

Przykładowe rozwiązania laboratoriów 3 z Modelowania Matematycznego

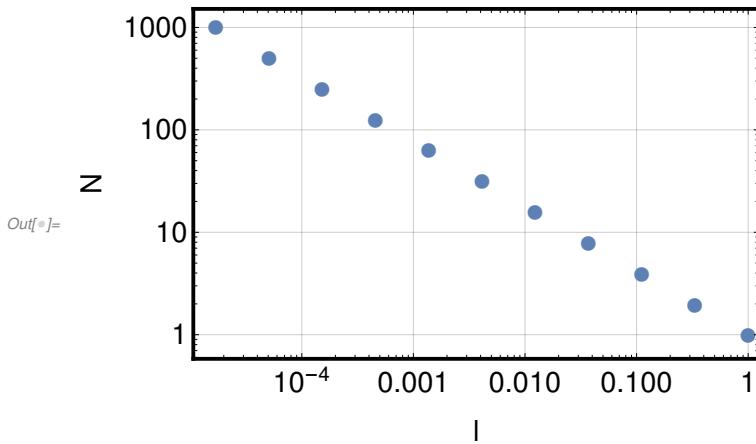
Zbiór Cantora

Zapisujemy wartości N oraz l odpowiadające kolejnym metodom pokrycia zioru Cantora odcinkami:

```
In[1]:= lista = {{1, 1}, {1/3, 2}, {1/9, 4}, {1/27, 8}}  
Out[1]= {{1, 1}, {1/3, 2}, {1/9, 4}, {1/27, 8}}
```

Zgadujemy ogólny przepis postaci

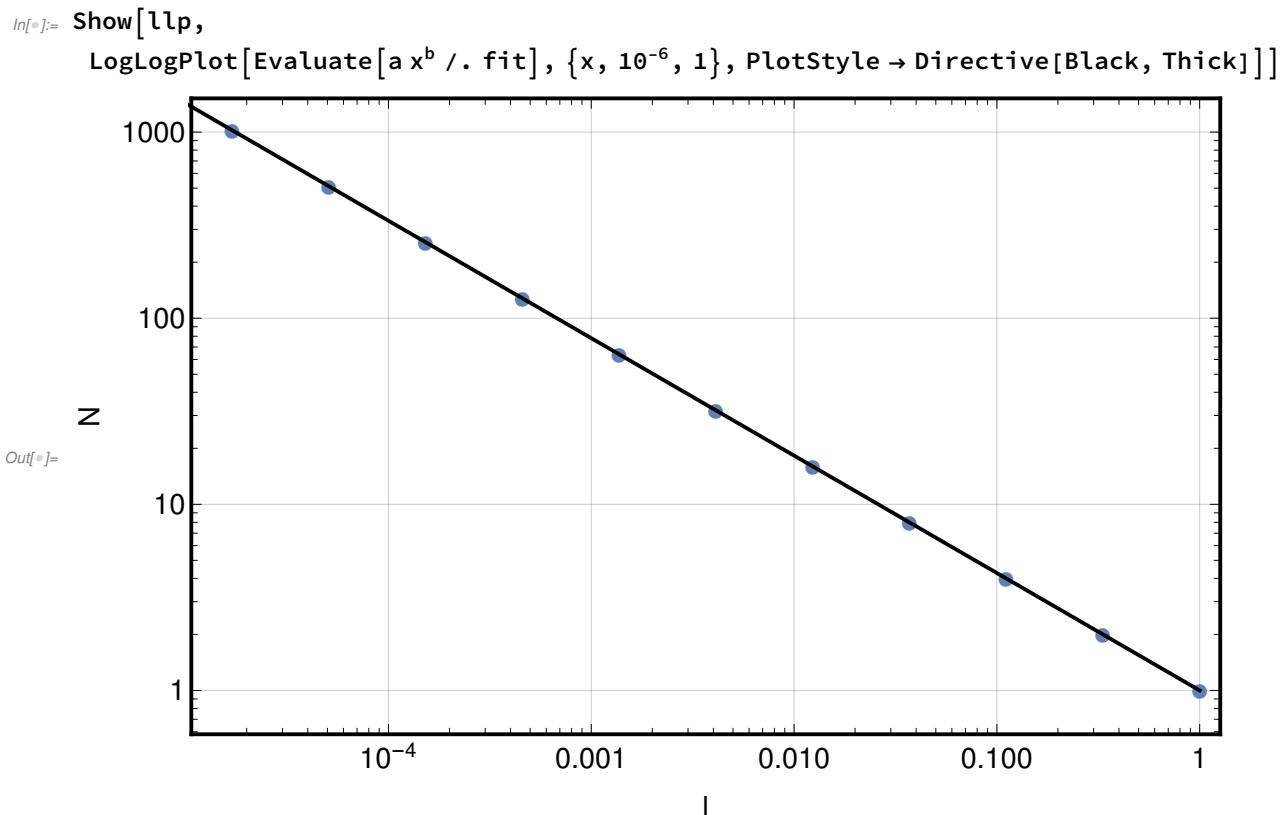
```
In[2]:= lista = Table[{3^{-n}, 2^n}, {n, 0, 10}];  
  
In[3]:= llp = ListLogLogPlot[lista, Frame -> True, FrameStyle -> Directive[Thick, 15],  
GridLines -> Automatic, FrameLabel -> {"l", "N"}, PlotMarkers -> {Automatic, Medium}]
```



Dopasowujemy relację potęgową

```
In[4]:= fit = FindFit[lista, a x^b, {a, b}, x]  
Out[4]= {a -> 1., b -> -0.63093}
```

Sprawdzamy czy przewidywanie jest dobre



Sprawdźmy wymiar fraktalny z teoretycznym

$$\ln[1]:= \text{Log}[2] / \text{Log}[3] // \text{N}$$

$$\text{Out}[1]= 0.63093$$

Narysujmy zbiór Cantora: najpierw podejście naiwne, w którym ręczni wpisujemy kolejne etapy

```
In[1]:= Graphics[{Thick, Line[{{0, 1/2}, {1, 1/2}}],  
Line[{{0, 2/2}, {1/3, 2/2}}], Line[{{2/3, 2/2}, {3/3, 2/2}}],  
Line[{{0, 3/2}, {1/9, 3/2}}], Line[{{2/9, 3/2}, {3/9, 3/2}}],  
Line[{{6/9, 3/2}, {7/9, 3/2}}], Line[{{8/9, 3/2}, {9/9, 3/2}}]}]
```



```
Out[1]=
```



Metoda bardziej zautomatyzowana (zachęcam do jej przeanalizowania, dla czytelności pozostawiam etapy posrednie, ale ze średnikiem na końcu, żeby się dało czytać)

```
In[8]:= RandomReal[{0, 1}, {40}];

RealDigits[#, 3, 3, -1] & /@ RandomReal[{0, 1}, {40}];

RealDigits[#, 3, 1, -1][[1]] & /@ RandomReal[{0, 1}, {40}];

Select[RandomReal[{0, 1}, {100}], FreeQ[RealDigits[#, 3, 1, -1][[1]], 1] &

Graphics[{LightGray, Rectangle[{-0.1, -0.1}, {1.1, 0.1}], Black, Point[{#, 0}] & /@

Select[RandomReal[{0, 1}, {100}], FreeQ[RealDigits[#, 3, 1, -1][[1]], 1] &}]]

Out[8]= {0.958439, 0.276597, 0.760456, 0.0574913, 0.820713, 0.254615, 0.871778, 0.791844,
0.833977, 0.0312574, 0.829756, 0.281618, 0.118817, 0.280521, 0.0437835,
0.769174, 0.295871, 0.701031, 0.239369, 0.163857, 0.117388, 0.332793,
0.0198804, 0.873407, 0.0772406, 0.235403, 0.152083, 0.210648, 0.668668,
0.211963, 0.720511, 0.943981, 0.67972, 0.0443203, 0.947878, 0.709915,
0.692548, 0.184474, 0.014869, 0.28539, 0.0727415, 0.753994, 0.0727776,
0.10781, 0.976124, 0.145366, 0.841362, 0.00109985, 0.272986, 0.747274,
0.980131, 0.133139, 0.156244, 0.807356, 0.0984021, 0.0187227, 0.255321,
0.298421, 0.199664, 0.738847, 0.711779, 0.172265, 0.897501, 0.984916, 0.999632,
0.140185, 0.201683, 0.729924, 0.89361, 0.913346, 0.789339, 0.672218, 0.250507}
```

Out[8]=

Zmieniamy teraz trzeci z parametrów funkcji RealDigits i obserwujemy kolejne “pokolenia”

```
In[1]:= Table[Graphics[{LightGray, Rectangle[{-0.1, -0.1}, {1.1, 0.1}], Black,
PointSize[0.01], Point[{#, 0}] & /@ Select[RandomReal[{0, 1}, {1000}],
FreeQ[RealDigits[#, 3, n, -1][[1]], 1] &]}], {n, 6}]
```

Out[1]=

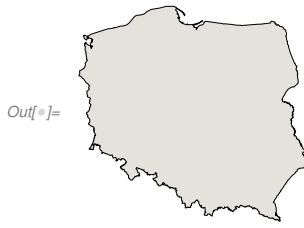
```
In[2]:= Graphics[{LightGray, Rectangle[{-0.01, -0.01}, {1.01, 0.01}],
Black, PointSize[0.001], Point[{#, 0}] & /@
Select[RandomReal[{0, 1}, {1000}], FreeQ[RealDigits[#, 3, 6, -1][[1]], 1] &}]]
```

Out[2]=

Wymiar pudełkowy dla rzeczywistej grafiki

Wczytujemy ulubioną grafikę

```
In[1]:= pl = CountryData["Poland", "Shape"]
```



Sprawdzamy rozmiar obrazka

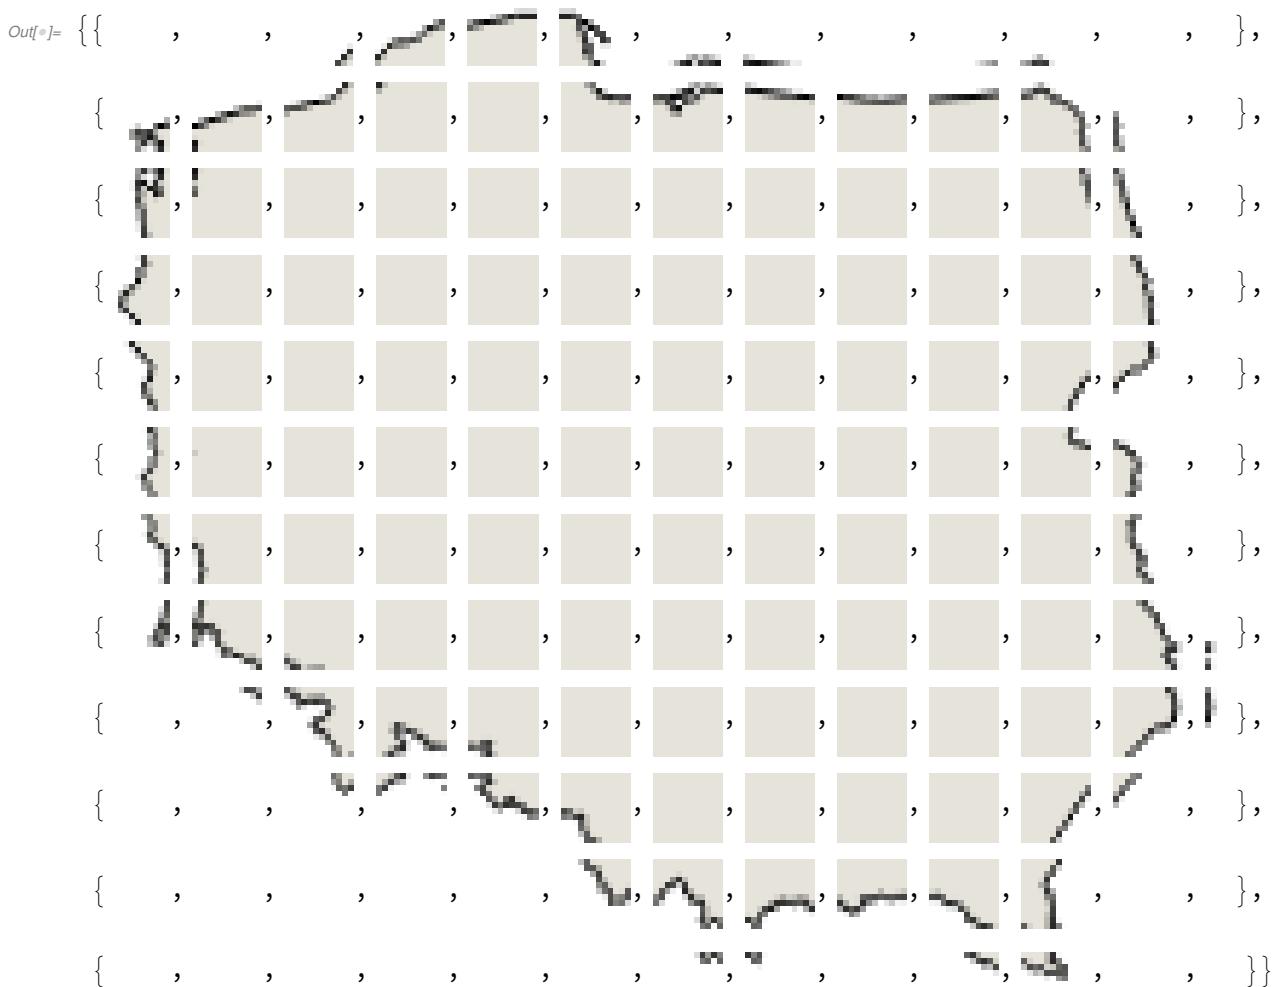
```
In[2]:= dimpl = ImageDimensions[pl]
```

```
Out[2]= {124, 117}
```

Przyjmujemy za parametr δ rozmiar "plasterka" na jakie kroimy grafikę

```
In[3]:= δ = 10;
```

```
Table[ImageTrim[pl, {{i, j}, {i + δ, j + δ}}],  
{j, dimpl[[2]] - δ, -δ, -δ}, {i, 0, dimpl[[1]], δ}]
```



Wyszukujemy plasterki, które mają w sobie tylko kolor szary

```
In[8]:= szary = Mean@Flatten[Map[Total, ImageData[], {2}]]  
δ = 10;  
Count[Mean@Flatten[Map[Total, ImageData[#], {2}]] & /@  
(Flatten@Table[ImageTrim[pl, {{i, j}, {i + δ, j + δ}}],  
{j, dimpl[[2]] - δ, -δ, -δ}, {i, 0, dimpl[[1]], δ}]), szary]  
Out[8]= 2.64314  
Out[9]= 63  
2.6430000000000002`  
Out[10]= 0
```

Zauważmy, że możemy wszystkie obliczenia przyspieszyć od razu analizując macierz, a nie obrazek. Drobne różnice wynikają z różnic w uśrednianiu wartości pikseli, nie powinny nas one niepokoić.

```
δ = 10; pltab = Map[Total, ImageData[pl], {2}];  
RepeatedTiming@Count[Mean /@  
(Flatten[#] & /@ Flatten[Partition[pltab, {δ, δ}, δ, 1, 10.], 1]), u_ /; u == szary]  
RepeatedTiming@Count[Mean@Flatten[Map[Total, ImageData[#], {2}]] & /@  
(Flatten@Table[ImageTrim[pl, {{i, j}, {i + δ, j + δ}}],  
{j, dimpl[[2]] - δ, -δ, -δ}, {i, 0, dimpl[[1]], δ}]), szary]
```

```
Out[11]= {0.0018, 65}
```

```
Out[12]= {2.38, 63}
```

Sprawdźmy o ile przyspieszyło (dla $\delta = 10$)

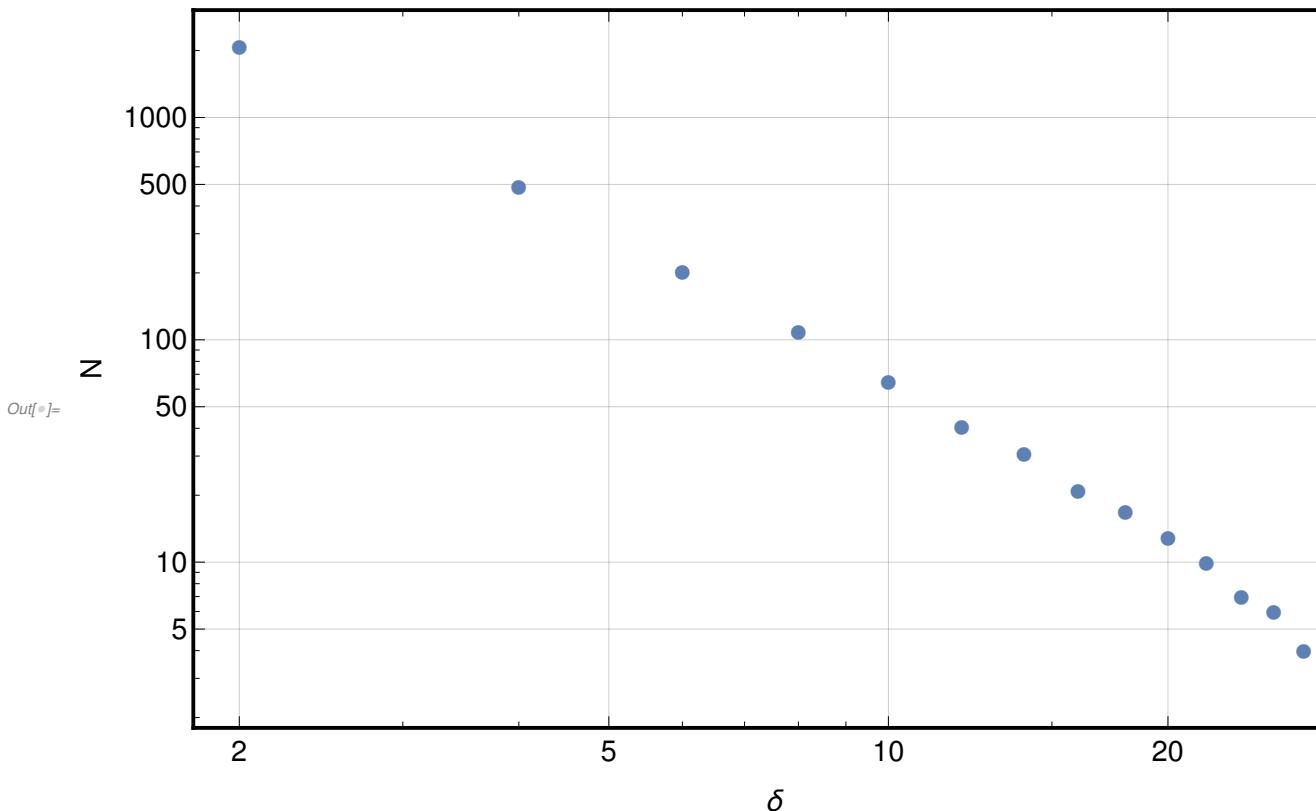
```
In[13]:= 2.38 / 0.001840526119402985`2.
```

```
Out[13]= 1293.11
```

Skupmy się zatem na metodzie szybszej: policzymy N dla różnych rozmiarów $l=\delta$

```
In[14]:= tab = Table[  
{δ, Count[Mean /@ (Flatten[#] & /@ Flatten[Partition[pltab, {δ, δ}, δ, 1, 10.], 1]),  
u_ /; u == szary]}, {δ, 2, 30, 2}]  
Out[14]= {{2, 2097}, {4, 491}, {6, 204}, {8, 109}, {10, 65}, {12, 41}, {14, 31},  
{16, 21}, {18, 17}, {20, 13}, {22, 10}, {24, 7}, {26, 6}, {28, 4}, {30, 3}}
```

```
In[8]:= llp = ListLogLogPlot[tab, Frame → True, FrameStyle → Directive[Thick, 15],
  GridLines → Automatic, FrameLabel → {" $\delta$ ", "N"}, PlotMarkers → {Automatic, Medium}]
```

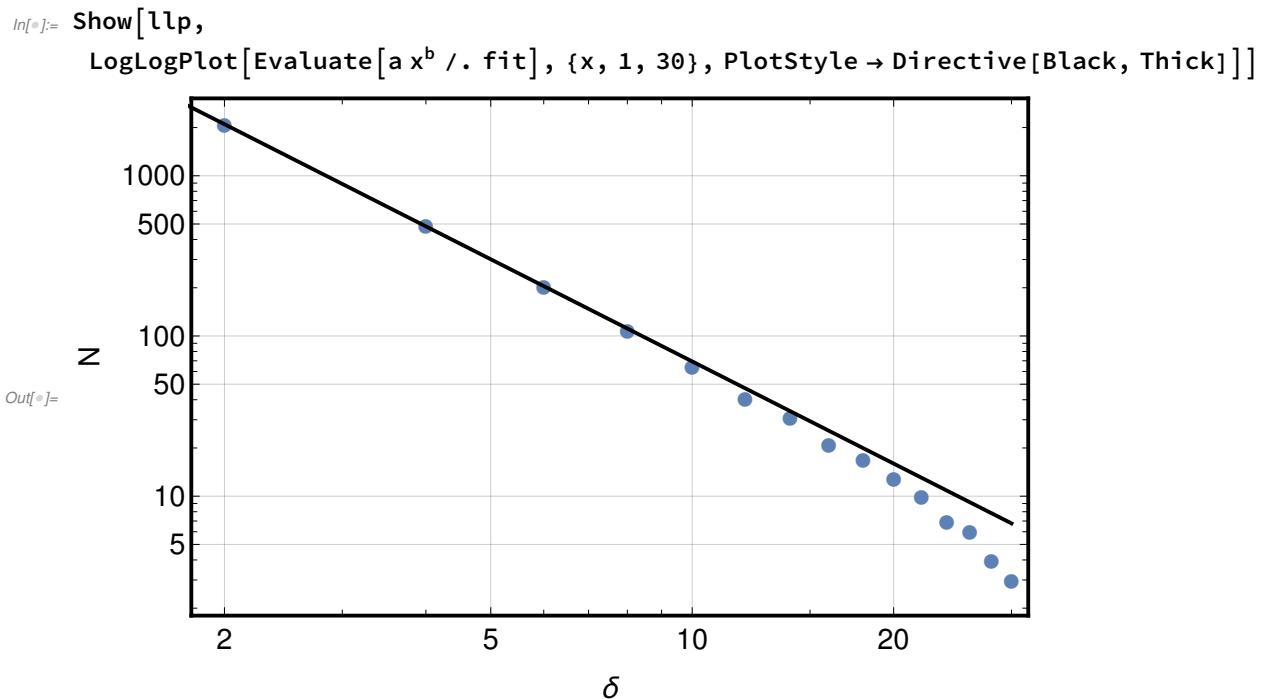


Dopasowujemy relację potęgową

```
In[9]:= fit = FindFit[tab, a xb, {a, b}, x]
```

```
Out[9]= {a → 9110.35, b → -2.11843}
```

Sprawdzamy czy przewidywanie jest dobre

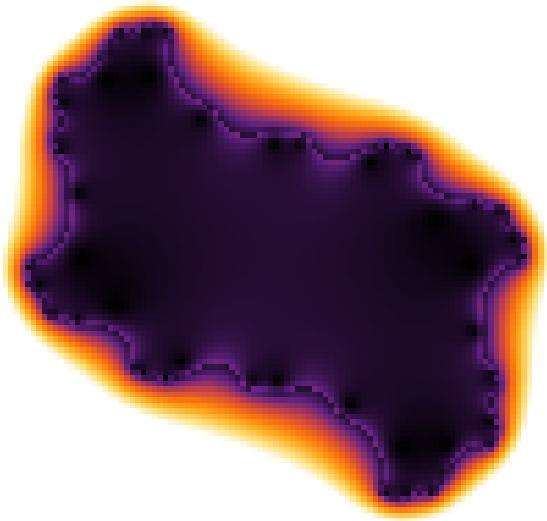


Wymiar ok. 2.118 :)

Zbiór Julii i Mandelbrota

```
In[3]:= z = Table[x + I y, {x, -2, 2, 0.025}, {y, -2, 2, 0.025}];  
c = 0.2 - 0.5 I;  
ArrayPlot[Map[If[Abs[#] > 2, Min[Log@Abs[#], 10], Abs[#]] &,  
Nest[#2 + c &, z, 6], {2}], ColorFunction -> "SunsetColors"]
```

Out[5]=



In[6]:=

```
z = ParallelTable[If[Abs[#] > 2, Min[Log@Abs[#], 10], Abs[#]] &@
Nest[(x + I y) + #2 &, 0, 7], {x, -2.5, 1, 0.025}, {y, -1.5, 1.5, 0.025}];
ArrayPlot[Transpose@z, ColorFunction -> "AvocadoColors"]
```

Out[7]=

