




Rozwiązanie zadania F 904.

Każdy maszynista usłyszy wynik interferencji dźwięków dwu sygnałów: „własnej” lokomotywy i lokomotywy nadjeżdżającej z przeciwna. Częstota pierwszego z sygnałów nie ulegnie zmianie, a drugi, na skutek zjawiska Dopplera, będzie odbierany jako dźwięk o częstoci f :

$$f = \frac{c+v}{c-v} f_0.$$

Złożenie harmonicznych sygnałów o częstoci f i f_0 daje sygnał o częstoci $F_1 = (f + f_0)/2$ o amplitudzie modulowanej z częstocią $F_2 = (f - f_0)/2$. Podstawiając dane, otrzymujemy: $f \approx 477,5$ Hz, $F_1 \approx 458,7$ Hz i $F_2 \approx 18,7$ Hz.



Cechami charakterystycznymi obiektów astronomicznych mogą być, między innymi, ich rozmiary katowe, przesunięcie ku czerwieni, okres zmienności i jej amplituda, strumień promieniowania w zadanej długości fali, natężenie i szerokość linii widmowych, czy też różnica strumieni (zwana kolorem).

*Narodowe Centrum Badań Jądrowych w Warszawie

Co prawda, pamięć RAM, zgodnie ze swoją nazwą, jest pamięcią o bezpośrednim dostępie do dowolnej komórki, jednak istnieje jeszcze jeden mechanizm, który powoduje, że w praktyce również w tej pamięci dostęp do kolejnych komórek jest szybszy niż dostęp zupełnie losowy. Mianowicie, dane przesyłane są pomiędzy różnymi rodzajami pamięci nie jako pojedyncze bajty, a w blokach zawierających pewną liczbę kolejnych bajtów. Im większa pamięć, tym większe rozmiary bloków. Przykładowo, podczas pobierania danych z pamięci operacyjnej do pamięci podręcznej oprócz potrzebnego nam bajtu są też kopiowane 63 kolejne bajty (zatem dostęp do pozostałych będzie szybszy, bo w przyszłości będą znajdować się w pamięci podręcznej). Z kolei kopiowanie danych z dysku twardego odbywa się w blokach zawierających po 512 bajtów. W przypadku naszego ucznia odpowiada to kserowaniu całych stron książki, pomimo tego, że potrzebne są mu tylko niektóre informacje zawarte na danej stronie.

Oczywiście, w artykule nie wyliczyliśmy wszystkich możliwości, jakie ma uczeń, gdy chce zdobyć informacje na temat Brazylii (może przecież zapytać nauczyciela, zadzwonić do konsulatu, a w ostateczności może wsiąść w samolot i zdobyć informacje z pierwszej ręki). Podobnie nie omówiliśmy wszystkich sposobów, w jakie użytkownik komputera może dostarczyć mu dane. Wśród pominiętych rodzajów pamięci możemy wspomnieć o różnorodnych pamięciach zewnętrznych, takich jak dyskietki, dyski optyczne (CD, DVD), karty pamięci lub taśmy magnetyczne. Ponadto, aby przyspieszyć ich działanie, dyski twarde również mogą być zaopatrzone w dodatkową pamięć podręczną, obsługiwaną przez specjalny układ zwany kontrolerem dysku. A w dobie Internetu jedną z podstawowych metod pozyskiwania danych jest „ściągnięcie” ich z sieci (gdzie przy ograniczonej prędkości światła istotne jest, w którym miejscu na świecie znajduje się serwer, z którym się łączymy). Zachęcamy Czytelników do samodzielnego sprawdzenia, jakie charakterystyki mają te pamięci, i zaproponowania, jaka analogia ze świata ucznia im odpowiada.

Na koniec warto wspomnieć, że aktualnie kluczowym parametrem przy wyborze komputera biurowego nie jest wcale szybkość procesora, ale szybkość dysku twardego. Zatem to właśnie inwestycja w dysk SSD (lub dwa dyski: mały SSD zawierający partycję z programami oraz większy dysk talerzowy z danymi) może znacząco poprawić komfort pracy z komputerem.

Sztuczna inteligencja w astrofizyce

Aleksandra SOLARZ*, Katarzyna MAŁEK*

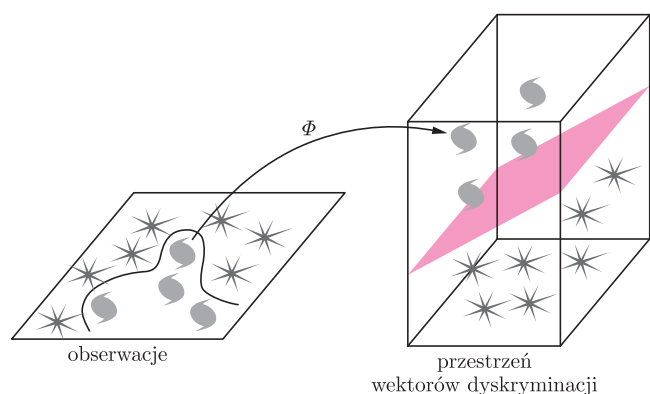
W swojej pracy astronomowie często korzystają z katalogów będących wynikiem wielkich przeglądów nieba. Zebrane w nich dane poddawane są różnorodnym analizom. Ważne jest przy tym, aby katalogi charakteryzowały się jak największą kompletnością i jednorodnością. Niejednokrotnie podczas analizy statystycznej dobrze poznanych typów obiektów wykrywane są źródła rzadko spotykane lub wykazujące niezwykle zachowanie. Dlatego też odpowiedni sposób klasyfikacji obserwowanych obiektów jest bardzo istotnym, o ile nie najistotniejszym krokiem, który należy wykonać przed przystąpieniem do zaawansowanego badania właściwości fizycznych obserwowanych obiektów niebieskich.

Cechy charakterystyczne. Przy tworzeniu przeglądów nieba, bądź tych ukierunkowanych na wykrywanie konkretnych klas obiektów, bądź tych zbierających wszystkie możliwe dane z danego obszaru nieba, bardzo ważna jest znajomość cech charakterystycznych obiektów, które spodziewamy się zaobserwować. Ułatwia to proces samej detekcji oraz klasyfikacji zebranych danych i, co za tym idzie, szybkiego wydobycia ważnych informacji z przeprowadzonego przeglądu do dalszej analizy. Często zdarza się, że unikalna klasa obiektów, choć obecna w przeglądzie, nie zostaje wykryta, ponieważ wykazuje cechy charakterystyczne podobne do innych źródeł licznie wykrytych przez przegląd.

O wyzwaniach dotyczących pomiaru przesunięcia ku czerwieni pisaliśmy w *Delcie* 3/2015.

W przeglądach obserwujących skrawek nieba położony poza płaszczyzną ekliptyki typy obiektów, które spodziewamy się wykryć, to głównie galaktyki, gwiazdy, kwazary oraz obiekty szczególne. Te cztery kategorie można podzielić na podklasy ze względu na ich fizyczne cechy charakterystyczne, tj. typ morfologiczny bądź spektralny rozkład energii. Dlatego morfologia, kolor bądź poszczególne linie widmowe to najpowszechniej używane kryteria służące do klasyfikacji obiektów astronomicznych.

Podczas klasyfikacji nienadzorowanej algorytm tworzy klasy obiektów ze względu na pewien zadany model, np. ze względu na stopień zagęszczenia obiektów w danej przestrzeni parametrycznej. Zaletą takiego podejścia do identyfikacji obiektów astronomicznych jest to, że wkład użytkownika jest minimalny, co sprawia, że wzorce w danych są wyszukiwane niezależnie od poglądów użytkownika na to, jak miałyby one wyglądać.



W przestrzeni trójwymiarowej nietrudno sprawdzić, czy zadany punkt o współrzędnych (X, Y, Z) leży „nad” płaszczyzną opisaną równaniem $ax + by + cz = 1$. Odpowiedź będzie twierdząca, jeśli wyrażenie $aX + bY + cZ - 1$ będzie miało taki sam znak jak c . Jeśli zatem potrafimy wymyślić odwzorowanie Φ z przestrzeni zawierającej wyniki obserwacji do przestrzeni wektorów dyskryminacji rozdzielające rozważane obiekty jak na powyższym rysunku, zadanie ich klasyfikacji będzie niemal wykonane.

Dlatego jest bardzo ważne, by przegląd nieba był efektywny w mierzeniu różnych cech charakterystycznych obserwowanych źródeł. Jednak takie obserwacje są niezwykle trudne i kosztowne. Zatem, chcąc uzyskać jak najliczniejsze próbki obiektów z danej klasy, które posłużą do dalszej analizy, często trzeba poświęcić tzw. „czystość” katalogu i pozwolić na pewien procent błędnych identyfikacji.

To jeszcze astronomia czy już informatyka? Wraz ze wzrostem liczby przeprowadzanych kosmicznych misji obserwacyjnych oraz wzrostem wydajności procesu zbierania danych pojawił się problem z przetwarzaniem oraz identyfikacją istotnych informacji z terabajtów danych bezustannie napływających z satelitów. Dlatego zamiast „ręcznych” technik klasyfikacji (takich jak diagramy kolor-kolor bądź kolor-strumień) wykorzystuje się automatyczne metody pozwalające na wykrywanie i separację różnych typów obiektów z minimalnym zaangażowaniem użytkownika przeglądu. Jednym z najbardziej użytecznych i najpowszechniej wykorzystywanych do tego celu algorytmów jest obecnie uczenie maszynowe (ang. *machine learning*). Metoda ta pozwala wykrywać pewne prawidłowości we wprowadzonych wektorach danych.

Z matematycznego punktu widzenia automatyczną klasyfikację można zdefiniować jako przekształcanie N -wymiarowego wektora zawierającego mierzone parametry określające dany obiekt na tzw. wektor dyskryminacji. Przekształcenie to definiujemy tak, by w pewien sposób podkreślało lub nawet wyolbrzymiało charakterystyczne cechy poszczególnych obiektów. Dlatego bardzo ważny jest wybór przestrzeni cech charakterystycznych obiektów: optymalna klasyfikacja będzie miała miejsce wtedy, gdy różne typy źródeł będą występowały w innych obszarach danej przestrzeni wektorów dyskryminacji i będą się w jak najmniejszym stopniu przekrywały. Jeżeli wykorzystywany przez nas przegląd nieba nie był specjalnie zaprojektowany do wykrywania interesujących nas obiektów, znalezienie odpowiedniego zestawu cech charakterystycznych może być bardzo trudne. W takim przypadku możemy użyć *klasyfikatorów nienadzorowanych*, stworzonych do wykrywania różnych prawidłowości w danych bez uprzedniej wiedzy na temat ich zawartości. Niestety, ten typ klasyfikacji bardzo silnie zależy od wyboru mierzonych parametrów.

Każdy proces klasyfikacji może zostać usprawniony, jeżeli poszukiwane klasy obiektów zostaną sprecyzowane, a wartości ich cech charakterystycznych dokładnie opisane. Wtedy można stworzyć modele klas poszukiwanych obiektów, które posłużą jako wzór, który następnie będzie poszukiwany w danych. Takie typy klasyfikacji nazywane są *nadzorowanymi* i pozwalają na bardzo precyzyjne wyszukiwanie danego typu obiektów. Jeden z najczęściej obecnie używanych w astronomii klasyfikatorów nadzorowanych to maszyna wektorów nośnych (ang. *support vector machine*, SVM). Algorytm ten przekształca wektory zawierające wyniki obserwacji do przestrzeni H wektorów dyskryminacji, używając nieliniowej funkcji $\Phi : X \rightarrow H$, tak by granice między klasami można było opisać w jak najprostszym sposób. Na podstawie wektorów z próbki obiektów wzorcowych SVM dzieli przestrzeń H na odpowiednie klasy. W kolejnym kroku obiekty o nieznanym „przynależności klasowej” zostają przekształcone do przestrzeni H i w zależności od położenia obiektów względem granicy podziału – odpowiednio sklasyfikowane.

Algorytm SVM stosowany jest z sukcesami do generalnej identyfikacji obiektów takich jak gwiazdy, galaktyki, czy kwazary w wielkich przeglądach (między innymi AKARI, VIPERS, WISE), jak też do poszukiwania ich szczególnych podtypów.