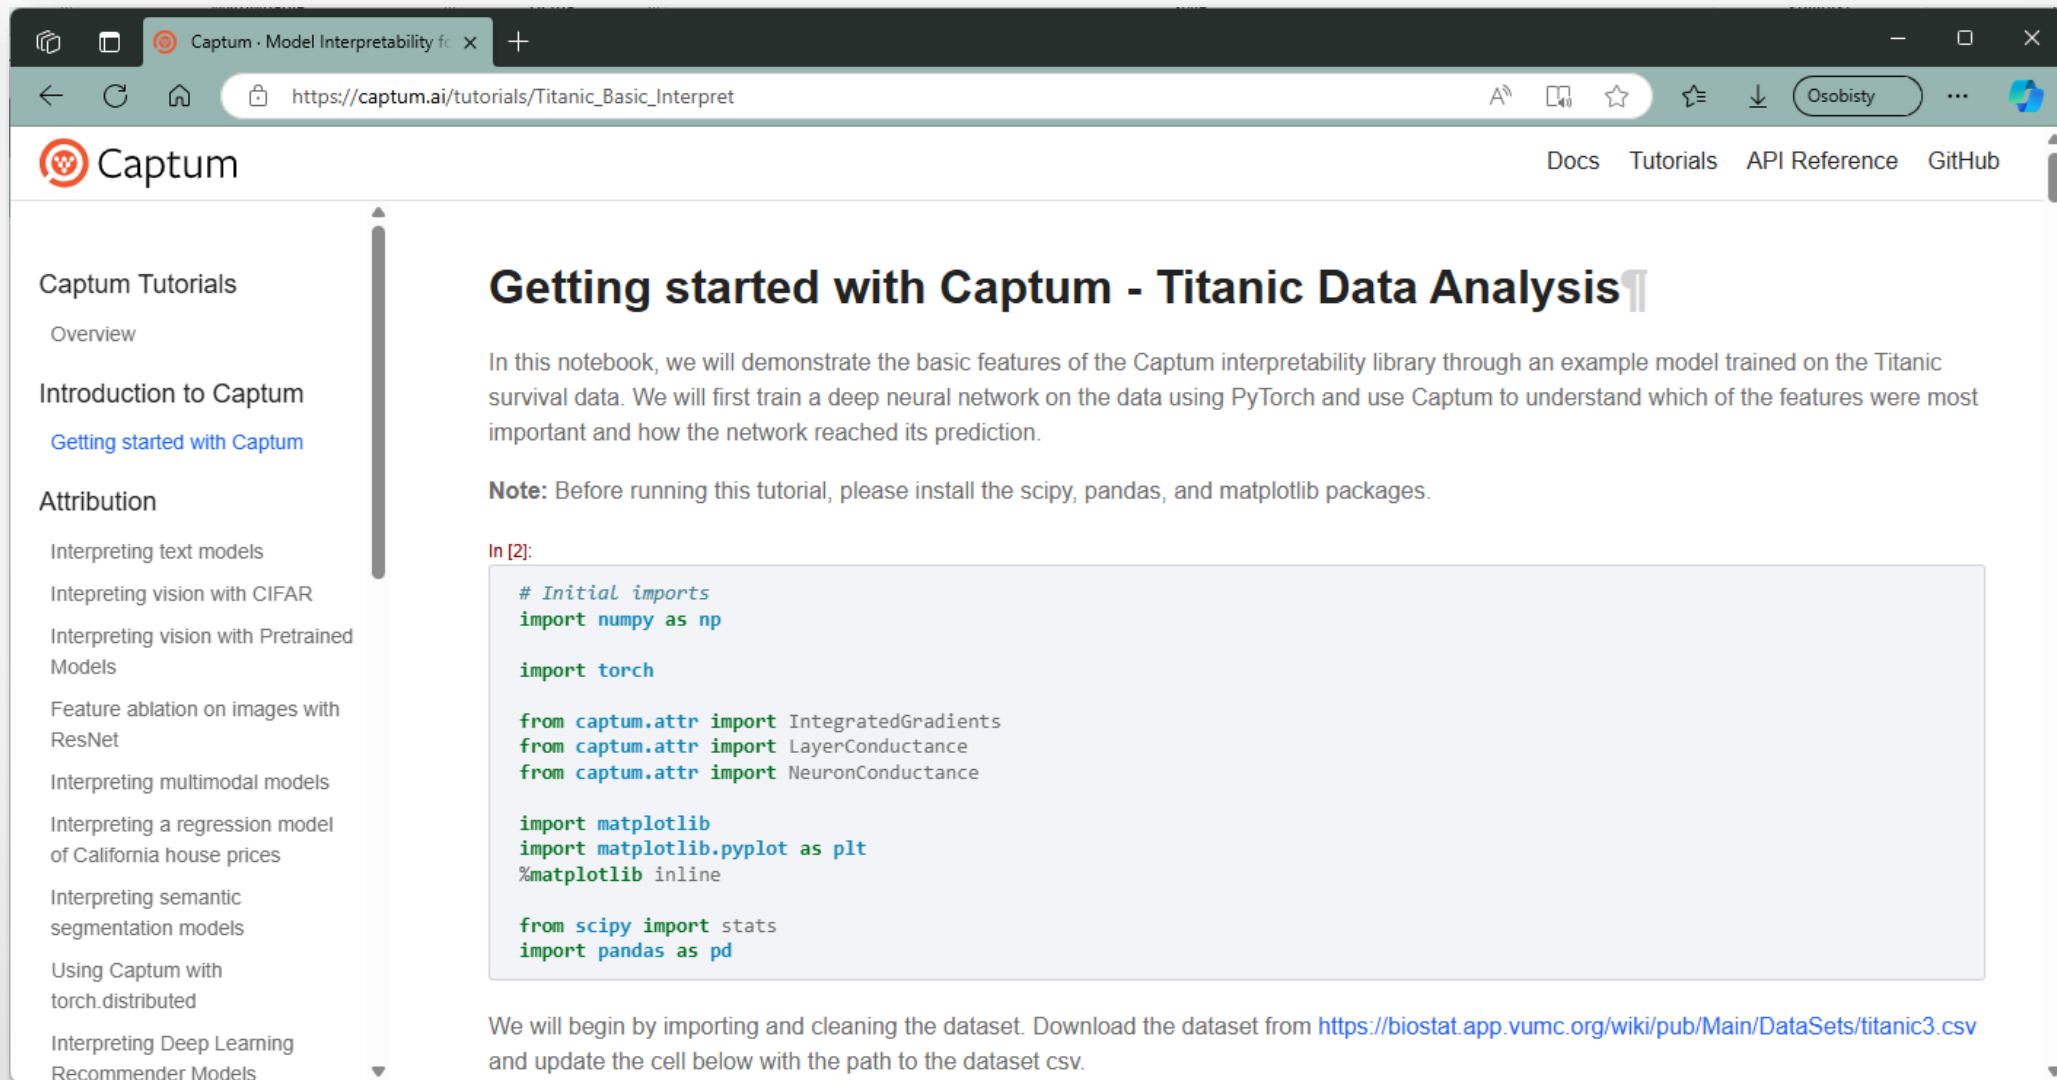
Robert Nowicki^{1,2}, Leszek Rutkowski^{2,3}

¹ Katedra Sztucznej Inteligencji
Wydział Informatyki i Sztucznej Inteligencji
Politechnika Częstochowska

² Wydział Informatyki
Akademia Górniczo-Hutnicza im. St. Staszica w Krakowie

³ Instytut Badań Systemowych
Polska Akademia Nauk

Inspiracja – mail od LR



The screenshot shows a web browser window with the URL https://captum.ai/tutorials/Titanic_Basic_Interpret. The page title is "Getting started with Captum - Titanic Data Analysis". The left sidebar contains a navigation menu with the following items: Captum Tutorials, Overview, Introduction to Captum (with a sub-link "Getting started with Captum"), Attribution, Interpreting text models, Interpreting vision with CIFAR, Interpreting vision with Pretrained Models, Feature ablation on images with ResNet, Interpreting multimodal models, Interpreting a regression model of California house prices, Interpreting semantic segmentation models, Using Captum with torch.distributed, and Interpreting Deep Learning Recommender Models. The main content area starts with the heading "Getting started with Captum - Titanic Data Analysis". Below the heading is an introductory paragraph: "In this notebook, we will demonstrate the basic features of the Captum interpretability library through an example model trained on the Titanic survival data. We will first train a deep neural network on the data using PyTorch and use Captum to understand which of the features were most important and how the network reached its prediction." A "Note" section follows, stating: "Before running this tutorial, please install the scipy, pandas, and matplotlib packages." Below the note is a code cell labeled "In [2]:" containing the following Python code:

```
# Initial imports
import numpy as np

import torch

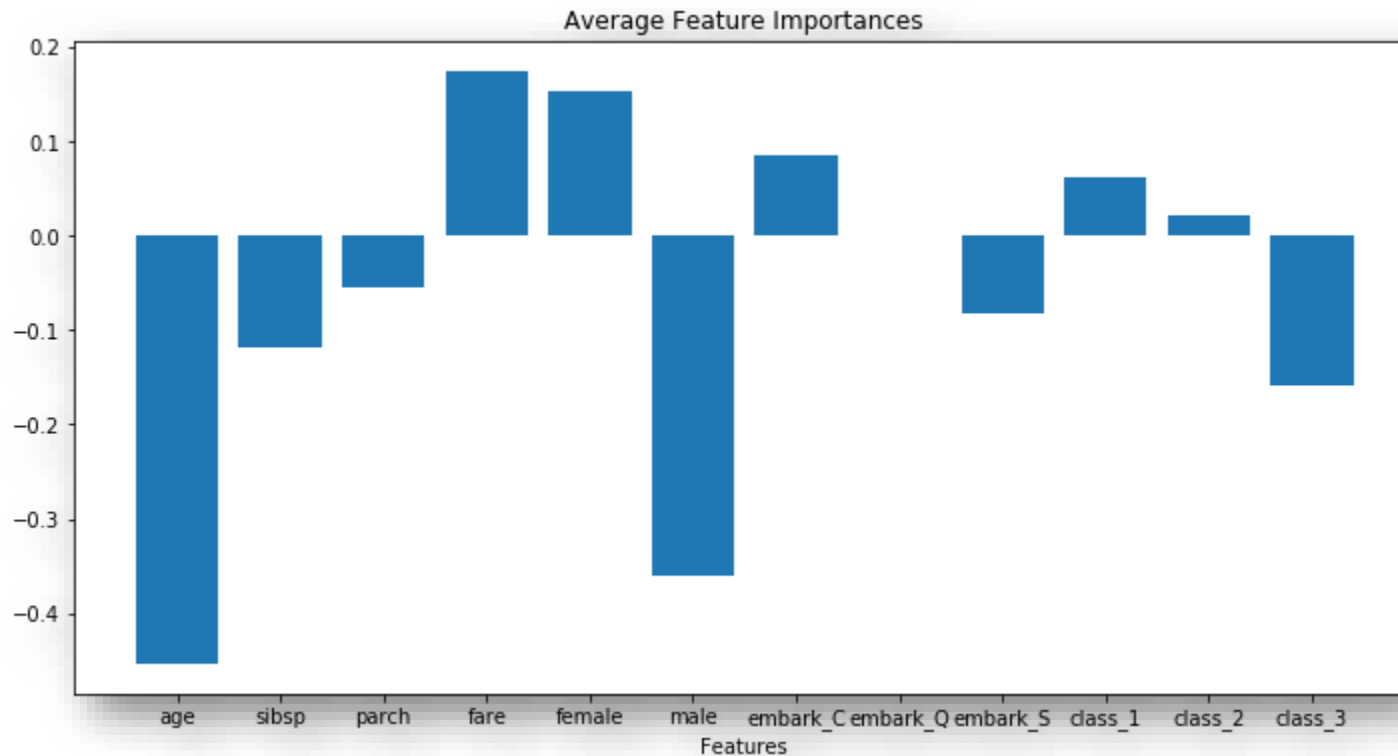
from captum.attr import IntegratedGradients
from captum.attr import LayerConductance
from captum.attr import NeuronConductance

import matplotlib
import matplotlib.pyplot as plt
%matplotlib inline

from scipy import stats
import pandas as pd
```

Below the code cell, the text reads: "We will begin by importing and cleaning the dataset. Download the dataset from <https://biostat.app.vumc.org/wiki/pub/Main/DataSets/titanic3.csv> and update the cell below with the path to the dataset csv."

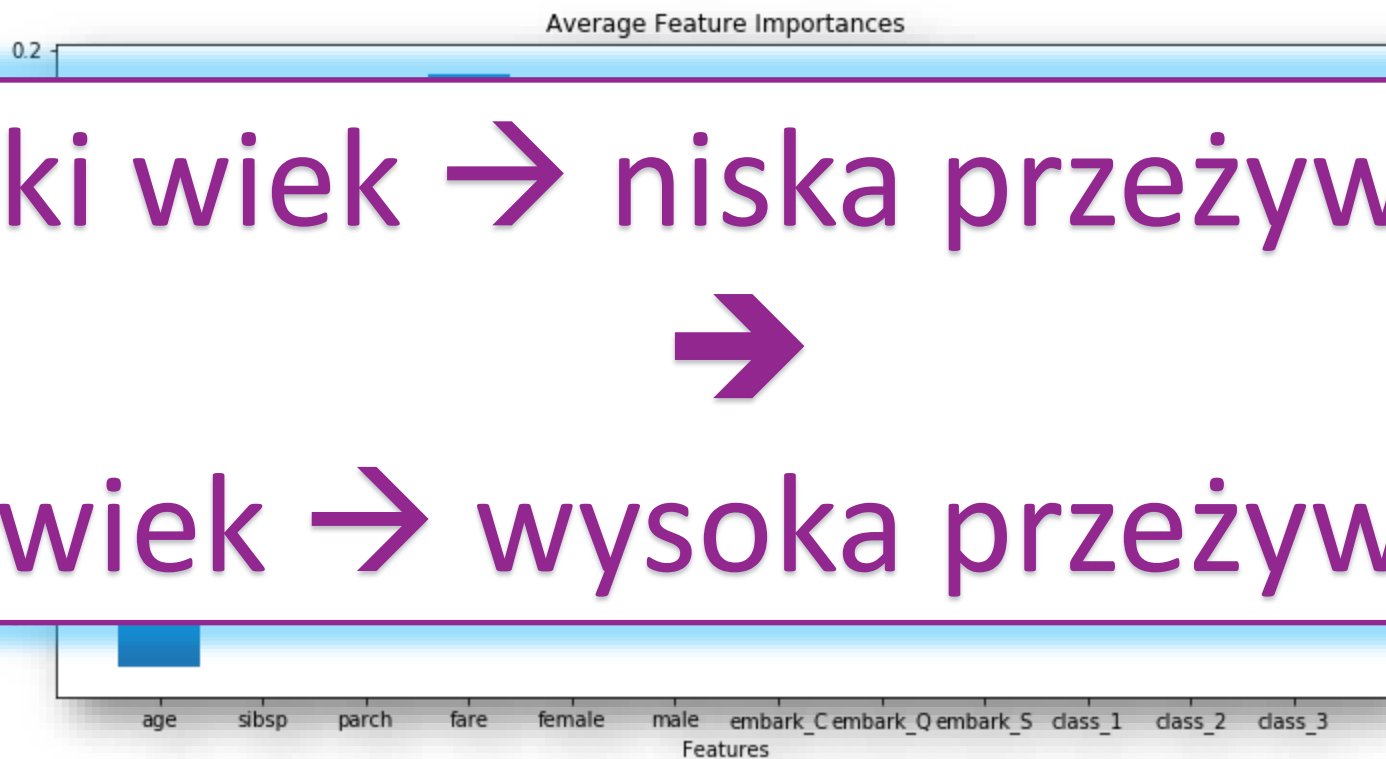
Wynik [https://captum.ai/...](https://captum.ai/)



class_1, class_2
i class_3 są
traktowane
jako oddzielne,
ale związane
atrybuty
warunkowe.

„From the feature attribution information, we obtain some interesting insights regarding the importance of various features. We see that the strongest features appear to be age and being male, which are negatively correlated with survival. Embarking at Queenstown and the number of parents / children appear to be less important features generally.”

Wynik [https://captum.ai/...](https://captum.ai/)



wysoki wiek → niska przeżywalność



niski wiek → wysoka przeżywalność

„From the feature attribution information, we obtain some interesting insights regarding the importance of various features. We see that the strongest features appear to be age and being male, which are negatively correlated with survival. Embarking at Queenstown and the number of parents / children appear to be less important features generally.”



Zbiory przybliżone w pigułce

$$\begin{aligned}\underline{R}X &= \{x \in U: [x]_R \subseteq X\} \\ \overline{R}X &= \{x \in U: [x]_R \cap X \neq \emptyset\} \\ [x]_R &= \{\hat{x} \in U: xR\hat{x}\} \\ R &= \tilde{P} \text{ gdzie } P \subseteq Q\end{aligned}$$

Zbiory przybliżone w pigułce

$$\begin{aligned}\underline{R}X &= \{x \in U: [x]_R \subseteq X\} \\ \overline{R}X &= \{x \in U: [x]_R \cap X \neq \emptyset\} \\ [x]_R &= \{\hat{x} \in U: xR\hat{x}\} \\ R &= \tilde{P} \text{ gdzie } P \subseteq Q\end{aligned}$$

$$\text{Pos}_R(X) = \underline{R}X$$

$$\text{Neg}_R(X) = U \setminus \overline{R}X$$

$$\text{Bn}_R(X) = \overline{R}X \setminus \underline{R}X$$

Zbiory przybliżone w pigułce

$$\begin{aligned}\underline{R}X &= \{x \in U: [x]_R \subseteq X\} \\ \overline{R}X &= \{x \in U: [x]_R \cap X \neq \emptyset\} \\ [x]_R &= \{\hat{x} \in U: xR\hat{x}\} \\ R &= \tilde{P} \text{ gdzie } P \subseteq Q\end{aligned}$$

$$\text{Pos}_R(X) = \underline{R}X$$

$$\text{Neg}_R(X) = U \setminus \overline{R}X$$

$$\text{Bn}_R(X) = \overline{R}X \setminus \underline{R}X$$

$$\chi = \{X_1, X_2, \dots, X_M\}$$

$$\text{Pos}_R(\chi) = \cup \text{Pos}_R(X_i)$$

$$\text{Neg}_R(\chi) = \emptyset$$

$$\text{Bn}_R(\chi) = \cup \text{Bn}_R(X_i)$$

Zbiory przybliżone w pigułce

$$\begin{aligned}\underline{R}X &= \{x \in U: [x]_R \subseteq X\} \\ \overline{R}X &= \{x \in U: [x]_R \cap X \neq \emptyset\} \\ [x]_R &= \{\hat{x} \in U: xR\hat{x}\} \\ R &= \tilde{P} \text{ gdzie } P \subseteq Q\end{aligned}$$

$$\text{Pos}_R(X) = \underline{R}X$$

$$\text{Neg}_R(X) = U \setminus \overline{R}X$$

$$\text{Bn}_R(X) = \overline{R}X \setminus \underline{R}X$$


$$\chi = \{X_1, X_2, \dots, X_M\}$$

$$\text{Pos}_R(\chi) = \cup \text{Pos}_R(X_i)$$

$$\text{Neg}_R(\chi) = \emptyset$$

$$\text{Bn}_R(\chi) = \cup \text{Bn}_R(X_i)$$

Podstawy wraz z przykładami w podręczniku.



Zbiory przybliżone w pigułce

$$\begin{aligned}\underline{R}X &= \{x \in U: [x]_R \subseteq X\} \\ \overline{R}X &= \{x \in U: [x]_R \cap X \neq \emptyset\} \\ [x]_R &= \{\hat{x} \in U: xR\hat{x}\} \\ R &= \tilde{P} \text{ gdzie } P \subseteq Q\end{aligned}$$

W tak zdefiniowanej przestrzeni aproksymacji można budować różne systemy decyzyjne. Przykłady w monografii.

$$\text{Pos}_R(X) = \underline{R}X$$

$$\text{Neg}_R(X) = U \setminus \overline{R}X$$


$$\text{Bn}_R(X) = \overline{R}X \setminus \underline{R}X$$

$$\chi = \{X_1, X_2, \dots, X_M\}$$

$$\text{Pos}_R(\chi) = \bigcup \text{Pos}_R(X_i)$$

$$\text{Neg}_R(\chi) = \emptyset$$

$$\text{Bn}_R(\chi) = \bigcup \text{Bn}_R(X_i)$$



Istotność atrybutu/-ów

Jakość aproksymacji

$$\gamma_C(D^*) = \frac{\overline{\overline{\text{Pos}_C(D^*)}}}{\overline{\overline{U}}}$$

Znormalizowany współczynnik istotności (ZWI)

$$\sigma_{(C,D)}(C') = \frac{\gamma_C(D^*) - \gamma_{C''}(D^*)}{\gamma_C(D^*)}$$
$$C'' = C \setminus C'$$

Istotność atrybutu/-ów

Wartość ZWI danego C' silnie zależy od pozostałych atrybutów (C).
Przykład w publikacji.


Jakość aproksymacji

$$\gamma_C(D^*) = \frac{\overline{\overline{\text{Pos}_C(D^*)}}}{\overline{\overline{U}}}$$

Znormalizowany współczynnik istotności (ZWI)

$$\sigma_{(C,D)}(C') = \frac{\gamma_C(D^*) - \gamma_{C''}(D^*)}{\gamma_C(D^*)}$$
$$C'' = C \setminus C'$$

NOWICKI AND SCHERER CUSTOMER CHURN PREDICTION BY ROUGH NEURO-FUZZY ...




32ND INTERNATIONAL CONFERENCE ON INFORMATION SYSTEMS DEVELOPMENT (ISD2024) GDAŃSK, POLAND

Customer Churn Prediction by Rough Neuro-Fuzzy Classifier with CA Defuzzification

Robert K. Nowicki
Częstochowa University of Technology/Department of Intelligent Computer Systems
Częstochowa, Poland
robert.nowicki@pcz.pl

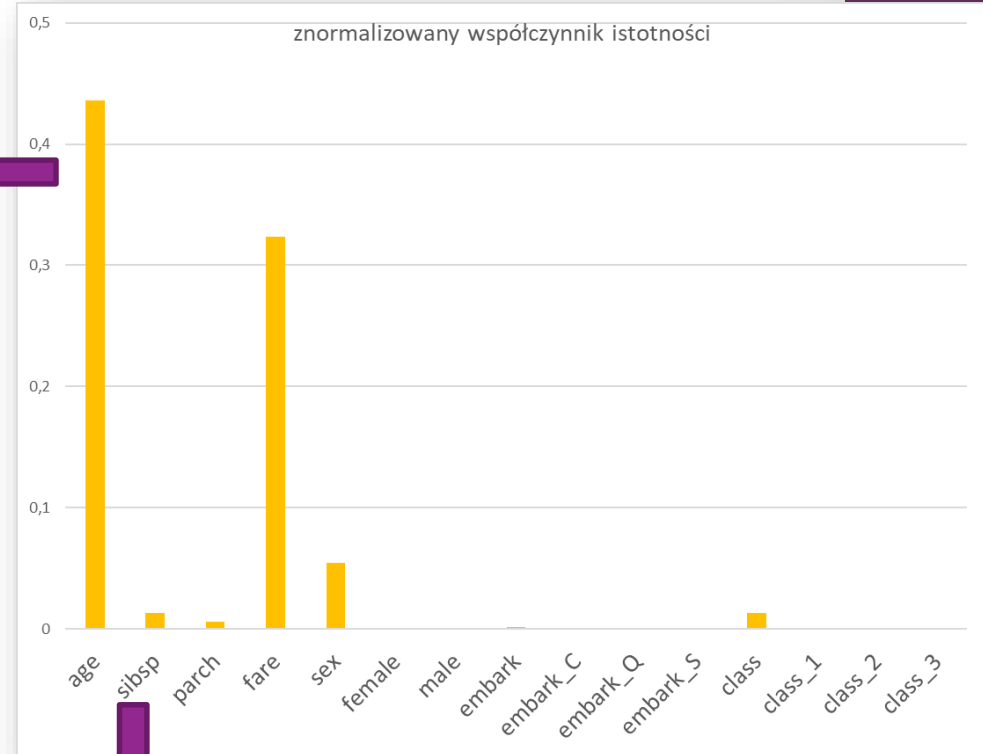


Magdalena M. Scherer
Częstochowa University of Technology/Faculty of Management
Częstochowa, Poland
magdalena.scherer@pcz.pl

Titanic – istotność atrybutów



Klasa podróży traktowana jest dwójako – jako jeden atrybut warunkowy **class** przyjmujący wartości 1, 2 i 3 z ustalonym porządkiem oraz jako trzy osobne atrybuty **class_1**, **class_2** i **class_3**. Podobnie miejsce zaokrętowania **embark**, lecz przy braku ustalonego porządku.



Titanic – rozkład istotność



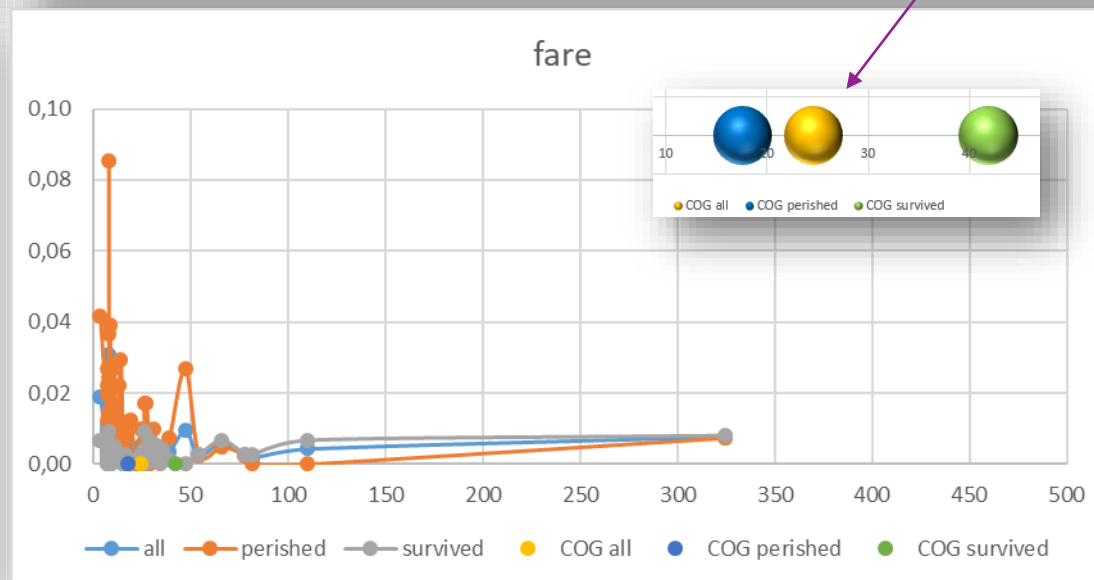
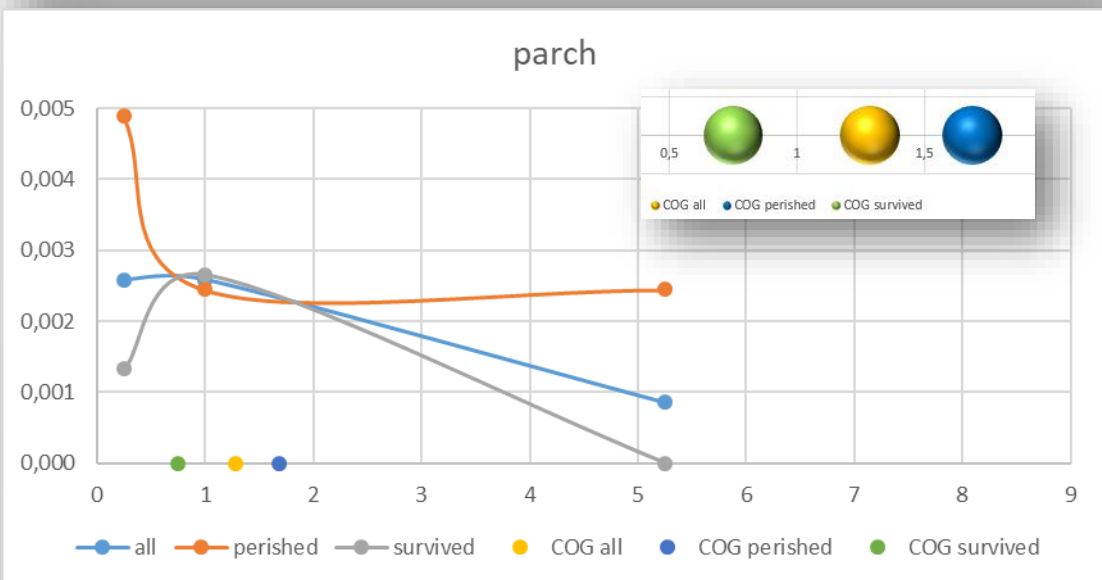
Rozkład ZWI
na zgrupowane
wartości warunkowe
i decyzyjne

Punkty reprezentują zgrupowane dane.
Łączące je linie służą tylko
zwiększeniu czytelności wykresów.

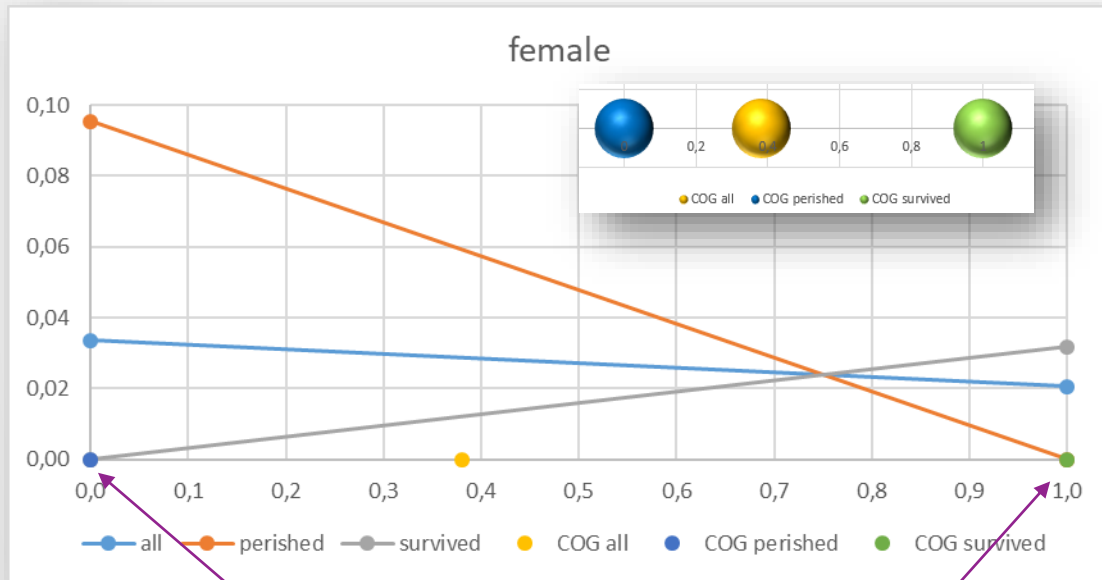
Titanic – rozkład istotności



COG – średnia ważona




Titanic – rozkład istotności



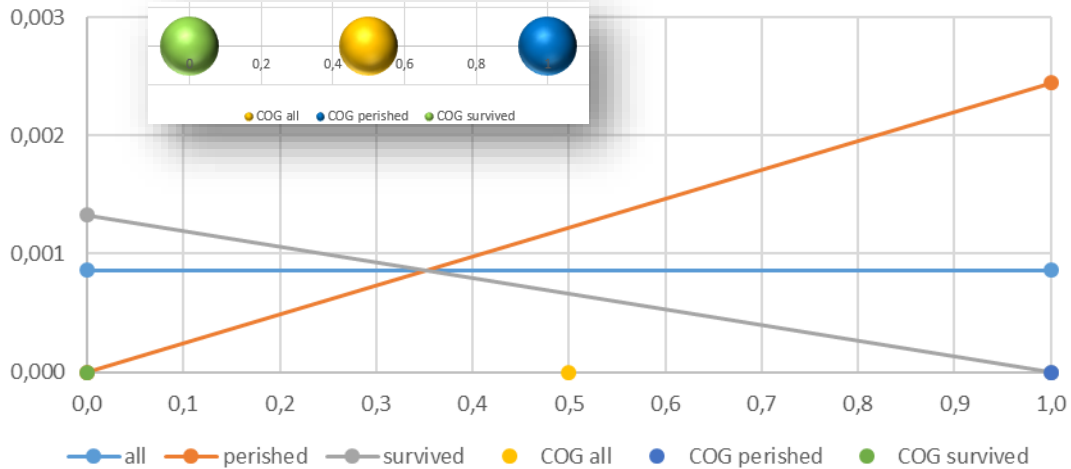
NIE

TAK




Titanic – rozkład istotności


embark_C



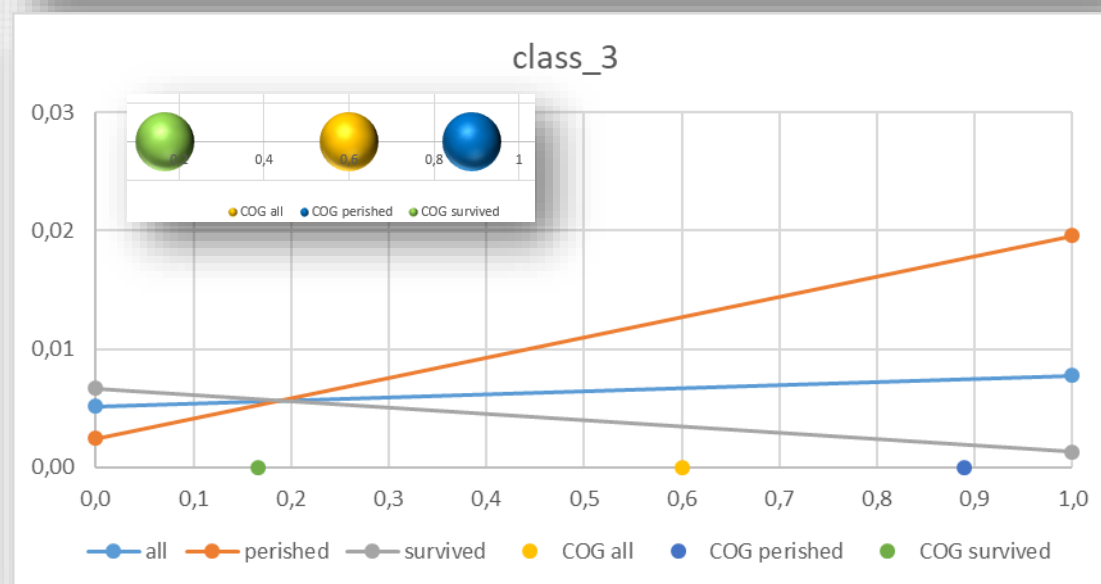



embark_Q



embark_S













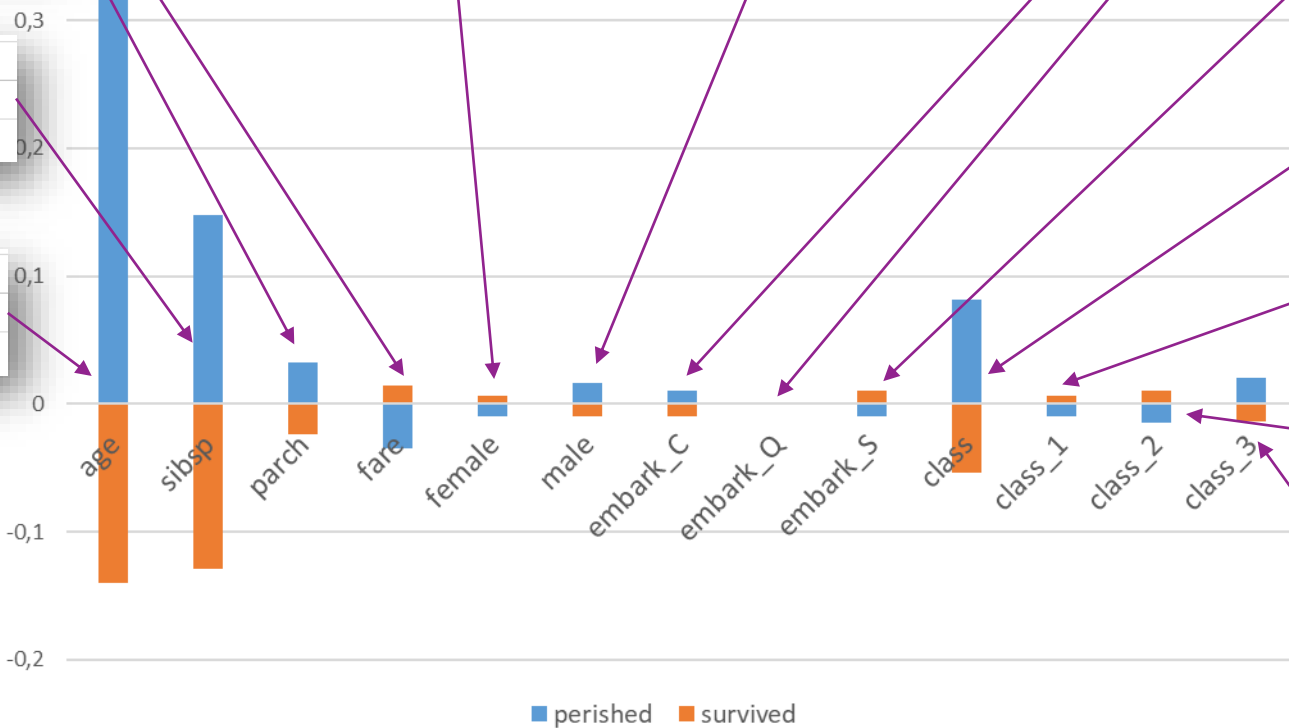


Titanic – rozkład istotności





Titanic – istotność atrybutów

Średnia istotność atrybutów warunkowych względem decyzyjnych



Titanic – istotność atrybutów



Podsumowanie

- Teoria zbiorów przybliżonych prof. Zbigniewa Pawlaka jest nadal użytecznym narzędziem do
 - selekcji atrybutów
 - interpretacji danych
 - generowania reguł
 - przetwarzania danych niepełnych
 - przetwarzania danych niejednoznacznych
 - przetwarzania danych nieprecyzyjnych
 - szeroko rozumianej analizy danych
 - ...



6th Int. Conference "Neural Networks and Soft Computing",
Zakopane, June 11-15, 2002. fot. Robert Nowicki lub Rafał Scherer*
*w trakcie ustalania

Więcej szczegółów, więcej wzorów, więcej przykładów już wkrótce.
Szukajcie naszych publikacji w roku 2025.

Robert Nowicki^{1,2}, Leszek Rutkowski^{2,3}

Dziękujemy za uwagę

KONIEC

- ¹ Katedra Sztucznej Inteligencji
Wydział Informatyki i Sztucznej Inteligencji
Politechnika Częstochowska
- ² Wydział Informatyki
Akademia Górniczo-Hutnicza im. St. Staszica w Krakowie
- ³ Instytut Badań Systemowych
Polska Akademia Nauk