

Archipelag sztucznej inteligencji. Część II

Ryszard Tadeusiewicz

Wprowadzenie


W poprzednim numerze miesięcznika „Napędy i Sterowanie” zdefiniowałem, czym w istocie jest sztuczna inteligencja, oraz wyjaśniłem, dlaczego sztuczną inteligencję porównuję do archipelagu wysp. Dodatkowo w tym poprzednim artykule omówiłem już trzy wyspy tego archipelagu. Te trzy już omówione wyspy to kolejno: metody symboliczne, sieci neuronowe i systemy ekspertowe.

Przypomnę też wprowadzoną w tym pierwszym artykule koncepcję, że słowo „wyspa”, będące oczywiście metaforą jakiejś grupy metod sztucznej inteligencji, będziemy pisać bez cudzośłowu – pamiętając wszakże stale o jego umownym charakterze.

W tym artykule postaram się przedstawić kolejne metody sztucznej inteligencji – także korzystając z owej metafory.

Wyspa mgieł

Metaforyczny obraz, pokazany na rysunku 1, ma przywołać obszar sztucznej inteligencji opisywany jako zbiory rozmyte i logika rozmyta.



Rys. 1. Mglista wyspa jako metafora metod rozmytych

Kontury wyspy się rozmywają, wszystko jest zamglone, nieostre... I tego właśnie potrzebujemy!

Dzieje się tak dlatego, że twórcy sztucznej inteligencji próbujący naśladować w komputerach ludzki sposób rozumowania przez długi czas napotykali istotną przeszkodę, wynikającą z tego, że komputer zawsze operuje pojęciami bardzo ściśle i formalnie zdefiniowanymi, natomiast ludzie myślą w kategoriach niezbyt precyzyjnie określonych, co im wcale nie przeszkadza uzyskiwać użytecznych wniosków. Co więcej – już u zarania sztucznej inteligencji dostrzeżono szereg przykładów zadań, w których nieprecyzyjne myślenie ludzi prowadziło do lepszych rezultatów niż precyzyjne obliczenia komputerowe. Modelując w systemach sztucznej inteligencji metody, jakie ludzie stosują przy rozwiązywaniu życiowych problemów – trzeba więc było

„rozmyć” kategoryczne sądy i pojęcia. W ten sposób powstały **metody rozmyte**, które okazały się bardzo przydatne.

Wyjaśnijmy najpierw, na czym to „rozmycie” polega, zaczynając od podstawowego pojęcia – **zbioru rozmytego**.

Tradycyjna teoria zbiorów (wiązana z nazwiskiem Cantora) przyjmuje bardzo kategoryczny podział obiektów na te **należące** do zbioru – oraz te, które do zbioru z pewnością **nie należą**. Nie ma żadnych stanów pośrednich, tylko prosta dychotomia: **tak** albo **nie**.

Rozważmy przykład zbioru studentów pierwszego roku dowolnej uczelni. Są oni przyjmowani na studia na podstawie określonej punktacji (najczęściej odwołującej się do wyników matury). Otóż w procesie rekrutacyjnym przyjmuje się zawsze pewien próg liczby punktów, poczynając od którego kandydat może być przyjęty na studia. Każdy, kto ten próg przekroczy, staje się elementem zbioru studentów, a każdy, kto uzyska tych punktów za mało – na ten kierunek studiów przyjęty nie zostanie (rys. 2).



Rys. 2. Zasada tworzenia tradycyjnego zbioru

Wszyscy znamy z praktyki konsekwencje takiego „twardego” podziału. Ci, którzy się dostali, są szczęśliwi. Ci, którym zabrakło wielu punktów – godzą się ze swoim losem i podejmują inne zajęcia. Najgorzej jest tym, którzy znaleźli się „tuż pod kreską”. Każdy, kto uczestniczył w komisji rekrutacyjnej, zna wiele przypadków, gdy ci pechowi kandydaci starają się przekonać, że powinni jednak być przyjęci, bo przecież zabrakło im tylko jednego czy dwóch punktów.

Ale w przypadku zbiorów Cantora kryterium jest twarde i zbiór studentów zostaje domknięty bez żadnej wątpliwości co do tego, jakie elementy powinny do niego należeć, a jakie nie.

Nie zawsze jest to dobre rozwiązanie, a ponadto nie wszystkie zbiory dadzą się wyznaczyć tak kategorycznie.

Rozważmy przykładowo pojęcie **młodzież**. Często się do niego odwołujemy i wydaje nam się raczej oczywiste.

Tymczasem wcale nie jest ono oczywiste! Nie ulega wątpliwości, że przynależność do zbioru określanego jako „młodzież” jest zależna od dającego się dokładnie wyliczyć parametru, jakim jest wiek. Jeśli wiek jest za mały, to mamy do czynienia z dzieckiem, a nie z młodzieńcem. Jeśli wiek jest za duży – to mamy człowieka w pełni dojrzałego lub nawet starego. Młodzieżą są ci, którzy już nie są dziećmi, a jeszcze nie powinni być zaliczeni do ludzi dojrzałych czy nawet starych.

No dobrze, ale który dzień życia człowieka jest tym momentem, w którym przestaje on być dzieckiem i staje się młodzieńcem? A także w której minucie i sekundzie życia młodość się kończy i zaczyna się wiek dojrzały?

Na pozór jest to „dzielenie włosa na czworo”, bo w działaniach ludzi na ogół potrafimy sobie z tym nieprecyzyjnym pojęciem poradzić. Ale w przypadku komputera problem jest trudny.

Wyobraźmy sobie, że zarząd jakiegoś banku wydał polecenie, że młodzieży należy udzielać kredytów na zasadach preferencyjnych. Komputer bankowy zna datę urodzenia kandydata na kredytobiorcę, więc w każdej chwili może obliczyć jego wiek (z dokładnością do jednego dnia). Ale jak przejść od tej liczby, określającej wiek, do decyzji, czy dany klient zalicza się do młodzieży czy raczej nie?

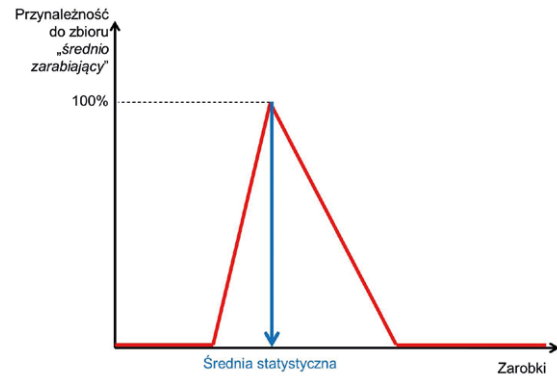
W zdroworozsądkowym podejściu do tego problemu pomaga wprowadzenie tak zwanej **funkcji przynależności**. Obiekty, które z pewnością należą do rozważanego zbioru (w rozważanym przykładzie – młodzieży) otrzymują wartość tej funkcji wynoszącą **100%**. Obiekty, które ponad wszelką wątpliwość do tego zbioru nie należą – otrzymują wartość funkcji wynoszącą **zero**. Ale obiekty z pobliżu granicy mogą otrzymać wartość pośrednią, na 30 albo 70%. Nie ma gwałtownego przeskoku od całkowitej przynależności do całkowitego braku przynależności (lub odwrotnie), tylko łagodne przejście (najczęściej w postaci linii prostej rosnącej lub malejącej) od jednej skrajnej sytuacji do drugiej (rys. 3).



Rys. 3. Funkcja przynależności dla zbioru rozmytego „młodzież”

Ten prosty pomysł okazał się bardzo skuteczny. Można bez trudu podać przykłady różnych użytecznych funkcji przynależności, opisujących różne spotykane w praktyce sytuacje. Na przykład na rysunku 4 pokazano przykładową funkcję przynależności dla zbioru rozmytego „średnio zarabiający”. Warto się przyjrzeć tej funkcji i zastanowić się, czemu nachylenia lewego i prawego zbocza funkcji wyraźnie się różnią?

Jest to wynik psychologicznego mechanizmu polegającego na tym, że ludzie wychodzący z biedy bardzo szybko akceptują swoją przynależność do zbioru średnio zarabiających i znajdują w tym rzetelną satysfakcję. Natomiast dalszy wzrost zarobków



Rys. 4. Funkcja przynależności dla zbioru rozmytego „średnio zarabiający”

powyżej średniej statystycznej, który powinien implikować przekonanie o przechodzeniu do grupy dużo zarabiających – z trudem przyjmowany jest do wiadomości. Ludzie długo są przekonani, że ciągle zarabiają za mało!

Jak dużo subtelnych cech pojęcia „średnio zarabiający” udało się odwzorować w prostym i wygodnym obliczeniowo pojęciu zbioru rozmytego!

Kilka słów warto teraz przytoczyć na temat **logiki rozmytej**. Jest ona dzisiaj chętnie używana, gdyż w odróżnieniu od tradycyjnej logiki dwuwartościowej, w której funkcjonuje ostry podział na prawdę i fałsz – w logice rozmytej możliwa jest ocena, że jakaś sytuacja jest w pewnym stopniu prawdziwa lub częściowo fałszywa – przy czym „dawkowanie” tej prawdy i fałszu może być wyrażone liczbowo, co pozwala odróżnić tezę prawdziwą w 90% od tezy prawdziwej w 15%. Okazuje się, że w wielu zastosowaniach takie podejście jest korzystne.

Tradycyjna logika opiera się na trzech operatorach: negacji, alternatywie i koniunkcji. Jeśli jakieś pierwotne stwierdzenie poprzedzimy operatorem **negacji**, to otrzymujemy stwierdzenie, które jest prawdziwe wszędzie tam, gdzie pierwotne stwierdzenie było fałszywe – i odwrotnie. W logice rozmytej miarą prawdziwości jakiegoś stwierdzenia jest funkcja przynależności. Negację otrzymujemy, gdy w każdym punkcie odejmiemy wartość tej funkcji przynależności od 100%. W efekcie tam, gdzie funkcja przynależności pierwotnego stwierdzenia miała wartość 0 – pojawia się wartość 100%, wszędzie tam, gdzie funkcja przynależności miała wartość 100% pojawia się 0, zaś w stanach pośrednich mamy tym większą wartość funkcji przynależności, im oryginalna funkcja miała wartość mniejszą.

Staram się w tym popularnym artykule unikać ujęć formalnych i wzorów matematycznych, ale kilka muszę tu wprowadzić, żeby ważnej tematyki zbiorów rozmytych nie pozostawić wyłącznie w sferze ogólników. Zacniemy od matematycznej formuły opisującej zbiór rozmyty.


Zbiorem rozmytym A , określonym na przestrzeni X jest zbiór uporządkowanych par:

$$A = \{(x, \mu_A(x)) \mid x \in X\}$$

gdzie μ_A jest funkcją przynależności do zbioru A , która przyjmuje wartość 1 dla całkowitej przynależności, 0 dla całkowitego braku przynależności oraz wartości pośrednie dla przynależności częściowej

Zbiór B, będący negacją zbioru A, to będzie analogiczny zbiór par, tylko dla każdego $x \in X$

$$\mu_B(x) = 1 - \mu_A(x)$$




Rys. 5. Przykład działania negacji dla logiki rozmytej

Funkcja negacji jest jednoargumentowa, to znaczy bierze pod uwagę tylko jedno stwierdzenie (którego znaczenie jak gdyby odwraca). Natomiast dwie kolejne funkcje logiczne są dwuarargumentowe. Jako ich argumenty występują dwa stwierdzenia, którym może być przypisana wartość logiczna prawdy lub fałszu, które połączone określonym spójnikiem logicznym tworzą zdanie złożone, którego prawdziwość lub fałszywość może być ustalona według ściśle określonych reguł.

Pierwszym spójnikiem logicznym jest słowo „LUB”. Konstrukcja złożona z dwóch stwierdzeń logicznych połączonych tym spójnikiem nazywa się **alternatywą** (albo sumą logiczną). W klasycznej logice wartością logiczną całej alternatywy jest **prawda**, jeśli chociaż jedno ze składowych stwierdzeń ma wartość **prawda**. Przenosząc tę zasadę do logiki rozmytej, korzystamy z pojęcia tak zwanej s-normy. Bywa ona różnie definiowana, ale najprostsza reguła polega na przypisaniu do wyniku alternatywy **większej** z dwóch wartości funkcji przynależności stwierdzeń składowych:

$$\mu_c(x) = \max\{\mu_A(x), \mu_B(x)\} \text{ dla } x \in X$$

Przykład działania rozmytej alternatywy można obejrzeć na rysunku 6.




Rys. 6. Cały pokryty kolorem obszar - to funkcja przynależności rozmytej alternatywy

Drugą z dwuarargumentowych funkcji logiki klasycznej jest **koniunkcja** (używany jest spójnik „I”). Funkcja ta przyjmuje wartość **prawda** wtedy i tylko wtedy, gdy oba stwierdzenia składowe są prawdziwe. Przeniesiona do logiki rozmytej koniunkcja zamienia się w tak zwaną t-normę, której najprostsza postać ma formę zasady, że wartość funkcji przynależności wyniku odpowiada **mniejszej** z dwóch wartości funkcji przynależności obu składowych.

$$\mu_c(x) = \min\{\mu_A(x), \mu_B(x)\} \text{ dla } x \in X$$

Ilustracja działania rozmytej koniunkcji pokazana jest na rysunku 7.




Rys. 7. Pokryty kolorem obszar - to funkcja przynależności rozmytej koniunkcji


Dla operatorów dwuarargumentowych odpowiednie formuły bywają modyfikowane, więc w sposób ogólny wprowadza się pojęcie tak zwanej S-normy (odpowiadającej alternatywie) oraz T-normy (odpowiadającej koniunkcji). Nie przytaczam tu formalnych wzorów dla tych norm (jest ich dużo!), bo podobno każdy wzór zmniejsza liczbę czytelników o połowę, natomiast na rysunku 8 przedstawiam wynik działania dwóch dodatkowych definicji rozmytej alternatywy i koniunkcji (na dole). U góry dla porównania przywołane rysunki 6 i 7.

S-norma

$$\mu_{A \vee B}(x) = \max\{\mu_A(x), \mu_B(x)\}$$




$$\mu_{A \vee B}(x) = \min\{1, \mu_A(x) + \mu_B(x)\}$$




T-norma

$$\mu_{A \wedge B}(x) = \min\{\mu_A(x), \mu_B(x)\}$$



$$\mu_{A \wedge B}(x) = \mu_A(x) \cdot \mu_B(x)$$




Rys. 8. Przykłady działania różnie zdefiniowanych rozmytych operatorów alternatywy i koniunkcji

Warto dodać, że w podobny sposób jak na rysunku 4 można odwzorować w metodologii zbiorów rozmytych koncepcję **liczb przybliżonych**. Często w różnych okolicznościach posługujemy


się określeniem „około”, mając na myśli jakąś wartość liczbowa zgrubnie tylko oszacowaną albo zmierzoną z niewielką dokładnością. Na przykład informacja „około 5” może być w komputerze odwzorowana za pomocą zbioru rozmytego, którego funkcja przynależności jest podobna do tej pokazanej na rysunku 4, tylko z maksimum ulokowanym nie w punkcie „średnia statystyczna” tylko przy wartości 5. Funkcja przynależności dla liczb przybliżonych jest zwykle symetryczna (inaczej niż ta pokazana na rysunku 4), chociaż zdarzają się liczby przybliżone, o których z góry wiadomo, że są wyznaczane raczej z nadmiarem (lub z niedomiarem) i wtedy asymetria funkcji przynależności jest uzasadniona.

Reprezentacja liczby przybliżonej za pomocą zbioru rozmytego ma szereg zalet. Po pierwsze, można łatwo różnicować liczby, których przybliżenie jest bardzo niedokładne (odpowiednia trójkątna funkcja przynależności ma wtedy szeroką podstawę) od tych, które są wyznaczone precyzyjniej (funkcja przynależności jest wtedy smukła). Po drugie, w teorii zbiorów rozmytych ustalone są metody wykonywania działań arytmetycznych na tych liczbach, co jest ważne z punktu widzenia praktyki. Jeśli bowiem chcemy wykonać działanie „około 5” mnożone przez „około 3”, to wynik oczywiście jest „około 15”. Jednak istotne jest to, jak bardzo rozmyte jest owo „około 15” w sytuacji, kiedy znamy rozmycie obu liczb budujących iloczyn. Nie ma tu miejsca na szczegółową dyskusję arytmetyki liczb rozmytych, ale warto spojrzeć na rysunek 9, pokazujący, jak wyglądają (i jak są obliczane) funkcje przynależności przy dodawaniu i przy mnożeniu.

Dodawanie: $\mu_{A+B}(x) = \max\{\mu_A(y), \mu_B(z) \mid x = y+z\}$



Iloczyn: $\mu_{A \cdot B}(x) = \min\{\mu_A(y), \mu_B(z) \mid x = y \cdot z\}$



Rys. 9. Sposób obliczania funkcji przynależności wyniku przy działaniach na liczbach rozmytych

Problem wbrew pozorom nie jest tylko akademicki, bo świadomość tego, jak bardzo niedokładny będzie wynik określonych działań wykonywanych na niedokładnych danych, może mieć duże znaczenie praktyczne.

Rozważmy przykład maszyny zbudowanej z wielu części. Każda z tych części jest wykonana z pewną **niedokładnością** w stosunku do wymiarów i kształtów przewidzianych przez konstruktora maszyny, bo proces wytwarzania nigdy nie jest idealny. Zwykle jednak dla elementów składowych wprowadzone są pewne granice tolerancji. Elementy, których wymiary nie są idealne, ale mieszczą się w granicach tolerancji – są

używane do produkcji finalnego wyrobu. Ważne pytanie jest jednak następujące: Jak stopień rozmycia wymiarów elementów składowych wpłynie na stopień rozmycia działania końcowego urządzenia? Może się przecież zdarzyć, że urządzenie zmontowane z niedokładnie wykonanych elementów będzie działać w sposób tak odległy od pierwotnych zamierzeń, że będzie nieprzydatne. Możliwość przewidzenia tego ryzyka i oszacowania jego wielkości poprzez funkcje przynależności odpowiedniego zbioru rozmytego – to bardzo istotne udogodnienie przy planowaniu różnych technologii.

W tym przeglądowym artykule nie ma niestety miejsca na obszerniejszą dyskusję metod sztucznej inteligencji opartych na koncepcji zbiorów rozmytych i logiki rozmytej, a także metod wnioskowania rozmytego, ale jeszcze raz warto podkreślić, że opierając się na tym podejściu, rozwiązano bardzo wiele praktycznych problemów, zwłaszcza związanych z automatyką i robotyką.


Zbiory przybliżone

Omówioną wyżej teorię zbiorów rozmytych (*fuzzy sets*) stworzył Lofti Zadeh, Amerykanin irańskiego pochodzenia, z którym miałem okazję współpracować – między innymi przy redagowaniu książek (rys. 10).



Rys. 10. Przykładowe dwie książki z większego zbioru prac wspólnie redagowanych (między innymi) przez autora tego artykułu i twórcę zbiorów rozmytych Lofti Zadeha

Natomiast twórcą podobnego, ale pod wieloma względami odmiennego, zestawu metod sztucznej inteligencji wchodzących w skład tzw. „teorii zbiorów przybliżonych” (*rough sets*) był Polak, prof. Zdzisław Pawlak, z którym także blisko współpracowałem w Komitecie Badań Naukowych i w Centralnej Komisji ds. Stopni i Tytułów Naukowych. Wyjątkowo zamieszczę tu jego fotografię (rys. 11), bo bez wątpliwości jest to jedyny polski kreator całkowicie nowej wyspy w archipelagu sztucznej inteligencji.



Rys. 11. Prof. Zdzisław Pawlak, twórca teorii zbiorów przybliżonych

Wyspę stworzoną przez prof. Pawlaka przedstawiam na rysunku 12.



Rys. 12. Wyspa reprezentująca metody zbiorów przybliżonych

Na marginesie warto dodać, że pokazywane na tym rysunku (i na następnych) formacje geologiczne złożone z oddzielnych słupów bazaltowych pochodzą z wybrzeża Irlandii Północnej (tak zwana Grobla Olbrzyma) i zostały przeze mnie wybrane, bo – moim zdaniem – dobrze ilustrują zasadnicze idee teorii zbiorów przybliżonych, a jednocześnie kojarzą się z metaforą wyspy, która jest stale tu przywoływana.

Cechą wyróżniającą tę wyspę jest fakt, że formujące ją skały są rozbite na osobne bazaltowe słupy, których już podzielić nie można, więc w każdym kontekście trzeba brać zawsze pod uwagę cały słup, wiążąc z nim decyzję pozytywną albo negatywną. To rozbitcie przestrzeni, w której zdefiniowane jest Uniwersum rozważanych tu metod na tak zwane zbiory elementarne (niepodzielne – patrz rys. 13), wynika z faktu, że parametry definiujące wszelkie obiekty w tym Uniwersum są mierzone (lub w inny sposób ustalane) z **ograniczoną dokładnością**, w wyniku czego każdy zbiór jest „ziarnisty”. Będą z tego powodu istnieć w tym Uniwersum obiektywnie oddzielne obiekty (punkty w obrębie jednego słupa), które jednak będą niemożliwe do rozróżnienia.



Rys. 13. Obrazowe przedstawienie właściwości Uniwersum, w którym definiowane będą zbiory przybliżone

Taka struktura Uniwersum powoduje, że jeśli będziemy chcieli w nim wyznaczyć jakieś granice pomiędzy obszarami, w których powinno się podejmować przeciwstawne decyzje – to

może pojawić się obszar, w którym ani pozytywna, ani negatywna decyzja nie będzie w pełni uzasadniona. Przy tradycyjnym podejściu do podejmowania decyzji granica pomiędzy obszarem decyzji pozytywnych i negatywnych jest ostra i dobrze określona w każdym miejscu. Rozważmy sytuację przedstawioną na rysunku 14. Widoczny jest na nim obszar **ciągły**, w którego niektórych miejscach (suchy ląd) decyzja pozytywna jest pewna i oczywista, oraz drugi obszar (toń morza), gdzie równie pewna i oczywista jest decyzja negatywna.



Rys. 14. Przykład ciągłego Uniwersum, w którym decyzje są pewne i jednoznaczne


Rozważmy jednak sytuację w przypadku Uniwersum złożonego ze zbiorów elementarnych (rys. 15).



Rys. 15. Przykład problemu decyzyjnego w przypadku zbioru przybliżonego

Na tym przykładzie widzimy, że w przypadku zbioru przybliżonego są obszary całkiem pewnych decyzji: pozytywnych na całkiem suchych słupach bazaltowych po prawej stronie i negatywnych w głębi morskiej toni. Ale są też obszary wieloznaczne, słupy bazaltowe częściowo zalane. Spełniają one po trosze kryteria zarówno przynależności do obszaru decyzji pozytywnych i po części mają cechy obszaru decyzji negatywnych. To one tworzą ważny w teorii zbiorów przybliżonych **brzeg zbioru**. Można to obejrzeć na rysunku 16.

Mamy na nim Uniwersum złożone ze zbiorów elementarnych (puzzle), na którym białą linią zaznaczono granice rozważanego zbioru. Widać, że niektóre puzzle (czarne na rysunku) bezdyskusyjnie do tego zbioru należą. Jest to tak zwana dolna aproksymacja zbioru. Inne puzzle (białe) z pewnością do niego nie należą. Jest to tak zwany obszar negatywny. Ale są też takie,



Rys. 16. Ilustracja podstawowych pojęć w teorii zbiorów przybliżonych

które należą częściowo, są więc także zaciemnione, chociaż nie w takim stopniu jak te, które należą do zbioru w sposób bezdyskusyjny. Cały ten ciemny obszar (w części zaciemniony mocniej, a w części słabiej) na rysunku 16 nazwiemy górną aproksymacją zbioru. Szare puzzle, te częściowo należące do zbioru i częściowo nie należące, nazywa się **brzegiem** zbioru.

Formalna definicja mówi: Zbiór jest **zbiorem przybliżonym**, jeżeli jego brzeg jest zbiorem niepustym, czyli dolna aproksymacja tego zbioru jest **różna** od górnej aproksymacji tego zbioru. Jeżeli dolna i górna aproksymacja zbioru są równe, to wtedy zbiór jest **dokładnie zdefiniowany**.

Żeby nie poprzestawać na obrazkach z abstrakcyjnymi puzzlami czy z bazaltowymi słupami – rozważmy przykład bazy danych szpitalnych, na podstawie której algorytm sztucznej inteligencji powinien sugerować diagnozę dla nowego pacjenta na podstawie danych tych, którzy byli wcześniej leczeni. Diagnoza będzie dotyczyła wykrycia, czy pacjent jest chory na COVID – czy nie, bo jak wszyscy pamiętamy, to rozróżnienie było w całym 2020 roku bardzo ważne.

Oczywiście to, co będę mógł pokazać na rysunku 17, to będzie miniaturka takiej **hipotetycznej** bazy danych, która w rzeczywistości powinna zawierać dziesiątki kolumn podających różne


Pacjent	Ból głowy	Ból mięśni	Temperatura	COVID
1	nie	tak	podwyższona	tak
2	tak	nie	podwyższona	tak
3	tak	tak	wysoka	tak
4	nie	tak	normalna	nie
5	tak	nie	podwyższona	nie
6	nie	nie	wysoka	tak

Rys. 17. Przykładowa baza danych dla systemu automatycznej diagnostyki

symptomy i powinna obejmować tysiące wierszy, rejestrujących dane wcześniej badanych i leczonych pacjentów.

Pierwszy rzut oka na tę tabelkę nie ujawnia tego faktu, ale mamy tu do czynienia ze zbiorem przybliżonym, bo pacjenci nr 2 i 5 mają te same symptomy (więc należą do tego samego zbioru elementarnego), ale diagnoza u nich jest różna: jeden choruje na COVID, a drugi nie. Mamy więc przybliżenie dolne zbioru chorych na COVID (pacjenci 1, 3 i 6), przybliżenie górne tego zbioru (pacjenci 1, 2, 3, 5 i 6) oraz obszar brzegowy (pacjenci 2 i 5).

Jak wspominałem, teoria zbiorów przybliżonych (*rough sets*) została utworzona przez prof. Zdzisława Pawłaka, ale obecnie zajmują się nią ludzie na całym świecie, czego przykładem może być tom materiałów z rokrocznie odbywającej się (w różnych krajach świata) konferencji International Joint Conference On Rough Sets, do której mam duży sentyment, bo od wielu lat jestem członkiem Komitetu Naukowego owych kolejnych Konferencji. Fragment okładki wspomnianego zbioru materiałów przytaczam na rysunku 18.



Rys. 18. Fragment okładki materiałów z International Joint Conference On Rough Sets

Rozpoznawanie obrazów (*pattern recognition*)

Programy realizujące zadania określane po angielsku jako *pattern recognition* (tłumaczone w Polsce jako automatyczne rozpoznawanie obrazów) są kolejną wyspą, którą warto poznać (rys. 19).



Rys. 19. Wyspa symbolizująca metody rozpoznawania obrazów

Metody *pattern recognition* mogą służyć do automatycznej klasyfikacji i rozpoznawania różnych obiektów. Powstały one bardzo wcześnie, w latach 60. XX wieku, ale początkowo były utajnione, bo ich obszary zastosowań miały związek z wojskiem. Algorytmy *pattern recognition* były stosowane do przeglądania zdjęć szpiegowskich (lotniczych, a potem satelitarnych, stąd pierwotna nazwa „rozpoznawanie obrazów”), ale potem także

do rozpoznawania szumów wrogich okrętów podwodnych, a także głosów ludzi. Potem metody te przeszły do cywila i znalazły mnóstwo zastosowań. Rozpoznawanymi obrazami stały się na przykład odciski palców lub wizerunki ludzkich twarzy, rozpoznawanymi dźwiękami tony i szmery serca w diagnostyce kardiologicznej, rozpoznawanymi sygnałami wibracje maszyn w diagnostyce technicznej, rozpoznawanymi wzorcami dane ekonomiczne firm ubiegających się o kredyt – przykładów można by było przytaczać mnóstwo.

Zajmowałem się tym problemem od początku lat 70., najpierw tłumacząc rosyjskie książki na ten temat (które nadały za osiągnięciami amerykańskimi, a były w Polsce blisko **stukrotnie** tańsze od amerykańskich oryginałów). Przykład takiego tłumaczenia można zobaczyć na rysunku 20.



Rys. 20. Pierwsza książka o rozpoznawaniu obrazów wydana w 1975 roku w języku polskim

Potem w 1985 roku wydałem dwie własne książki [1, 2] na ten temat (rys. 21).



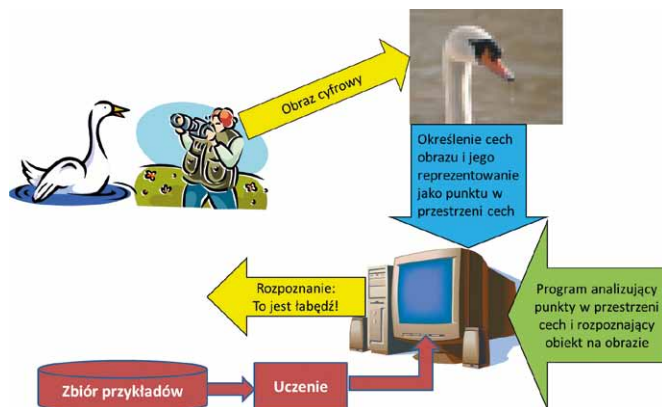
Rys. 21. Książki prezentujące rozpoznawanie obrazów od strony teorii i zastosowań

Jeszcze jedna książka ukazała się w 1987 r. [4], kolejna w 1991 roku [3] i jeszcze jedna w 1992 r. (o zawężonym zakresie zastosowań rozpoznawania do samej robotyki [5]) oraz w kontekście potrzeb medycznych w 2011 [6].

Mając bardzo osobisty stosunek do metod rozpoznawania obrazów (stosowanych także przy rozpoznawaniu mowy [7]), tym tematem wypełnię tekst tego artykułu aż do jego końca, zapowiadając, że w następnym numerze miesięcznika „Napędy i Sterowanie” pojawi się kolejny odcinek „Archipelagu sztucznej inteligencji”, bo w kolejce czeka jeszcze sporo interesujących wysp!

Ogólny schemat procesu rozpoznawania (w tym węższym znaczeniu, sprowadzonego wyłącznie do rozpoznawania obrazów) przedstawiony został na rysunku 22.

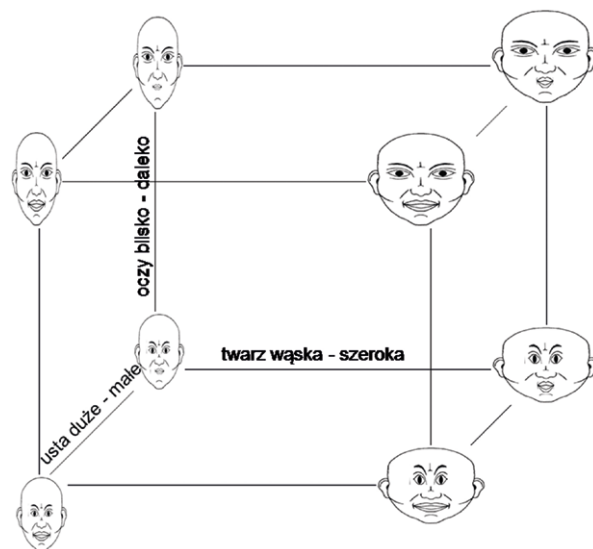
Pierwszą czynnością jest pozyskanie obrazu w formie cyfrowej. Dzisiaj jest to trywialne, bo wszystkie aparaty fotograficzne czy kamery TV dostarczają obrazy właśnie w tej postaci, ale na początkowym etapie prac nad rozwojem automatycznego rozpoznawania obrazów trzeba było samemu budować konwerter



Rys. 22. Schemat systemu rozpoznawania obrazów – dyskusja w tekście

analogowo-cyfrowy i pamięć buforową, żeby wprowadzić do komputera obraz z kamery analogowej (bo tylko takie były dostępne) [8].

Obraz cyfrowy jako struktura danych o bardzo dużym rozmiarze (od kilkuset kB do kilku MB) jest niewygodny do bezpośredniego rozpoznawania, dlatego jego wprowadzeniu do systemu rozpoznającego musi towarzyszyć proces określania **cech** obrazu. Cechy mogą być ilościowe albo jakościowe. Odkładane na osiach układu współrzędnych tworzą **przestrzeń cech** (rys. 23).

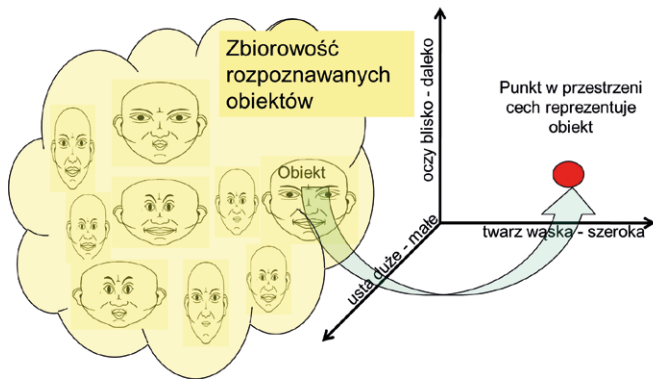


Rys. 23. Przykładowa przestrzeń cech przydatna przy rozpoznawaniu twarzy


W tej przestrzeni cech każdy konkretny obraz ma swoją dokładnie określoną lokalizację. Określenie cech zamienia więc obraz na punkt w przestrzeni cech (rys. 24).

Przy dobrze dobranej przestrzeni cech punkty odpowiadające bardzo podobnym obrazom gromadzą się blisko siebie, natomiast punkty reprezentujące obrazy niepodobne – lokują się daleko (rys. 25).

Ponieważ reguły rozpoznawania są zwykle nieznanne – podstawą działania algorytmu rozpoznającego jest to, że przed jego użyciem do rozpoznawania odbywa się jego uczenie. Polega ono na tym, że wykorzystuje się bazę danych, w której zawarty jest zbiór przykładów – na przykład zbiór wizerunków twarzy z informacjami, kto jest kim (rys. 26).



Rys. 24. Przejście od obrazu do punktu w przestrzeni cech



Rys. 25. Reprezentacja różnych obrazów w przestrzeni cech




Rys. 26. Fragment zbioru przykładów do rozpoznawania twarzy

Oczywiście w rzeczywistości taki zbiór uczący musi być bardzo liczny, bo twarz każdego branego pod uwagę człowieka trzeba wiele razy pokazać algorytmowi rozpoznającemu – w różnym oświetleniu, w różnej pozycji (*en face* oraz po niewielkim obrocie w lewo i w prawo albo w pochyleniu lub podniesieniu głowy), w różnych układach mimicznych itd.

A ludzie do rozpoznawania mogą być setki lub nawet miliony (w Chinach, gdzie kamery bezpieczeństwa są w stanie rozpoznawać wszystkich mieszkańców miast). Dlatego uczenie w systemach rozpoznawania obrazów jest procesem długotrwałym i trudnym.

Warto tu dodać jedną uwagę. Przykład rozpoznawania twarzy, o którym była wcześniej mowa, bo można było go ilustrować sugestywnymi rysunkami, jest w istocie przykładem nietypowym, bo różne obrazy twarzy tego samego człowieka trzeba przypisać do jednego identyfikatora (nazwiska). W typowych przykładach rozpoznawanie obrazów polega na tym, że obrazy grupuje się w pewne kategorie (na przykład psy i ryby – patrz rys. 27) i nowy obiekt trzeba zaliczyć do jednej z tych kategorii.

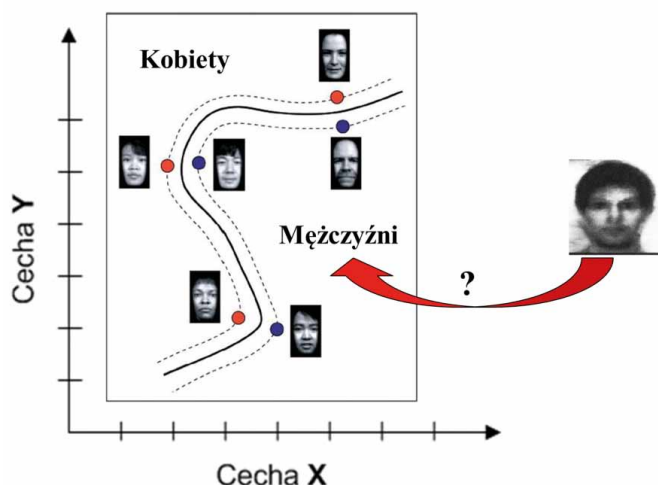
Niektóre metody rozpoznawania obrazów polegają na zapamiętaniu całego zbioru uczącego (w postaci punktów w przestrzeni cech) i na zaliczaniu nieznanego obrazu do tej kategorii, do której należy większość punktów, reprezentujących zapamiętane obiekty zbioru uczącego, znajdujących się w pobliżu punktu, w którym znalazła się reprezentacja rozpoznawanego (nieznanego) obrazu. Na rysunku 27 pokazano żartobliwie istotę takiego rozpoznawania, nazywanego *NN* (od *Nearest Neighbor*) albo *kNN* (*k Nearest Neighbors*), gdy bierze się pod uwagę grupę *k* najbliższych sąsiadów, wśród których powinni dominować przedstawiciele tej kategorii, która powinna być wskazana jako proponowane rozpoznanie.



Rys. 27. Żartobliwe przedstawienie istoty rozpoznawania metodą najbliższego sąsiada w przestrzeni cech

Metoda *kNN* jest skuteczna, ale kłopotliwa, bo trzeba trzymać w pamięci wszystkie obiekty zbioru uczącego, obliczać ich odległości od punktu reprezentującego obiekt wymagający rozpoznania i wyszukiwania *k* najmniejszych odległości. Żeby usprawnić proces rozpoznawania, inne metody zakładają, że jest możliwe stworzenie (w trakcie nauki) linii granicznej pomiędzy obiektami należącymi do różnych kategorii i podejmowanie decyzji na podstawie położenia nowego punktu po jednej lub drugiej stronie owej linii granicznej (rys. 28).

Oczywiście realizacja tego pomysłu wymaga dopracowania szeregu elementów: matematycznego opisu linii granicznej (która w istocie jest hiperpowierzchnią w *n*-wymiarowej przestrzeni, ponieważ zwykle bierzemy pod uwagę wiele cech), sposobu formowania tej granicy w procesie uczenia, sprawnego określenia położenia nowego punktu w stosunku do licznych powierzchni granicznych przy rozpoznawaniu, które zakłada



Rys. 28. Rozpoznawanie na podstawie podziału przestrzeni cech na obszary przypisane do różnych kategorii

istnienie wielu kategorii itp. Ale w metodach rozpoznawania obrazów wszystkie te zagadnienia zostały rozwiązane i odpowiednie algorytmy są możliwe do wykorzystania.

Na koniec chcę jeszcze raz z naciskiem podkreślić, że metody *pattern recognition* mogą klasyfikować i kategoryzować rozmaite obiekty, czego przykładem mogą być moje dawne prace [9, 10, 11 i 12].

O kolejnych wyspach w archipelagu sztucznej inteligencji napiszę w następnym numerze miesięcznika „Napędy i Sterowanie”. Będzie ciekawie!

Literatura

[1] TADEUSIEWICZ R.: *Rozpoznawanie obrazów – zarys teorii*. Skrypt UJ nr 499, Kraków 1985, https://www.academia.edu/42059662/Rozpoznawanie_obrazow_-_zarys_teorii.

[2] TADEUSIEWICZ R.: *Rozpoznawanie obrazów w zastosowaniach ekonomicznych*. Skrypt AE, Kraków, 1985 https://www.academia.edu/42124750/Rozpoznawanie_obrazow_w_zastosowaniach_ekonomicznych.

[3] TADEUSIEWICZ R., FLASIŃSKI M.: *Rozpoznawanie obrazów*. PWN, Warszawa 1991, <http://winntbg.bg.agh.edu.pl/skrypty/0005/>; http://otworzksiazke.pl/ksiazka/rozpoznawanie_obrazow/.

[4] TADEUSIEWICZ R., KOROHODA P.: *Komputerowa analiza i przetwarzanie obrazów*. Wydawnictwo Fundacji Postępu Telekomunikacji, Kraków 1997, <http://winntbg.bg.agh.edu.pl/skrypty2/0098/>.

[5] TADEUSIEWICZ R.: *Systemy wizyjne robotów przemysłowych*. WNT, Warszawa 1992.

[6] TADEUSIEWICZ R., ŚMIETAŃSKI J.: *Acquisition of Medical Images and their Processing, Analysis, Automatic Recognition and Diagnostic Interpretation* [In Polish: *Pozyskiwanie obrazów medycznych*

oraz ich przetwarzanie, analiza, automatyczne rozpoznawanie i diagnostyczna interpretacja]. Wydawnictwo STN, Kraków 2011, http://hps.biblos.pk.edu.pl/ST/2011/07/100000258879/100000258879_Tadeusiewicz_Pozyskiwanie.pdf.

[7] TADEUSIEWICZ R.: *Sygnal mowy* (Monografia książkowa wydana w serii „Problemy elektroniki i telekomunikacji”). WKiŁ, Warszawa 1988, <http://winntbg.bg.agh.edu.pl/skrypty/0004/>; http://otworzksiazke.pl/ksiazka/sygnal_mowy/.


[8] TADEUSIEWICZ R.: *Cyfrowe przetwarzanie obrazów telewizyjnych w celu ich analizy i rozpoznawania*. W mat. IV Sympozjum MPN WEAE AGH, 1978, str. 5–8, https://www.academia.edu/30259841/Cyfrowe_przetwarzanie_obrazow_C3%B3w_telewizyjnych_w_celu_ich_analizy_i_rozpoznawania.

[9] TADEUSIEWICZ R., MYSONA-BYRSKA E., KORPAL E.: *Ustalenie rodzaju potrzebnej terapii w przypadku raka sutka metodą rozpoznawania obrazów z zastosowaniem maszyny cyfrowej*. W mat. konferencji „Elektronika i automatyka w służbie medycyny”, Katowice 1974, str. 84–86, https://www.academia.edu/37300005/Ustalenie_rodzaju_potrzebnej_terapii_w_przypadku_raka_sutka_metoda_rozpoznawania_obrazow_z_zastosowaniem_maszyny_cyfrowej.

[10] GÓRECKI H., SKOWINIAK A., TADEUSIEWICZ R.: *Analiza możliwości zastosowania układów uczących się do rozpoznawania obrazów dźwiękowych. Teoria sterowania – część V*. Wydawnictwo Naukowo-Dydaktyczne AGH, Kraków 1975, str. 143–156, https://www.academia.edu/37425367/Analiza_mozliwosci_zastosowania_ukladow_uczacych_sie_do_rozpoznawania_obrazow_dzwiekowych.

[11] TADEUSIEWICZ R.: *Próba zastosowania rozpoznawania obrazów w diagnostyce neuroinfekcji*. W pracy zbiorowej: *Systemy informatyczne w diagnostyce i terapii*. Akademia Medyczna, Kraków 1977, str. 68–76; https://www.academia.edu/34142340/Pr%C3%B3ba_zastosowania_rozpoznawania_obrazow_w_diagnostyce_neuroinfekcji.

[12] KORDEK J., NIPL R., NOWIKOW P., ROMANOWSKI J., SZUBA T., TADEUSIEWICZ R.: *Rozpoznawanie obrazów optycznych w przeróbce surowców mineralnych*. W mat. Sympozjum „Automatyzacja procesów przeróbki węgla”, Katowice 1978, str. 148–154, PDF https://www.academia.edu/34304023/Rozpoznawanie_obrazow_C3%B3w_optycznych_w_przer%C3%B3bce_surowcow_C3%B3w_mineralnych.

 prof. dr hab. inż. Ryszard Tadeusiewicz
AGH – Akademia Górniczo-Hutnicza w Krakowie
e-mail: rtad@agh.edu.pl, www.Tadeusiewicz.pl