

## Wykorzystanie ultrasłabej emisji fotonowej do klasyfikacji i oceny jakości czekolad

**Streszczenie.** W badaniach podjęto próbę wykorzystania ultrasłabej emisji fotonowej do oceny jakości wybranych surowców biologicznych. Sprawdzono poziom wtórnej luminescencji z trzech rodzajów czekolad: gorzkiej, mlecznej oraz białej. Do przeprowadzenia pomiarów użyto stanowiska wyposażonego w fotopowielacz, służący do identyfikacji pojedynczych fotonów. Odnotowano znaczne zróżnicowanie w poziomie emisyjności fotonów z wybranych produktów. Dokonano analizy wyników porównując je z zawartością poszczególnych składników odżywczych. Zastosowano sztuczne sieci neuronowe do określenia zależności pomiędzy poszczególnymi zmiennymi oraz do klasyfikacji rodzaju czekolady na podstawie liczby emitowanych przez nią fotonów.

**Abstract.** The research attempts to use ultra-low photonic emission to assess the quality of selected biological raw materials. The level of secondary luminescence from three kinds of chocolate: dark, milk and white. A station equipped with a photomultiplier used to identify individual photons was used to do the measurements. There was a appreciable difference in the emissivity level of photons from selected products. The results were compared comparing them with the content of various nutrients. Artificial neural networks were used to check the relationships between individual variables and to classify chocolate based on the number of photons it emits. (**Using emission of photons to evaluate the quality of exotic fruits.**)

**Słowa kluczowe:** emisja fotonów, czekolada, jakość żywności, sztuczne sieci neuronowe.

**Keywords:** photon emission, chocolate, quality of food, artificial neural networks.

### Wstęp

Określenie jakości żywności jest kluczowym elementem wprowadzenia produktu na rynek oraz jedną z najważniejszych kwestii podczas wyboru produktu przez klienta. Stanowi ono jednak wciąż ogromny problem dla technologii oceny produktów spożywczych. Tradycyjne metody laboratoryjne, pozwalające precyzyjnie określić jakość produktu, w oparciu o badanie szeregu parametrów, wykorzystują techniki wymagające dużych nakładów czasowych oraz finansowych [1, 2]. Specjalnym rodzajem badań laboratoryjnych są techniki instrumentalne, które cechują się nowoczesnością i wielokierunkowością badań. Dzięki wykorzystaniu metod elektrochemicznych, chromatograficznych oraz optycznych, możliwe staje się szybkie określenie wielu właściwości towaru, bez jego zniszczenia. Są to jednak procedury wymagające skomplikowanego, a co za tym idzie - drogiego wyposażenia badawczego i pomiarowego. Z tego powodu, do oceny żywności najczęściej wykorzystuje się techniki oceny organoleptycznej, polegające na ocenie jakości za pomocą zmysłów. Rozwiązania te są jednak bardzo subiektywne, przez co nie dają jednoznacznego i precyzyjnego wyniku.

Jedną z koncepcji badania jakości żywności, opracowaną przez niemieckiego biofizyka F.A. Popp'a [3], jest pomiar emisji fotonów emitowanych z produktów spożywczych oraz surowców biologicznych. Emisja fotonów nie jest widoczna gołym okiem, bo chociaż fotony emitowane są w zakresie widzialnym, to emisja ta jest niższa niż próg energetyczny czułości ludzkiego oka. Według Popp'a, wszystkie organizmy żywe emitują promieniowanie charakteryzujące się niewielkim natężeniem i długością fali w zakresie 300 do 800 nm oraz koherencją. Pomiar emisji fotonów jest możliwy dzięki temu, że wszystkie organizmy począwszy od bakterii, a skończywszy na człowieku, stale emitują słabe światło zwane wtórną luminescencją [4]. Hipoteza zaproponowana przez Popp'a podkreśla, że do poprawnego funkcjonowania i rozwoju organizmów żywych potrzebna jest żywność, która posiada zarówno wysoką jakość jak również wysoką wartość negentropii czyli tzw. ujemnej entropii. Idea ta wykazuje, że żywność posiadająca wysoki poziom negentropii posiada optymalną liczbę „uwalnianych” na

zewnątrz fotonów, które pozwalają w organizmie na uporządkowanie struktur i procesów, na różnych poziomach [5]. Na podstawie wieloletnich badań F.A. Popp dowiódł, że jakość żywności jest zależna od skumulowanej w niej energii świetlnej w postaci fotonów, a produkty wyższej jakości mają większą zdolność do kumulowania światła [4].

Chociaż istnieje wiele publikacji porównujących produkty o różnej jakości i emitowanej przez te produkty ilości fotonów, pomiar ultrasłabej luminescencji wciąż traktuje się jako uzupełnienie innych metod określania jakości żywności.

### Materiał


Dzięki zawartości flawonoidów pochodzenia roślinnego, a zwłaszcza epikatechiny, spożywanie czekolady pozytywnie wpływa na zdrowie człowieka. Związki te należą do grupy polifenoli [6]. Największe stężenie flawonoidów odnotowuje się do 3 godzin po spożyciu czekolady, ale związki te utrzymują się w organizmie nawet do 8 godzin [7]. Czekolada ciemna, zawierająca większe ilości kakao, charakteryzuje się wyższym stężeniem polifenoli niż czekolada mleczna czy biała [8]. Na tej podstawie uznaje się, że czekolada gorzka jest zdrowsza niż jej mleczne odpowiedniki. Pozytywny związek flawonoidów na organizm zachodzi poprzez działanie mechanizmów: produkcji tlenu azotu, działania antyoksydacyjnego, przeciwpłytkowego, przeciwzapalnego, spadku poziomu lipidów, a także redukcji insulinooporności [9]. Kolejnym wartościowym składnikiem czekolady jest tryptofan i powstająca z niego serotonina. Czekolada z zawartością 85% kakao posiada więcej serotoniny – 2,9 mikrograma na gram, natomiast czekolada z zawartością 70-85% kakao bogatsza jest w jej prekursor – tryptofan – 13,3 mikrograma na gram [10]. Ciemna czekolada oprócz wprowadzania serotoniny zawartej w swoim składzie podnosi również jej poziom w organizmie, przez cukry, które pobudzają tkanki do jej produkcji. Serotonina jest aminą biogenną, popularnie nazywaną „hormonem szczęścia” [11]. Pobudza ona agregację płytek krwi, poprawiając mechanizm krzepnięcia. Jest też neuroprzekaznikiem pełniącym wiele funkcji w centralnym układzie nerwowym, m.in. reguluje ośrodek głodu, sen, nastrój, procesy pamięci i uczenia. Niedobór tej cennej aminy jest przyczyną depresji [13].

Celem pracy było określenie poziomu emisji fotonów z czekolady gorzkiej, mlecznej i białej oraz sprawdzenie zależności pomiędzy ilością fotonów emitowanych przez produkt, a zawartością poszczególnych składników. Zakres pracy obejmował badanie ultrasłabej emisji fotonowej w 20 wybranych produktach spożywczych, tj. w 5 czekoladach gorzkich, 5 czekoladach mlecznych oraz 10 czekoladach białych różnych producentów, a także statystyczną analizę otrzymanych wyników.

### Metodyka badań

Zliczanie pojedynczych fotonów (Single Photon Counting- SPC), emitowanych z surowców biologicznych, odbywa się z wykorzystaniem ultraczułych fotopowielaczy. Zakres spektralnej czułości tych urządzeń można modyfikować poprzez odpowiedni skład materiału fotokatody, zaś szумы i prąd ciemny obniżać poprzez ich chłodzenie [12]. Zwykle miarą natężenia promieniowania jest prąd średni fotopowielacza. Większą zdolność pomiaru uzyskuje się, zliczając impulsy prądu pochodzące od pojedynczych fotonów. W ten sposób można mierzyć mniejszy strumień fotonów, rzędu kilkudziesięciu fotonów na sekundę.

Do przeprowadzenia badań został wykorzystany autorski układ pomiarowy, będący wyposażeniem Laboratorium Eksperymentalnych Technik Badawczych Surowców i Produktów Biologicznych. Układ pomiarowy (rys. 1) pozwala na rejestrację oraz zliczanie uwalnianych fotonów z badanej próbki. Urządzenie składa się z komory pomiarowej i wbudowanego fotopowielacza, dzięki któremu realizowany jest pomiar emisji fotonów. Emitująca światło próbka jest umieszczona w centralnej części komory pomiarowej, w osi symetrii szczeliny fotopowielacza. Ten światłoczuły element zamienia sygnały świetlne pochodzące od badanego obiektu na impulsy elektryczne. Impulsy elektryczne, przekształcane w dyskryminatorze na impulsy logiczne, są następnie zliczane w liczniku [14,15].




Rys.1. Układ pomiarowy: a – fotopowielacz, b- komora pomiarowa, c – interfejs, d – komputer, e – oprogramowanie BioLumi

Pomiar zaników fluorescencji metodą skorelowanego w czasie zliczania pojedynczych fotonów wizualizowany jest w czasie rzeczywistym na ekranie komputera i archiwizowany w sposób automatyczny w jego pamięci.

Czekolady, umieszczone w opakowaniu światłoszczelnym, były przechowywane w temperaturze 19-20°C, w pomieszczeniu pozbawionym światła przez 24 godziny. Sposób postępowania z próbkami określono w autorskiej procedurze badawczej (Procedura badawcza PB-01 wyd. 4 z dnia 30.09.2018r.), akredytowanej przez Polskie Centrum Akredytacji. Po założonym czasie wynoszącym 24 godziny, z każdej z tabliczek przygotowano po pięć próbek o masie 5g (z dokładnością do 0,1g) każda. Materiał umieszczano na jednorazowym szkle laboratoryjnym (rys.2). Czas pomiaru zawsze wynosił 600


sekund, przy częstotliwości detekcji 0,8 Hz. Badania przeprowadzono w wyizolowanym pod względem oświetlenia pomieszczeniu, w laboratorium zamkniętym, w którym temperatura powietrza wynosiła średnio 19,5°C, a wilgotność względna – średnio 41%.



Rys.2. Rozdrobniony materiał badawczy umieszczony na szalkach Petriego

### Wyniki badań

Średnia liczba fotonów emitowanych przez próbki czekolad gorzkich wynosiła 110 fotonów/600 sekund (odchylenie standardowe wynosiło 33 sztuk), średnia liczba fotonów emitowanych przez próbki czekolad mlecznych wynosiła 69 fotonów/600 sekund (odchylenie standardowe wynosiło 15 sztuk), a średnia liczba fotonów emitowanych przez próbki czekolad białych wynosiła 132 fotonów/600 sekund (odchylenie standardowe wynosiło 6 sztuk). Na wykresie poniżej przedstawiono średnią liczbę fotonów emitowanych przez wszystkie próbki poszczególnych czekolad z zaznaczeniem odchylenia standardowego. Największą średnią liczbę emitowanych fotonów odnotowano w czekoladzie białej nr 1 (135 fotonów/600 sek.), najmniejszą zaś w czekoladzie gorzkiej nr 1 (56 fotonów/600 sek.).



Rys.3. Średnia liczba fotonów emitowanych przez próbki czekolad gorzkich (G1-G5), mlecznych (M1-M5) i białych (B1-B5)

Z uwagi na fakt, że składnikiem prozdrowotnym w czekoladach jest kakao, zbadano zależność pomiędzy zawartością tego substratu, a emisją fotonów w czekoladach gorzkich i mlecznych. W tym celu, obliczono współczynnik korelacji pomiędzy wymienionymi dwoma zmiennymi. Współczynnik ten określa, w jakim stopniu jedna zmienna zależy od drugiej. Wyniki porównano z klasyfikacją J.Guilford'a [16], która przedstawia się następująco:

- |r|=0|r|=0 – brak korelacji
- 0,0<|r|≤0,1 - korelacja nikła
- 0,1<|r|≤0,3 - korelacja słaba
- 0,3<|r|≤0,5 - korelacja przeciętna
- 0,5<|r|≤0,7 - korelacja wysoka
- 0,7<|r|≤0,9 - korelacja bardzo wysoka
- 0,9<|r|<1,0 - korelacja niemal pełna
- |r|=1|r|=1 - korelacja pełna

gdzie  $r$  – współczynnik korelacji pomiędzy zmiennymi.

Współczynnik korelacji ilości emitowanych fotonów z zawartością masy kakaowej wynosi 0,6. Według klasyfikacji J.Guilford'a, jest to korelacja wysoka. Nie stwierdzono istotnej zależności pomiędzy liczbą fotonów emitowanych przez próbki czekolad, a zawartością cukru, tłuszczu, białka oraz wartością energetyczną badanych produktów. Współczynniki korelacji dla tych zmiennych, według określonej wyżej klasyfikacji, są określone jako słabe lub nikłe.

Oceniono również możliwość zastosowania sztucznych sieci neuronowych do modelowania zależności pomiędzy zawartością składników odżywczych, a liczbą emitowanych fotonów.

Na proces budowy neuronowego modelu regresyjnego złożyły się następujące etapy: (1) określenie charakteru zmiennych; (2) wybór typu i określenie struktury sieci neuronowej; (3) uczenie sieci neuronowej; (4) ocena modelu sieci. Zaprojektowana sieć neuronowa powinna odzwierciedlać istniejące w rzeczywistości powiązania pomiędzy zestawem zmiennych wejściowych, a zestawem zmiennych wyjściowych [17].

Określono następujące dane wejściowe: minimalna zawartość masy kakaowej [%], zawartość cukru [g/100g], zawartość tłuszczu [g/100g], zawartość białka [g/100g], wartość energetyczna [kcal/100g], rodzaj czekolady (gorzka/mleczna/biała). Dane wyjściowe były reprezentowane przez liczbę fotonów emitowanych przez poszczególne próbki czekolad. Fragment zestawu danych uczących w postaci zmiennych wejściowych i wyjściowych przedstawia rysunek 4.

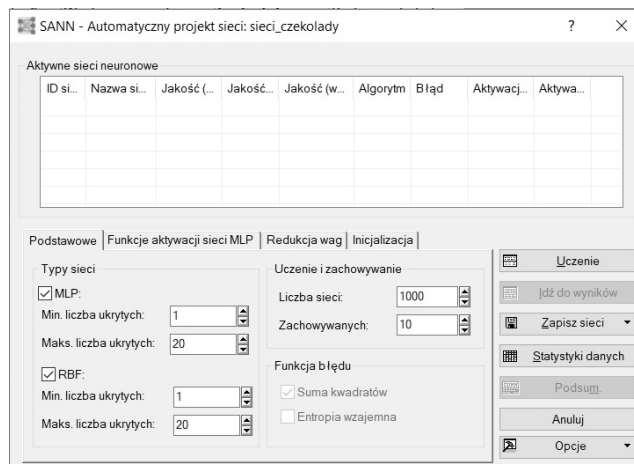
Id sieci	Nazwa sieci	Jakość (uczenie) [%]	Jakość (testowanie) [%]	Jakość (walidacja) [%]	Jakość (średnia) [%]	Algorytm uczenia	Funkcja błędów	Aktywacja (ukryte)	Aktywacja (wyjściowe)
1	RBF 8-9-1	0,787562	0,740909	0,956507	0,828326	RBFT	SOS	Gaussa	Liniowa
2	RBF 8-12-1	0,861208	0,891723	0,973689	0,915540	RBFT	SOS	Gaussa	Liniowa
3	RBF 8-16-1	0,884159	0,897167	0,972607	0,917984	RBFT	SOS	Gaussa	Liniowa
4	RBF 8-13-1	0,873995	0,840887	0,953682	0,889521	RBFT	SOS	Gaussa	Liniowa
5	RBF 8-6-1	0,884709	0,927873	0,961089	0,924557	RBFT	SOS	Gaussa	Liniowa
6	RBF 8-13-1	0,877644	0,889744	0,974212	0,913867	RBFT	SOS	Gaussa	Liniowa
7	RBF 8-15-1	0,882283	0,896809	0,972084	0,917059	RBFT	SOS	Gaussa	Liniowa
8	RBF 8-13-1	0,903853	0,925693	0,956858	0,928801	RBFT	SOS	Gaussa	Liniowa
9	RBF 8-9-1	0,894726	0,932905	0,956263	0,927965	RBFT	SOS	Gaussa	Liniowa
10	RBF 8-13-1	0,890037	0,934384	0,957883	0,927435	RBFT	SOS	Gaussa	Liniowa

Rys.4. Fragment zbioru uczącej sieć neuronową

Zbiór ten został podzielony na zbiór danych uczących (70%), zbiór danych testowych (15%) oraz zbiór danych walidacyjnych (15%). Wybór stosowanej metody (tj. sieci neuronowej) automatycznego rozpoznawania wzorców zależy od rozwiązania problemu. Brak jednego, uniwersalnego narzędzia nie wynika z niedoskonałości metod rozpoznawania, ale ze złożoności pozyskiwanych sygnałów źródłowych [18]. Do przedstawionego w artykule problemu użyto sieci typu perceptron wielowarstwowy - MLP (ang. Multilayer Perceptron) oraz sieci o radialnych funkcjach bazowych - RBF (ang. Radial Basis Function). Wybór ten warunkowany był ograniczeniem narzędzia stosowanego do tworzenia sieci neuronowej (pakiet STATISTICA Neural Networks).

Opracowanie neuronowego modelu wymagało, w pierwszej kolejności, wyznaczenia optymalnej architektury sieci. Pod pojęciem doboru struktury sieci rozumiane jest nie tylko ustalenie liczby neuronów w warstwie wejściowej, ale również liczby warstw oraz liczby neuronów w warstwach ukrytych. Problem doboru odpowiedniej architektury sieci (tj. przede wszystkim, ilości warstw ukrytych), rozwiązano poprzez zastosowanie

Automatycznego Projektanta Sieci będącego częścią pakietu Statistica Neural Networks StatSoft (rys.5).



Rys.5. Okno modułu automatycznego projektanta sieci z pakietu Statistica Neural Networks StatSoft

Utworzono 1000 sieci typu MLP i typu RBF. Założono minimalną liczbę neuronów w warstwie ukrytej równą 1 i maksymalną liczbę neuronów w warstwie ukrytej równą 20. Rysunek poniżej przedstawia fragment tabeli zawierającej podsumowanie wyników automatycznego poszukiwania najbardziej efektywnej sieci.

Id sieci	Nazwa sieci	Jakość (uczenie) [%]	Jakość (testowanie) [%]	Jakość (walidacja) [%]	Jakość (średnia) [%]	Algorytm uczenia	Funkcja błędów	Aktywacja (ukryte)	Aktywacja (wyjściowe)
1	RBF 8-9-1	0,787562	0,740909	0,956507	0,828326	RBFT	SOS	Gaussa	Liniowa
2	RBF 8-12-1	0,861208	0,891723	0,973689	0,915540	RBFT	SOS	Gaussa	Liniowa
3	RBF 8-16-1	0,884159	0,897167	0,972607	0,917984	RBFT	SOS	Gaussa	Liniowa
4	RBF 8-13-1	0,873995	0,840887	0,953682	0,889521	RBFT	SOS	Gaussa	Liniowa
5	RBF 8-6-1	0,884709	0,927873	0,961089	0,924557	RBFT	SOS	Gaussa	Liniowa
6	RBF 8-13-1	0,877644	0,889744	0,974212	0,913867	RBFT	SOS	Gaussa	Liniowa
7	RBF 8-15-1	0,882283	0,896809	0,972084	0,917059	RBFT	SOS	Gaussa	Liniowa
8	RBF 8-13-1	0,903853	0,925693	0,956858	0,928801	RBFT	SOS	Gaussa	Liniowa
9	RBF 8-9-1	0,894726	0,932905	0,956263	0,927965	RBFT	SOS	Gaussa	Liniowa
10	RBF 8-13-1	0,890037	0,934384	0,957883	0,927435	RBFT	SOS	Gaussa	Liniowa

Rys.6. Fragment wyniku symulacji w module Automatycznego projektanta sieci z pakietu Statistica Neural Networks StatSoft (dla badanego modelu regresyjnego)

Po przeanalizowaniu różnych struktur sieci neuronowej stwierdzono empirycznie, że najlepsze wyniki uczenia osiąga sieć RBF o 13 neuronach w warstwie ukrytej (zaznaczona na rysunku 6, na żółto sieć RBF 6-13-1). Opracowany model posiada strukturę złożoną z sześciu neuronów w warstwie wejściowej, trzynastu neuronów w warstwie ukrytej oraz jednego neuronu w warstwie wyjściowej. Wybrana sieć osiąga bardzo dobrą jakość uczenia - równą ponad 0,9, przy wykorzystaniu algorytmu uczenia RBFT.

Zbadano także możliwość wykorzystania informacji o liczbie emitowanych fotonów do klasyfikowania czekolady na gorzką, mleczną lub białą. Jako dane wejściowe do modelu klasyfikującego, wprowadzono liczbę fotonów emitowanych z próbki, a jako warstwę wyjściową – cyfrę określającą rodzaj czekolady (1 - gorzka, 2 - mleczna, 3 - biała). Podobnie jak wcześniej, utworzono sieci MLP i RBF. Założono minimalną liczbę neuronów w warstwie ukrytej równą 1 i maksymalną liczbę neuronów w warstwie ukrytej równą 20. Rysunek 7 przedstawia fragment tabeli zawierającej podsumowanie wyników automatycznego poszukiwania najbardziej efektywnej sieci.

Id sieci	Nazwa sieci	Jakość (uczenie) [%]	Jakość (testowanie) [%]	Jakość (walidacja) [%]	Jakość (średnia) [%]	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
...	...	...	...	...	...	...	...	...	...
16	MLP 1-19-3	66,03774	90,9091	72,72727	76,55803	BFGS 4	SOS	Wykładnicza	Tanh
17	MLP 1-12-3	69,81132	90,9091	63,63636	74,78559	BFGS 5	Entropia	Linowa	Softmax
18	MLP 1-22-3	67,92453	100,0000	54,54545	74,15666	BFGS 9	Entropia	Logistyczna	Softmax
19	RBF 1-12-3	69,81132	90,9091	54,54545	71,75529	RBFT	SOS	Gausa	Linowa
20	MLP 1-23-3	67,92453	90,9091	63,63636	74,15666	BFGS 5	Entropia	Tanh	Softmax
21	RBF 1-2-3	73,58491	81,8182	72,72727	76,04345	RBFT	Entropia	Gausa	Softmax
22	RBF 1-6-3	79,24528	81,8182	72,72727	77,93025	RBFT	SOS	Gausa	Linowa
23	RBF 1-20-3	71,69811	81,8182	36,36364	63,29331	RBFT	SOS	Gausa	Linowa
24	MLP 1-7-3	69,81132	100,0000	54,54545	74,78559	BFGS 12	Entropia	Logistyczna	Softmax
25	RBF 1-23-3	73,58491	100,0000	45,45455	73,01315	RBFT	SOS	Gausa	Linowa
26	MLP 1-7-3	77,35849	81,8182	81,81818	80,33162	BFGS 32	SOS	Tanh	Tanh

Rys.7. Fragment wyniku symulacji w module Automatycznego projektanta sieci z pakietu Statistica Neural Networks StatSoft (dla badanego modelu klasyfikującego)

Po przeanalizowaniu różnych struktur sieci neuronowej stwierdzono empirycznie, że najlepsze wyniki uczenia osiąga sieć MLP o 7 neuronach w warstwie ukrytej (zaznaczona na rysunku 7, żółto sieć MLP 1-7-3). Opracowany model posiada strukturę złożoną z jednego neuronu w warstwie wejściowej, siedmiu neuronów w warstwie ukrytej oraz trzech neuronów w warstwie wyjściowej. Wybrana sieć osiąga bardzo dobrą średnią jakość - równą ponad 80% (w tym jakość uczenia równą ponad 77%), przy wykorzystaniu algorytmu uczenia BFGS 32.

#### Podsumowanie i wnioski

Choć metoda zliczania fotonów została odkryta w poprzednim stuleciu, wciąż uznawana jest za nowatorską i rzadko stosowaną. Niewątpliwą zaletą metody pomiaru emisji fotonów jest jej nieinwazyjność w badany materiał [12], ponieważ emitowanie promieniowania odbywa się poza obszarem obiektu badanego. W badaniach podjęto próbę oceny przydatności badania emisji fotonów z czekolad białych do oceny ich jakości. Dokonano analizy wyników emisji fotonów z czekolad gorzkich, mlecznych oraz białych, różnych producentów, a otrzymane wartości skorelowano z zawartością składników odżywczych. Badane próbki znacząco różniły się otrzymanymi wynikami, przy czym nie potwierdzono hipotezy zakładającej, że czekolady z wysoką zawartością kakao będą emitowały najwięcej fotonów. Zależność ta jest prawdziwa przy porównywaniu czekolad gorzkich i mlecznych, ponieważ stwierdzono wysoki stopień korelacji pomiędzy zawartością kakao, a liczbą emitowanych fotonów. Nie potwierdza się ona przy analizie wyników emisji fotonowej dla czekolad białych, jednak wysoka emisyjność fotonowa w przypadku tego produktu może być wywołana zawartością innych składników (w tym również uznanych za prozdrowotne). Nie stwierdzono istotnej korelacji pomiędzy zawartością cukru [g/100g], zawartością tłuszczu [g/100g], zawartością białka [g/100g] oraz wartością energetyczną [kcal/100g], a liczbą emitowanych fotonów. Stwierdzono natomiast zasadność stosowania sztucznej sieci neuronowej do sprawdzenia zależności pomiędzy wymienionymi zmiennymi. Utworzony model regresyjny uzyskał w procesie uczenia wysoką jakość równą ponad 0,9. Otrzymane wyniki mogą posłużyć uogólnieniu na nowe przypadki (tj. produkty), które nie były prezentowane sieci podczas procesu uczenia [65]. Opracowany neuronowy model klasyfikujący rodzaj

czekolady ze względu na liczbę emitowanych fotonów uzyskał wysoką jakość równą ponad 80%.

**Autorzy:** dr inż. Karolina Trzyniec, mgr inż. Ernest Popardowski, prof. dr hab. inż. Tadeusz Juliszewski, dr inż. Dariusz Baran, mgr inż. Anna Miernik, Uniwersytet Rolniczy w Krakowie, Wydział Inżynierii Produkcji i Energetyki, Katedra Eksploatacji Maszyn, Ergonomii i Procesów Produkcyjnych, ul. Balicka 116B, 30-149 Kraków, E-mail: karolina.trzyniec@urk.edu.pl; ernest.popardowski@urk.edu.pl, tadeusz.juliszewski@urk.edu.pl; rtbarand@cyf-kr.edu.pl, miernikanna07@gmail.com

#### LITERATURA

- [1] Kordowska-Wiater M., Sosnowska B., Waśko A., Janas P. 2002. Ocena jakości mikrobiologicznej wybranych mrożonych owoców jagodowych. Żywność, Nr 4(33).
- [2] Jakubowski T. 2018. The reaction of garden cress (*Lepidium sativum* L. to microwave radiation. Applications of Electromagnetics in Modern Techniques and Medicine (PTZE), IEEE Xplore digital library, s. 81-84, DOI:10.1109/PTZE.2018.8503170.
- [3] Popp F.A. 2010. Przekaz jedzenia, czyli co nas odżywia. Wydawnictwo Virgo, Warszawa.
- [4] Kielbasa P., Drózd T., Nawara P., Drózd M. 2017. Wykorzystanie emisji biofotonów do parametryzacji jakościowej produktów spożywczych. Przegląd Elektrotechniczny, nr 1, s. 153-156.
- [5] Oziębłowski M., Drózd M., Kielbasa P., Drózd T., Gąsiorowski A., Nawara P., Tabor S. 2017. Ultra słaba luminescencja (USL) jako potencjalna metoda ocena jakości żywności tradycyjnej. Przegląd Elektrotechniczny, Nr 93(12).
- [6] Manach C., Scalbert A., Morand C. 2004. Polyphenols: food sources and bioavailability, The American Journal of Clinical Nutrition.
- [7] Richelle M., Tavazzi I., Enslin M., Offord E. 1999. Plasma kinetics in man of epicatechin from black chocolate. European Journal of Clinical Nutrition.
- [8] Miller K., Stuart D., Smith N. 2006. Antioxidant activity and polyphenol and procyanidin contents of selected commercially available cocoa-containing and chocolate products in the United States. Journal of Agricultural and Food Chemistry.
- [9] Ding E., Hutfless S., Ding X., Girotra S. 2006. Chocolate and prevention of cardiovascular disease: a systematic review. Nutrition & Metabolism.
- [10] Guillén-Casla V, Rosales-Conrado N, León-González ME. 2012. Determination of serotonin and its precursors in chocolate samples by capillary liquid chromatography with mass spectrometry detection.
- [11] Berger M., Gray J., Roth B. 2009. The expanded biology of serotonin. Annual Review of Medicine.
- [12] Borc R., Jaśkowska A., Dudziak A. 2015. Ultraślaba emisja fotonowa z układów żywych, Wydawnictwo Politechniki Lubelskiej.
- [13] Mutschler E, Geisslinger G, Heyo K. 2013. Farmakologia i toksykologia. MedPharm Polska, Wrocław.
- [14] Trzyniec K., Juliszewski T., Nawara P., Popardowski E., Oziębłowski M. 2019. Wykorzystanie emisji fotonów do oceny jakości owoców egzotycznych. Przegląd Elektrotechniczny, Nr 1/2019, s. 117-120, ISSN 0033-2097.
- [15] Galazka-Czarnecka, I.; Korzeniewska E., Czarnecki A. et al., Evaluation of Quality of Eggs from Hens Kept in Caged and Free-Range Systems Using Traditional Methods and Ultra-Weak Luminescence, Applied Sciences-Basel, 9 (2019), No. 12, 2430.
- [16] Guilford J. P. 1965. Fundamental Statistics in Psychology and Education. New York
- [17] Siderska J. 2013. Analiza możliwości zastosowania sieci neuronowych do modelowania wartości kapitału społecznego w firmach IT. Economics and Management, 1/2013, s. 84-97.
- [18] Kwiatkowski W. 2007. Metody automatycznego rozpoznawania wzorców. BEL Studio Sp. z o. o., Warszawa