

▲

# **Przetwarzanie i rozpoznawanie obrazów**

## **Wstęp**

**Dr hab. Inż. Zapotoczny Piotr, prof. UWM**  
**Uniwersytet Warmińsko-Mazurski w Olsztynie**


# **Plan wykładów**

- 1. Przetwarzanie i rozpoznawanie obrazów - Wstęp**
- 2. Akwizycja obrazu**
- 3. Typy plików graficznych**
- 4. Metody segmentacji**
- 5. Przekształcenia filtracyjne**
- 6. Barwa - modele**
- 7. Kształt obiektów**
- 8. Tekstury obrazu**
- 9. Eksploracja danych**


# Plan wykładu




Wprowadzenie



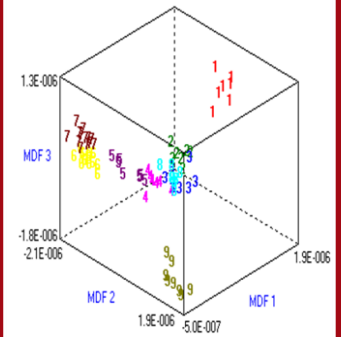
Zastosowanie  
KAO



Złudzenia  
optyczne




Przegląd  
literatury



Komputerowa analiza obrazu

- Co to jest analiza obrazu ?
- A co to jest przetwarzanie obrazu ?



*analiza  
obrazu*

*przetwarzanie  
obrazu*

# Zastosowanie

- **kryminalistyka, zastosowania militarne,**
- **diagnostyka obrazowa, analiza obrazów biomedycznych (automatyczna analiza i rozpoznawanie obrazów, ultrasonograficznych, rentgenograficznych, tomograficznych, MRI),**
- **sortowanie przesyłek pocztowych, czytanie etykiet, rozpoznawanie tekstu,**
- **robotyka,**
- **kontrola, monitoring i ocena jakości,**
- **ekologia, geologia, kartografia,**
- **prognoza pogody, poszukiwanie złóż mineralnych, monitorowanie zanieczyszczeń, wykonywanie map terenu.**

# Zastosowanie - rolnictwo

- ✓ **Ocena jakości surowca i gotowego produktu;**
- ✓ **Klasyfikacja jakości technologicznej surowców i produktów spożywczych;**
- ✓ **Analiza zmian struktury materiału wynikających z procesów życiowych;**
- ✓ **Analiza zmian struktury materiału zachodzących podczas procesów technologicznych;**
- ✓ **Identyfikacja i klasyfikacja odmianowa;**
- ✓ **Przewidywanie jakości produktu;**
- ✓ **Ocena stanu mikrobiologicznego produktu, itp.**

# Zalety cyfrowych systemów wizyjnych

- 1. Niższa cena analizy,**
- 2. Powtarzalność analizy,**
- 3. Szybki czas reakcji,**
- 4. Możliwość automatycznego zapisu informacji,**
- 5. Łatwość budowy powtarzalnych systemów,**
- 6. Możliwość automatycznego programowania procesu przetwarzania,**
- 7. Praca w dowolnym zakresie widma (światło widzialne, podczerwień, ultrafiolet),**
- 8. Brak oporów moralnych, brak instynktu samozachowawczego,**
- 9. Praca w środowisku nieprzyjawnym dla człowieka,**
- 10. Brak czynników ludzkich (zmęczenie, stres, znudzenie), odporność na złudzenia optyczne.**




# **Złudzenia optyczne**

**Jest to stan pojawienia się niezgodności pomiędzy fizycznym wyglądem obiektu a jego reprezentacją obrazową w korze mózgowej.**


**Obserwator nie zdaje sobie sprawy i odnosi się z pełnym zaufaniem do złudnego spostrzeżenia.**

# Strukturyzacja wzrokowa – grupowaniu rozproszonych plam w spójne ale wyimaginowane struktury




# **Pułapki w percepcji kształtów**

Wikipedia




**Spirala Frasera – czy aby na pewno spirala ?**


# Strukturyzacja wzrokowa - grupowaniu rozproszonych plam w spójne ale wyimaginowane struktury




# **Wrażenie rozdławiania granic obiektów o dużym kontraście - Efekt Macha**




# Indukcja przestrzenna - wzmocnienie kontrastu wyglądu



**Iluzja Sandera - która z przekątnych  
jest dłuższa ?**







**Iluzja Müllera-Lyera - znowu problem z długością !**



# Iluzja Müllera-Lyera - znowu problem z długością !




# Iluzja Ebbinghausa – które z białych kół jest większe ?




# Widzimy to co chcemy widzieć



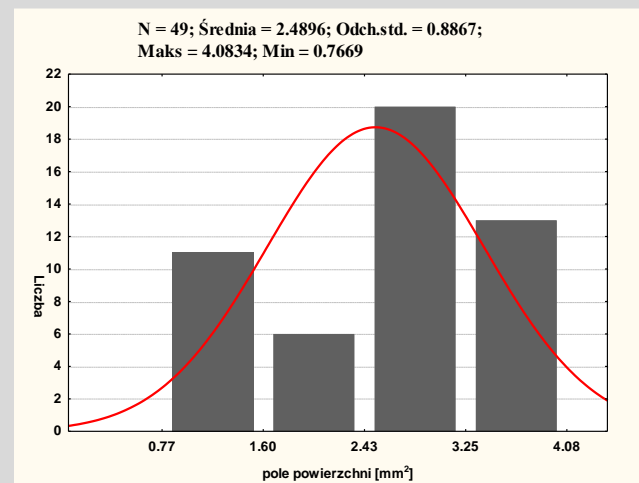
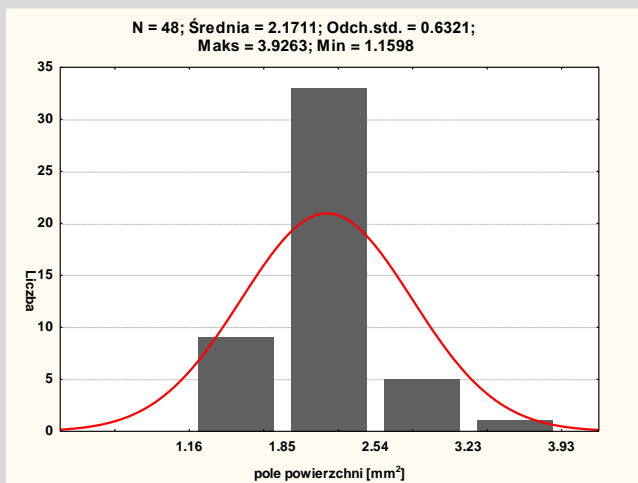




# Inny przykład



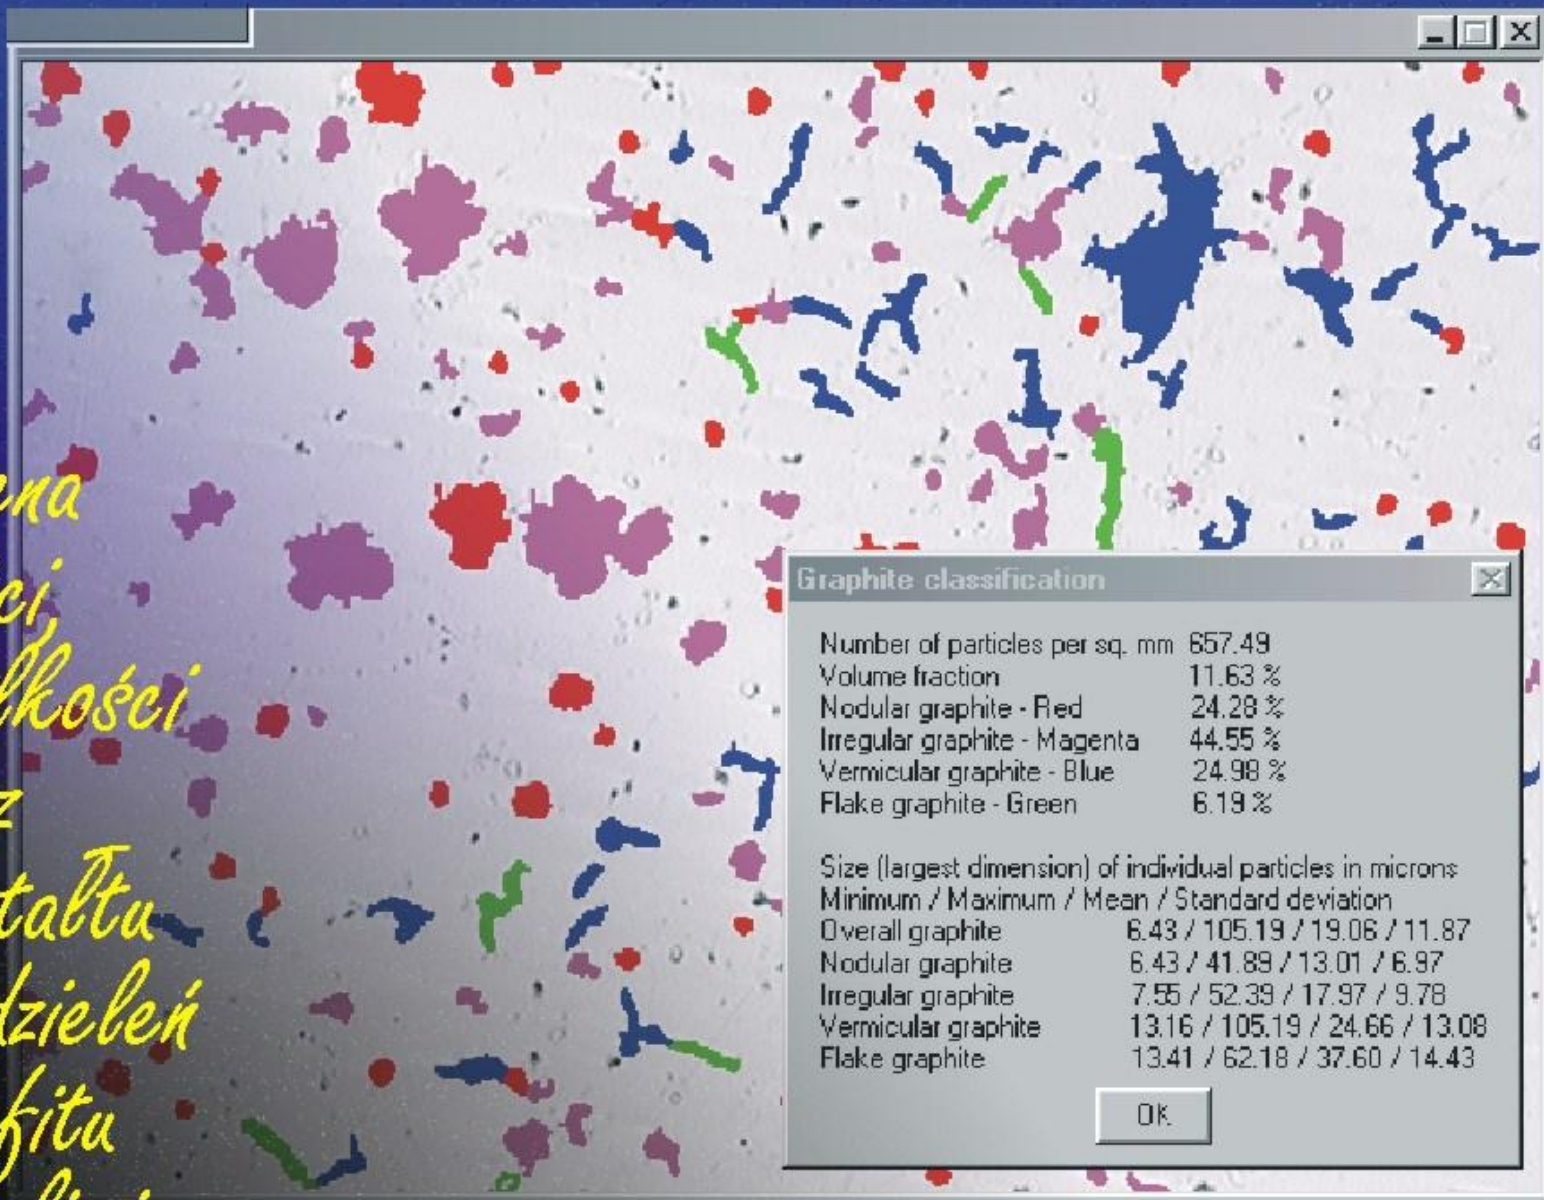
**Patrzeć nie znaczy widzieć**

# Czy to te same obrazy?




**Przykłady  
wykorzystania KAO  
rolnictwie i nie tylko**

Ocena  
ilości,  
wielkości  
oraz  
kształtu  
wydzielen  
grafitu  
w żeliwie






*Ocena  
wielkości  
ziarna*



**Źródłem obrazów wymagających komputerowego przetwarzania, analizy i rozpoznawania są techniki obrazowania medycznego: Radiografia, Tomografia Komputerowa, Rezonans Magnetyczny, Ultrasonografia, Medycyna Nuklearna (tomografia pozytonowa - PET i jednego fotonu - SPECT), metody optyczne i impedancyjne)**



dr inż. Piotr Zapotoczny


# Wizualizacja



# Analiza ilościowa




# Diagnostyka przesiewowa





# Rekonstrukcija 3D



# Obrazy 3 D



# Zastosowanie: kryminalistyka




analiza pisma



porównywanie portretów  
pamięciowych

porównywanie linii papilarnych





# Tą metodą można wykrywać fałszerstwa


a)

A rectangular box containing a scan of handwritten text in cursive script. The text is written in black ink on a light background. The text reads: "Prasa i wypłacenie panu Rg kwoty 92800 złotych". The handwriting is somewhat slanted and appears to be a personal or official note.

b)



# Podczerwień



**Zdjęcie wykonane kamerą termowizyjną**



# Obraz uzyskany z zakresu UV

**Skrajne** – długość fali: 10-121 nm

**Dalekie** – długość fali: 122-200 nm

**Pośrednie** – długość fali: 200-300 nm

**Bliskie** – długość fali 300-400 nm



# Kamera C-10633-13


## Ultrafiolet




▲ Observation by visible light (Normal camera)  
The letter under lacquer is invisible.

▲ Observation by IR light (C10633-13)  
The letter under lacquer is clearly visible.

# ULTRAVIOLET






# ULTRAVIOLET



# ULTRAVIOLET



# Sensor obrazu C9732DK-11 CMOS dla obrazów uzyskanych z promieniowania X





▲C8750-05FC




▲C8750-10FC



# Przegląd literatury





Zdjęcie wykonane w świetle z zakresu – 400-700 nm





Obraz z mikroskopu skaningowego

# Mikroskopia elektronowa



# Przegląd literatury

P. Strumiłło, J. Niewczas, P. Szczypiński, P. Makowski, W. Woźniak,  
*Computer System for Analysis of X-Ray Images of Wheat Grains*, Int.  
Agrophysics, 1999, 13, pp. 133-140




A screenshot of a software interface for grain analysis. The interface includes a menu bar with 'Analysis', 'Processing Options', 'Analysis Tables', and 'Analysis Options 2'. Below the menu is a 'Damage Indices' section with a table of values. To the right of the table are input fields for 'Gear' and 'Gear's code'. At the bottom, there is a 'Dose' button and a 'Test Mode' checkbox. The main area shows a grayscale image of a grain with a cyan outline and a yellow grid overlaid on it. The status bar at the bottom indicates 'Engine: 0', 'X: 10p', 'Y: 10p', 'Z: 2.57mm', and '0.5mm'.

Damage Indices:	
Overall:	9
Integer:	645
Fractional:	0.88481
User defined:	9
Continuous:	1.68572


# Przegląd literatury





C7921CA-02 1x1 mode 0.35f/s  
X-ray source: RIGAKU 150CPT  
(Focus size: 300um, Window Be: 1mm) 35kV 1.7mA



C7942CA-02 1x1 mode 7.5f/s  
X-ray source: RIGAKU 150CPT  
(Focus size: 300um, Window Be: 1mm) 80kV 2.0mA



Foreign object !!





▲Pseudo color

Possible to detect a rotten part of orange.




Possible to detect orange seeds.

# Przegląd literatury




# Przegląd literatury

M. Pluta, W. Bicz: **Synthetic aperture acoustic microscope for evaluation of fingertip peripheral skin structure**; SPIE Vol. 2390;



# Przegląd literatury

R. Choudhary, S. Mahesh, J. Paliwal, D.S. Jayas. 2009. Identification of wheat classes using wavelet features from near infrared hyperspectral images of bulk samples. *Biosystems engineering* 102 (2009) 115 – 127




**Table 3 – Classification accuracy (%) of quadratic discriminant classifier using top 10–top 100 features ranked by STEPDISC procedure.**


Class	Top 10	Top 20	Top 30	Top 40	Top 50	Top 60	Top 70	Top 80	Top 90	Top 100
CPSR	100	99.3	99.3	99.3	99.3	99.3	99.0	99.3	99.3	98.0
CPSW	68.3	85.7	93.7	93.3	93.7	93.3	94.7	93.7	99.3	93.3
CWAD	95.0	98.7	99.3	99.7	99.7	98.7	99.0	99.0	99.3	99.7
CWES	91.7	96.7	97.0	98.0	98.3	96.7	97.3	96.7	98.0	96.3
CWHWS	89.3	93.7	98.3	98.0	97.3	97.7	97.3	96.7	97.3	97.3
CWRS	85.3	91.3	95.3	97.3	96.3	98.3	97.0	97.3	97.3	96.7
CWRW	99.7	99.7	100	100	100	100	100	100	100	100
CWSWS	98.0	98.3	98.7	98.3	97.7	95.7	95.3	96.7	96.0	96.0
Average	90.9	95.4	97.8	97.9	97.8	97.5	97.5	97.4	98.3	97.2

# Przegląd literatury


Patrick M. Mehl, Yud-Ren Chen, Moon S. Kim, Diane E. Chan.  
Development of hyperspectral imaging technique for the detection of  
apple surface defects and contaminations. *Journal of Food Engineering*  
61 (2004) 67–81



450 nm, g=7



675 nm, g=3



686 nm, g=11



S. Sankarana, A. Mishraa, R. Ehsania, C. Davisb. A review of advanced techniques for detecting plant diseases. *Computers and Electronics in Agriculture* 72 (2010) 1–13

**Table 3**  
Examples of studies on plant disease detection using imaging techniques.

Plant	Disease/Damage	Statistical Methods	Optimum spectral range	Reference
Wheat	Scab (Fusarium head blight)	Step discrimination and discriminant analysis	568, 715 nm (550, 605, 623, 660, 697 and 733 nm)	Delwiche and Kim (2000)
Tomato	Late blight disease	Minimum noise fraction transformation and spectral angle mapping-based classification	700–750 nm, 750–930 nm, 950–1,030 nm, and 1,040–1,130 nm	Zhang et al. (2003, 2005)
Wheat	Yellow rust, nutrient deficiency	Self-organizing map neural network, quadratic discriminant analysis	680, 725 and 750 nm	Moshou et al. (2005, 2006)
Wheat	Yellow rust	Regression analysis	–	Huang et al. (2007)
Grapefruit (fruit)	Citrus canker	Principal component analysis	553, 677, 718 and 858 nm	Qin et al. (2008)
Vidalia sweet onions	Sour skin disease	Image analysis	1,150–1,280 nm	Wang et al. (2009)
Sweet orange	Blue mold, Browning rot	Difference in reflectance	540 and 680 nm	Sighicelli et al. (2009)

**Table 4**  
Vegetative indices used in spectroscopic studies for disease detection.

Vegetative Index	Estimation	Reference
Disease index ( $f_D$ ) (specific for individual study)	$f_D = \frac{I_{550\text{ nm}}}{I_{550\text{ nm}} + I_{690\text{ nm}}}$	Moshou et al. (2005)
Normalized difference vegetation index (NDVI)	$NDVI = \frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}}$	Yang and Cheng (2001), Bravo et al. (2004), Yang et al. (2007), Naidu et al. (2009)
Green normalized difference vegetation index (Green NDVI)	$Green\ NDVI = \frac{R_{GREEN} - R_{RED}}{R_{GREEN} + R_{RED}}$	Yang et al. (2007)
Water Band Index ( $I_{WB}$ )	$I_{WB} = \frac{R_{950\text{ nm}}}{R_{900\text{ nm}}}$	Xu et al. (2007)
Soil-adjusted vegetation index (SAVI)	$SAVI = \frac{(R_{NIR} - R_{RED})(1+L)}{R_{NIR} + R_{RED} + L}$ $L = 0.5$	Yang et al. (2007)
Other indices	$(R_{NIR} - R_{RED}), \frac{R_{RED}}{R_{NIR}}, \frac{R_{GREEN}}{R_{RED}}, \frac{R_{NIR}}{R_{RED}}$	Yang et al. (2007)
Photochemical reflectance index (PRI)	$PRI = \frac{R_{531\text{ nm}} - R_{570\text{ nm}}}{R_{531\text{ nm}} + R_{570\text{ nm}}}$	Huang et al. (2007), Naidu et al. (2009)
Red-edge vegetation stress index (RVSI)	$RVSI = \frac{R_{714\text{ nm}} + R_{752\text{ nm}}}{2 - R_{733\text{ nm}}}$	Naidu et al. (2009)
Modified chlorophyll (a and b) absorption in reflectance index (MCARI)	$MCARI = [(R_{700\text{ nm}} - R_{670\text{ nm}}) - 0.2(R_{700\text{ nm}} - R_{550\text{ nm}})] \times \frac{R_{700\text{ nm}}}{R_{670\text{ nm}}}$	Naidu et al. (2009)
Visible atmospherically resistance index (VARI)	$VARI = \frac{R_{GREEN} - R_{RED}}{R_{GREEN} + R_{RED} - R_{BLUE}}$	Naidu et al. (2009)
Water Index (WI)	$WI = \frac{R_{900\text{ nm}}}{R_{970\text{ nm}}}$	Naidu et al. (2009)

I: Fluorescence intensity; R: Reflectance.

# Przegląd literatury

S. Neethirajan, D.S. Jayas a, C. Karunakaran. Dual energy X-ray image analysis for classifying vitreousness in durum wheat. *Postharvest Biology and Technology* 45 (2007) 381–384






Table 1

Comparison of classification percentages of vitreous kernels in durum wheat using statistical and BPNN classifiers

Type	Moisture content (%)	Linear discriminant and parametric (PAR)*	Back propagation neural network (BPNN)*
Vitreous	12	89 ± 1.2 <sup>a,u</sup>	93 ± 2.3 <sup>a,v</sup>
	14	90 ± 1 <sup>a,u</sup>	91 ± 1.5 <sup>a,u</sup>
	16	92 ± 1.5 <sup>b,u</sup>	94 ± 2.4 <sup>a,u</sup>
	12	90 ± 2.4 <sup>a,u</sup>	94 ± 1.5 <sup>a,u</sup>
Non-vitreous	14	88 ± 3 <sup>a,u</sup>	93 ± 1 <sup>a,v</sup>
	16	89 ± 2.3 <sup>a,u</sup>	94 ± 1.5 <sup>a,v</sup>





\* Numbers followed the same superscript characters (a and b) in each column and (u and v) in each row are statistically similar ( $\alpha = 0.05$ ).



Inverted gray values of vitreous (a) and non-vitreous (b) durum wheat kernels at 12% moisture content.

# Przegląd literatury

A. Manickavasagan, D. S. Jayas, N. D.G. White. Thermal Imaging to Identify Western Canadian Wheat Classes. *An ASAE Meeting Presentation Paper Number: 056078 2005* .



## Conclusions:

Thermal imaging has potential for non destructive and online identification of wheat classes.


# steganografia

Obraz w komputerowej analizie obrazu może pochodzić z różnych źródeł. Samo pozyskanie obrazu nie jest skomplikowanym procesem. Mamy najczęściej do dyspozycji cyfrowe kamery, aparaty, skanery lub inne urządzenia. Binarne zdjęcia, zawierają informację o barwie, kształcie i teksturze obiektów w nich zapisanych. Laboratoria naukowe na całym świecie pracują nad tym jak postąpić z tą informacją bitową aby uzyskać jak najwięcej informacji. Denerwujące dla każdego początkującego naukowca jest zrozumienie podstaw działania programów do komputerowej analizy obrazu.

# steganografia

**O**braz w komputerowej analizie obrazu może pochodzić z różnych źródeł. **S**amo pozyskanie obrazu nie jest skomplikowanym procesem. **M**amy najczęściej do dyspozycji cyfrowe kamery, aparaty, skanery lub inne urządzenia. **B**inarne zdjęcia, zawierają informację o barwie, kształcie i teksturze obiektów w nich zapisanych. **L**aboratoria naukowe na całym świecie pracują nad tym jak postąpić z tą informacją bitową aby uzyskać jak najwięcej informacji. **D**enerwujące dla każdego początkującego naukowca jest zrozumienie podstaw działania programów do komputerowej analizy obrazu.


# steganografia




# Przykład zastosowania – badania własne




# Sposób ułożenia ziarniaków



KANAŁ- R




KANAŁ- G




KANAŁ- B



KANAŁ- S






KANAŁ- U



KANAŁ- V



# Ustalanie obszarów ROI



# Przykład zastosowania

Computers and Electronics in Agriculture 87 (2012) 32–38



Contents lists available at SciVerse ScienceDirect

## Computers and Electronics in Agriculture

journal homepage: [www.elsevier.com/locate/compag](http://www.elsevier.com/locate/compag)



### Computer vision algorithm for barley kernel identification, orientation estimation and surface structure assessment

Piotr M. Szczypiński<sup>a,1</sup>, Piotr Zapotoczny<sup>b,\*</sup>

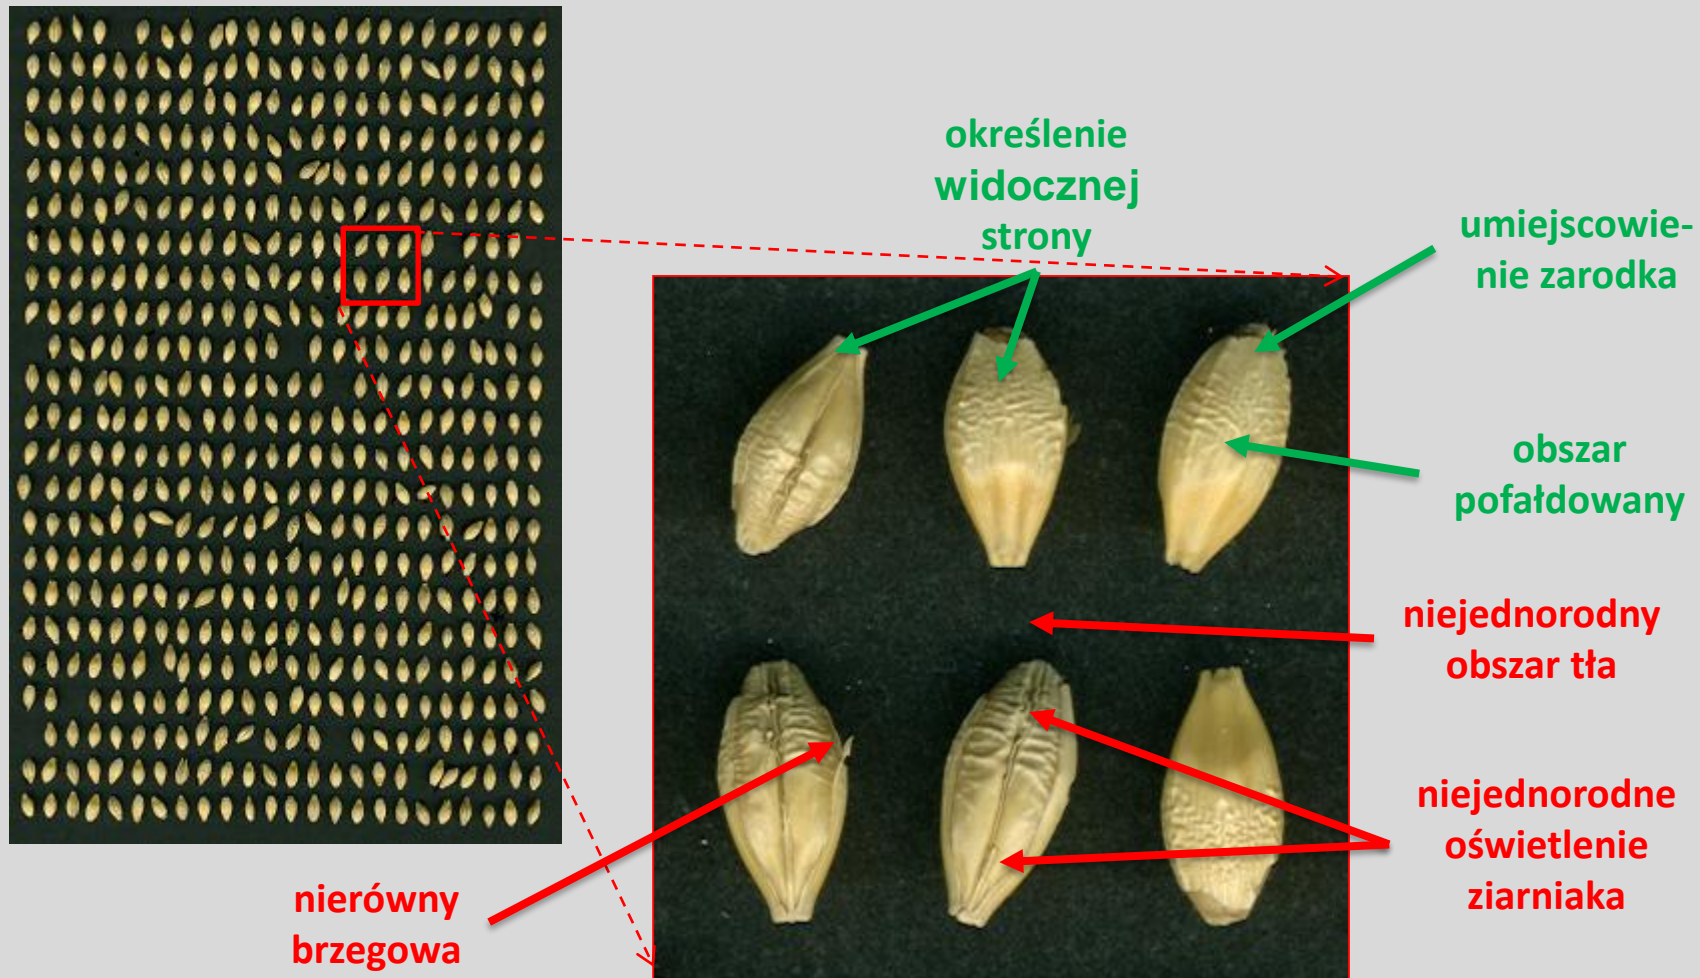
<sup>a</sup>Institute of Electronics, Technical University of Lodz, Wolczanska 211/215, 90-924 Lodz, Poland

<sup>b</sup>Department of Agri-Food Process Engineering, University of Warmia and Mazury in Olsztyn, Heweliusza 14, 10-718 Olsztyn, Poland



Selected kernels with incorrectly determined orientations: (a) grain with an elongated fold incorrectly recognized as crease, (b) deformed, asymmetric grain whose crease was not detected, and (c) grain with incorrectly identified germ–brush direction.

# Material, motywacja i cel projektu



# Sekwencja metod




Segmentacja obrazu i wyznaczenie obszarów ziaren

Identyfikacja poszczególnych ziaren

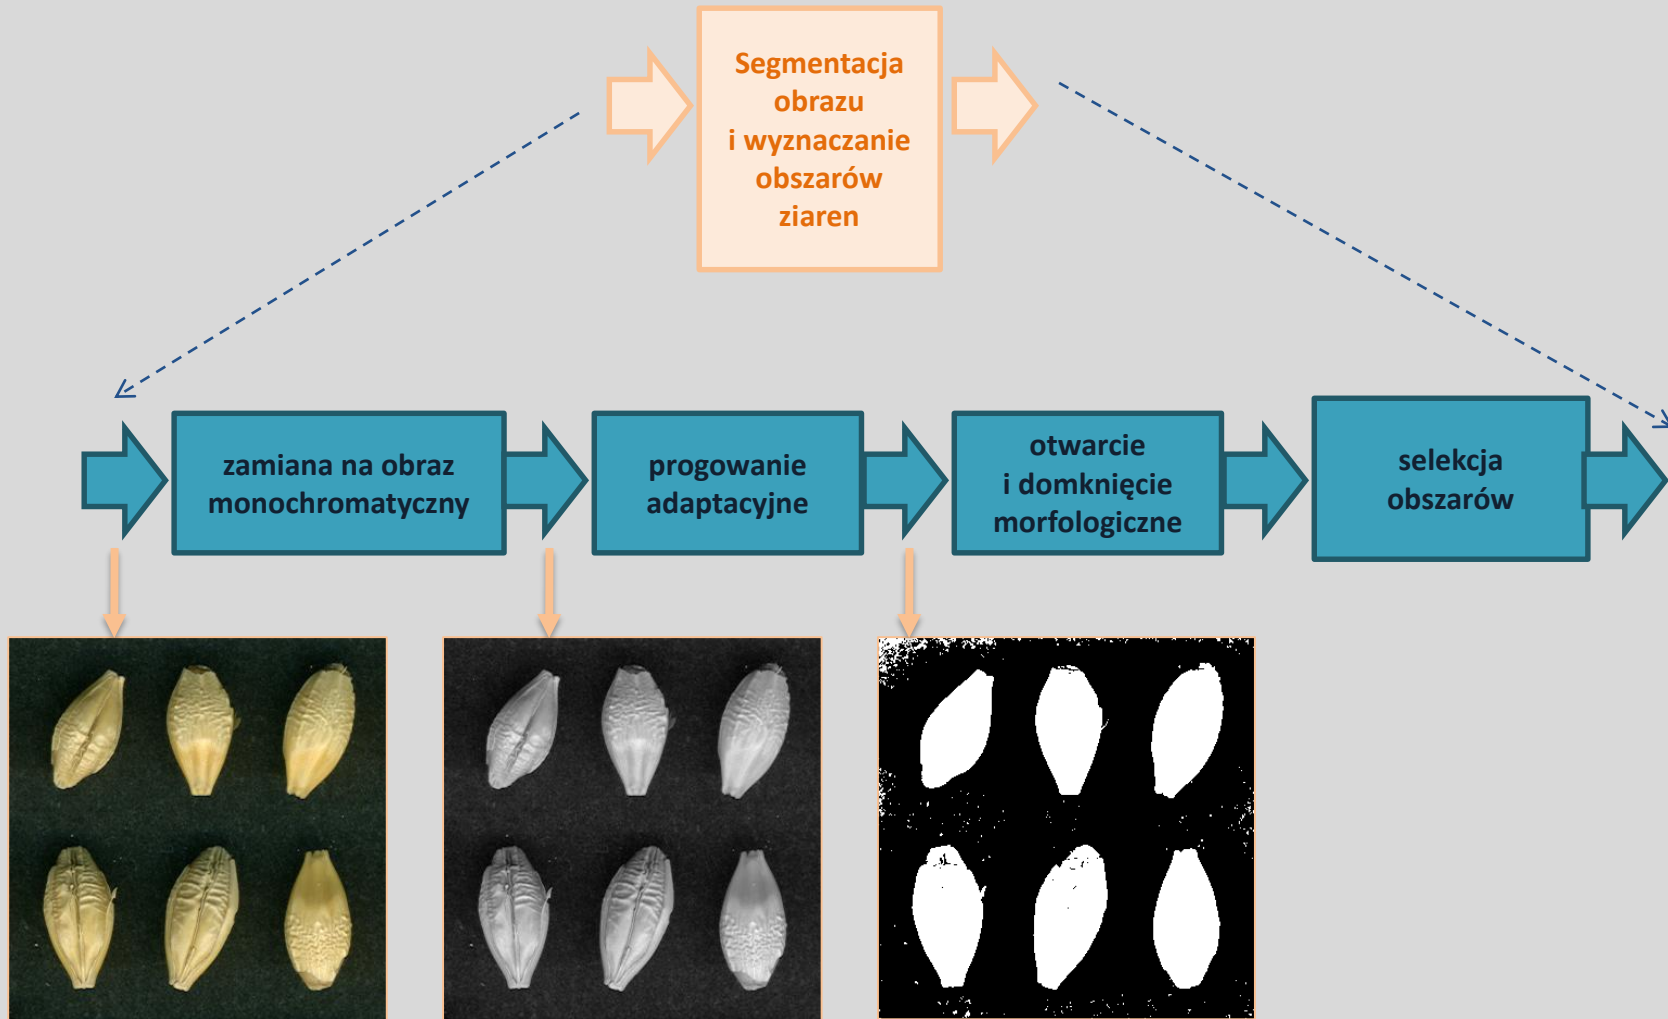
Określenie orientacji ziarniaka

Detekcja bruzdki i określenie widocznej strony


Wyznaczenie obszaru pofalowanego



# Segmentacja obrazu - progowanie



# Jęczmień browarny




Example fragment of (a) the input image and (b) its histogram




The result of the segmentation (a) after the image gray-scale thresholding and (b) followed by morphological closing and opening

# Jęczmień browarny




Determination of the kernel's visible side: the dorsal (at the top row) and the ventral dorsal (at the bottom row).



Mapping the LRE moments

# Jęczmień browarny



A comparison of manually and automatically depicted regions: (a) original image, (b) regions corresponding to individual grains, and (c) regions of wrinkled areas. The regions depicted by the assessor are marked green (FN area), the regions depicted automatically are shown in red (FP area), and the intersection of two regions (TP area) is marked yellow. (For interpretation of the references to color in this figure legend, the reader is referred to the web version of this article.)




# Jęczmień browarny

**Table 3**

Assessment of the automatic analysis results on various varieties of barley kernels.

Variety	Moisture content (%)	Detected kernels	Omitted kernels	Incorrect wrinkled region	Incorrect brush-germ orientation	Dorsal side detected	Ventral side incorrectly detected	Ventral side detected	Dorsal side incorrectly detected
Prymus	12	479	0	1	35	196	7	283	47
	14	480	0	7	31	182	3	298	37
	16	479	0	4	37	188	9	291	38
Serwal	12	479	0	5	4	214	15	265	11
	14	480	0	3	4	231	8	249	12
	16	479	0	0	7	221	15	258	10
Signora	12	479	0	0	3	257	6	222	6
	14	478	2	3	2	253	8	225	8
	16	479	0	0	1	273	5	206	4
STH	12	479	0	2	1	185	3	294	23
	14	479	0	2		218	13	261	31
	16	479	0	1	1	187	6	292	18
Victorina	12	479	0	1	1	261	10	218	1
	14	478	0	2	5	228	6	250	1
	16	476	0	1	4	232	7	244	2
Afrodita	12	476	2	4	3	223	2	253	13
	14	480	0	3	5	209	1	271	8
	16	478	2	4	6	204	1	274	16
Blask	12	479	0	1	3	231	10	248	3
	14	478	0	3	7	229	10	249	4
	16	478	2	2	9	235	12	243	1
Bordo	12	480	0	2	4	266	12	214	1
	14	480	0	2	6	253	9	227	3
	16	479	0	5	3	256	8	223	2
Conchita	12	478	2	4	6	208	5	270	11
	14	479	0	2	4	224	5	255	5
	16	476	2	3	7	226	9	250	11
Kormoran	12	478	0	4	6	226	2	252	6
	14	478	0	1	11	228	5	250	9
	16	479	0	2	10	190	3	289	13
Mercanda	12	475	4	1	12	218	11	257	15
	14	478	0	0	3	254	12	224	14
	16	479	0	2	13	228	11	251	17
Total error (%)	-	-	0.10	0.49	1.61	-	1.58	-	2.54

# Jęczmień browarny



# Mięso wieprzowe

Meat Science 97 (2014) 518–528



ELSEVIER

Contents lists available at [ScienceDirect](#)

Meat Science

journal homepage: [www.elsevier.com/locate/meatsci](http://www.elsevier.com/locate/meatsci)



The use of computer-assisted image analysis in the evaluation of the effect of management systems on changes in the color, chemical composition and texture of *m. longissimus dorsi* in pigs











Piotr Zapotoczny <sup>a,\*</sup>, Wojciech Kozera <sup>b</sup>, Krzysztof Karpiesiuk <sup>b</sup>, Rodian Pawłowski <sup>b</sup>

<sup>a</sup> Department of System Engineering, University of Warmia and Mazury in Olsztyn, Heweliusza 14, 10-718 Olsztyn, Poland

<sup>b</sup> Department of Pig Breeding, University of Warmia and Mazury in Olsztyn, Oczapowskiego 5, 10-718 Olsztyn, Poland

# Mięso wieprzowe



# Mięso wieprzowe


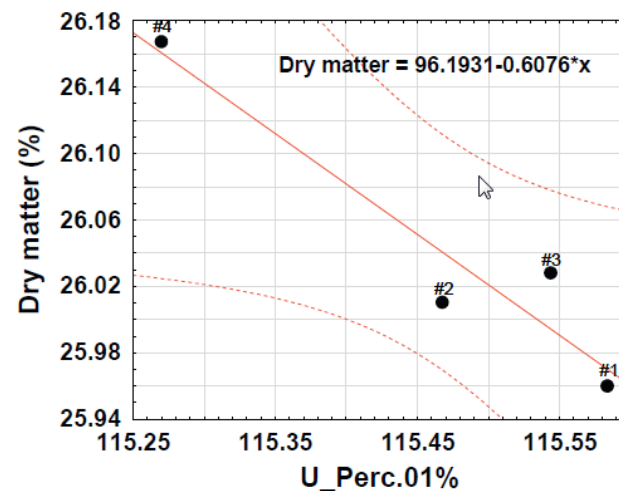
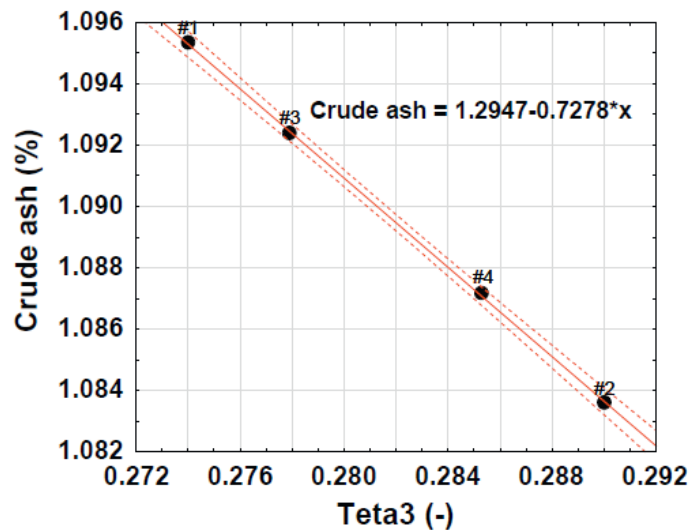


Fig. 2. Texture maps for image of m. longissimus dorsi (S\_Variance, S\_Mean).

# Mięso wieprzowe



**Table 10**  
Results of a discriminant analysis based on combined texture, color, chemical composition and spectral distribution parameters for the experimental groups.

Classification method	Total [%]	Group_1	Group_2	Group_3	Group_4
Accuracy of group classification [%]					
Naive Bayes	76	55	80	89	78
NaiveBayesSimple	73	54	80	89	78
<b>Functions.MultilayerPerceptron</b>	<b>95</b>	<b>93</b>	<b>96</b>	<b>94</b>	<b>96</b>
Lazy.KStar	88	78	88	91	87
Meta.FilteredClassifier	86	76			
Rules.PART -M 2	90	83			
Trees.BFTree	89	83			
Discriminant analysis	Forward stepwise	91	88		
	Backward stepwise	91	87		
	Best-subset	79	70		

P. Zapotoczny et al. / Meat Science 97 (2014) 518–528





Fig. 6. Classification diagrams for four experimental groups.

# Wędliny wieprzowe i drobiowe



Acknowledgments: This study was financed by grant No. N313 789140 from the Polish Ministry of Science and Higher Education.

**PLPS – Podwawelska drobiowa,**

**PLKS – Krakowska sucha drobiowa,**

**PLZS – Żywiecka podsuszona drobiowa,**

**PLCH – Szyńska konserwowa drobiowa,**

**PLSS – Szyńska drobiowa,**

**PLTB – Pierś pieczona z indyka,**

**PLWS – Parówkowa z indyka,**

**PLBS – Szyńska z pierśią indyczą**

**PKPS – Podwawelska wieprzowa**

**PKKS – Krakowska sucha wieprzowa**

**PKZS – Żywiecka podsuszona wieprzowa**

**PKCH – Szyńska konserwowa wieprzowa**

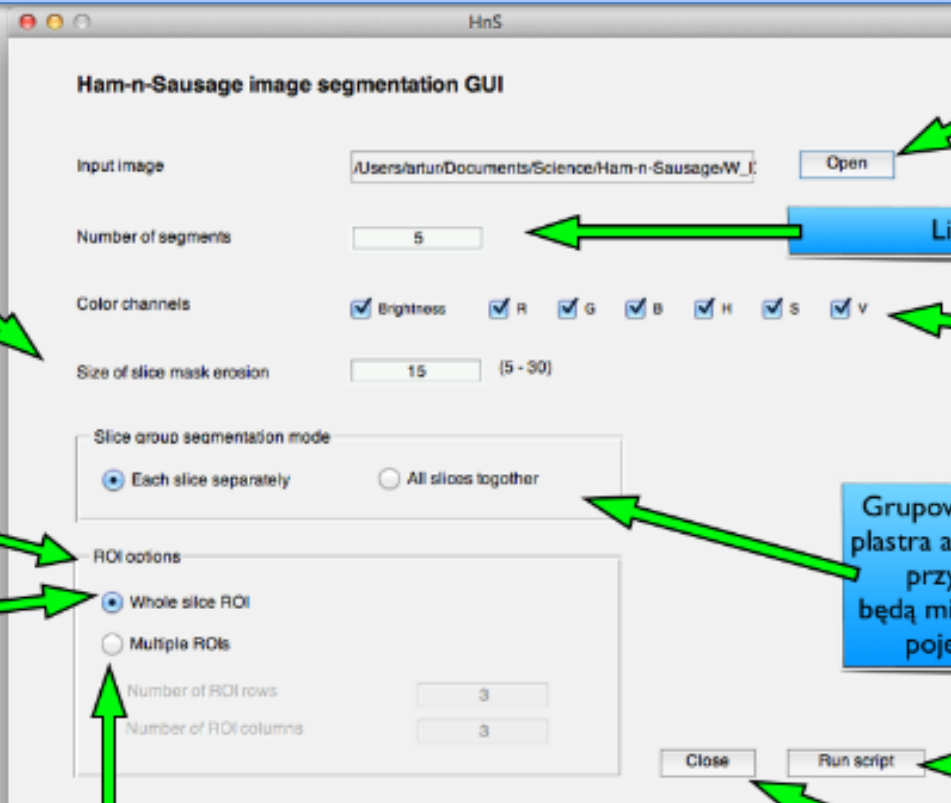
**PKSS – Szyńska wieprzowa**

**PKSL – Sopocka wieprzowa**

**PKWS – Parówkowa wieprzowa**

**PKTS – Mielonka Tyrolska,**

# Wędliny wieprzowe i drobiowe - Matlab



Wczytuje ścieżkę do obrazu

Szerokość obciętego brzegu pojedynczego plastra wędliny (dla uniknięcia segmentacji krawędzi)

Liczba wynikowych segmentów

Kanały barwowe uwzględniane w segmentacji

Opcje eksportu wyniku segmentacji


Grupowanie podobnych pikseli osobno dla każdego plastra albo razem dla wszystkich plasterów. W drugim przypadku, semantycznie podobne segmenty będą miały ten sam kolor. Wada: drobne segmenty w pojedynczych plasterkach mogą być pominięte.

Jeden obraz po segmentacji dla całego plastra wędliny

Uruchamia skrypt segmentacji




Podział wyniku segmentacji pojedynczego plastra wędliny na kwadratowe obszary zainteresowania. Obraz segmentacji dzielony jest na  $R$  wierszy i  $K$  kolumn

Zamyka okno opcji







# Wędliny wieprzowe i drobiowe



## Obraz RGB





## Obraz hiperspektralny



# Wędliny wieprzowe i drobiowe

## Krok V – Macierz klasyfikacji przypadków oraz wykres rozrzutu zmiennych kanonicznych

Grupa	Procent	PLCH	PLKS	PLWS	PLTB	PLPS	PLSS	PLBS	PLZS
PLCH	95	143	1	0	1	0	0	0	5
PLKS	79	0	296	0	0	0	0	0	79
PLWS	97	0	2	1241	0	37	1	0	0
PLTB	88	0	4	0	143	0	8	5	2
PLPS	98	0	3	20	0	1205	0	0	4
PLSS	64	0	0	0	0	0	54	30	0
PLBS	83	0	0	0	0	0	17	91	1
PLZS	88	0	44	0	0	1	0	2	333
Razem	93	143	350	1261	144	1243	80	128	424



**PLPS – Podwawelska drobiowa,**  
**PLBS – Szyńka z piersią indyczą,**  
**PLKS – Krakowska sucha drobiowa,**  
**PLZS – Żywiecka poduszona drobiowa,**  
**PLCH – Szyńka konserwowa drobiowa,**  
**PLSS – Szyńkowa drobiowa,**  
**PLTB – Pierś pieczona z indyka,**  
**PLWS – Parówkowa z indyka,**

# Wędliny wieprzowe i drobiowe

## Analiza dyskryminacyjna - postępująca

Rodzaj wędliny	%								
	poprawnej klasyfikacji	a	b	c	d	e	f	g	h
W_D_Krakowska	69	251	0	0	112	0	0	0	0
W_D_Parówkowa	99	0	1317	7	2	1	0	0	0
W_D_Podwawelska	99	0	13	1218	2	0	1	0	0
W_D_Żywiecka	94	18	0	0	360	1	1	0	1
W_D_Konserwowa	100	0	0	0	0	56	0	0	0
W_D_Konserwowa_1	95	0	0	1	2	1	103	1	0
W_D_Pieczeń	91	1	1	0	1	1	8	147	2
W_D_Szynkowa	99	0	0	0	0	1	0	0	192





Tabela 1. Możliwości aplikacji komputerowej analizy obrazu wykorzystywane na świecie w celu bezpośredniej oceny oraz predykcji i oceny pośredniej

Table 1. Possibilities of applying computer image analysis used throughout the world for the purposes of direct evaluation and prediction, and indirect evaluation

Oceniany surowiec rolno-spożywczy		Czynniki oceniane bezpośrednio	Czynniki poddawane predykcji oraz ocenie pośredniej
Mięso surowe	Mięso wołowe	– barwa – marmurkowatość – dojrzałość szkieletowa	– klasa jakości – wydajność – skład podstawowy mięsa – kruchość
	Mięso wieprzowe	– barwa – marmurkowatość	– klasa jakości – skład podstawowy mięsa
	Mięso jagnięce	– brak badań	– klasa jakości
	Ryby i owoce morza	– wielkość – kształt – barwa	– brak badań
	Tuszki drobiowe	– detekcja splenomegalii – ocena wnętrzości i uszkodzeń skóry	– klasa jakości – stan zdrowia zwierząt
Mięso poddane obróbce cieplnej		– skurcz (objętość i kształt elementu) – porowatość – barwa	– wydajność – zawartość wody – tekstura
Owoce (np. owoce cytrusowe, jabłka, truskawki)		– kształt – barwa – uszkodzenia powierzchni – stopień zabrudzenia	– klasa jakości – stopień dojrzałości – kruchość/ miękkość – zawartość związków rozpuszczalnych
Warzywa (np. oliwki)		– uszkodzenia powierzchni – barwa	– klasa jakości – kruchość/ miękkość
Ziemniaki		– uszkodzenia i wady powierzchni – barwa	– klasa jakości
Ziarna zboża, ryż, kukurydza		– wielkość – kształt – barwa – zanieczyszczenie grzybami	– tekstura – zawartość wody i jej dystrybucja – zawartość związków rozpuszczalnych – klasa jakości
Sery twarde		– zdolność topienia – wady struktury	– zawartość tłuszczu
Pieczywo		– barwa – kształt – wielkość	– tekstura



**POTENCJAŁ ORAZ ZASTOSOWANIE  
KOMPUTEROWEJ ANALIZY I PRZETWARZANIA OBRAZU  
W PRZEMYSŁE ROLNO-SPOŻYWCZYM**

Dominika Guzek, Agnieszka Wierzbicka  
Zakład Techniki w Żywności, Katedra Żywności Funkcjonalnej i Towaroznawstwa,  
Szkoła Główna Gospodarstwa Wiejskiego w Warszawie

Dominika Głowska  
Zakład Dietetyki, Katedra Dietetyki, Szkoła Główna Gospodarstwa Wiejskiego w Warszawie

# Nauki biologiczne

- **szybkie zliczanie i mierzenie komórek, organizmów lub cech**
- **zastosowanie automatyzacji**



# Rys historyczny

W roku **1920** uruchomiono telegraf do przesyłania treści gazet między Londynem i Nowym Jorkiem, za pomocą kabla transatlantyckiego.

Rok **1950** pierwsze maszyny cyfrowe. Przekształcenie zdjęć księżyca i planet pozbawione zniekształceń wprowadzanych przez ówczesne kamery TV

Lata **1960-1979** dynamiczny rozwój komputerów cyfrowych na uczelniach.  
Rzeczywisty rozwój pierwszych robotów

W latach **1980** pojawienie się ultraszybkich układów elektronicznych analogowych i cyfrowych


W latach **1990** rozwijają się specjalizowane procesory wideo realizują transformacje optyczne i geometryczne obrazów w czasie rzeczywistym, tj. w czasie 40 ms na obraz

Rok i dalej 2000 ..... ??????

# Co nas czeka ?

Skanowanie 3D

Drukowanie 3D



Papryka



Dziękuję za uwagę

Dr hab. Inż. Piotr Zapotoczny, prof. UWM