

RECOGNITION OF SELECTED VARIETIES OF APPLES USING NEURAL MODELING

Summary

The paper attempts to identify varieties of apples on the basis of their characteristics, using the chosen methods of artificial intelligence. For this purpose were used the selected topologies of artificial neural networks as tools to identify the apples on the basis of their digital images.

ROZPOZNAWANIE WYBRANYCH ODMIAN JABŁEK Z WYKORZYSTANIEM MODELOWANIA NEURONOWEGO

Streszczenie

W pracy podjęto próbę rozpoznawania odmian jabłek na podstawie ich cech charakterystycznych, z wykorzystaniem wybranych metod sztucznej inteligencji. W tym celu zastosowano wybrane topologie sztucznych sieci neuronowych, jako narzędzi do identyfikacji jabłek na podstawie ich cyfrowych obrazów.

1. Wstęp

Dużym zainteresowaniem cieszą się metody sztucznej inteligencji, a w szczególności próby jej praktycznego zastosowania w różnych obszarach życia. Najczęściej pojęcie to kojarzy się z myślącymi maszynami mającymi „poczucie” własnej odrębności a nawet osobowości. Wytłumaczyć to można m.in. tym, że w ostatnich latach napisano wiele książek oraz nakręcono mnóstwo filmów na ten temat. Choć są one na ogół wynikiem fantazji i wyobraźni autorów, to w dobie dynamicznego rozwoju elektroniki i informatyki coraz częściej można dopatrzeć się w nich ziarenka prawdy. Już dziś istnieją roboty obdarzone elementami różnych form inteligencji, które praktycznie wykorzystywane są w różnych dziedzinach działalności człowieka. Mówiąc o inteligencji mamy na ogół na myśli nie tylko zdolność do uczenia się (np. w oparciu o podane przykłady), ale również umiejętność uogólniania zdobytej wiedzy oraz jej odpowiedniego wykorzystania. Rozwijająca się technika stwarza coraz szersze możliwości w zakresie usprawniania procesów produkcyjnych zarówno w przemyśle, jak również w rolnictwie. Niezastąpiony (do tej pory) człowiek teraz bywa zastępowany przez nowoczesne urządzenia, których atutem jest szybkość działania, brak zmęczenia oraz fakt nie popełniania błędów. Mogą one pracować w trybie ciągłym z nielicznymi przerwami na ewentualną konserwację lub naprawę. Jednocześnie stawiane są przed nimi coraz bardziej skomplikowane zadania. Nie wystarczy już, aby maszyny automatycznie powtarzały daną sekwencję czynności. Muszą jeszcze być zdolne do rozpatrywania indywidualnie danego przypadku, wykrywania nieprawidłowości i podejmowania trafnych decyzji. Staramy się tworzyć układy charakteryzujące się dużą elastycznością działania i odpornością na niekompletne lub zaszumiane dane wejściowe. Można więc powiedzieć, że wykazują się one inteligencją w działaniu podobnie jak człowiek.

Sztuczna inteligencja to nie tylko roboty czy automaty wykonujące pewne procesy, lecz także oprogramowanie nimi sterujące. Aplikację uważamy za inteligentną, jeżeli

potrafi wnioskować na podstawie zależności występujących w dostarczonym zbiorze danych, gdy jest w niewielkim stopniu wrażliwa na niekompletność tych danych i stabilna w działaniu, nawet podczas częściowego uszkodzenia. Jednym z wielu przykładów różnorodnych form sztucznej inteligencji są sztuczne sieci neuronowe występujące w postaci układów scalonych, oprogramowania robotów czy innych maszyn oraz samodzielnych aplikacji będących w istocie numerycznymi symulatorami mózgu.

Jedną z ciekawszych cech sieci neuronowych jest ich umiejętność identyfikacji zależności nie wykrywalnych przez człowieka (czasami nawet przez specjalistę w danej dziedzinie). Sieć, o właściwej dla danego problemu topologii, wytrenowana na odpowiednim zbiorze uczącym, jest w stanie skutecznie identyfikować sygnały zaszumiane oraz wcześniej jej nieznanne.

2. Modelowanie neuronowe w analizie obrazu

Sztuczne sieci neuronowe to nie tylko inteligentne systemy informatyczne służące do predykcji bądź klasyfikacji. Konstruowane obecnie są także układy scalone na wzór połączeń występujących w ludzkim mózgu, który jest niedoścignionym wzorcem w dziedzinie sztucznej inteligencji. Uzyskane w ten sposób procesory noszą nazwę neuromorficznych. Bodźcem do tworzenia tego typu struktur jest potencjalna wydajność ludzkiego mózgu. Mimo, że komputery wykonują znacznie większą liczbę operacji na sekundę (w najnowszych procesorach graficznych do sto milionów a ludzki mózg tylko do trzech operacji), to pod względem ilości przetwarzanych instrukcji mózg jest znacznie wydajniejszy. Wynika to z faktu, że jedno polecenie przetwarzane przez procesor cyfrowy porównywalne jest ze wzbudzeniem pojedynczego neuronu. Ilość aktywowanych połączeń synaptycznych wynosi średnio ok. dziesięć tysięcy bilionów na sekundę, co daje ogromne możliwości przetwarzania informacji, również w formie przetwarzania równoległego. Szacuje się, że ok. 80% sygnałów dochodzących do centralnego ośrodka układu nerwowego człowieka to informacje postrzegane za pomocą narządu wzroku i dotyczące

procesu widzenia. Wnioskować zatem można, że z pośród pięciu dostępnych człowiekowi zmysłów, wzrok oraz związany z nim proces widzenia stanowi nasz podstawowy interfejs, za pomocą którego rejestrujemy otaczający nas świat.

Do niedawna naukowcy porównywali narząd wzroku do kamery telewizyjnej rejestrującej pojedyncze obrazy. Ostatnie badania przeprowadzone przez Franka Werblina oraz Botonda Roskę [5] pokazują, że takie porównanie nie jest właściwe. Siatkówka jest wypustką mózgu, która jest wysunięta na zewnątrz czaszki, umożliwiającą akwizycję obrazu. Tutaj odbywa się także pierwszy, wstępny etap przetwarzania obrazu. Dalej sygnał przekazywany jest w postaci tzw. „siatkówkowych filmów” (nie w postaci klatek filmowych, jak do tej pory sądzono) za pomocą nerwu wzrokowego poprzez ciało kolankowate boczne *LGN (Lateral Geniculate Nuclei)* do pierwszorzędowej kory wzrokowej. Wiadomo, że takich ścieżek (filmów) jest dwanaście i niosą one ciągłą informację o otoczeniu. Niestety, do tej pory nie odkryto pełnego znaczenia ich wszystkich. Jedno natomiast jest pewne, że to z tych dwunastu składników nasz mózg składa obraz otaczającego nas świata.

W zagadnieniu neuronowej analizy obrazu staramy się odwzorować działanie centralnego ośrodka układu nerwowego. Tworzymy zatem aplikacje, które (podobnie jak mózg) przetwarzają dostarczone informacje w sposób równoległy oraz rozproszony. Nie jest to niestety do końca prawdą, ponieważ symulator sieci neuronowych realizowany jest obecnie na maszynie (procesorze), która przetwarza informację potokowo (szeregowo). Mimo to, technologia sztucznych sieci neuronowych daje w wielu przypadkach wyniki, trudne do osiągnięcia, przy „klasycznym” podejściu do badanego problemu.

Istnieje kilka kryteriów podziału sztucznych sieci neuronowych. Pierwszym, dość często pomijanym, jest podział w zależności od sposobu implikacji. Wyróżnić tutaj można sztuczne sieci w postaci aplikacji komputerowej lub w postaci sprzętowej (mikroprocesor neuromorficzny). Częściej spotykanymi (i łatwiejszymi w konstruowaniu) są układy w postaci programowej. Te z kolei dzielą się m.in. w zależności od ilości warstw neuronów, rodzaju wykorzystanej funkcji transportowej oraz od kierunku przepływu sygnału. I tak wyróżnić można sieci jednokierunkowe oraz ze sprzężeniem zwrotnym (kryterium kierunku przepływu sygnału), sieci typu MLP (perceptron wielowarstwowy), RBF (sieci o radialnych funkcjach bazowych), liniowe, samoorganizujące się mapy cech (SOM lub sieci Kohonena) czy ART (sieci z rezonansem adaptacyjnym). Należy podkreślić, że wymienione wyżej rodzaje sieci neuronowych są najczęściej wykorzystywane, ale istnieje jeszcze wiele innych, o których nie wspomnieliśmy.

Zupełnie w drugą stronę postanowił pójść zespół Kwabeny Boahena z Uniwersytetu Stanford [6]. Za cel postawili sobie wytworzenie krzemowej siatkówki odtwarzającej aktywność nerwu wzrokowego i samoorganizujących się obwodów scalonych powielających proces rozwoju nerwu wzrokowego. W 2001 r. jego doktorant Kareem Zaghloul [7] wytworzył półprzewodnikową siatkówkę: Visio1. Odzworowuje ona działanie czterech z pośród pięciu typów komórek zwojowych siatkówki człowieka. W tym samym roku inny doktorant z tego samego zespołu, Brian Taba, stworzył

układ scalony o nazwie NeuroTrop1, który odwzorowuje proces tworzenia połączeń nerwowych w mózgu. Synapsa łącząca komórki nerwowe tworzy się wtedy, gdy dwa neurony są jednocześnie pobudzone. Zatem połączenia mogą cały czas się tworzyć i zanikać na przestrzeni całego życia. W układzie scalonym nie ma możliwości fizycznej zmiany połączeń, zamiast tego postanowiono zmieniać przestrzeń adresową pamięci. Postanowiono także połączyć sztuczną siatkówkę Visio1 z NeuroTrop1. Jak się okazało powstał dzięki temu „inteligentny” układ, który potrafił chaotyczne połączenia zoptymalizować tak, żeby skojarzone elementy leżały jak najbliżej siebie. Konfiguracja połączeń nie była jednak idealna, ze względu na występujące szумы. Eksperyment ten pokazuje jednak, że badania prowadzone są w dobrym kierunku.

Układy neuromorficzne tworzone są szczególnie z myślą o ludziach niewidomych, którzy mogliby odzyskać dzięki temu normalną percepcję. Zanim jednak to nastąpi urządzenia te zostaną najprawdopodobniej wykorzystane w technice. Sztuczna siatkówka może znaleźć zastosowanie jako czujnik dla robotów, maszyn przemysłowych czy automatów sterujących. Rolnictwo jest jednym z wielu obszarów, w którym z powodzeniem może być wykorzystywana.

3. Neuronowa analiza obrazu w inżynierii rolniczej

Obecnie znanych jest kilka projektów (w zakresie inżynierii rolniczej) opierających się na sztucznych sieciach neuronowych. Wśród nich jest kilka wspomagających procesy decyzyjne w wybranych zadaniach analizy oraz klasyfikacji obrazów. Pozyskiwanie informacji zawartej w obrazie jest w rolnictwie problemem zasadniczym. Możemy np. ocenić, na podstawie obserwacji, stan plantacji pod kątem występowania szkodników czy pojawiających się chorób. Wśród projektów zagranicznych można wymienić maszynę do wykrywania chwastów **API (Autonomous Platform and Information system for registration of crops and weeds)**, neuronowego robota do monitoringu stanu pola i plonu **ACROSS (Autonomous spatial-temporal Crop and Soil Surveying)**, neurorobota czyszczącego budynki inwentarskie **ISAC (Intelligent Sensor for Autonomous Cleaning In livestock buildings)**, **SLUGBOTA**: neurorobota do wykrywania i usuwania ślimaków, **TARZANA**: robota drzewnego wspomagający proces inteligentnego monitorowania zmian środowiskowych w koronach drzew [1].

W pracy podjęto próbę rozpoznawania odmian jabłek na podstawie ich cech charakterystycznych z wykorzystaniem wybranych metod sztucznej inteligencji. W tym celu zastosowano wyselekcjonowane topologie sztucznych sieci neuronowych jako narzędzi do identyfikacji trzech odmian jabłek na podstawie informacji zawartych w postaci cyfrowych obrazów.

4. Obiekt badań

Jabłoń to rodzaj rośliny wieloletniej z rodziny różowatych i jako jedna z najstarszych roślin uprawnych jest szeroko rozpowszechniona w strefie klimatów umiarkowanych. Na świecie znanych jest obecnie ok. dwadzieścia pięć dziko rosnących gatunków, z czego tylko kilka występuje w Polsce. Barwne kwiaty i owoce

sprawiają, że jabłoni znajdują zastosowanie także, jako roślina ozdobna.

Jabłkowaty (owoc jabłoni) popularne nazywany jabłkiem to organ drzewa zawierający nasioną (tzw. owoc pozorny). Powstaje on nie tylko ze ścian załazni słupka, ale także z mięsistego dna kwiatowego. Poszczególne gatunki i odmiany jabłek różnią się pod względem kształtu, kolorów, długości ogonka, wyglądu szypułki, smaku, konsystencji miąższu oraz wartości odżywczych. Doświadczony specjalista jest w stanie, po wyglądzie konkretnego owocu, rozpoznać z jaką odmianą ma do czynienia. Wzrok ludzki jest jednak podatny na zmęczenie a subiektywizm człowieka może być przyczyną spadku efektywności w procesie identyfikacji. Dlatego zastosowanie sieci neuronowej (pozbawionej wymienionych wyżej wad) jako instrumentu wspomagającego podejmowanie decyzji klasyfikacyjnych, wydaje się być uzasadnione.

5. Metodyka badawcza

Podczas selekcji zmiennych, podawanych na wejście sieci neuronowej, postanowiono skupić się na kolorach oraz kształtach owoców, pomijając wielkość i kształt ogonka, rodzaj szypułki, konsystencję, smak i aromat. Kolejne uproszczenie to klasyfikacja tylko trzech spośród kilku tysięcy znanych odmian. Odmiana *Ligol* charakteryzuje się stosunkowo dużymi, smukłymi i czerwono-żółtymi owocami. *Melrose* jest zazwyczaj mniejsze, bardziej okrągłe, z przewagą koloru czerwonego. Natomiast *Golden Delicious* to odmiana cechująca się jednolitym żółtym, zielonożółtym lub pomarańczowożółtym kolorem. Wymienione odmiany przedstawia rys. 1.



Rys. 1. Odmiany jabłek: *Ligol*, *Melrose*, *Golden Delicious* [8]

Fig. 1. Apple varieties: *Ligol*, *Melrose*, *Golden Delicious* [8]

Dane w postaci zdjęć cyfrowych wymienionych odmian jabłek uzyskano dzięki uprzejmości dra Jerzego Mazura z Rolniczo-Sadowniczego Gospodarstwa Doświadczalnego Przybroda, jednostki doświadczalnej Uniwersytetu Przyrodniczego w Poznaniu. W celu dobrego odwzorowania cech charakterystycznych poszczególnych odmian, zbudowano stanowisko fotograficzne przedstawione na rys. 2.



Rys. 2. Stanowisko badawcze [8]

Fig. 2. Research stand [8]

Zastosowano namiot bezcieniowy z białym tłem oraz dwie lampy błyskowe o barwie światła 5500 K i energii błysku 68 Ws każda. Aparat został zamocowany na statywie na wysokości podstawy namiotu, co przy ustawianiu jabłek szypułkami w dół i oświetleniu bocznym skierowanym z góry pod małym kątem (centralnie na obiekt), pozwoliło zlikwidować efekt powstawania cienia przy podstawie owocu. Odległość fotografowania była stała i wynosiła 35 cm, co pozwoliło na oddanie proporcji wielkości występujących pomiędzy poszczególnymi odmianami. Aparat Fuji FinePix S602Z charakteryzujący się jasną optyką obiektywu F2.8, ustawiony był manualnie w celu uzyskania efektu powtarzalności warunków oświetleniowych. Wartość migawki wynosząca 1/1000, czułość matrycy ISO 160 oraz wielkość przesłony F11, przy dostępnym natężeniu oświetlenia, pozwoliły uzyskać najlepszą ekspozycję. Wykonano po 210 zdjęć jabłek każdej z odmian, z czego po 200 przypadło na zbiór uczący, a reszta stanowiła zbiór, który wykorzystano do testowania wytworzonej aplikacji. Po uzyskaniu zbioru fotografii (w rozdzielczości jednego miliona pikseli), obrazy przekonwertowano z formatu JPG do BMP w celu wczytania ich do systemu informatycznego „Przetwarzanie obrazu”, wytworzonego w ramach badań prowadzonych w Instytucie Inżynierii Rolniczej Uniwersytetu Przyrodniczego w Poznaniu (Nowakowski K., Boniecki P., 2008). Proces ekstrakcji cech charakterystycznych polegał na poborze próbek koloru w dziewięciu punktach obszaru jabłka (za pomocą narzędzia „próbnik” zaimplementowanego w wykorzystywanym systemie informatycznym) oraz zapisaniu ich w pliku o formacie CSV wraz z pięcioma wybranymi współczynnikami kształtu: bezwymiarowym, cyrkularności 1, cyrkularności 2, Malinowskiej oraz polem powierzchni. Uzyskano w ten sposób czternaście zmiennych wejściowych niezbędnych do budowy zbioru uczącego (techniką „z nauczycielem”) dla generowanych topologii modeli neuronowych. Tak przygotowane dane (w postaci zbioru uczącego) zapisane zostały w jednym pliku, który stanowił reprezentatywny zbiór sześciuset przypadków. Podział na zbiór uczący, walidacyjny i testowy odbywał się losowo w stosunku 2:1:1.

6. Wyniki

Do uczenia wybrane zostały trzy rodzaje sztucznych sieci neuronowych, zaimplementowane w komercyjnym pakiecie *Statistica* v. 8.0: perceptron wielowarstwowy (MLP - MultiLayer Perceptron), baysowska sieć probabilistyczna (PNN - Probabilistic Neural Networks) oraz sieć o radialnych funkcjach bazowych (RBF - Radial Basis Function). W tabeli poniżej zestawione zostały błędy RMS (Root Mean Square – pierwiastek błędu średniokwadratowego) poszczególnych etapów uczenia oraz testowania wytworzonych klasyfikatorów neuronowych.

Tab. 1. Zestawienie błędów wygenerowanych sieci neuronowych

Tab. 1. Summary of errors generated by neural networks

Topologia sieci	Błąd uczenia	Błąd walidacji	Błąd testowy
MLP	12,0 %	13,6 %	12,7 %
PNN	8,3 %	15,7 %	12,9 %
RBF	15,0 %	18,4 %	14,5 %

Najlepsze wyniki osiągnął perceptron czterowarstwowy o strukturze sieci 14-15-10-3. Podane w zestawieniu parametry sieci udało się osiągnąć w procesie uczenia dwuetapowego. Najpierw uczono sieć metodą wstecznej propagacji błędów (w dwustu epokach), a następnie metodą gradientów sprzężonych (w 177 epokach). Przeprowadzona analiza wrażliwości wygenerowanej sieci MLP na poszczególne zmienne wejściowe wykazała, że najważniejszymi cechami reprezentatywnymi są (w kolejności): zmienna „pole powierzchni” oraz zmienna „kolor”.

7. Podsumowanie oraz wnioski

Wykorzystanie metod analizy obrazu do identyfikacji oraz ekstrakcji reprezentatywnych cech identyfikacyjnych wybranych odmian jabłek, pozwoliło na przygotowanie zbiorów uczących zawierających adekwatne dane empiryczne. W konsekwencji umożliwiło to wytworzenie efektywnego klasyfikatora neuronowego, którym okazał się

perceptron czterowarstwowy. Wnioski można sformułować następująco:

1. Modelowanie neuronowe jest właściwym narzędziem do rozpoznawania i klasyfikacji wybranych odmian jabłek na podstawie ich zdjęć.
2. Przeprowadzona analiza wrażliwości wykazała, że najważniejszą zmienną wejściową, spośród czternastu wybranych przez autorów, okazała się zmienna „pole powierzchni” oraz „kolor”.
3. W trakcie testowania sztucznych sieci neuronowych stwierdzono, że nie jest ona odporna na zmianę rozmiaru analizowanego obrazu (w porównaniu do rozmiaru obrazów wykorzystanych do stworzenia zbioru uczącego).
4. Celowym wydaje się dodatkowe „douceńie” sieci, aby ograniczyć popełniane przez nie błędy.

8. Literatura

- [1] Boniecki P.: Elementy modelowania neuronowego w rolnictwie, WUP Poznań 2008.
- [2] Boniecki P., Piekarska-Boniecka H.: The SOFM Neural Network in the Process of Identification of Selected Orchard Pests, *Journal of Research and Applications in Agricultural Engineering*, 2004, Vol. 49(4), str. 5-10.
- [3] Nowakowski K., Boniecki P.: Neuronowy model do identyfikacji makrouszkodzeń ziarniaków, *Journal of Research and Applications in Agricultural Engineering*, 2008, Vol. 53(2), str. 79-82.
- [4] Tadeusiewicz R., Korohoda P.: Komputerowa analiza i przetwarzanie obrazów, Wyd. FPT 1997.
- [5] Werblin F.S. & Roska B.: Parallel Visual Processing: A Tutorial of Retinal Function. *Int. J. Bifurcation and Chaos*, 2004, 14: 83-85.
- [6] Sridharan D., Percival B., Arthur J. and Boahen K.: An *in-silico* Neural Model of Dynamic Routing through Neuronal Coherence, *Advances in Neural Information Processing Systems 20*, D Koller, Y Singer and J Platt Eds., MIT Press 2008.
- [7] Zaghoul, K.A.: A Silicon Implementation of a Novel Model for Retinal Processing, Doctoral Dissertation, Department of Neuroscience, University of Pennsylvania, Philadelphia 2001, PA.
- [8] Kicuła M., Jakubek A.: Praca magisterska. Uniwersytet Przyrodniczy w Poznaniu 2008.