Przetwarzanie informacji obrazowej

Temat 2

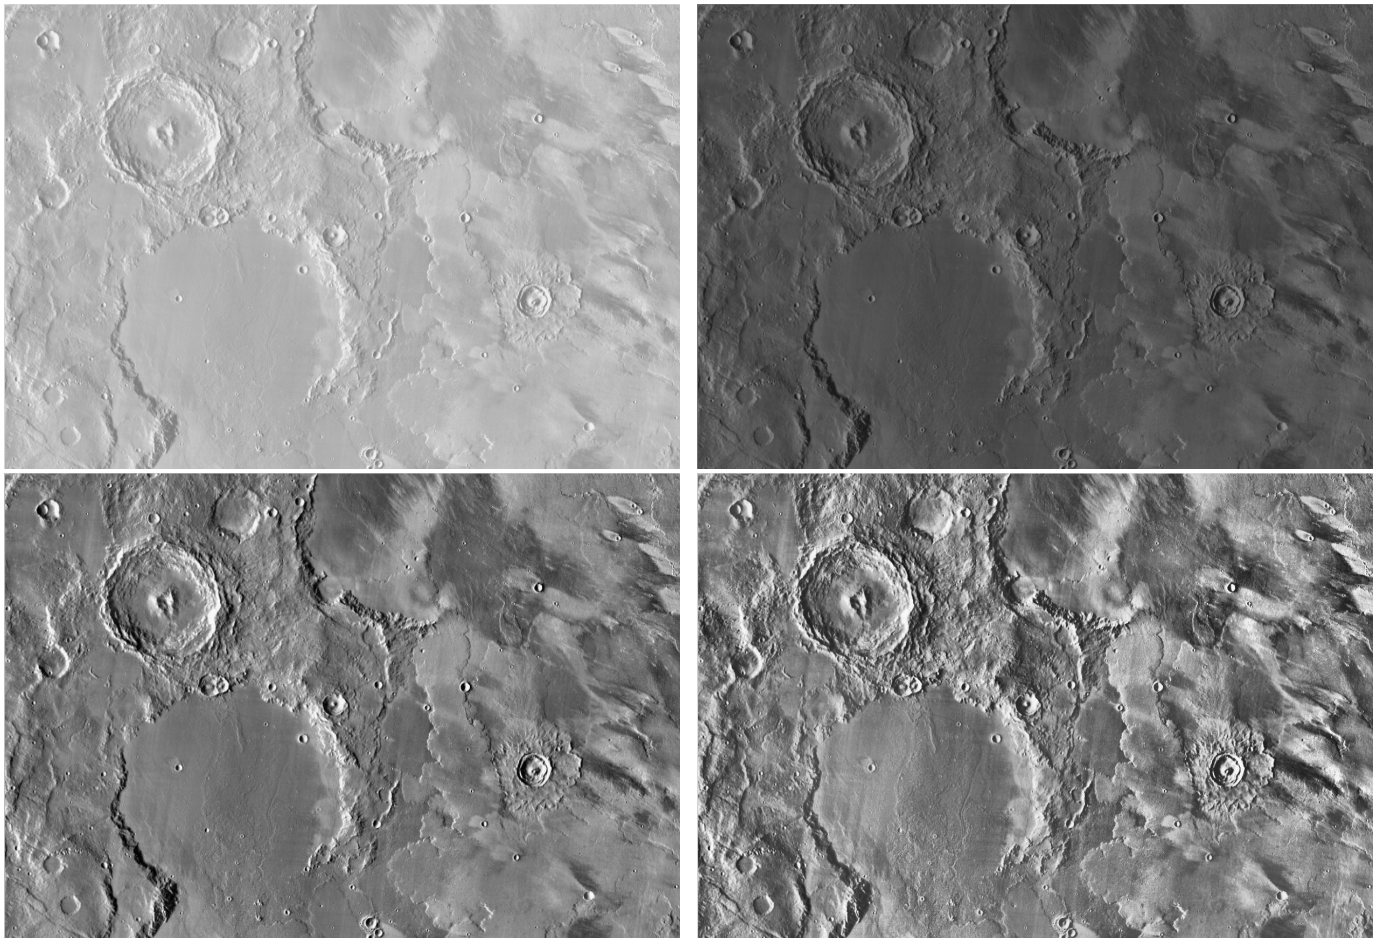
Piotr Syga

11.03.2022

Czym jest kontrast?

- różnica w intensywności, natężeniu koloru lub luminancji pikseli tworzących jeden region, a pikseli sąsiednich
- brak jednolitej definicji:
  - $\frac{I_H}{I_L}$ (uogólnienie kontrastu urządzenia, [1:1, 2^{N}:1]),
  - $\frac{I_H - I_L}{I_H}$ (dla obiektów na jednolitym tle, [0, 1]),
  - $\frac{I_H - I_L}{I_H + I_L}$ (*widoczność*, [0, 1]),
  - $\frac{I_H - I_L}{I_{\mathrm{avg}}}$ (siła kontrastu postrzeganego, $[0, 2^N - 1]$),
  - $\sqrt{\frac{1}{nm} \sum_{i,j} (I_{ij} - \bar{I})^2}$ (odległość średniokwadratowa dla intensywności znormalizowanych, [0, 1])
- niezależnie od przyjętej definicji (miary) – wysoki kontrast ułatwia zauważenie szczegółów i segmentację, może jednak powodować utratę detali

Przykłady

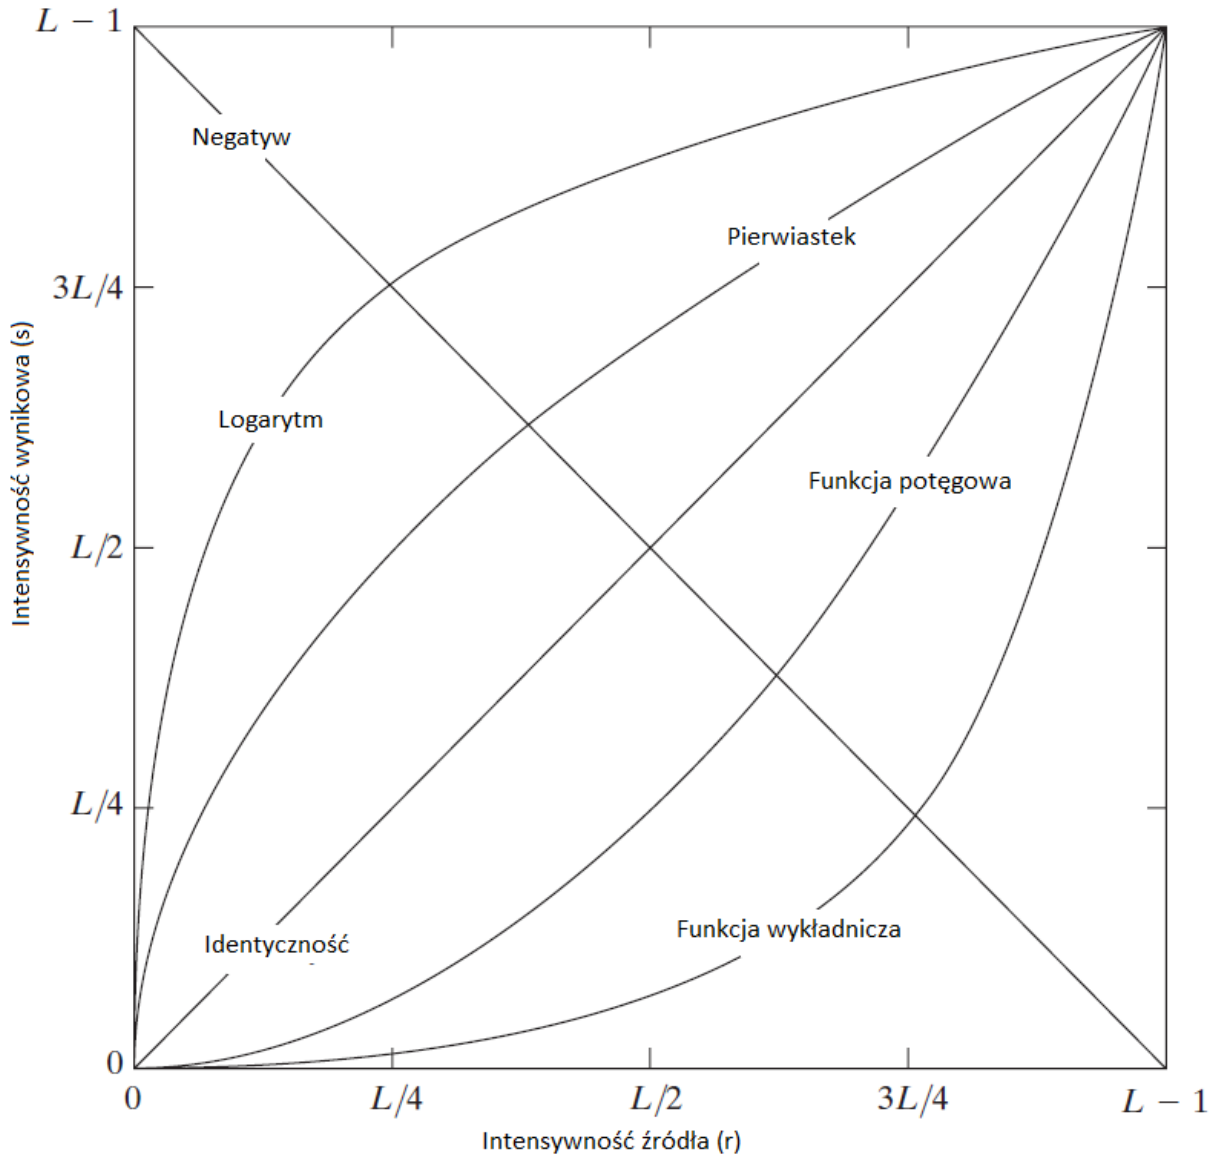


Obrazy o $I_H = 244$, $I_L = 125$; $I_H = 144$, $I_L = 25$; $I_H = 255$, $I_L = 0$ (liniowe rozciągnięcie histogramu); $I_H = 254$, $I_L = 15$ (adaptatywne wyrównanie histogramu zgodnie z rozkładem Rayleigha)

Obraz jako funkcja

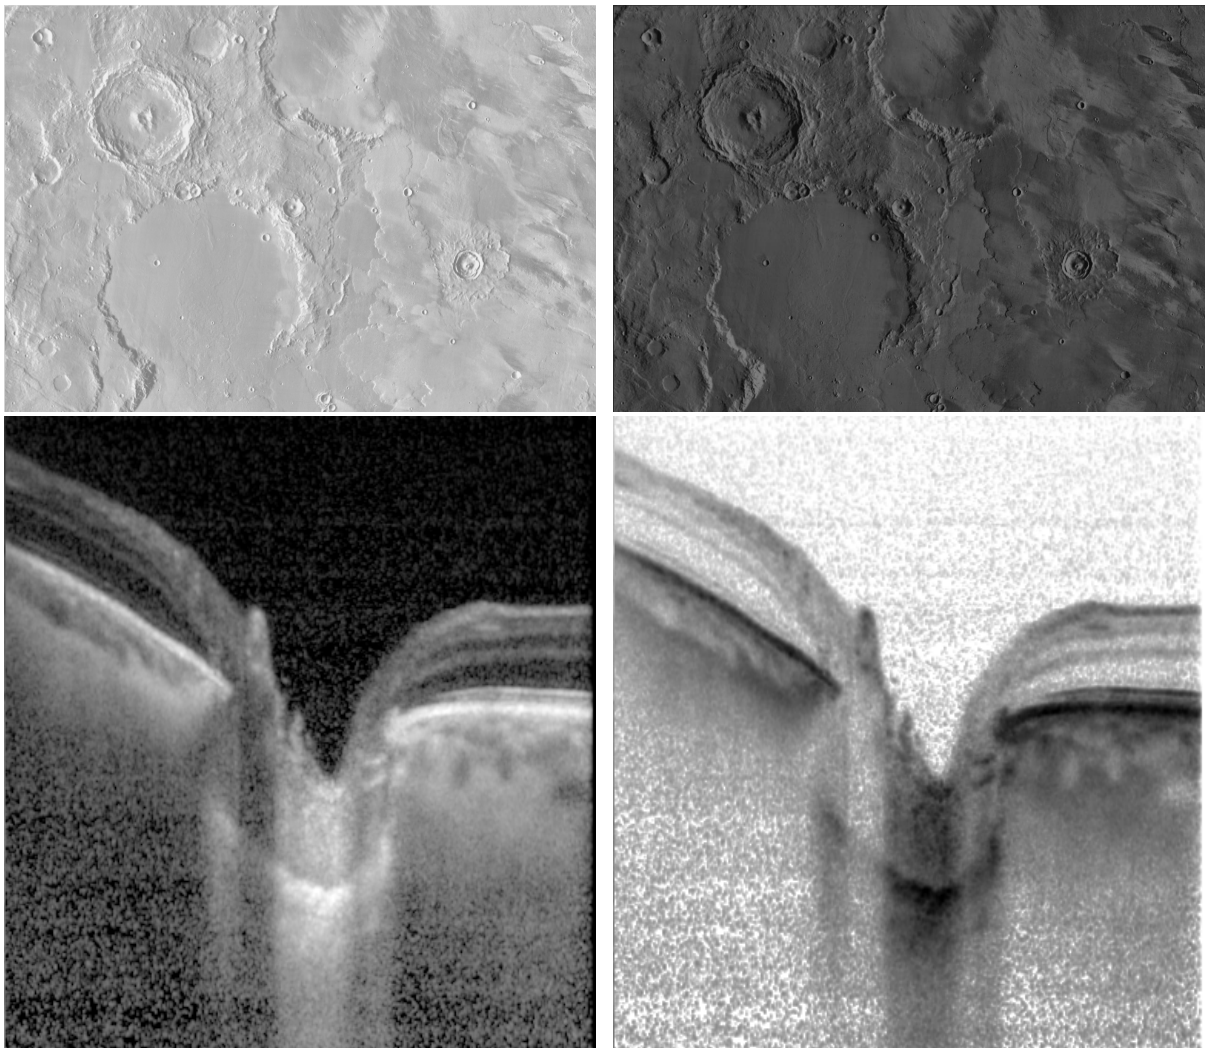
- Na poprzednim wykładzie zapisywaliśmy obraz jako $f(x, y) = i(x, y)r(x, y)$.
- Operacje w dziedzinie przestrzennej będziemy zapisywać jako $\mathcal{I}(x, y) = \mathrm{Op}[f(x, y)]$, dla pewnego operatora Op.
- Przykładam operatora może być, np. splot z ustalonym kernelem, progowanie, negacja, operacje logarytmiczne, operacje potęgowe, ...

Efekt podstawowych operacji



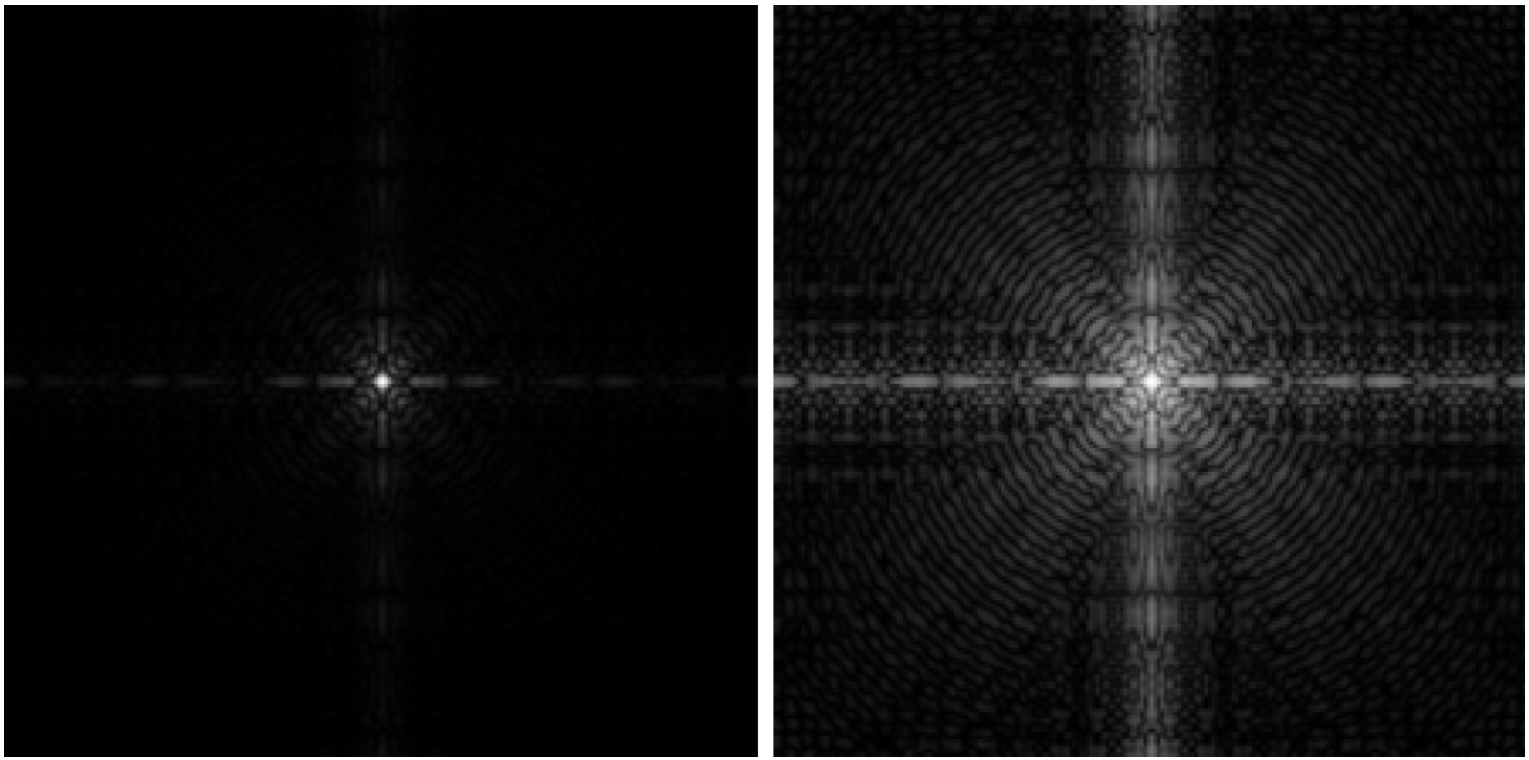
Negacja

$$s = L - 1 - r$$



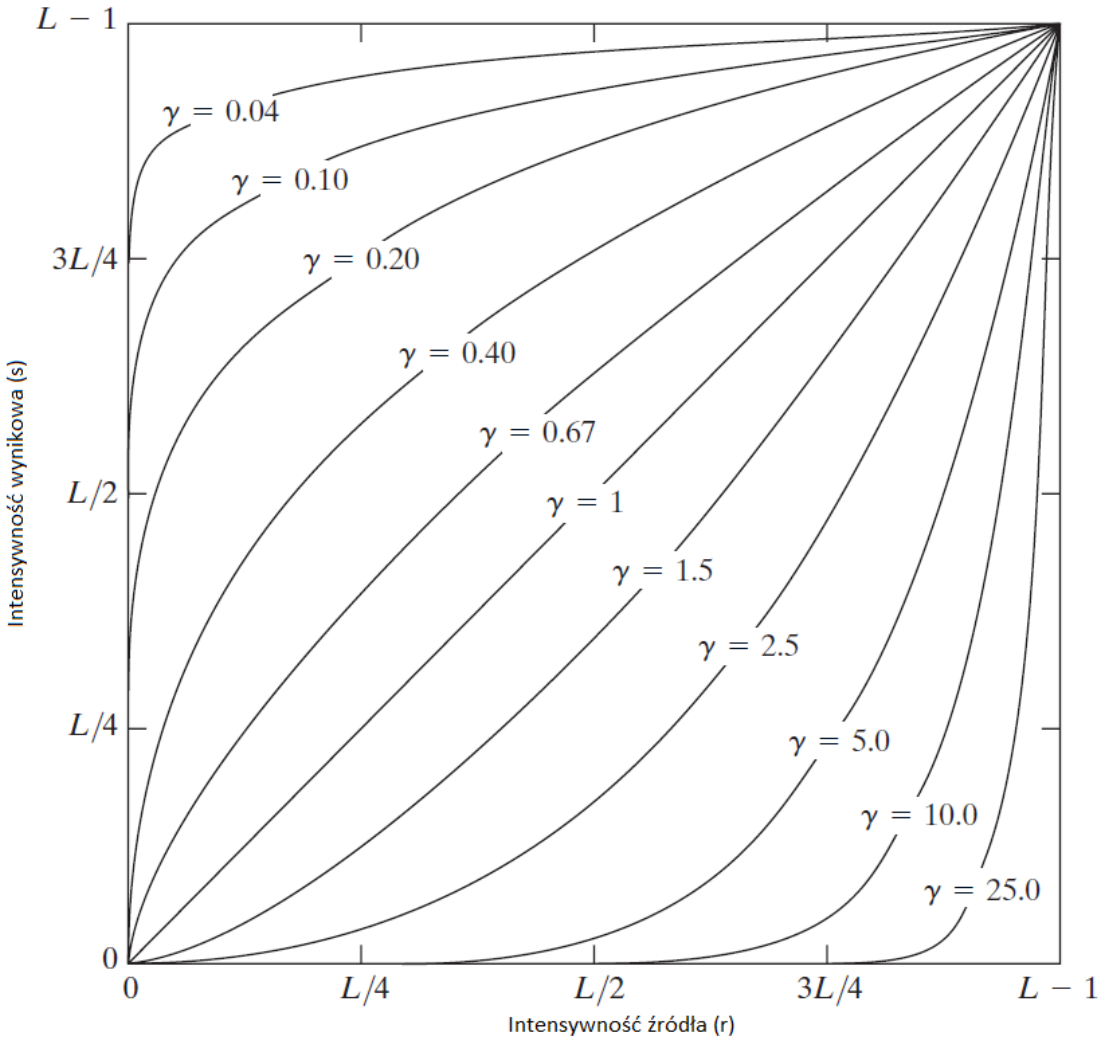
Logarytm

$$s = c \log(r + 1)$$

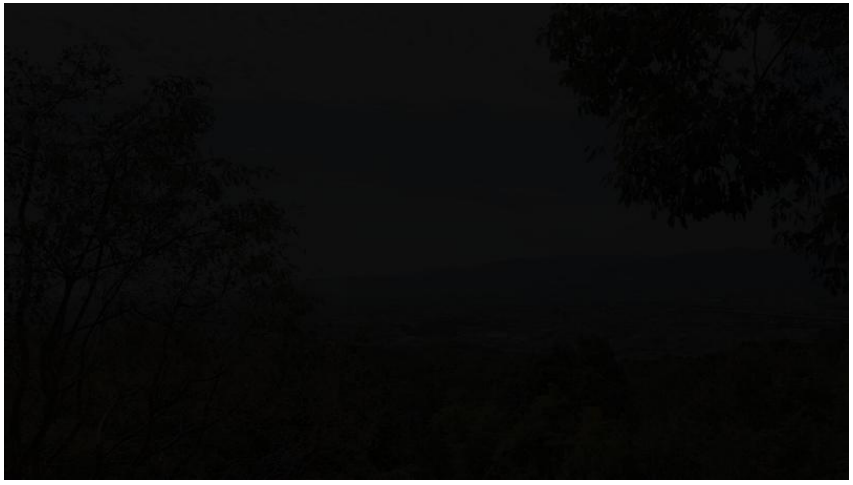


Funkcje potęgowe

$$s = c \cdot r^{\gamma}$$



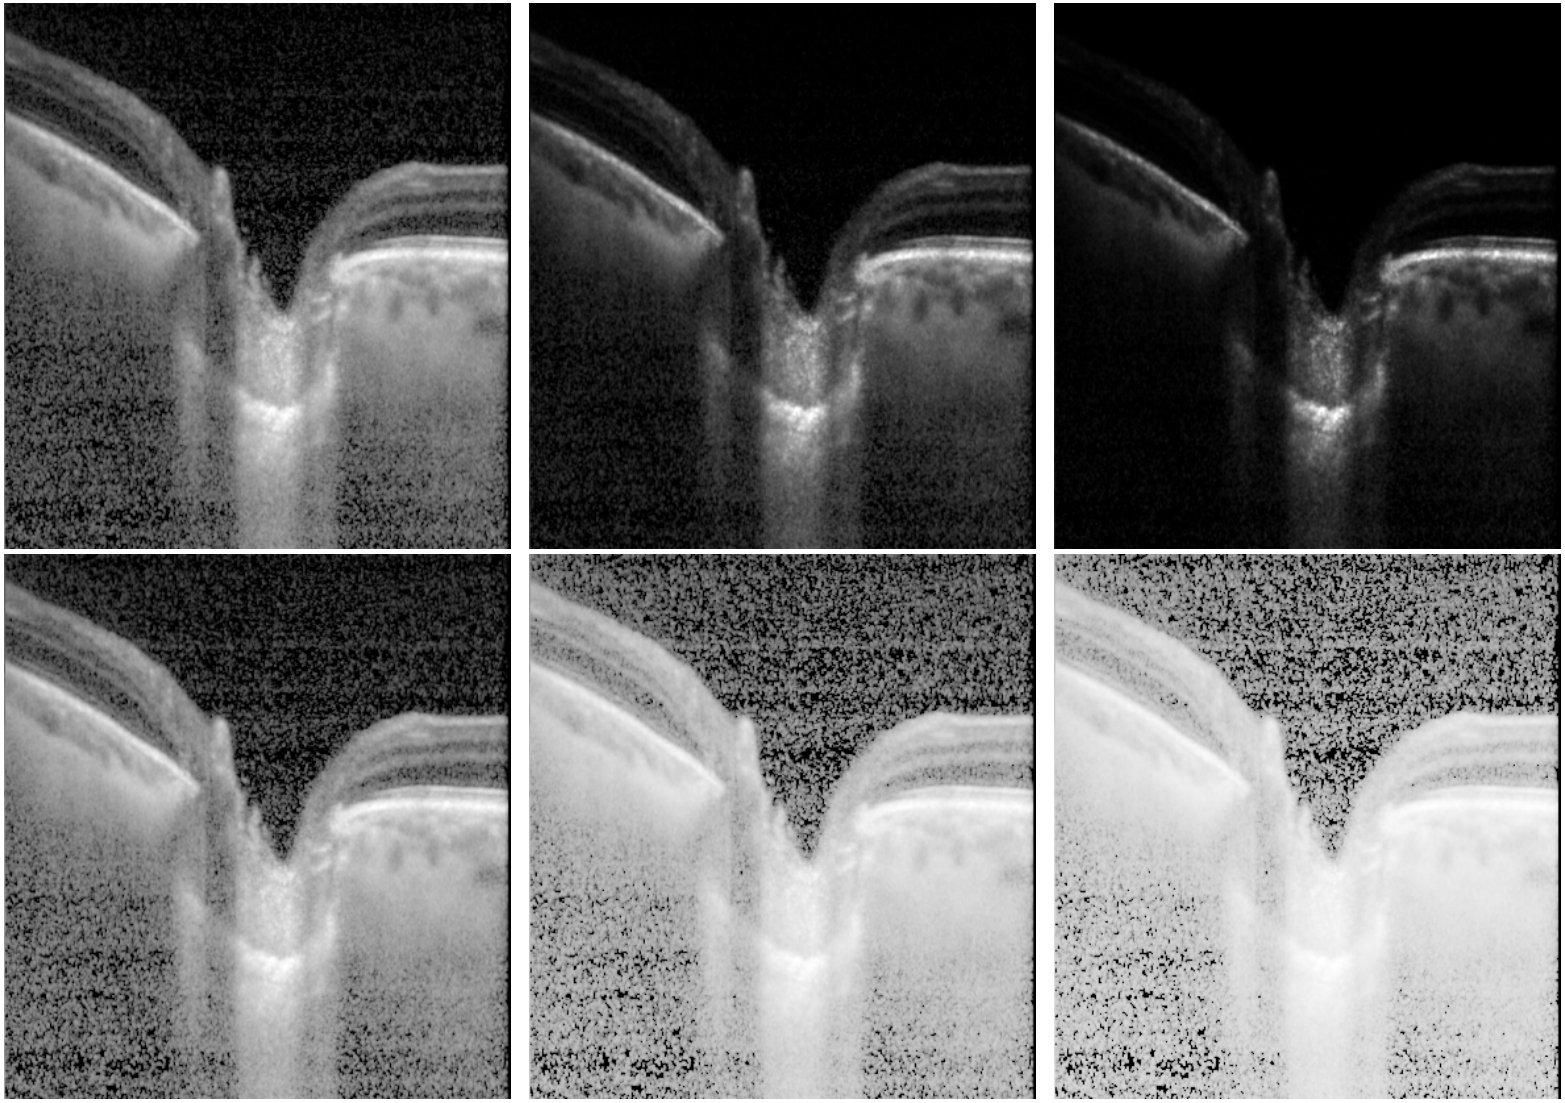
Funkcje potęgowe







Funkcje potęgowe

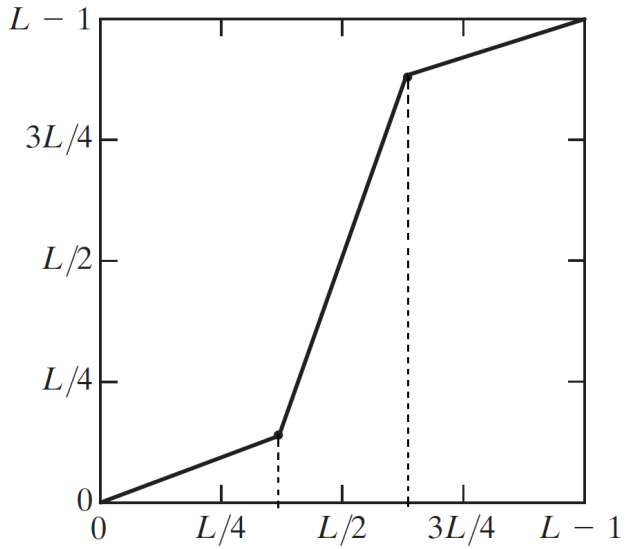


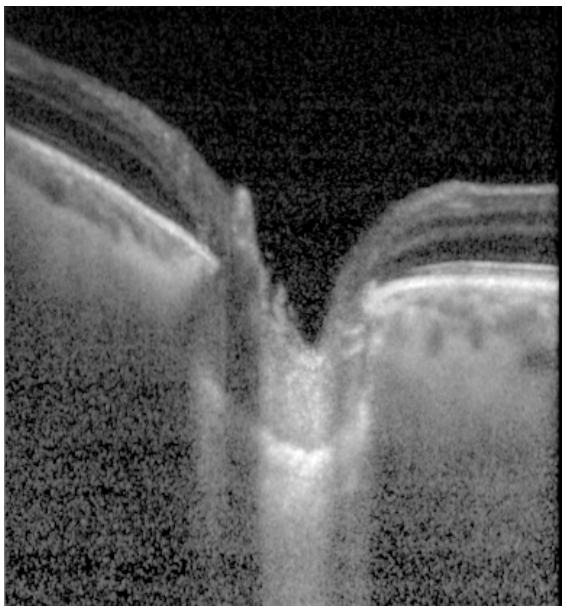
Transformacja fragmentami liniowa

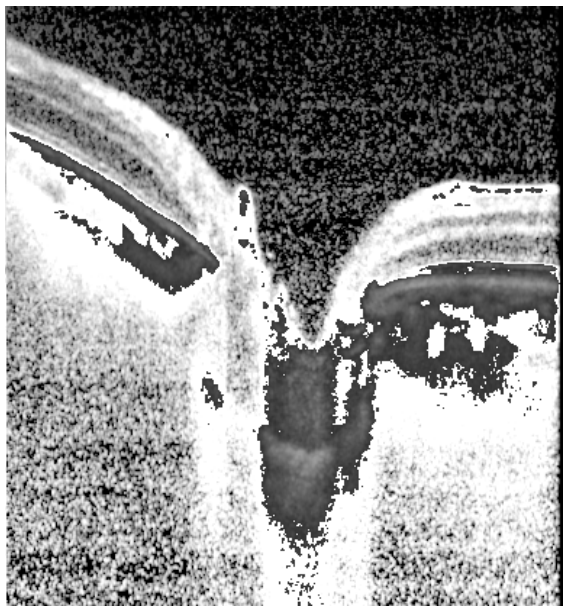
$$s = \begin{cases} a_1 r + b_1 & \text{dla } r \leq T_1 \\ a_2 r + b_2 & \text{dla } T_1 < r \leq T_2 \\ \vdots & \\ a_k r + b_k & \text{dla } T_{k-1} < r \end{cases}$$

- Chcemy wzmocnić lub wygasić określone intensywności w różny sposób
- Dla każdego z przedziałów funkcja szybko wyliczalna
- Wzmacnianie lokalnego kontrastu

Transformacja fragmentami liniowa



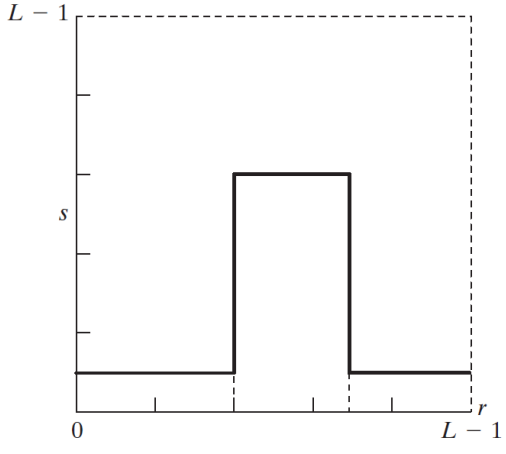


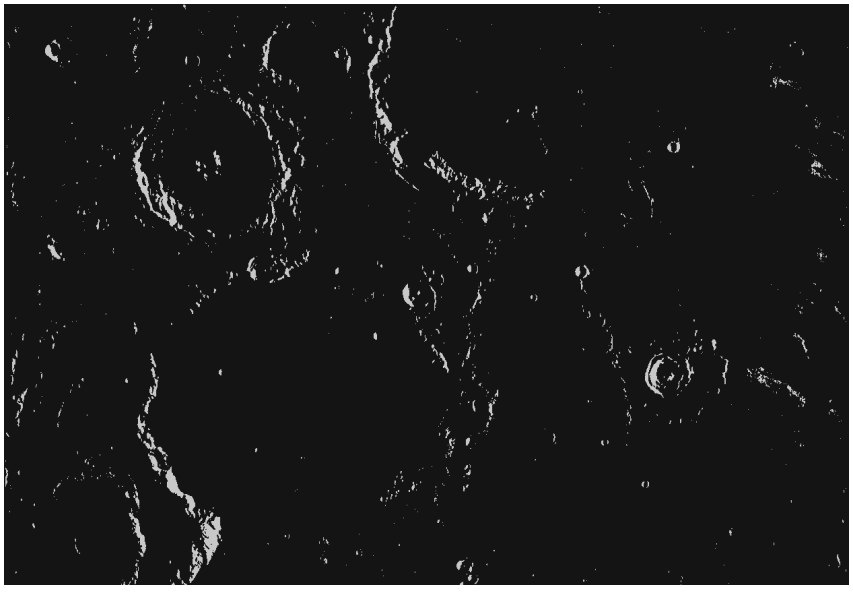


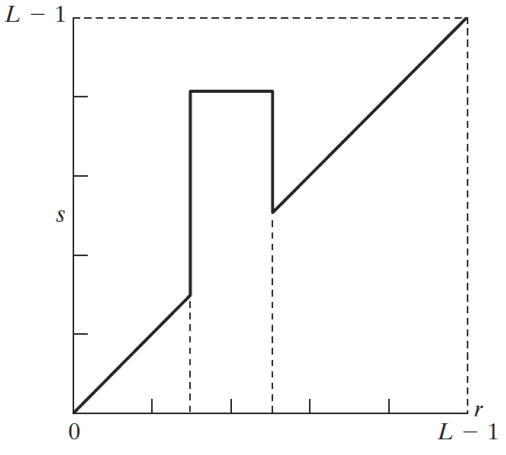
Szczególne przypadki

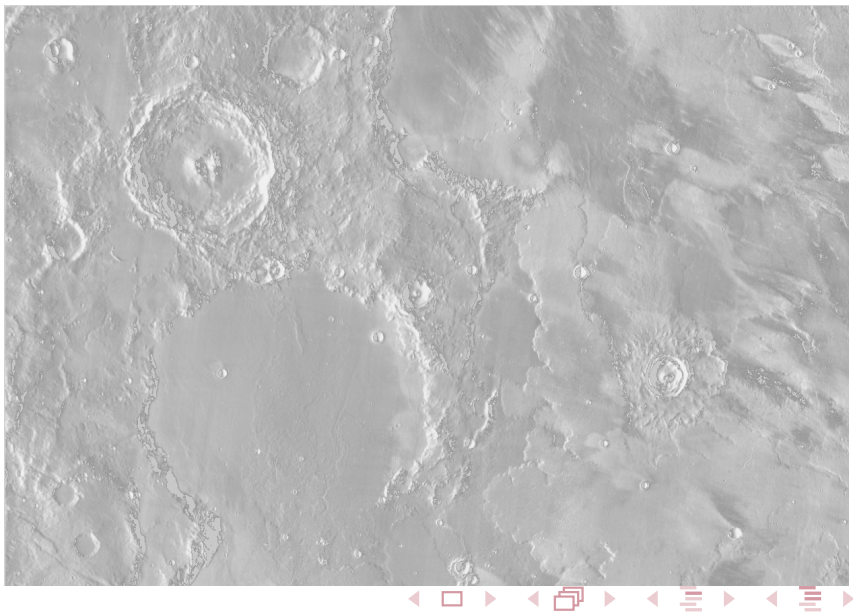
- $$s = \begin{cases} c_0 & \text{dla } r \leq T_1 \\ c_1 & \text{dla } T_1 < r \leq T_2 \\ c_0 & \text{dla } T_{k-1} < r \end{cases}$$
- $$s = \begin{cases} r & \text{dla } r \leq T_1 \\ c & \text{dla } T_1 < r \leq T_2 \\ r & \text{dla } T_{k-1} < r \end{cases}$$

Szczególne przypadki



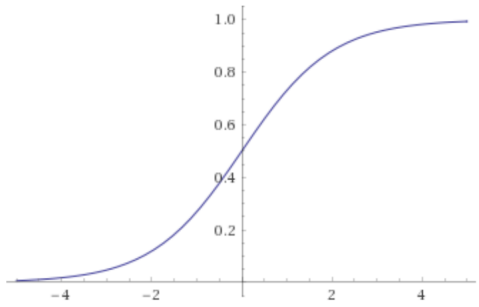




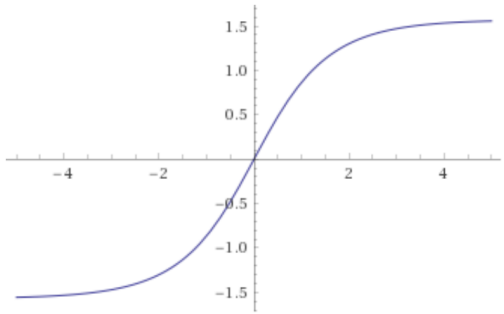


Uogólnienie – sigmoid

- podobny efekt, ale bez wprowadzania sztucznych kontrastów osiągnąć można poprzez funkcje ciągłe



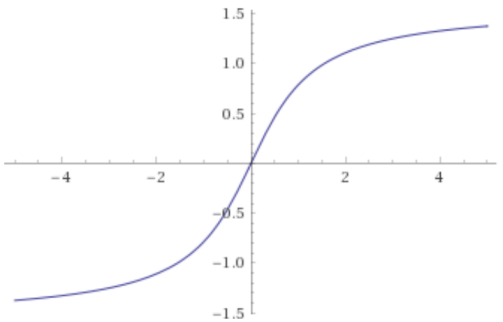
- funkcja logistyczna: $f(x) = \frac{M}{1+e^{(x_0-x)t}}$
- uogólniona funkcja logistyczna $f(x) = L + \frac{U-L}{(C+Qe^{-tx})^{\frac{1}{\nu}}}$



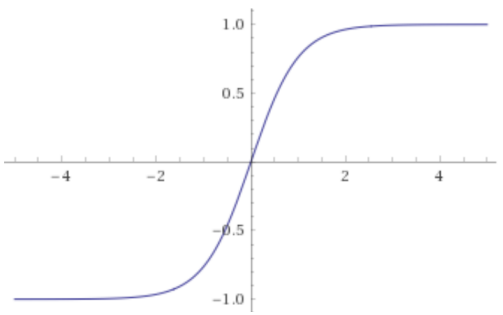
- funkcja Gaudermanna $f(x) = \int_0^x \frac{1}{\cosh t}\,dt$

Uogólnienie – sigmoid

- podobny efekt, ale bez wprowadzania sztucznych kontrastów osiągnąć można poprzez funkcje ciągłe
- arcus tangens $f(x) = \operatorname{arc\,tg}\, x$

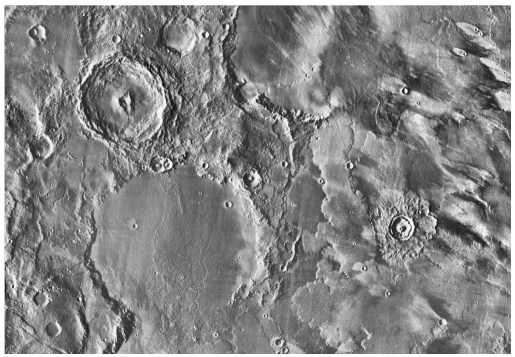
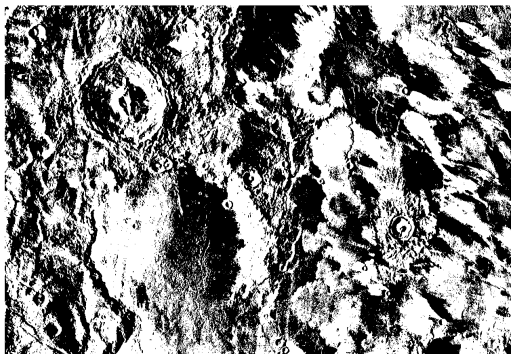
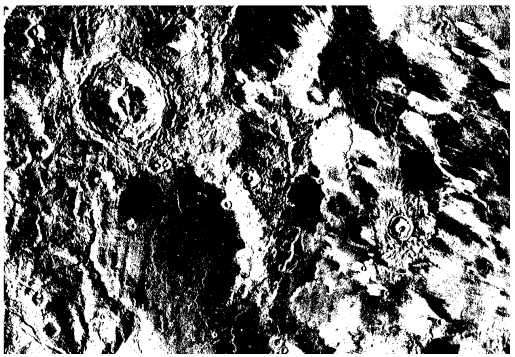


- tangens hiperboliczny $f(x) = \operatorname{tgh}\, x = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

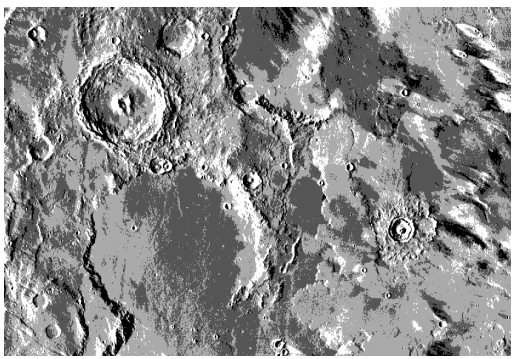
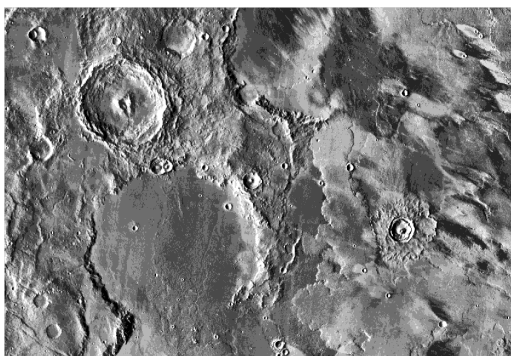
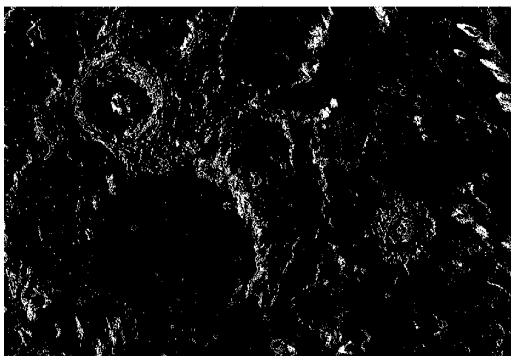


Znajdowanie progów

- W przypadku binaryzacji wspomnieliśmy progowanie z zadanym T oraz metodę Otsu(`cv.threshold(img,0,255,cv.THRESH_BINARY+cv.THRESH_OTSU)`)

- wieloprogowa metoda Otsu

Zasada działania

- szukamy progów, tak by maksymalizować separacje między zbiorami (minimalizując wariancję wewnątrzklasową)
- zakładamy, że obraz jest w skali szarości o L poziomach
- oznaczmy liczbę pikseli o intensywności i przez f_i, zatem $N = n \times m = f_0 + f_1 + \cdots + f_{L-1}$
- szacujemy prawdopodobieństwo pojawienia się każdej intensywności na obrazie $p_i = \frac{f_i}{N}$ (oczywiście $\forall_i\ p_i \geq 0$ oraz $\sum_{i=0}^{L-1} p_i = 1$)

Zasada działania

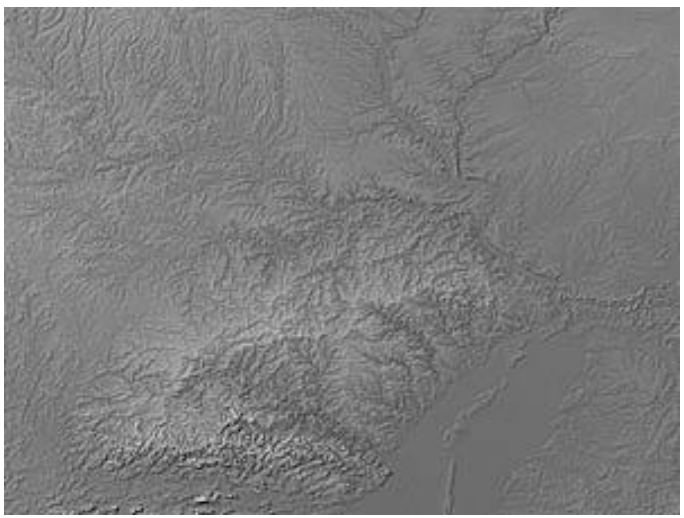
- załóżmy podział na k klas, zatem potrzebujemy wyznaczyć progi $T_0, \ldots, T_{k-2}$
- prawdopodobieństwo, że piksel należy do danej klasy, to suma prawdopodobieństw posiadania intensywności, z których klasa się składa $\omega_j = \sum_{i \in K_j} p_i$
- średnia intensywność klasy to $\mu_j = \sum_{i \in K_j} i \cdot \frac{p_i}{\omega_j}$
- średnia intensywność obrazu to $\mu_I = \sum_{i \in K_j} i \cdot p_i$, a z rozbiciem na klasy $\mu_I = \sum_{j=0}^{k-1} \mu_k \omega_k$
- wariancja międzyklasowa to: $\sigma_C^2 = \sum_{j=0}^{k} \omega_j (\mu_j - \mu_I)^2$
- znalezienie optymalnego podziału: $(\hat{T}_0, \ldots, \hat{T}_{k-2}) = \arg_{0 \leq T_0 < \cdots < T_{k-2} < L-1} \max \left\{ \sigma_C^2(T_0, \ldots, T_{k-2}) \right\}$

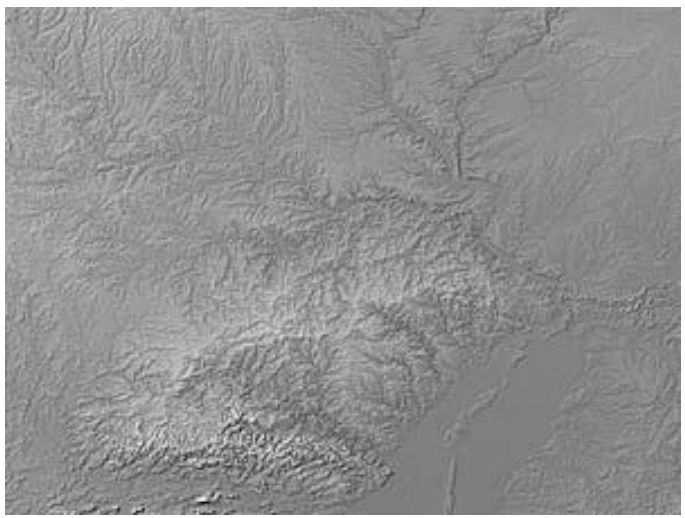
Rozciąganie histogramu – intuicje

- załóżmy, że mamy obraz w skali szarości o intensywnościach $I = \{I_m, I_{m+1}, \ldots, I_M\}$, tż. $|I| < L$ oraz $I_m > 0 \vee I_M < L - 1$.
- możemy wykonać przekształcenie, w taki sposób by: nie zmienić znacząco intensywności żadnego piksela, nie zmienić znacząco stosunku intensywności między poszczególnymi pikselami, poprawić lokalny kontrast

Rozciąganie histogramu – przekształcenie liniowe

1. $r \leftarrow (r - \min(r))$
2. $r \leftarrow \frac{r}{\max(r)}$
3. $r \leftarrow \mathrm{round}(r \cdot (L-1))$





Wyrównanie histogramu

- pamiętamy o tym, że chcemy zastosować przekształcenie liniowe
- podobnie jak dla metody Otsu, ustalmy prawdopodobieństwo wystąpienia konkretnych poziomów szarości $p_r(r_k) = \frac{n_k}{n}$, dla $k \in \mathbb{Z}$, $0 \leq k \leq L-1$
- skoro $s = \mathrm{Op}(r)$, to $p_s(s_k) = \sum_{i:\mathrm{Op}(r_i)=s_k} p_r(r_i) = \sum \frac{n_i}{n}$, zatem mamy prawdopodobieństwo dla s

Wyrównanie histogramu

- pamiętamy o tym, że chcemy zastosować przekształcenie liniowe
- podobnie jak dla metody Otsu, ustalmy prawdopodobieństwo wystąpienia konkretnych poziomów szarości $p_r(r_k) = \frac{n_k}{n}$, dla $k \in \mathbb{Z}$, $0 \leq k \leq L-1$
- skoro $s = \mathrm{Op}(r)$, to $p_s(s_k) = \sum_{i:\mathrm{Op}(r_i)=s_k} p_r(r_i) = \sum \frac{n_i}{n}$, zatem mamy prawdopodobieństwo dla s

Dlaczego wyrównanie?

Wyrównanie histogramu

- załóżmy chwilowo, że zmienne r i s są ciągłe
- załóżmy, że $s = \mathrm{Op}(r)$, oraz $0 \leq r \leq 1$.
- jeśli chcemy wzmocnić kontrast zachowując wierność oryginałowi to, $0 \leq \mathrm{Op}(r) \leq 1$, co więcej Op musi być funkcją różnowartościową, rosnącą na całym przedziale
- możemy traktować obrazy s i r jako zmienne losowe o gęstościach $p_s(s)$ i $p_r(r)$
- znając zależności między s i r oraz Op , możemy obliczyć brakujące gęstości: $p_s(s) = p_r(r)\left|\frac{dr}{ds}\right|$, $s = \mathrm{Op}(r) = \int_0^r p_r(t)dt$
- mając dystrybuantę r: $\frac{ds}{dr} = \frac{d\mathrm{Op}(r)}{dr} = \frac{d}{dr}[\int_0^r p_r(t)dt] = p_r(r)$
- ponieważ $p_s(s) = p_r(r)\left|\frac{dr}{ds}\right| = p_r(r)\left|\frac{1}{p_r(r)}\right| = 1$, zatem s ma rozkład jednostajny na $[0, 1]$ niezależnie od $p_r(r)$.

Wyrównanie histogramu

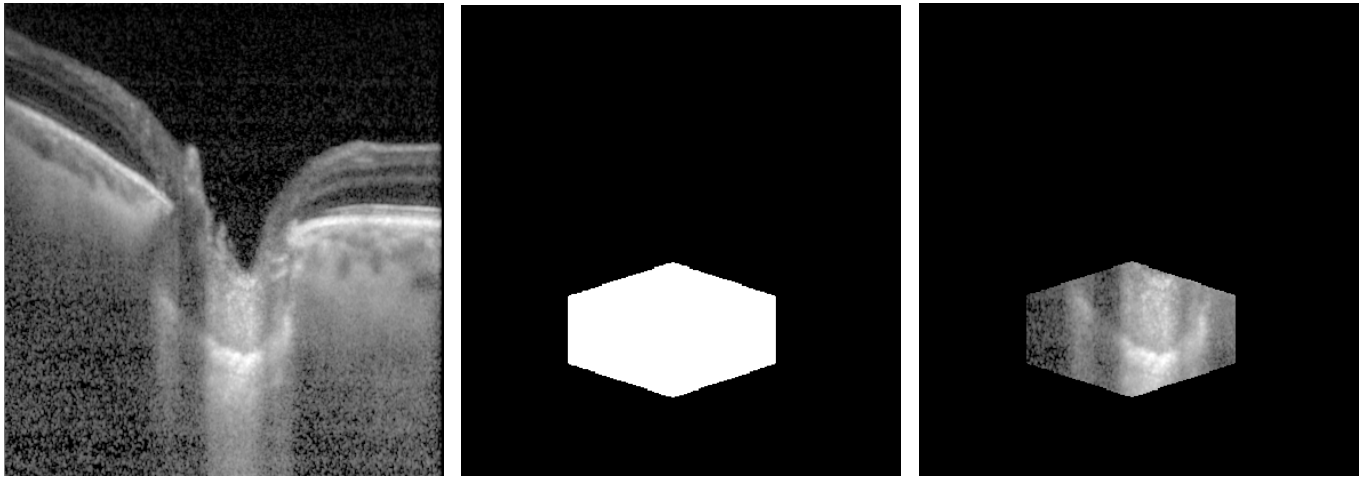
- rozszerzając metodę, można „wyrównywać" histogram do dowolnego rozkładu (odpowiednio przesuniętego)
- potrzebny do tego jest drugi odwracalny operator $\widehat{\mathrm{Op}}$.
- Idea: wykonujemy $\widehat{\mathrm{Op}}^{-1}(\mathrm{Op}(r))$. Dobór $\widehat{\mathrm{Op}}$ (a właściwie odwrotności) determinuje otrzymany rozkład

Uwaga: W celu ograniczenia artefaktów kolorystycznych, dla obrazów 3 kanałowych, najlepiej konwertować obraz do przestrzeni HSV (lub LAB) i wyrównywać jedynie kanał V (lub L).

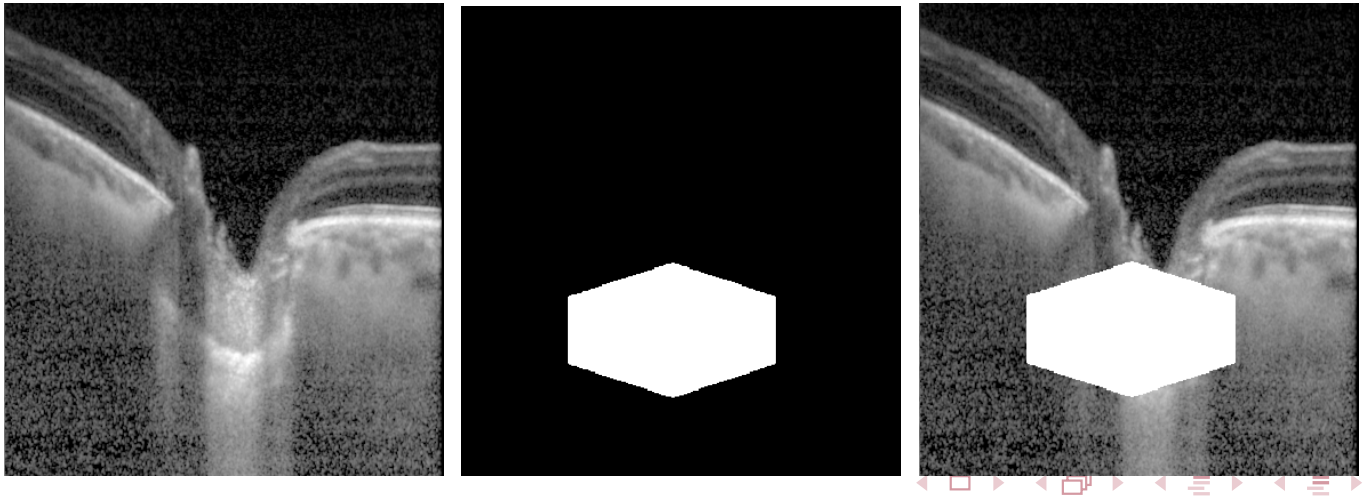
Operacje logiczne

Obrazy pozwalają na wykonywanie operacji logicznych na bitach.

- maska AND



- maska OR



Filtry

- Omawiane filtry będą opierały się na operacji splotu
- W większości przypadków stosować będziemy jądro o wymiarach 3x3
- Operacja splotu jest bardzo czasochłonna, w przyszłości zastanowimy się jak przyspieszyć filtrowanie

Filtry wygładzające

- boxfiltering

$$\begin{bmatrix} \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \\ \frac{1}{9} & \frac{1}{9} & \frac{1}{9} \end{bmatrix}$$





Filtry wygładzające

- filtr Gaussa

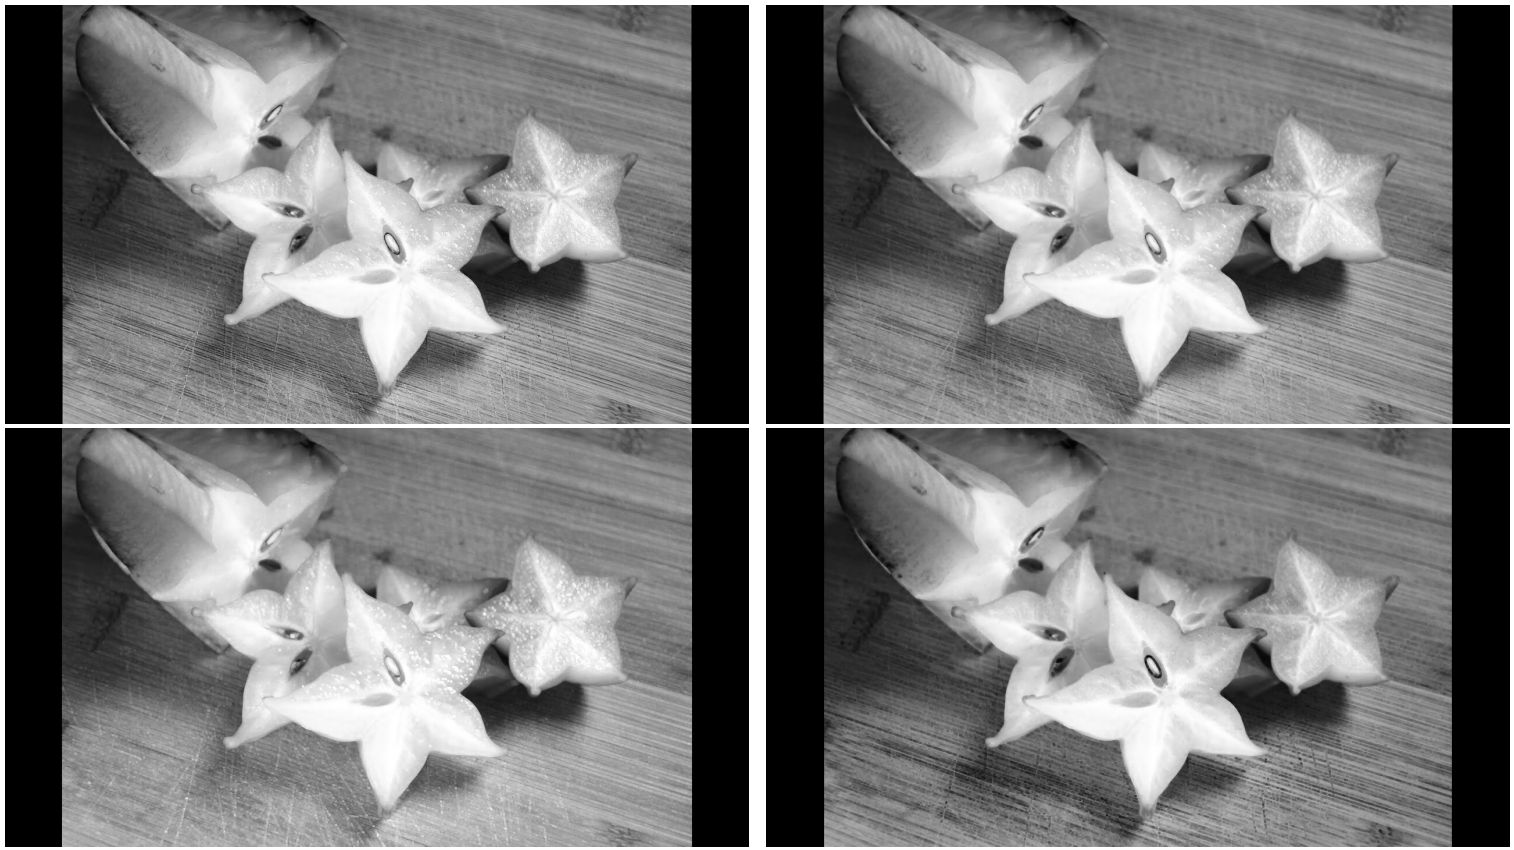
$$\begin{bmatrix} \frac{1}{16} & \frac{1}{8} & \frac{1}{16} \\ \frac{1}{8} & \frac{1}{4} & \frac{1}{8} \\ \frac{1}{16} & \frac{1}{8} & \frac{1}{16} \end{bmatrix}$$





Filtry wygładzające

- filtr medianowy (filtr oparty na statystyce pozycyjnej, inne popularne filtry tego typu to maxfilter i minfilter)



Wykrywanie krawędzi

$$\begin{bmatrix} -1 & 2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

$$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix}$$

$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$

Wykrywanie krawędzi

