

# **PREDYKCJA MODUŁU SZTYWNOŚCI MIESZANEK MINERALNO-ASFALTOWYCH ZA POMOCĄ SI**

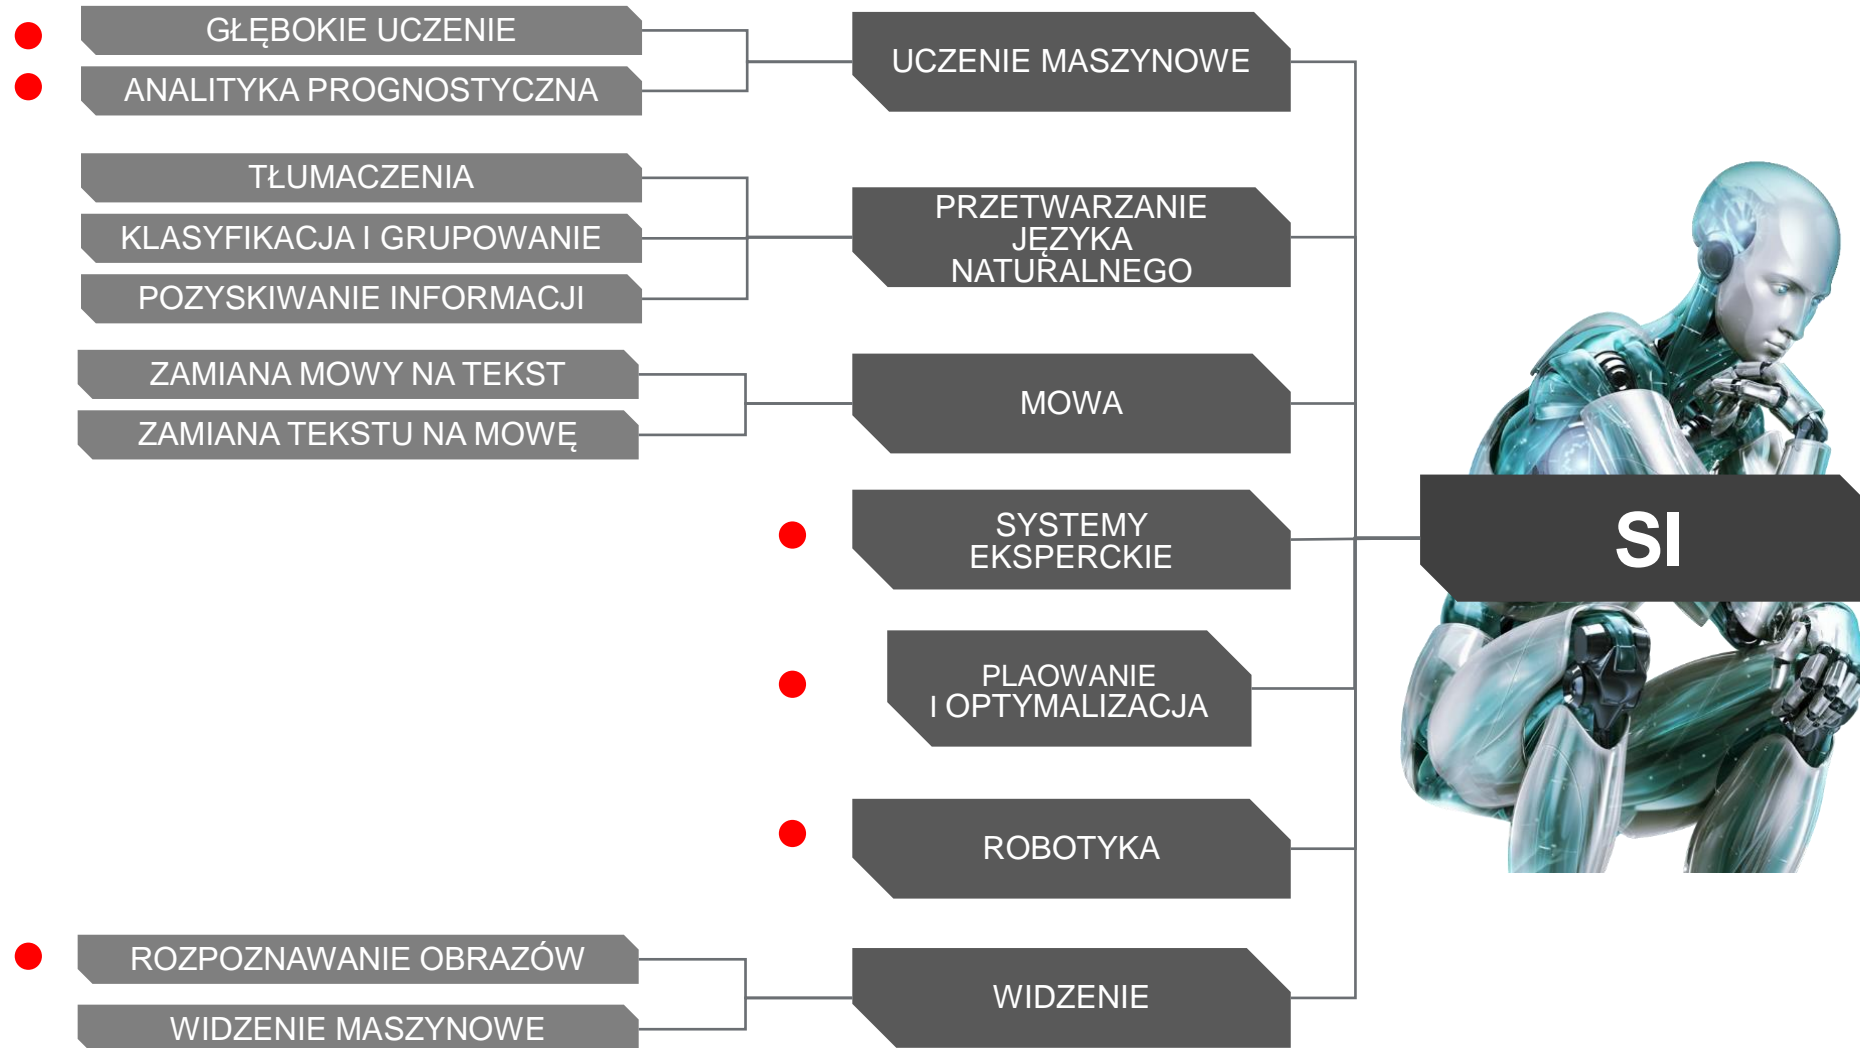
**dr Andrzej Janowski  
dr inż. Igor Ruttmar  
dr inż. Aleksander Zborowski**

**X WARMIŃSKO-MAZURSKIE FORUM DROGOWE**



**Warchały 2024**



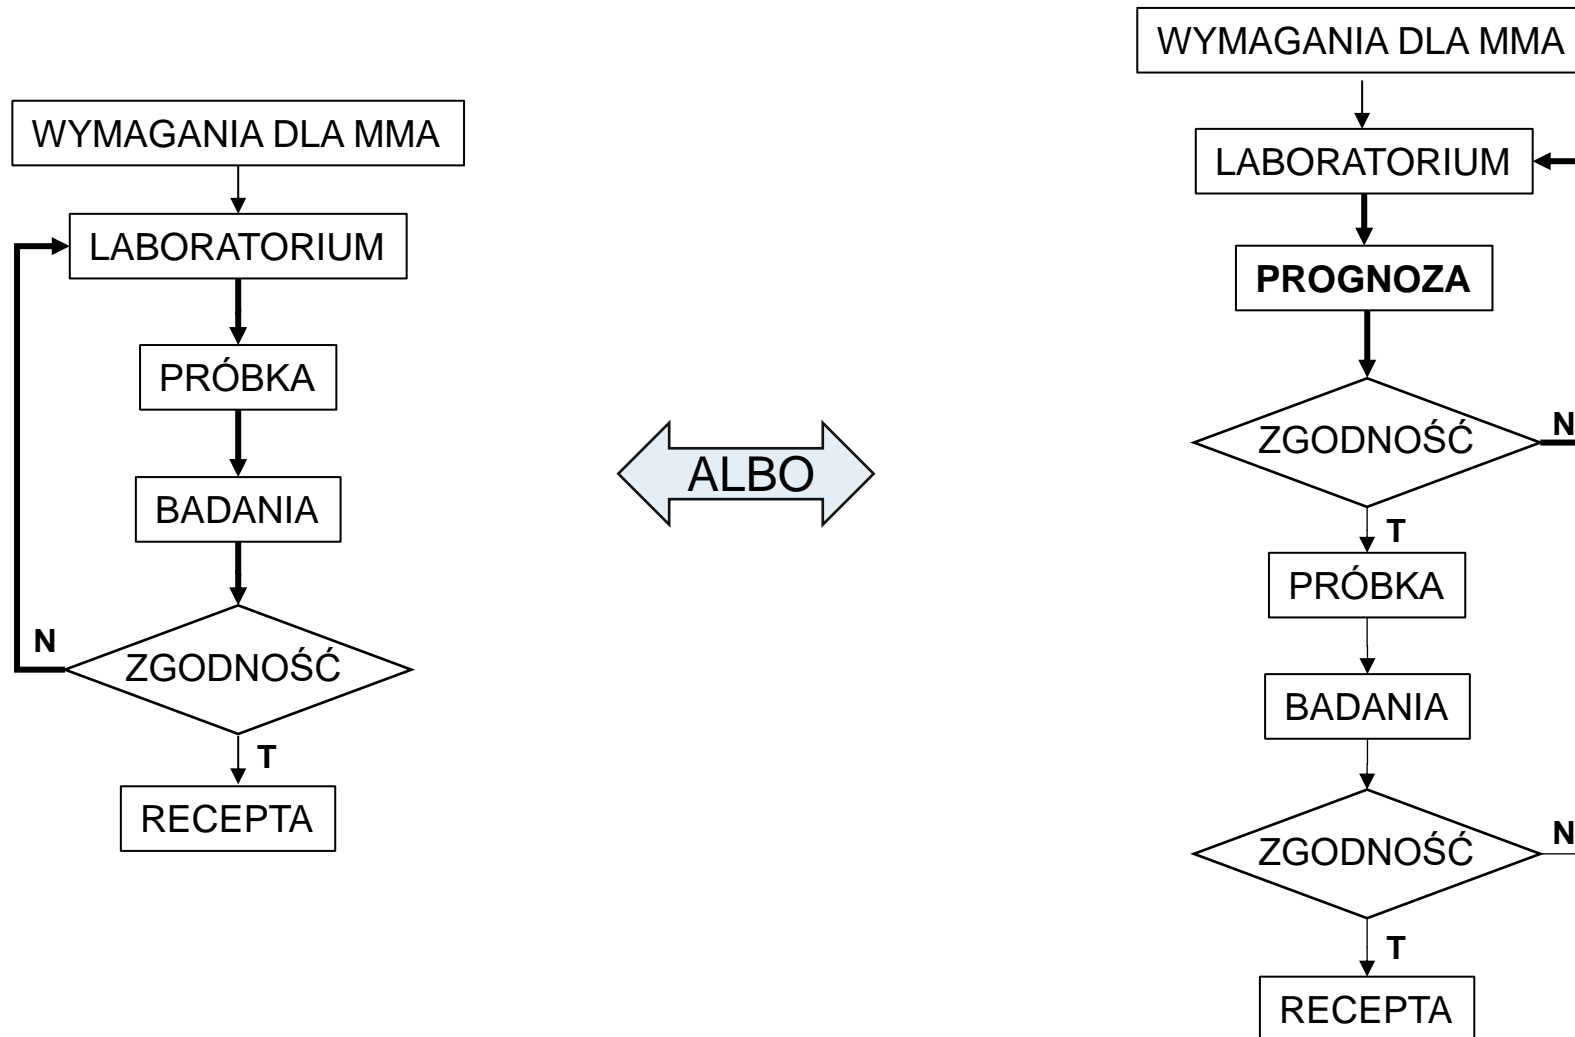
## OBSZARY ZASTOSOWAŃ SI



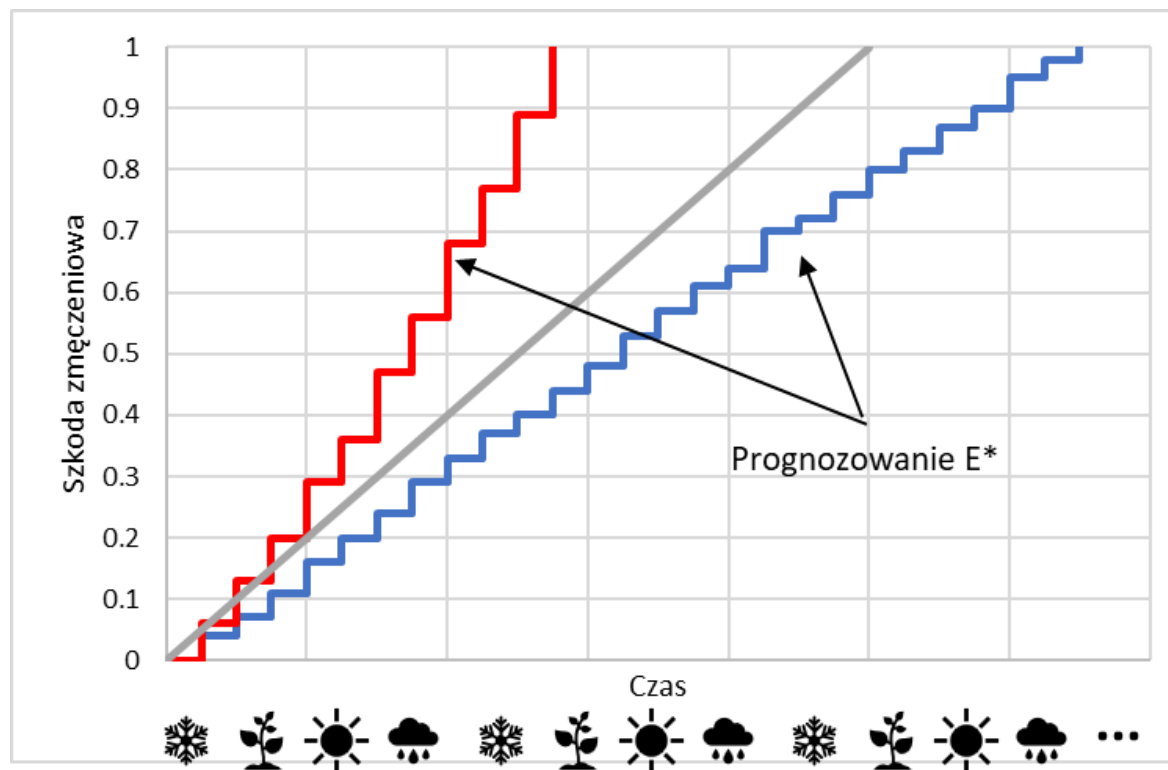
## DLACZEGO MODUŁ SPRĘŻYSTOŚCI MIESZANKI MINERALNO-ASFALTOWEJ $E^*$ JEST WAŻNY?



## FAZA PROJEKTOWA - PROJEKTOWANIE MIESZANKI



## FAZA PROJEKTOWA – WYMIAROWANIE KONSTRUKCJI



## JEDEN PARAMETR – DWA PROBLEMY


Jak przewidzieć  $E^*$  w różnych warunkach?

Mieszanka istnieje i została przebadana w różnych kombinacjach temperatury i częstotliwości obciążenia –  
INTERPOLACJA

Znany skład mieszanki –  
OBLICZENIA ANALITYCZNE



## PREDYKCJA E\* - RÓWNANIE WITCZAKA

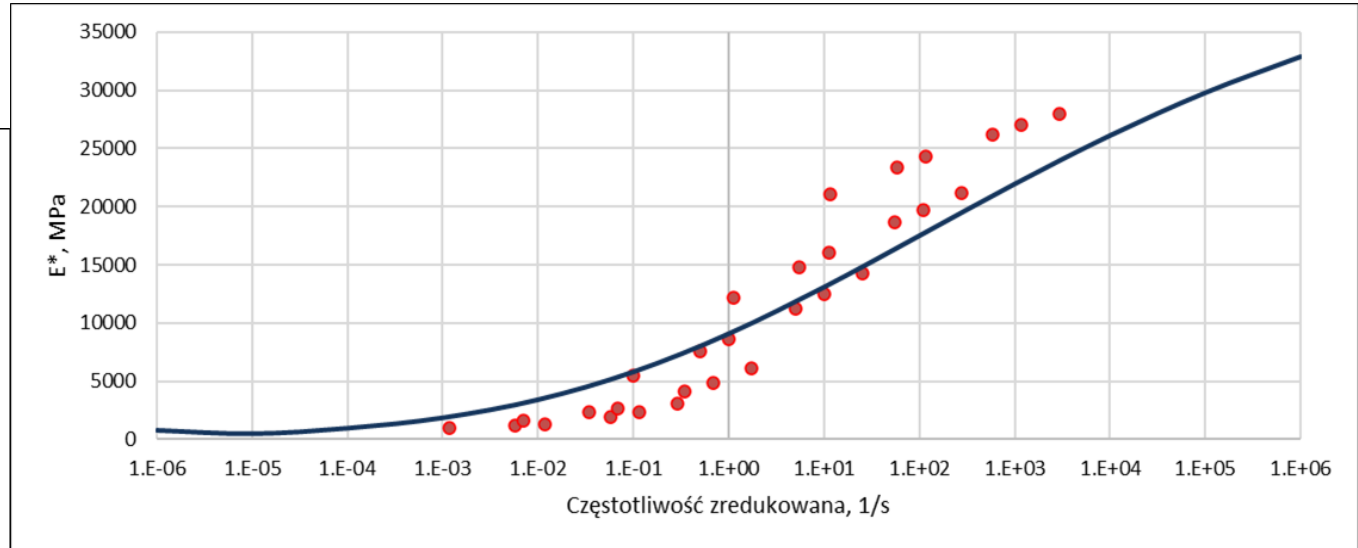
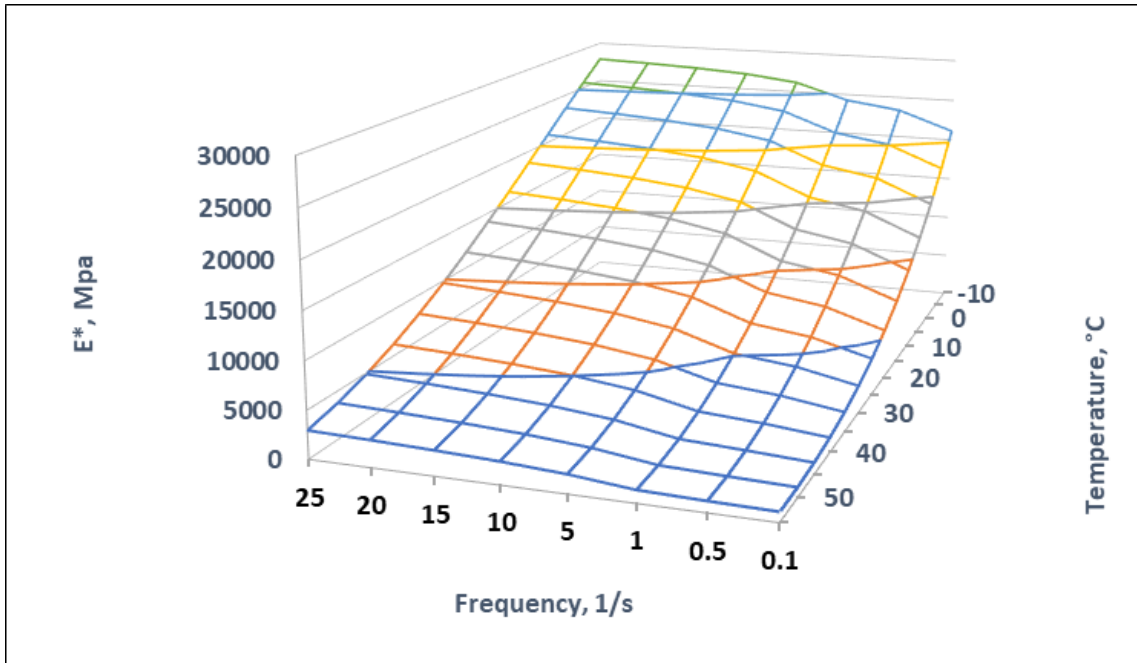


$$\log E = -1.249937 + 0.029232 \cdot p_{200} - 0.001767 \cdot (p_{200})^2 - 0.002841 \cdot p_4 - 0.058097 \cdot V_a - 0.802208 \cdot \frac{Vb_{eff}}{(Vb_{eff} + V_a)} + \frac{3.871977 - 0.0021 \cdot p_4 + 0.003958 \cdot p_{38} - 0.000017 \cdot (p_{38})^2 + 0.005470 \cdot p_{34}}{1 + e^{(-0.603313 - 0.313351 \cdot \log(f) - 0.393532 \cdot \log(\eta))}}$$

|             |                                  |
|-------------|----------------------------------|
| h           | Lepkość lepiszcza                |
| F           | Szybkość obciążania              |
| $V_a$       | Zawartość pustej przestrzeni     |
| $Vb_{eff}$  | Efektywna zawartość asfaltu      |
| $\rho_{34}$ | Odsiew na sicie 3/4 cala (19.05) |
| $\rho_{38}$ | Odsiew na sicie 3/8 cala (9.525) |
| $r_4$       | Odsiew na sicie nr 4 (4.76)      |
| $r_{200}$   | Przesiew na sicie nr 200 (0.074) |

## KRZYWE WIODĄCE

zasada superpozycji czasowo-temperaturowej




Stosowanie krzywych wiodących wiąże się z ograniczeniami, przy których model daje prawidłowe wyniki. Zakłada się, że badane materiały pracują w zakresie liniowej lepkości.



## INNE DROGI POSTĘPOWANIA

Przedstawione metody są kłopotliwe i bywają niedokładne  
**szukamy więc pomocy w sztucznej inteligencji!**



KILKA UWAG OGÓLNYCH

# PODOBNE INICJATYWY BYŁY PRZEDSIĘBRANE JUŻ DAWNO

IOWA STATE UNIVERSITY  
Digital Repository

Civil, Construction and Environmental Engineering  
Conference Presentations and Proceedings

2007


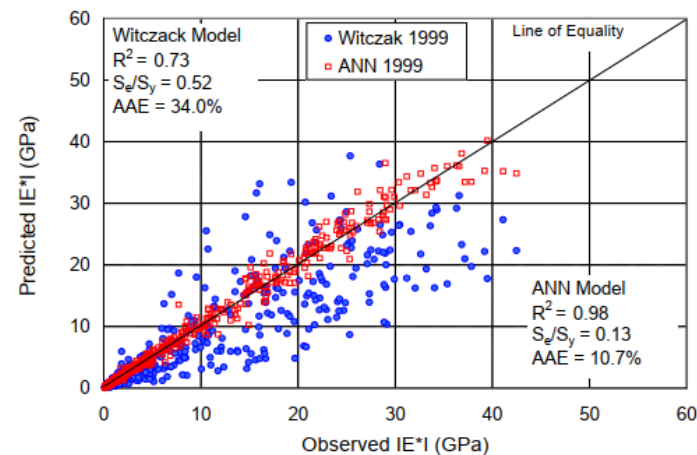
## Hot Mix Asphalt Dynamic Modulus Prediction Models Using Neural Networks Approach

Halil Ceylan  
Iowa State University, hceylan@iastate.edu

Sunghwan Kim  
Iowa State University, sunghwan@iastate.edu

Kasthurirangan Gopalakrishnan  
Iowa State University, rangnan@iastate.edu

+ Richard Kim



## REGRESJA

Równanie regresji

$$\hat{y} = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n$$

$\hat{y}$  – prognozowana wartość


$n$  – liczba cech

$x_i$  – wartość  $i$  – tej cechy


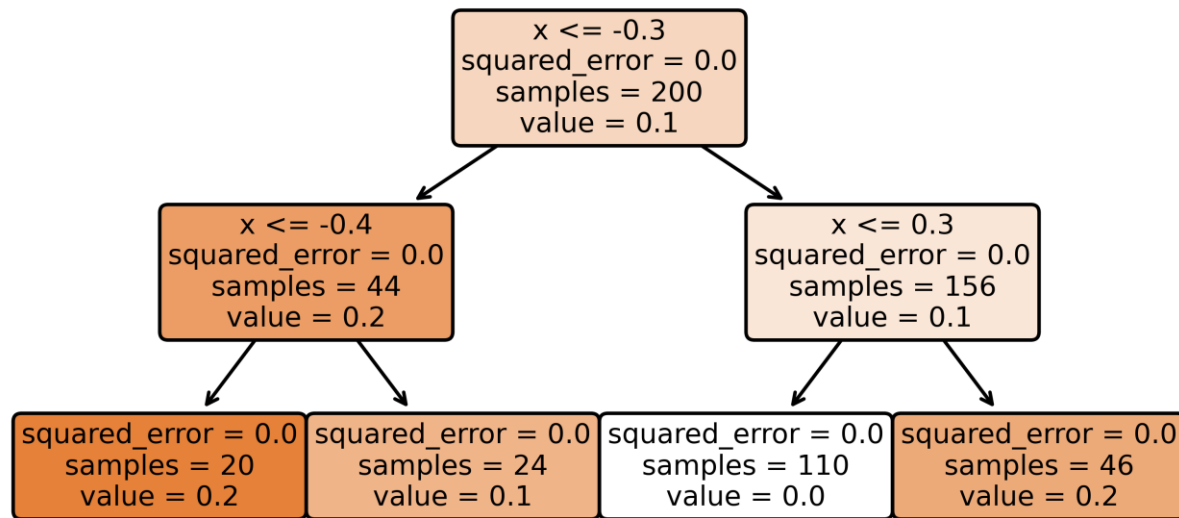
$\theta_j$  –  $j$  – ty parametr modelu

Funkcja błędu (kosztu)

$$MSE = \frac{1}{m} \sum_{i=1}^m (\theta x^{(i)} - y^{(i)})^2$$




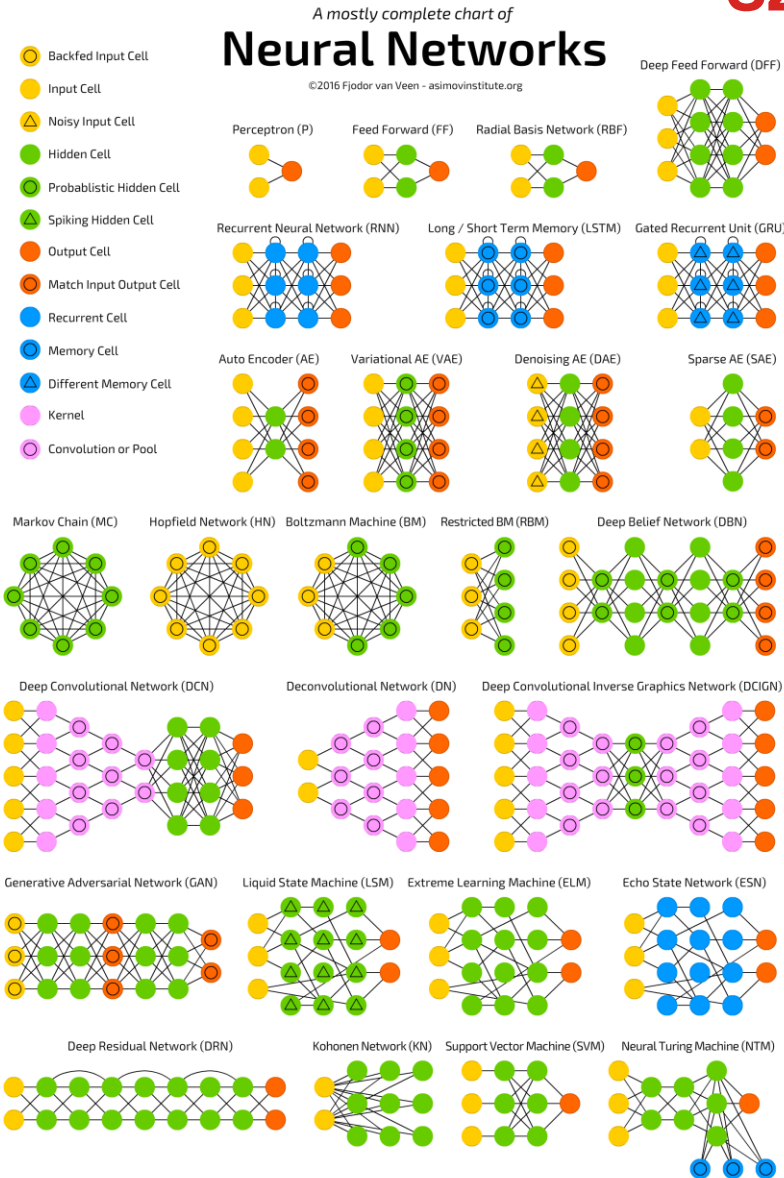


## DRZEWIA DECYZYJNE I LASY LOSOWE



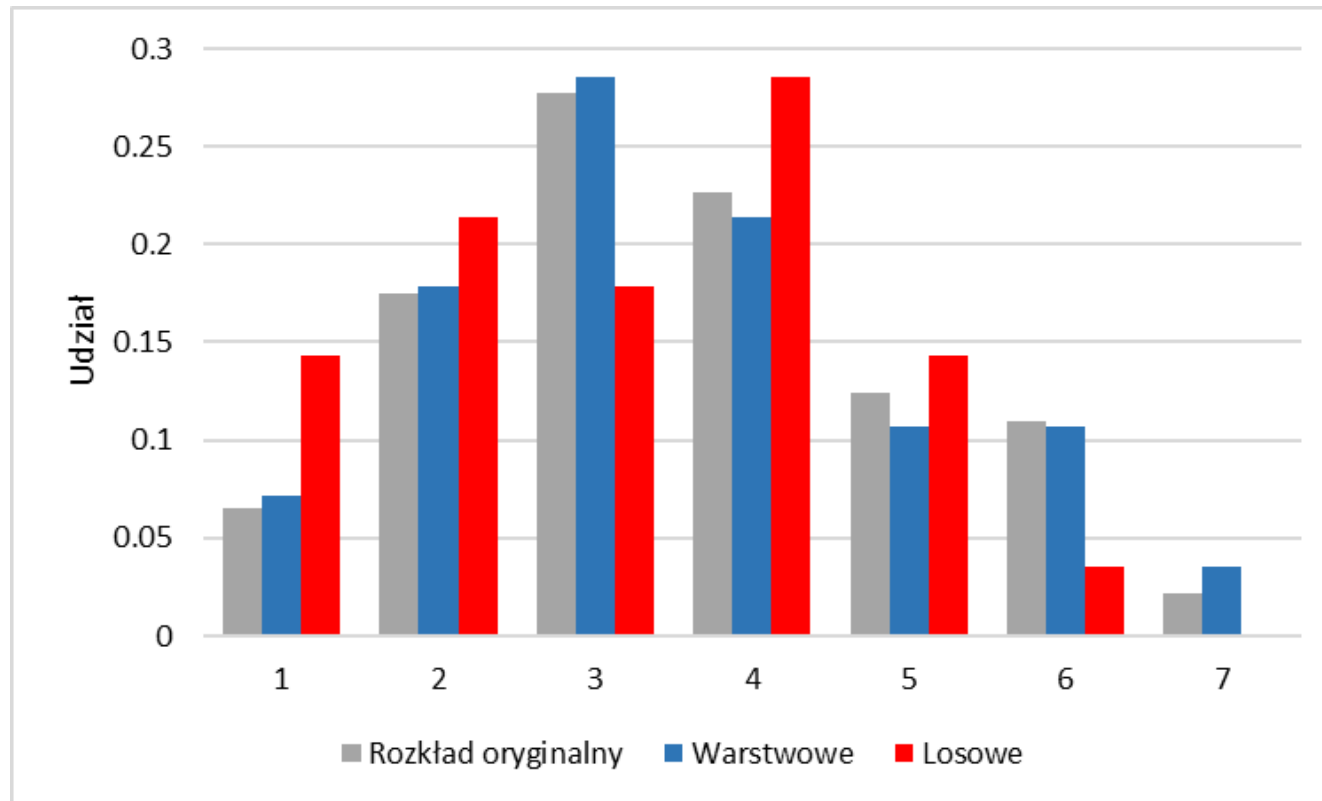
Jedną z form uczenia zespołowego polegającą na uczeniu drzew na losowo wybranych podzbiorach zbioru cech. Wynik uczenia jest średnią przy regresji lub dominantą przy klasyfikacji zbioru wyników poszczególnych drzew

# SZTUCZNA SIĘĆ NEURONOWA



## PRZYGOTOWANIA DO UCZENIA

1. Oczyszczenie i uzupełnienie danych
2. Odpowiednie przygotowanie zbioru danych testowych – losowanie warstwowe
3. Redukcja wymiarowości
4. Dostrajanie hiperparametrów

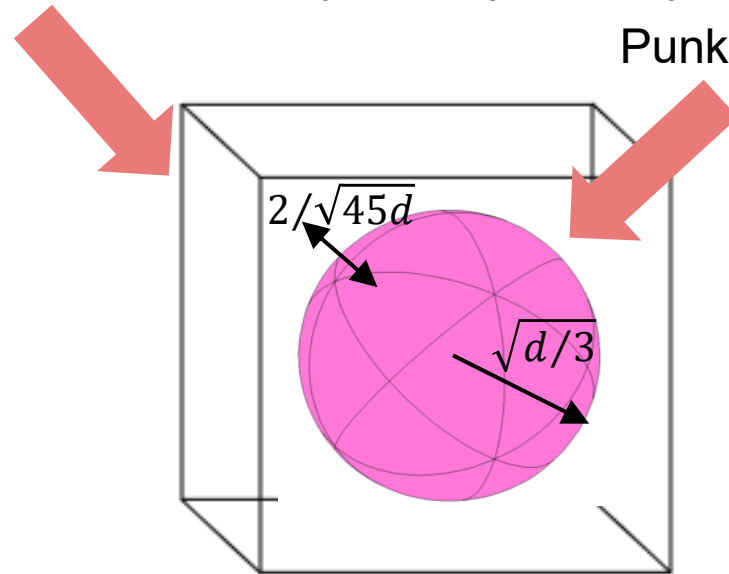


|    |          |      |
|----|----------|------|
| 1  | Type     | 4247 |
| 2  | Grade    | 4247 |
| 3  | ECS      | 3720 |
| 4  | aContent | 4247 |
| 5  | mmaVoid  | 4247 |
| 6  | aEffect  | 4247 |
| 7  | R31500   | 3751 |
| 8  | R22400   | 3751 |
| 9  | R16000   | 3751 |
| 10 | R11200   | 3751 |
| 11 | R08000   | 3751 |
| 12 | R05600   | 3751 |
| 13 | R04000   | 3751 |
| 14 | R02000   | 3751 |
| 15 | R00125   | 3751 |
| 16 | R00063   | 3751 |
| 17 | Pen5     | 3255 |
| 18 | Pen15    | 3255 |
| 19 | Pen25    | 3255 |
| 20 | RB       | 3751 |
| 21 | v090     | 2511 |
| 22 | v135     | 3534 |
| 23 | v160     | 3565 |
| 24 | T        | 4247 |
| 25 | f        | 4247 |
| 26 | G        | 3869 |
| 27 | aShift   | 3869 |
| 28 | E        | 4247 |
| 29 | mmaShift | 4247 |

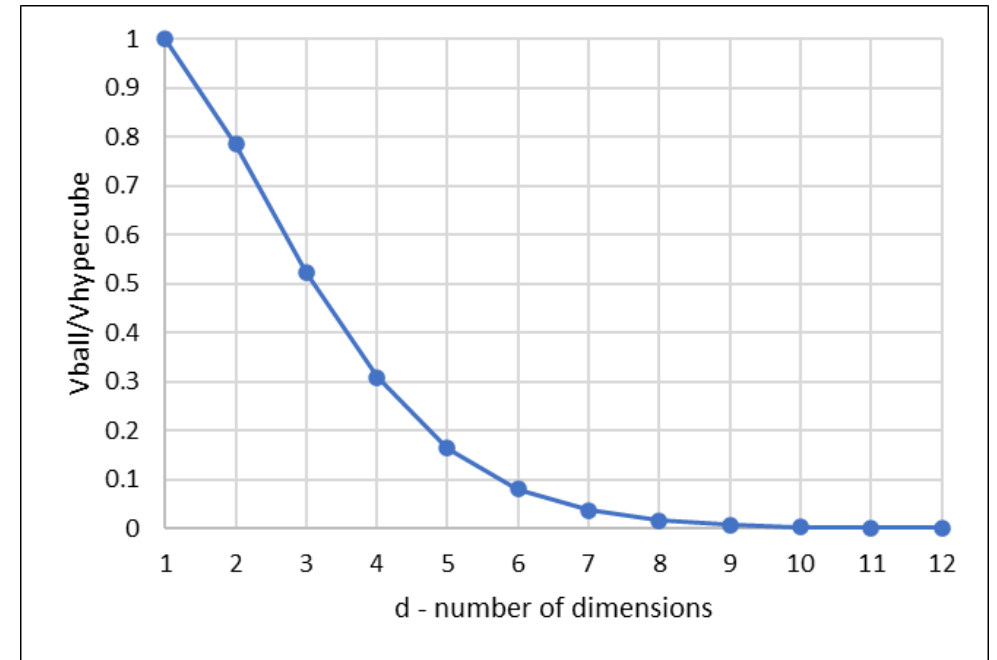
## KLĄTWA WYMIAROWOŚCI

Wartości cech tworzą wielowymiarowy hipersześcian.

Punkty danych tworzą wielowymiarową sferę




Nowa próbka może znajdować się daleko  $\sqrt{d}/6$  od przykładów uczących, wyliczone prognozy będą mniej pewne niż uzyskane w przestrzeni o mniejszej liczbie wymiarów.



**Wraz ze wzrostem liczby wymiarów zwiększa się ryzyko przeuczenia modelu**



Predykcja modułu sztywności mieszanek mineralno-asfaltowych za pomocą SI

|                       |              |
|-----------------------|--------------|
| <b>E</b>              | <b>1.000</b> |
| <b>T</b>              | <b>0.884</b> |
| <b>f</b>              | <b>0.188</b> |
| <b>Vb</b>             | <b>0.155</b> |
| <b>Uziarnienie</b>    | <b>0.154</b> |
| <b>Penetracja @25</b> | <b>0.135</b> |
| <b>Odsiew 5.6</b>     | <b>0.126</b> |
| <b>Penetracja @15</b> | <b>0.125</b> |
| <b>Vbeff</b>          | <b>0.118</b> |
| <b>Typ</b>            | <b>0.110</b> |
| <b>Vba</b>            | <b>0.107</b> |
| <b>Odsiew 11.2</b>    | <b>0.101</b> |
| <b>Odsiew 16</b>      | <b>0.091</b> |
| <b>Lepkość @90</b>    | <b>0.084</b> |
| <b>PiK</b>            | <b>0.083</b> |
| <b>Odsiew 2</b>       | <b>0.083</b> |
| <b>Penetracja @5</b>  | <b>0.080</b> |
| <b>Odsiew 22.4</b>    | <b>0.059</b> |
| <b>Odsiew 1.25</b>    | <b>0.054</b> |
| <b>Odsiew 4</b>       | <b>0.051</b> |
| <b>Lepkość @160</b>   | <b>0.047</b> |
| <b>Odsiew 8</b>       | <b>0.030</b> |
| <b>Lepkość @135</b>   | <b>0.022</b> |
| <b>Odsiew 0.063</b>   | <b>0.012</b> |
| <b>Odsiew 31.5</b>    | <b>brak</b>  |





## ISTOTNOŚĆ CECH




# REZULTATY

Opracowane modele SI były uczone na:

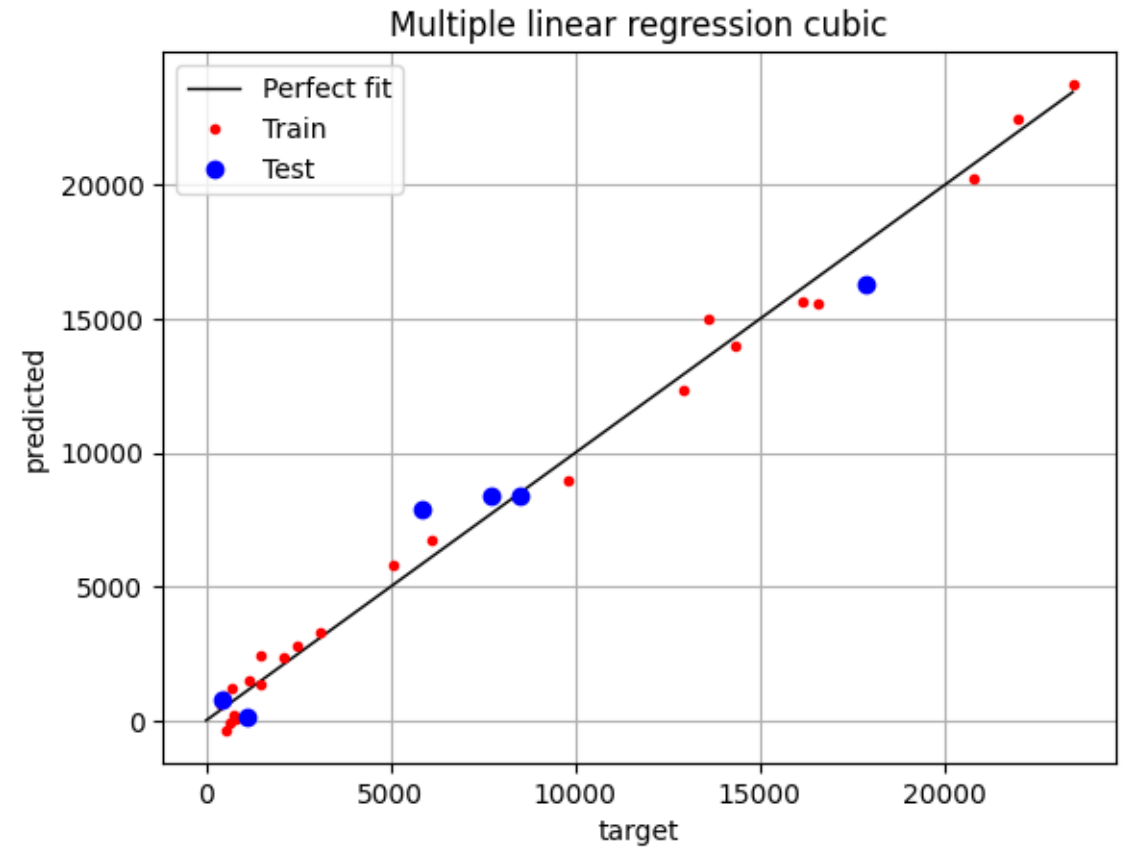
137 próbek mieszanek

4247 pomiarów  $E^*$

## „KRZYWE WIODĄCE” – Z REGRESJI WIELORAKIEJ






$$R^2 = 0.929$$






$$R^2 = 0.959$$

# PREDYKCJA E\* – Z WYKORZYSTANIEM LASU LOSOWEGO



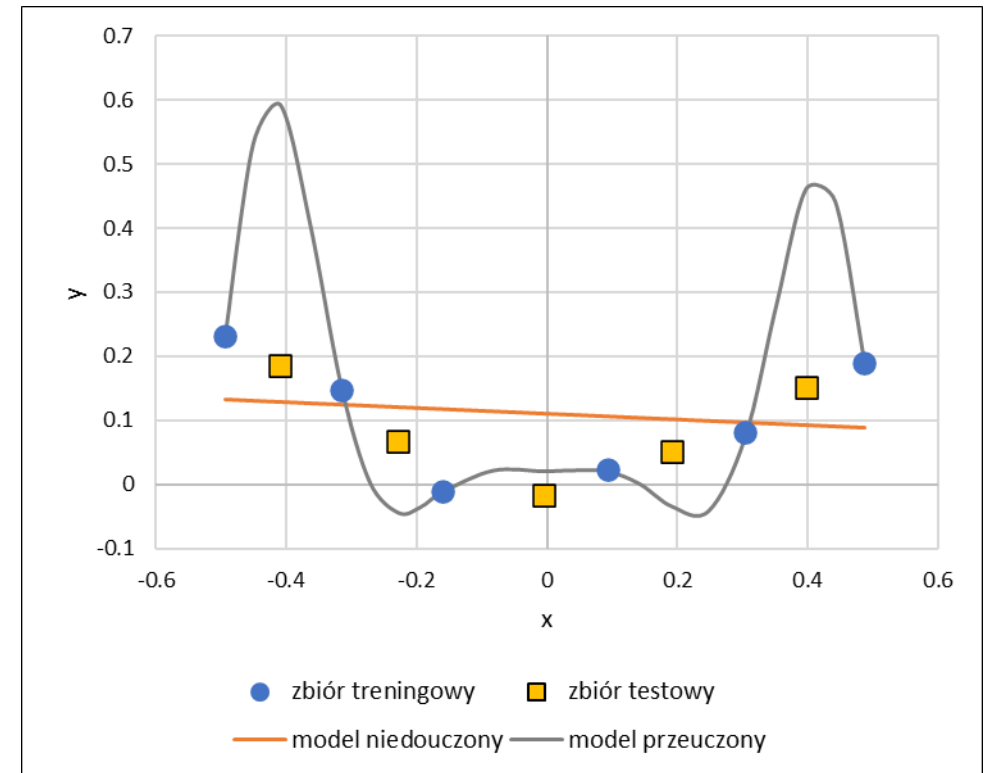
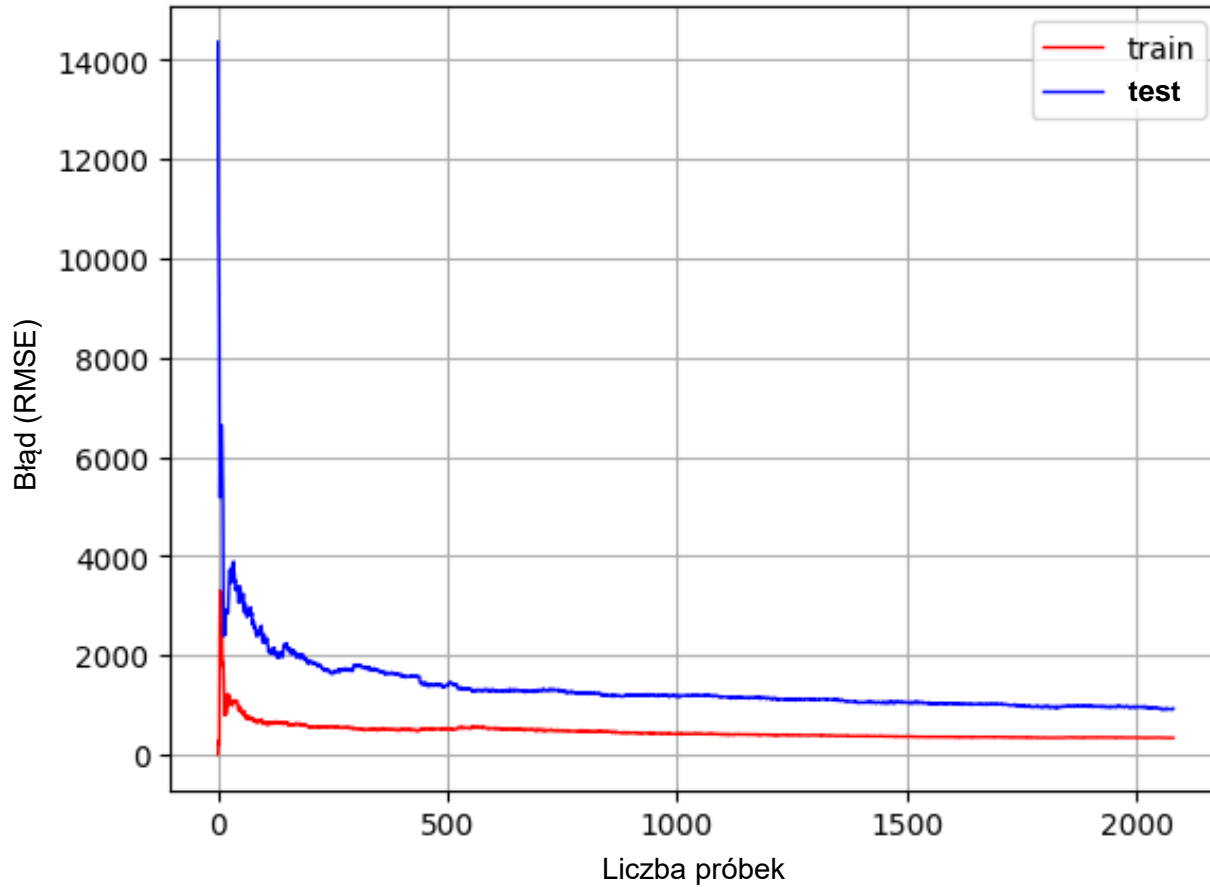
$R^2 = 0.958$   
 $m_0 = 458$   
 $m_1 = 0.991$

# PREDYKCJA E\* – Z WYKORZYSTANIEM SIECI NEURONOWEJ




$R^2 = 0.965$   
 $m_0 = 227$   
 $m_1 = 0.976$

## POTENCJAŁ DO DALSZEGO POSTĘPU




# SKUTECZNOŚĆ SI



## PODSUMOWANIE



**Złożone w budowie ale proste w użyciu narzędzie**



**Możliwe stałe doskonalenie**



**Potencjalne możliwości wykorzystania**

- **faza projektowania mieszanek i wymiarowania nawierzchni**
- **bieżąca kontrola produkcji w wytwórni**
- **kompleksowa kontrola gotowego produktu: nawierzchni drogowej / lotniskowej / etc.**



**Dziękuję za  
uwagę.**