

### **PIOTR WYCIŚŁOK**

Wydział Architektury, Budownictwa i Sztuk Stosowanych, Wyższa Szkoła Techniczna w Katowicach, Katowice, 40-555, Polska, adres email: [piotr.wycislok@wst.com.pl](mailto:piotr.wycislok@wst.com.pl)

### **ARTUR WYCIŚŁOK**

Wydział Automatyki, Elektroniki i Informatyki, Politechnika Śląska, Gliwice, 44-100, Polska, adres email: [artur.wycislok@polsl.pl](mailto:artur.wycislok@polsl.pl)

## **ALGORYTM WIZYJNY ROZPOZNAJĄCY ZABRUDZENIE KOMORY FARBOWEJ**

s. 77-88

### STRESZCZENIE

W artykule przedstawiono algorytm systemu wizyjnego oraz przedstawiono przykłady jego działania, przetwarzający obraz komory farbowej w sposób umożliwiający automatyczne rozpoznanie czy jest i w jakim stopniu zabrudzona farbą drukarską. Istotą algorytmu jest jego prostota, umożliwiająca jego aplikacje na wybranych sterownikach PLC. Przykładowe oprogramowanie oparto o system Vision firmy National Instruments. Algorytm stanowi część urządzenia myjącego komory farbowe.

### SŁOWA KLUCZOWE

system wizyjny, rozpoznawanie barw, komora farbowa, identyfikacja zabrudzeń.

### **1. Wstęp**

Automatyczne rozpoznawanie pojawienia się barw w miejscu gdzie one nie występowały jako takie, nie nastrocza kłopotów [1]-[3]. Zwłaszcza, jeżeli istnieje możliwość porównania obrazu obiektu ze zdjęciem określonego obiektu bez zmian w barwach [4]. Problemy jednak narastają, gdy pojawiają się dodatkowe obostrzenia lub utrudnienia, jak np. zmienność pola obserwacji obiektu (np. na skutek innego ustawienia kamery), zmienność oświetlenia obiektu (np. na skutek przesunięcia obiektu względem źródła światła), niedostatek oświetlenia oraz możliwość wystąpienia pośród barw dodatkowych bieli i czerni. W omawianym przypadku są również elementy ułatwiające rozwiązanie problemu, jaką jest bez wątpienia, naturalna barwa drukarskiej komory farbowej, na której obserwujemy pojawianie się barw dodatkowych, którą z dobrym przybliżeniem możemy uznać za barwę szarą. Największą jednak trudnością była konieczność zastosowania możliwie prostego algorytmu, z uwagi na przeznaczenie aplikacji opartej o algorytm do zastosowania w sterowniku PLC. Poniższa praca przedstawia propozycję sposobu rozwiązania problemu.

### **2. Opis sytuacji**

Obiektem, w którym należy rozpoznać zmiany barwne jest drukarska komora farbowa, tzw. komora rakłowa, będąca elementem linii drukarskiej, poddana procesowi mycia. Celem analizy wizyjnej jest określenie czy proces mycia doprowadził do usunięcia resztek farby. Farba pozostała po procesie jest elementem barwnym, którego wystąpienie należy rozpoznać. Do wymagań wobec systemu wizyjnego należy zaliczyć: brak informacji o kolorze farby drukarskiej, brak informacji o ostatecznym położeniu

komory względem kamery, jak i źródła światła, słabe oświetlenie komory pochodzące głównie z odbić zewnętrznego oświetlenia komory myjącej. Proces rozpoznawania zabrudzeń komory rozpoczyna się po umyciu komory i włączeniu oświetlenia komory myjącej, po którym następuje ustawienie kamery wewnątrz komory farbowej i wykonanie zdjęcia. Tak wykonaną fotografię należy poddać obróbce algorytmem wizyjnym, w celu ustalenia czy komora jest zabrudzona resztkami farby i określić stopień tegoż zabrudzenia. W przedstawionym problemie jest kilka pułapek. Pierwsza to brak określonej palety możliwych kolorów. Jest to spowodowane zarówno faktem różnorodności kolorystycznej farb drukarskich, jak i spostrzeżeniem, że farba jest wymieszana z rozpuszczalnikiem zmywającym, który ma własny, różny np. w okresie eksploatacji, kolor własny. Kolejną trudność sprawia brak powtarzalności w położeniu komory względem obiektywu i względem oświetlenia. Sprawia to, że uzyskiwany na fotografii obraz jest zawsze trochę inny i nie da się pozyskać wzorca. Zaś zastosowanie uczenia maszynowego, z uwagi na moc obliczeniową systemu, nie jest praktyczne, o ile w ogóle możliwe [5][6]. Z tych względów odpowiednie przetworzenie pozyskanych danych wizyjnych już na wczesnym etapie jest niezwykle istotne [7].

### 2.1. Zastosowana metoda analizy obrazu

Zastosowana po wielu nieudanych próbach metoda rozpoznawania zabrudzenia opiera się na dwu filarach. Po pierwsze, na uznaniu, że naturalna barwa komory jest zbliżona do idealnej barwy szarej, Po drugie, że niewielkie zmiany położenia komory farbowej nie wpływają zasadniczo na odczyt stanu barwnego komory.

Założenia te, zweryfikowane w trakcie prób, pozwoliły na zbudowanie algorytmu rozpoznawania zabrudzeń komory farbowej.

Pierwszym testowanym pomysłem była poprawa jakości badanego obrazu, poprzez normalizację barw w przestrzeni barwnej RGB, która pozwala wydobyć czyste kolory z pominięciem półcieni i drobnych przyciemnień rozjaśnień [8], a następnie zastosowanie progowania, w celu oddzielenia szarości odpowiadających barwie komory [9].

### 2.2. Normalizacja przestrzeni barwnej

Główną ideą analizy przy wykorzystaniu normalizacji przestrzeni barwnej jest wyeliminowanie wpływu intensywności światła padającego na poszczególne piksele oświetlanej sceny [10][11]. Badając piksele w przestrzeni RGB intensywność światła padającego na dany piksel można wyrazić jako :

$$I=R+G+B \quad (1)$$

, gdzie R, G i B są odpowiednio wartościami piksela w kanale czerwonym, zielonym i niebieskim. Przy tak zdefiniowanej intensywności można wyprowadzić znormalizowane wartości poszczególnych kanałów barwnych piksela poprzez podzielenie odpowiedniej wartości R, G lub B, przez I [12][13]:


$$R_{\text{norm}} = \frac{R}{I} = \frac{R}{R+G+B} \quad (2)$$

$$G_{\text{norm}} = \frac{G}{I} = \frac{G}{R+G+B} \quad (3)$$

$$B_{\text{norm}} = \frac{B}{I} = \frac{B}{R+G+B} \quad (4)$$

Zabieg ten pozwala uzyskać informacje o kolorze danego piksela, niezależnie czy jest on w pełni oświetlony, czy też znajduje się w cieniu.

Przeprowadzono próby działania algorytmu normalizacji w przedstawionej formie na rzeczywistych zdjęciach zabrudzonej komory rakłowej, dla farby zielonej oraz dla farby czarnej (Rys. 1.).



Rys. 1. Komora zabrudzona i efekt zastosowania normalizacji (lewa) dla farby zielonej, (prawa) dla farby czarnej  
 Fig. 1. Chamber with leftover paint and normalization effect (left) for green paint, (right) for black paint  
 Źródło: Opracowanie własne

W przypadku analizy zabrudzenia farbą zieloną widoczne jest, że algorytm bardzo skutecznie wyróżnił te piksele, dla których barwa jest najbliższa idealnej zieleni, natomiast nie poradził sobie z refleksami świetlnymi. Jednakże patrząc na rezultaty w przypadku farby czarnej należy stwierdzić, że uzyskany w wyniku działania algorytmu normalizacji obraz nie tylko nie wyróżnia pikseli czarnych, ale wręcz przeciwnie, różnice między barwami zostały zatarte.

Tak proste podejście, jak pokazano na wcześniejszych rysunkach, okazało się niestety nieskuteczne dla analizy kolorów nie będących złożeniem barw podstawowych, z silną dominacją jednej składowej. Pożądany efekt w takiej sytuacji można uzyskać jedynie w przypadku źródła emitującego światło białe, a także jednakowych charakterystyk dla poszczególnych barw na matrycy kamery. Jest to związane ze wzorem określającym wartość danego kanału barwnego w pikselu [4]:

$$f_c(x) = m_b(x) \int_{\omega} s(\lambda, x) e(\lambda, x) \rho_c(\lambda, x) d\lambda \quad (A)$$

We wzorze tym  $m_b(x)$  określa kosinus kąta padania światła względem normalnej do powierzchni,  $s(\lambda, x)$  oznacza albo  $e$  do punktu powierzchni dla danej długości fali,  $\rho_c(\lambda, x)$  jest charakterystyką danego kanału barwnego piksela matrycy kamery,  $e(\lambda, x)$  natomiast określa charakterystykę spektralną światła docierającego do danego punktu powierzchni. Całkowanie następuje po całym spektrum światła widzialnego.


W warunkach rzeczywistych uzyskanie światła jednorodnego, tj. o identycznej charakterystyce w każdym punkcie przestrzeni oraz białego, tj. obejmującego całe widmo światła widzialnego z jednakową intensywnością, jest niemal niemożliwe, za wyjątkiem specjalnie zaprojektowanych układów. Sprawia to, że do wzorów (2)-(4) należałoby dodać poprawki, wynikające z różnego udziału poszczególnych kanałów w świetle oświetlającym scenę. W warunkach przemysłowych poprawki takie nie są obliczalne ze względu na zastosowanie różnych źródeł światła, a także liczne odbicia.

Co więcej, z uwagi na specyfikę badanego zastosowania, a więc analizy pozostałości farb drukarskich, większość z wykorzystywanych kolorów jest daleka od idealnej czerwieni, zieleni lub niebieskiej barwy.

Z tych powodów zastosowanie normalizacji przestrzeni barw nie spełnia wymagań stawianych przed algorytmem rozpoznawania barwy i należało opracować do niego inne podejście.

### 2.3. Własny algorytm rozpoznawania barw

W ogólności algorytm opiera się na porównaniu wielkości rozpoznawanych plam barwnych w komorze czystej (wzorec), w porównaniu do wielkości plam barwnych komory weryfikowanej. Pomysł ten tylko z pozoru jest prosty. Trudność polega na tym, że komora nie ustawia się po wykonaniu czynności mycia dokładnie w takiej samej pozycji jak komora do zdjęcia wzorcowego. Powoduje to zmiany zarówno w oświetleniu komory, jak zmiany w zakresie ustawienia obiektu względem kamery. Rysunek 2 przedstawia zdjęcia komory wzorcowej i komory zabrudzonej:



Rys. 2. Zdjęcie komory wzorcowej oraz zabrudzonej;  
Fig. 2. Photo of the reference and dirty chamber;  
Źródło: Opracowanie własne

Na zdjęciach widać wyraźnie zmianę położenia komory brudnej względem wzorca (położenie dysz myjących), co zaowocowało pojawieniem się refleksów bieli w innych miejscach jak w komorze wzorcowej. W innych sytuacjach zmiana położenia komory może spowodować powstawanie np. głębszych cieni.

Ponieważ algorytm ma być zastosowany w sterowniku maszyny myjącej. Algorytm rozpoznawania nie może być zbyt rozbudowany, musi być możliwy do wykonania przez stosunkowo skromne możliwości obliczeniowe sterownika. Dlatego odrzucono pomysł, by wykorzystać uczenie maszynowe. Ostatecznie algorytm opiera się na odrzuceniu ze zdjęcia wszystkich tych pikseli, których barwa w pewnych granicach mieści się w pojęciu barwy szarej. Pozostałe po tym procesie piksele są zliczane, a ich ilość porównywana do ilości na zdjęciu wzorcowym. Jak ustalono w trakcie doświadczeń, niewielkie zmiany położenia komory farbowej nie zwiększają w sposób zdecydowany ogólnej ilości plam uznanych za barwne. Jednakże pod pewnymi warunkami.

Barwa szara to taka, której składowe kanałów barwnych są na takim samym, bądź bardzo zbliżonym poziomie. W tym sensie najdoskonalszymi przykładami barwy szarej jest biel i czerni. To powoduje, że rozpoznawanie barw, oparte czysto na pomysłcie opisanym powyżej, nie byłoby w stanie rozpoznać zabrudzeń farbami białą i czarną, Stąd narodziła się konieczność modyfikacji pomysłu i podzielenia go na trzy etapy: rozpoznawanie barw (z wyjątkiem bieli i czerni), rozpoznawanie bieli i rozpoznawanie czerni.

Na szczęście udało się to wykonać dla dokładnie tego samego algorytmu, ze zmienionymi tylko ustawieniami wyjściowymi stałych parametrów algorytmu.

### Metoda rozpoznania barw (bez bieli i czerni)

Analizując to co powiedziano o roli barwy szarej, udało się określić warunki uznania piksela za odpowiedzialny za przenoszenie informacji o zabrudzeniu komory. Zasadę wykrywania pikseli niosących informację o zabrudzeniu można zapisać, dla barwy każdej z wyjątkiem bieli i czerni:

$$p_b \in \{ [R-G] > \Delta \ [R-B] > \Delta \ [G-B] > \Delta \ C_b < R, G, B < C_w \} , \quad (5)$$

dla czerni:

$$p_b \in \{ [R-G] < -\Delta \ [R-B] < -\Delta \ [G-B] < -\Delta \ 0 < R, G, B < C_w \} , \quad (6)$$

dla bieli:

$$p_b \in \{ [R-G] < \Delta \ [R-B] < \Delta \ [G-B] < \Delta \ C_b < R, G, B < 255 \} . \quad (7)$$

Gdzie we wzorach 5,6 i 7 przyjęto oznaczenia:

$p_b$  – piksel zawierający informację o zabrudzeniu,

R, G, B – składowe barwne piksela w modelu RGB,

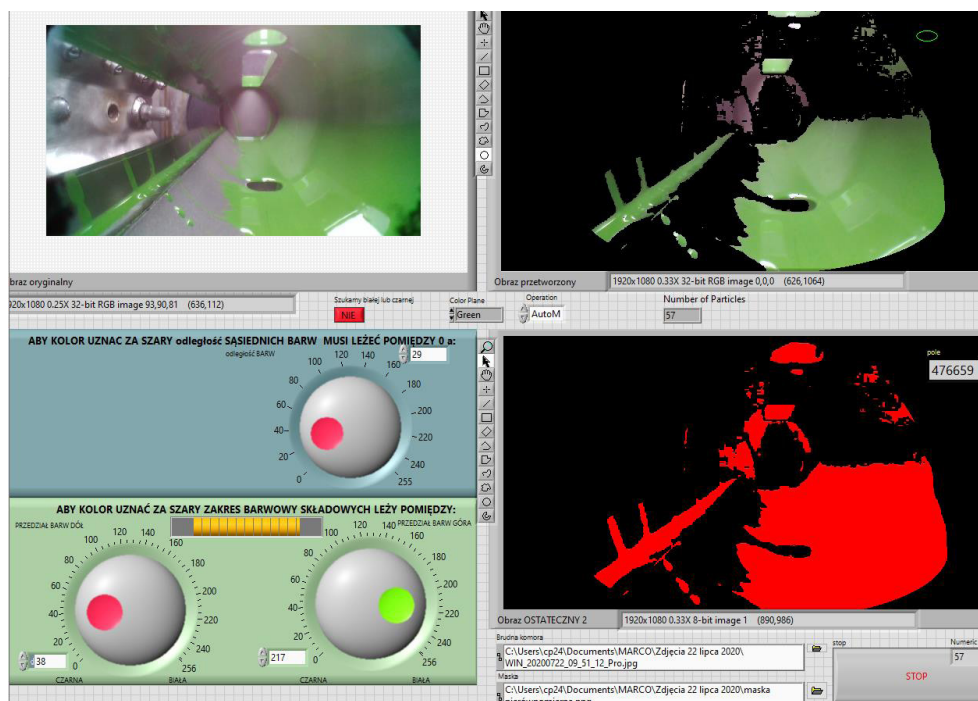
$\Delta$  – odstęp definiujący barwę szarą (ustalony doświadczalnie),

$C_b, C_w$  – granice wartości składowych barwnych, od których barwa szara traktowana jest jako odpowiednio jako czarna i biała; (0,  $C_b$ )-czarna, ( $C_w$ , 255)-biała.

### 3.3. Testowa implementacja algorytmu

Testowej implementacji algorytmu dokonano w programie Vision Firmy NI. Algorytm różni się nieznacznie od opisanego powyżej, jednak różnice wynikają tylko z jego adaptacji do możliwości Vision. W testowaniu algorytmu wykorzystano maskę.

Rysunek 3 obrazuje widok interfejsu użytkownika programu pozwalającego zarówno obserwować wpływ zmiany parametrów algorytmu na uzyskane wyniki, jak i obserwować zmiany zachodzące w analizowanym zdjęciu. Istotne z punktu widzenia algorytmu elementy to: obraz wyjściowy, odstęp składowych dozwolony dla barwy szarej, określenie granic barwy białej i czarnej, obraz po zastosowaniu maski i odrzuceniu barwy szarej oraz obraz binarny plam barwnych, wraz z jego powierzchnią.



Rys. 3. Widok interfejsu użytkownika programu testowego  
Fig. 3. Testing program user interface;

Źródło: opracowanie własne

#### 4. Wyniki badań

W trakcie powstawania algorytmu, jak i w trakcie poszukiwania parametrów optymalnych wykonano wiele prób, których opisu, jako nie wnoszących nic do wyników ostatecznych, nie zamieszczono. Poniżej jedynie przedstawiono pokrótce wpływ parametrów opisanych w algorytmie na rozpoznawanie zabrudzenia komory.


##### 4.1. Wpływ odstępu składowych barw na rozpoznawanie barwy szarej

W tabeli 1 zebrano wielkości obszaru uznanego przez algorytm za plamy barwne w eksperymencie badania wpływu odstępu pomiędzy składowymi RGB obrazu uznanego jako mieszczącego się w zakresie barwy szarej na działanie algorytmu. Na rysunku 4 natomiast pokazano, jakie obszary zostały przez algorytm zaklasyfikowane jako plamy barwne. Jako zdjęcie wyjściowe wzięto pod uwagę komorę wstępnie oczyszczoną, ale zabrudzoną resztkami barwy zielonej (Rys. 5.).


Tab. 1. Wybór odstępu ( $\Delta$ ) składowych barw RGB dla rozpoznania barwy szarej  
 Tab. 1. Selection of the spacing ( $\Delta$ ) of RGB color components for the gray color

Numer testu	$\Delta$	Obszar plam barwnych [pix]
1	10	872475
2	20	390231
3	25	186838
4	30	136232
5	40	106241
Komora referencyjna	40	8732

Źródło: opracowanie własne



Rys. 4. Obszary uznane przez algorytm jako plamy koloru w komorze zabrudzonej dla kolejno  $\Delta=10$ ,  $\Delta=20$ ,  $\Delta=25$ ,  $\Delta=30$ ,  $\Delta=40$  w komorze referencyjnej dla  $\Delta=40$   
 Fig. 4. Area defined by the algorithm as color stains in stained chamber for sequentially  $\Delta=10$ ,  $\Delta=20$ ,  $\Delta=25$ ,  $\Delta=30$ ,  $\Delta=40$  in reference chamber  $\Delta=40$   
 Źródło: opracowanie własne




Rys. 5. Zdjęcie komory po wstępnym płukaniu zabrudzonej farbą zieloną;  
Fig. 5. Chamber with green paint after initial rinsing ;

Źródło: opracowanie własne

Jak wykazują dane (Tab. 1 oraz Rys.4.) prawidłowy odstęp dla rozpoznania barwy szarej leży pomiędzy 30 a 40. Dla obu tych skrajnych wartości stosunek powierzchni uznanej za barwną, do barwy szarej to ponad 12 (plamy barwne komory czystej to mniej niż 8% plam zabrudzonej w tym przykładzie komory).

#### 4.2. Wpływ barwy białej i czarnej na rozpoznawanie zabrudzeń

Po znalezieniu ustawienia dla odstępów składowych RGB ustalono zasięg barwy białej i czarnej, deformującej wyniki poszukiwania barwy szarej. Najbardziej oczywistym wydawałoby się, jest przyjęcie, że czarny i biały jest również barwą szarą. Jednakże wyniki przeprowadzonych prób wskazują, że wtedy gubimy obszary zabrudzone, od których odbija się światło punktowo, dając białe refleksy. Na rysunku 6 (lewa) widać efekt rozpoznania barw przy założeniu, że czarny i biały są również kolorem szarym. Na rysunku 6 (prawa) przedstawiono to samo zestawienie z uwzględnieniem, że biały kolor nie jest szarym. Obrazy zestawiono ze zdjęciem wyjściowym.




Rys. 6. Porównanie rozpoznania barwy z obrazem wyjściowym, (lewa) dla uznawania barwy białej i czarnej jako szarej, (prawa) dla nieuznawania barwy białej jako szarej  
Fig. 6. Comparison of color detection versus input photo, (left) for treating black and white as gray, (right) for not treating white as gray; Źródło: opracowanie własne



Ostateczne porównanie rezultatów wskazuje, że rzeczywiście nieuwzględnienie obszarów białych jako szarych poprawia rozpoznawanie obszarów zabrudzonych, jednakże znacznym kosztem uwzględniania odbłyśków na powierzchniach czystych komory, jako plam barwnych. Należy uznać, że wyłączenie barwy czarnej i białej jest dyskusyjne i w dalszych analizach postanowiono zostawić tę kwestię do analizy rozpoznawania barwy białej i czarnej.


### 4.3. Rozpoznawanie zabrudzeń barwy czarnej

Rozpoznawanie barwy czarnej przeprowadzono dla komory farbowej zabrudzonej farbą czarną, jak na zdjęciu z Rys. 7.(lewa). Jego analiza wg wzoru (5), nie prowadzi do sukcesu, co pokazano na rysunku 7(prawa):



Rys. 7. (lewa) Komora farbowa zabrudzona farbą czarną (prawa) Wynik działania algorytmu  
 Fig. 7. (left) Chamber stained with black paint (right) Algorithm output ;  
 Źródło: opracowanie własne

Dlatego do komory zastosowano algorytm oparty o wzór (6), który uznaje, że poszukujemy barwy szarej, jednakże o ciemnej tonacji ( $0 < R, G, B < C_w$ ). Niezastosowanie tego ostatniego warunku, prowadzi do uznania całego obrazu jako szary. W wyniku prób ustalono, że dla oświetlenia panującego w komorze farbowej bardzo szybko kolor szary upodabnia się do koloru czarnego, a odstęp pomiędzy nimi jest niewielki. Najlepszym uzyskanym ustawieniem, było branie jako koloru czarnego takiego, dla którego wartości składowych RGB, nie były większe niż 100 (0-256), zaś odstęp składowych  $\Delta$ , podobnie jak w obrazie z plamami barwnymi, nie był większy niż 40 i nie mniejszy niż 30. Dla takich parametrów rozpoznanie koloru czarnego dało wyniki jak na rysunku 8 (maska ogranicza zarys obszaru rozpoznawania).



Rys. 8. Rozpoznawanie barwy czarnej na parametrach optymalnych;  
 Fig. 8. Black color recognition for optimal algorithm's parameters;  
 Źródło: opracowanie własne

#### 4.4. Rozpoznawanie zabrudzeń barwy białej

W okresie prowadzonych prób nie była użytkowana farba biała, analizy dokonano na negatywie zdjęcia komory z farbą czarną. Jednakże z uwagi na symetrię algorytmu, w sposób oczywisty, uzyskano identyczne wyniki jak dla barwy czarnej.

Z uwagi na niejednoznaczny wynik takiego testu dokonano modyfikacji zdjęcia zabrudzonej komory, podmieniając edycyjnie kolor zielony na biały. Efekt tych zabiegów zobrazowano na Rys. 9(lewa). Ponieważ fotografię poddawano jedynie badaniu algorytmem rozpoznawania bieli (wzór (7)), pozostała barwa zielona ma drugorzędne znaczenie. Po poddaniu zdjęcia rozpoznaniu bieli dla ustawień: odstęp składowych  $\Delta$  uznawanych za biel mniej niż 40, zaś zakres wartości składowych branych pod uwagę od 156 do 255. W rezultacie, algorytm rozpoznał jako biały, obszar przedstawiony na Rys. 9(prawa).



Rys. 9. (lewa)Przekształcone zdjęcie dla oddania bieli (prawa) Rozpoznawanie barwy białej na zdjęciu preparowanym;  
Fig. 9. (left) Photo transformed to emulate white paint stains (right) White color recognition on transformed  
photo; Źródło: opracowanie własne

Kopiowanie ustawień dla czerni okazało się złym pomysłem, z uwagi na liczne refleksy świetlne dające pozorne wrażenie barwy białej. Dlatego w wyniku dalszych prób ustalono, że optymalnym zakresem uznawania barwy za białą jest zakres od  $C_w$  do 255 dla  $C_w=206$  (Rys. 10).



Rys. 10. Rozpoznawanie barwy białej na zdjęciu preparowanym z ograniczonym zakresem, uznawanym za biel;  
Fig. 10. White color recognition on transformed photo with limited range of pixel values being treated as white;  
Źródło: opracowanie własne

## 5. Wnioski

Przeprowadzone analizy i próby wykazały, że prezentowana metoda rozpoznawania zabrudzeń komory farbowej, pozwala na zbadanie braku zabrudzeń pofarbowych lub wykazanie, że takowe zabrudzenia istnieją niezależnie od barwy farby brudzącej komorę. Największym problemem prezentowanego rozwiązania było rozpoznawanie barwy białej. Prezentowane rozwiązanie nie wyjaśniło do końca problemu refleksów świetlnych uznawanych, jako zabrudzenie po farbie białej. Drugim istotnym problemem okazała się barwa czarna, która z uwagi na trudności z uzyskaniem równomiernego oświetlenia komory rakłowej, mogła być wykryta pomimo braku zabrudzeń. Tym nie mniej prezentowane rozwiązanie zawiera wystarczającą dokładność rozpoznania do zastosowań przemysłowych, szczególnie, że istotnym elementem prezentowanego podejścia była postulowana od początku jego względna prostota, która dała możliwość implementacji algorytmu na sterowniku PLC.

## Bibliografia

- [1] Diplaros, A., Gevers, T., Patras, I.: Combining color and shape information for illumination-viewpoint invariant object recognition. W IEEE Transactions on Image Processing 2006, T. 15, nr 1, s. 1–11. ISSN: 1057-7149
- [2] Luo, J., Crandall, D.: Color object detection using spatial-color joint probability functions. W IEEE Transactions on Image Processing 2006, T. 15, nr 6, s. 1443–1453. ISSN: 1057-7149
- [3] Wu, Y., Huang, T.S.: Nonstationary color tracking for vision-based human-computer interaction. W IEEE Transactions on Neural Networks 2002, T. 13, nr 4, s. 948–960. ISSN: 1045-9227
- [4] Gevers, T., Gijssen, A., van de Weijer, J., Geusebroek, J.-M.: Color in Computer Vision. New York: John Wiley & Sons, Inc. 2012. ISBN: 9780470890844
- [5] Batchelor, B. G.: Intelligent Image Processing in Prolog. London: Springer-Verlag 1991. ISBN: 978-1-4471-0401-8
- [6] Batchelor, B. G., Whelan, P. F.: Real-time colour recognition in symbolic programming for machine vision systems. W Machine Vision and Applications 1995, T. 8, nr 6, s. 385–398. ISSN: 0932-8092
- [7] Stokman, H., Gevers, T.: Selection and fusion of color models for image feature detection. W IEEE Transactions on Pattern Analysis and Machine Intelligence 2007, T. 29, nr 3, s. 371–38. ISSN: 0162-8828
- [8] Cernadas, E., Fernández-Delgado, M., González-Rufino, E., Carrión P.: Influence of normalization and color space to color texture classification. W Pattern Recognition 2016, nr 61, s. 120–138. ISSN: 0031-3203
- [9] Sun, C., Talbot, H., Ourselin, S., Adriaansen, T. (Eds.): Digital Image Computing: Techniques and Applications. Canberra: Australian Pattern Recognition Society 2003. ISBN: 978-0-643-09098-9
- [10] Yang, J., Liu, C., Zhang, L.: Color space normalization: Enhancing the discriminating power of color spaces for face recognition. W Pattern Recognition 2009, nr 43, s. 1454–1466. ISSN: 0031-3203
- [11] Kandaswamy, U., Adjeroh, D., Schuckers, S. A., Hanbury A.: Robust Color Texture Features Under Varying Illumination Conditions. W IEEE Transactions on Systems, Man and Cybernetics - Part B: Cybernetics 2012, T. 42, nr 1, s. 58–68. ISSN: 1083-4419
- [12] Plataniotis, K. N., Venetsanopoulos, A. N.: Color Image Processing and Applications. Digital Signal Processing. Berlin: Springer 2000. ISBN: 978-3-540-66953-1
- [13] Weeks, A. R.: Fundamentals of Electronic Image Processing. Washington: SPIE Optical Engineering Press, IEEE Press 1996. ISBN: 9780780334106

## VISON ALGORITHM FOR DETECTION OF INK CHAMBER STAINS

### ABSTRACT

The article presents the algorithm of the vision system and presents examples of its operation, which processes the image of the ink chamber in a way that enables automatic recognition of whether it is dirty with printing ink and to what extent. The essence of the algorithm is its simplicity, which enables its applications on selected PLC devices. The sample software was based on the National Instruments Vision system. The algorithm is part of the ink chamber washing device.

### KEYWORDS

vision system, color recognition, ink chamber, stains identification.



Artykuł udostępniony na licencjach Creative Commons/ Article distributed under the terms of Creative Commons licenses: Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0). License available: [www.creativecommons.org/licenses/by-nc-sa/4.0/](http://www.creativecommons.org/licenses/by-nc-sa/4.0/)