

1. Wstęp – Potrójnie wartościowa!

Ryszard Tadeusiewicz

Na czym polega wartość dobrej książki?

Bywają książki, które warto przeczytać (i warto je stale mieć na półce!), ponieważ dotyczą ważnych i aktualnych zagadnień, budzących żywe zainteresowanie zarówno naukowców, jak i praktyków. Wiadomo, że do takiej książki będzie się często zaglądać, bo zagadnienia w niej dyskutowane będą nieraz powracały w kontekście problemów naukowych godnych rozważenia oraz w kontekście zadań praktycznych koniecznych do rozwiązania. Mając taki przewodnik problemowy, ma się otwartych mnóstwo dróg, na których odnosić można wiele sukcesów, właśnie ze względu na ważność i aktualność poruszanej w książce problematyki.

Są też takie książki, które koniecznie trzeba mieć, bo prezentują nowe i ciekawe metody rozwiązywania problemów. Szczególnie cenne są opisy takich metod, które już potwierdziły swoją przydatność w różnych dziedzinach, ale jeszcze nie są rutynowo stosowane w tej dziedzinie, która jest dyskutowana w książce. Można bowiem przypuszczać, że te dobrze działające metody po powszechnym uznaniu ich przydatności tak bardzo zakorzenia się w kontekście nowego zastosowania, że zapewne niebawem ich znajomość, a zwłaszcza umiejętność ich praktycznego użycia, będzie istotnym atutem przy podejmowaniu różnych prac, zleceń, projektów, grantów itp. Opłaca się być pionierem torującym drogę nowościom metodologicznym, bo pionierom najczęściej przypadają w udziale bardzo korzystne zlecenia, a także ich projekty traktowane są życzliwie przez wszelkie gremia oceniające, gdyż innowacyjność jest obecnie bardzo w cenie. Dlatego wiedząc (lub z dużym poziomem prawdopodobieństwa przypuszczając), że pewne metody zyskają uznanie i będą szeroko stosowane, dobrze jest mieć pod ręką tom prac wprowadzających w tę nową metodologię i w sposoby jej stosowania. Tom taki może być nieocenionym źródłem bardzo potrzebnej wiedzy, ale może także być źródłem inspiracji, widząc bowiem, jak te nowatorskie metody zastosowano, można łatwiej samemu znajdować kolejne pomysły i dobrze rokujące zastosowania.

Warto dodać, że w przypadku metod naprawdę dobrych i naprawdę szeroko używanych (po okresie niepewności i nieufności, które towarzyszą zawsze wszelkim nowościom) może się okazać, że obok efektu pozytywnego, polegającego na tym,

że badacze biegle posługujący się nowymi metodami zyskują dzięki temu przewagę (na przykład w różnych konkursach związanych z uzyskiwaniem zamówień lub z uzyskiwaniem finansowania proponowanych projektów badań naukowych lub działań praktycznych) – pojawi się także specyficzny efekt negatywny. Ten efekt negatywny dotyczył będzie tych wszystkich, którzy owych nowatorskich metod nie znają i nie stosują. Stwierdzenie podczas oceny prac wykonanych lub podczas ewaluacji prac planowanych, że twórcy takiego czy innego projektu usiłują rozwiązywać problemy wchodzące w zakres tematyczny projektu, stroniąc od użycia metod, które chociaż nowatorskie, są powszechnie uznane za najlepsze w tym obszarze zastosowań – jest bardzo obciążające. Takie stwierdzenie może skutkować tym, że owe projekty będą odrzucane, a ich autorzy utracą dobrą opinię, na którą pracowali całymi latami, ponieważ brak znajomości i gotowości stosowania najnowszych i najdoskonalszych metod jest dla współczesnego badacza dyskwalifikujący, niezależnie od tego, jak wiele zasług i jak wiele osiągnięć miał w przeszłości.

Dwie podstawowe zalety dobrej książki, które posiada niniejsza monografia

Powyższe ogólne rozważania, oczywiście zresztą dla każdego badacza, przedstawiono nie bez kozery na początku tej monografii, zatytułowanej *Sieci neuronowe w procesach dopasowania zdjęć lotniczych*. Już sam tytuł pokazuje połączenie bardzo ważnego obszaru zastosowań z nowatorską (przynajmniej na gruncie geodezji i kartografii) metodyką rozwiązywania problemów za pomocą sztucznych sieci neuronowych. Zatem przyjmując omówione wcześniej kryteria, można stwierdzić, że prezentowana książka jest **podwójnie** warta uwagi, a także **podwójnie** warta tego, żeby ją posiadać i z niej intensywnie korzystać. Jest bowiem w tej książce zawarta wiedza dotycząca ważnych i aktualnych zagadnień wykorzystania zdjęć lotniczych. We współczesnej fotogrametrii, geodezji, kartografii oraz teledetekcji zdjęcia lotnicze są jednym z najcenniejszych źródeł informacji, nieocenionym między innymi przy tworzeniu ortofotomapy albo przy budowaniu modelu terenu. Przy wszystkich swoich zaletach metody oparte na zdjęciach lotniczych prowadzą jednak do bardzo pracochłonnych procedur wówczas, kiedy trzeba znajdować ich korelacje oraz spasowywać obrazy, które zarejestrowano oddzielnie, ale przy interpretacji konieczne jest rozważanie ich łącznie. Ręczne (a dokładniej oparte na wykorzystaniu wzroku i umysłu wykwalifikowanego obserwatora) wykonywanie wymienionych czynności napotyka na trudności w sytuacji, gdy liczba zdjęć wymagających spasowania jest bardzo duża. Stąd zainteresowanie praktyków możliwością stosowania technik zautomatyzowanych, a także zainteresowanie badaczy podejmowaniem tego zagadnienia od strony naukowej wraz z tworzeniem różnych algorytmów i testowaniem różnych metod automatycznego korelowania obrazów (w szczególności zdjęć lotniczych).

Wskazując na to silne osadzenie niniejszej monografii w tematyce, która na gruncie współczesnej fotogrametrii, geodezji, kartografii oraz teledetekcji jest uważana za jedną z wiodących, dowodzimy, że biorąc pod uwagę pierwsze kryterium, wymienione

w pierwszych akapitach niniejszego wstępu – książkę tę warto studiować, a jeszcze lepiej – posiadać i mieć możliwość częstego z niej korzystania.


Prezentowana książka ma też wszelkie walory związane z drugim z opisywanych wyżej powodów, dla których pewne opracowania po prostu należy mieć. Chodzi o prezentację nowych, wysoce wydajnych i efektywnych metod rozwiązywania problemów. W rekomendowanej książce tymi metodami są sieci neuronowe. Te ciągle jeszcze innowacyjne i awangardowe (mimo prawie dwudziestu lat intensywnego rozwoju!) metody informatycznego rozwiązywania problemów za pomocą sztucznych systemów wzorowanych pod względem budowy i zasad działania na budowie i zasadach działania ludzkiego mózgu są narzędziem, które bezwarunkowo należy poznać. Biorąc pod uwagę liczbę potwierdzonych sukcesami zastosowań sieci neuronowych w różnych dziedzinach, można przewidywać, że czytelnik nie raz i nie dwa zetknie się jeszcze z sytuacją, w której najlepszym narzędziem do rozwiązania jakiegoś problemu (być może nawet bardzo odległego od rozważanych w tej książce zagadnień korelacji zdjęć lotniczych) będą sieci neuronowe, a wtedy wiedza wyniesiona ze studiowania tej książki okaże się niezwykle przydatna.

Dodatkowy (trzeci) walor monografii

Wyżej wymienione zostały **dwa** argumenty wskazujące na to, że książkę tę warto studiować i warto ją mieć w swojej podręcznej bibliotece. Wydaje się, że są to ważne argumenty i właściwie można by poprzestać na ich wskazaniu, nie szukając niczego więcej. Jednak tytuł tego wstępu sugeruje, że książka jest **potrójnie** wartościowa. Na czym więc polega ta trzecia wartość?

Otóż często jest tak, że mamy jakiś problem i jakieś narzędzie, ale jedno nie pasuje do drugiego. Wtedy przed badaczem staje trudne zadanie przekształcenia problemu do takiej formy, żeby możliwe było zastosowanie rozważanego narzędzia, lub takie dostosowanie narzędzia, żeby mogło ono zadziałać w przypadku tego właśnie problemu. Jest to trudna sztuka, dlatego niezwykle cenne są przykłady zadań, które udało się rozwiązać za pomocą takiego niezbyt dobrze (początkowo) dopasowanego narzędzia dzięki zastosowaniu pomysłowych zabiegów i w przypadku problemu, i w przypadku narzędzia. Oczywiście każdy taki przypadek trzeba rozpatrywać i analizować oddzielnie, jednak przyjrzenie się, jak sobie z tym poradzili inni badacze, bywa bardzo inspirujące.

W anonsowanej tu książce taka właśnie sytuacja ma miejsce. Na pierwszy rzut oka zagadnienie korelacji zdjęć lotniczych absolutnie nie pasuje do właściwości narzędzi, jakimi są sieci neuronowe. Powodów tego niedopasowania jest kilka. Pierwszy i najważniejszy związany jest z właściwościami sieci neuronowych jako narzędzi rozwiązywania problemów. Ogólny schemat takiego rozwiązywania problemu za pomocą sieci neuronowej pokazano na rysunku 1.1. Pewne szczegóły widoczne na tym schemacie będą jeszcze dalej dokładniej przedyskutowane, w tym momencie jednak poprzestańmy na tym ogólnym ujęciu.



Rys. 1.1. Ogólny schemat rozwiązywania zadania z wykorzystaniem sieci neuronowej

Jak widać z przytoczonego rysunku, sieć powinna otrzymać na swoim **wejściu** wektor sygnałów (generalnie niezbyt wielu, bo inaczej nie da się sieci skutecznie uczyć) reprezentujących **dane** opisujące problem, który ma być rozwiązany. Po otrzymaniu tych sygnałów wejściowych sieć przeprowadza stosowne wyliczenia (w które zaangażowane są wszystkie sztuczne neurony pokazane na rysunku 1.1 jako czerwone kropki) i daje jakiś **wynik**. Wynik ten manifestowany jest na zewnątrz w postaci jednego lub kilku sygnałów wyjściowych, które po odpowiedniej interpretacji przez użytkownika sieci dostarczają mu gotowego rozwiązania postawionego problemu.

Podczas zamiany danych wejściowych w potrzebny użytkownikowi wynik końcowy sieć korzysta z **wiedzy** zgromadzonej w swojej strukturze w trakcie procesu uczenia.

Tak to wygląda w teorii i tak to się daje prawie natychmiast zastosować w wielu zadaniach. Jednak przy rozważanym w tej książce zadaniu korelacji zdjęć lotniczych wcale nie było oczywiste, jak mają wyglądać dane na wejściu sieci neuronowej ani jak uzyskać z sieci neuronowej wynik, który będzie użyteczny w specyficznym kontekście zadania spasowania obrazów, ani nawet, jak taką sieć uczyć, żeby uzyskać dobre wyniki. Autorzy poszczególnych rozdziałów składających się na dalszą treść monografii rozwiązyli te problemy i przedstawili zarówno wyniki, które zostały osiągnięte, jak i wszystkie te pomysłowe metody, którymi się posłużono, żeby te wyniki uzyskać.

Oczywiście nie będziemy tu streszczać wszystkich tych pomysłów i wszystkich tych metod, które w związku z tym zastosowano w rekomendowanej książce, bo to jest właśnie jej najważniejszy i najwartościowszy element. Jednak warto wskazać na ten element jako na będący dla Czytelników szczególnie wartościowy. Wartości te są dwójakiego rodzaju. Po pierwsze są to gotowe wzory do naśladowania, które można zasto-

sować w różnych podobnych zadaniach. Problem tego, jak wprowadzić do sieci neuronowej specyficzną strukturę danych, jaką jest wysokorozdzielcze zdjęcie lotnicze, pojawiać się może w licznych innych zadaniach związanych na przykład z teledetekcją – a tu są gotowe (i sprawdzone!) wzory, jak to można zrobić. Po drugie, opierając się na tych wzorach, można się pokusić o zastosowanie sieci neuronowych do innych zadań, na przykład do analizy za pomocą sieci neuronowych danych z LIDAR albo do obróbki zdjęć satelitarnych wykorzystywanych w ochronie środowiska.

Krótką charakterystyka sieci neuronowych

Na zakończenie tego wstępu zamieścimy w nim pewne uzupełnienie treści książki, które może się okazać użyteczne przynajmniej dla niektórych Czytelników.


W książce jest dużo informacji o tym, jak sieci neuronowe należy stosować do zagadnień związanych z korelacją zdjęć lotniczych, lecz – jak to często w pracach zbiorowych bywa – żaden z Autorów nie wyjaśnił przystępnie, czym są sieci neuronowe i dlaczego są tak cenione jako narzędzie rozwiązywania problemów informatycznych. Zapewne każdy z Autorów sądził, że tym właśnie zajął się kolega piszący oddzielny rozdział, jednakże w istocie nikt się tym nie zajął i pozostało pewne niedopowiedzenie. Trochę wiadomości podstawowych podano w rozdziale 5, ale odnoszą się one do nowatorskiej (ale jeszcze nie nazbyt rozpowszechnionej) techniki sieci neuronowych impulsujących. Tymczasem o najczęściej używanych, typowych, można powiedzieć klasycznych sieciach neuronowych (w sensie ich budowy i działania) nie napisano prawie nic.

Biorąc pod uwagę fakt, że wśród specjalistów zajmujących się geodezją i kartografią podstawowa wiedza o sieciach neuronowych może nie być rozpowszechniona, postanowiono zamieścić w niniejszej przedmowie kilka podstawowych informacji o sieciach neuronowych jako swoisty pendant do tej książki. Tego rodzaju wiedza w pigułce będzie zapewne przydatna przy studiowaniu książki, a jednocześnie mając liczne przykłady udanych zastosowań sieci neuronowych w geodezji i kartografii (by wspomnieć tylko o pracach profesora Stanisława Gruszczyńskiego na ten temat), można przypuszczać, że wiedza taka może być dla geodetów i kartografów użyteczna. Osoby, które są przekonane, że podstawową wiedzę na temat sieci neuronowych już posiadają, mogą resztę wstępu po prostu pominąć.

Zacznijmy od stwierdzenia, że sieć neuronowa jest w jakimś stopniu następstwem modelowania mózgu (rys. 1.2).


Jednak nie jest to model służący celom poznawczym (choćby bywają sieci używane do prób interpretacji działania mózgu jako takiego), lecz najczęściej sieć neuronowa jest po prostu jeszcze jednym narzędziem informatycznym służącym do rozwiązywania wielu problemów zgodnie ze schematem pokazanym na rysunku 1.1.

W stosunku do rzeczywistego mózgu sieć neuronowa jest bardzo uproszczona. Pierwsze uproszczenie polega na tym, że elementy, z których jest ona zbudowana, są skrajnie ograniczone pod względem struktury i zasady działania w stosunku do rzeczywistych biologicznych neuronów (rys. 1.3).




Rys. 1.2. Wzorem dla sieci neuronowych jest mózg człowieka

a)



b)




Rys. 1.3. Neuron biologiczny (a – mikroskopowy obraz rzeczywistej struktury komórki i jej schemat) oraz sztuczny neuron używany przy tworzeniu sieci neuronowych (b)

Z licznych cech rzeczywistych komórek nerwowych w modelach stanowiących podstawę funkcjonowania sztucznych sieci zachowano wyłącznie trzy właściwości neuronu:

- ma on wiele wejść i jedno wyjście, dokonuje więc integracji sygnałów wejściowych;
- jego działanie uzależnione jest od wartości parametrów (wag), zmienianych podczas uczenia;
- jego sygnał wyjściowy trafia do innych neuronów sieci lub na jej wyjście (jako rozwiązanie).

Drugie uproszczenie polega na tym, że struktura sztucznej sieci neuronowej jest arbitralnie regularna i uboga w odróżnieniu od prawdziwych struktur nerwowych obserwowanych w rzeczywistym (biologicznym) mózgu (rys. 1.4). Szlaki połączeń rzeczywistych neuronów w mózgu są bardzo złożone i długo jeszcze będą musiały być badane, zanim potrafiemy wiernie odtworzyć ich przebieg. Natomiast struktura sztucznej sieci neuronowej wyznaczana jest przez arbitralnie wybierane warstwy, pomiędzy którymi sztuczne neurony (kwadraciki na rysunku 1.4) łączy się zgodnie z zasadą „każdy z każdym”.

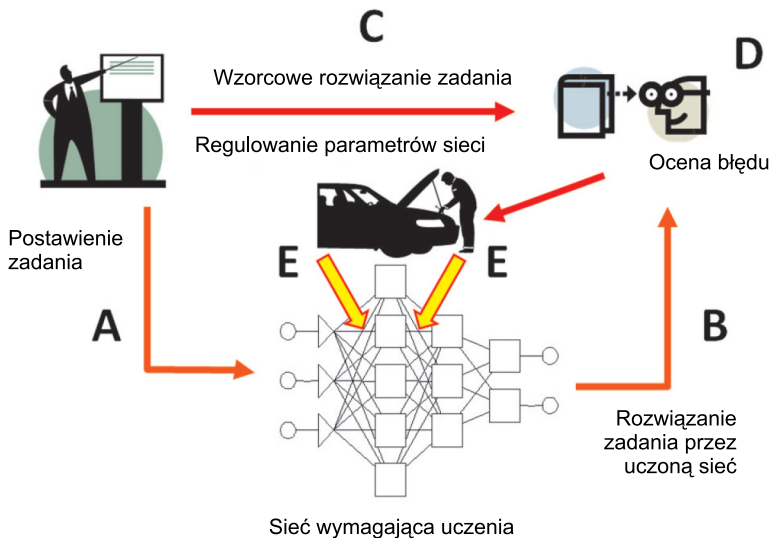


Rys. 1.4. Obraz trójwymiarowej rekonstrukcji fragmentu rzeczywistej struktury sieci komórek nerwowych w mózgu oraz schemat sztucznej sieci neuronowej z jej arbitralnymi elementami

Ważną zaletą sieci neuronowej jest to, że może być ona dostosowana do rozwiązywania konkretnych problemów za pomocą procesu uczenia. Istota procesu uczenia polega na działaniach pokazanych na rysunku 1.5.

Do tego, aby skutecznie nauczyć sieć neuronową, należy mieć zbiór przykładów (tak zwany zbiór uczący), w którym dla wielu przypadków zadanego problemu znane są zarówno dane wejściowe, stanowiące przesłankę do zbudowania rozwiązania, jak i wzorcowe rozwiązania (poprawne odpowiedzi). Z tych zasobów korzystamy podczas uczenia sieci w sposób pokazany na rysunku 1.5. Nauczyciel (w istocie jest to zawsze program komputerowy wykorzystujący bazę danych zawierającą zarówno przykładowe dane wejściowe, jak i wzorcowe poprawne rozwiązania) podaje do sieci dane wejściowe (stawia zadania do rozwiązania – czynność A na rysunku 1.5). Na tej podstawie sieć produkuje swoje rozwiązanie problemu (czynność B) – na ogół na początku uczenia błędne. Ze zbioru uczącego pobierane jest wzorcowe rozwiązanie tego samego problemu (czynność C) i przez jego porównanie z rozwiązaniem dostarczonym przez sieć (B) uzyskiwana jest ocena błędu popełnianego przez sieć. Nieco dalej pokażemy, w jaki sposób oszacowany błąd pozwala określać kierunek i wielkość poprawek, które trzeba wprowadzić w parametrach sieci (czynność E), żeby sieć lepiej rozwiązywała

w przyszłości to zadanie. Poprawki można wprowadzać równocześnie we wszystkich elementach sieci (co uwzględniono na rysunku 1.5), dlatego takie działanie wyjątkowo dobrze nadaje się do systemów obliczeniowych o architekturze rozproszonej; ale tego wątku nie będziemy tu rozwijali.




Rys. 1.5. Proces uczenia sieci neuronowej

Jednorazowa poprawka parametrów sieci wykonana według podanego wyżej schematu na ogół nie przynosi od razu rewelacyjnych wyników. Również pełny pojedynczy cykl, polegający na pokazaniu wszystkich przykładów wchodzących w skład całego zbioru uczącego (nazywany w technice sieci neuronowych epoką) – nie powoduje uzyskania godnego odnotowania wyniku, bo proces uczenia sieci przebiega zwykle wolno. Jednak cierpliwe wielokrotne przeglądanie zbioru uczącego prowadzi do tego, że sieć neuronowa stopniowo doskonali swoje działanie – aż do uzyskania optymalnego rozwiązania, które często bywa całkowicie bezbłędne (sieć poprawnie rozwiązuje wszystkie zadania) albo obarczone jest pewnym błędem, z reguły bardzo małym.

Dodamy teraz kilka słów na temat kluczowej idei będącej w istocie kwintesencją uczenia sieci neuronowej: wiązania oceny błędu popełnianego przez sieć ze zmianą jej parametrów podczas procesu uczenia. Realizacja tej idei w praktyce wiąże się z wykonywaniem dosyć skomplikowanych operacji matematycznych. Operacje te wykonuje się na wynikach porównania. Porównanie to wykazuje błąd popełniany przez sieć jako różnicę między tym, co sieć robi, mając pewien ustalony zbiór wartości swoich parametrów (wag we wszystkich neuronach), a tym, co zgodnie ze zbiorem uczącym robić powinna. Z tego porównania można wyciągnąć bardzo szczegółowe wnioski, określające, które parametry (które wagi w których neuronach) należy zwiększyć, a które zmniejszyć, żeby w przyszłości sieć nie popełniała wykrytego błędu.


Mimo bardzo skomplikowanych formuł matematycznych opisujących szczegółowo proces uczenia sieci naszkicowany wyżej, samą zasadę tego uczenia można stosunkowo łatwo zrozumieć.

Zacząć trzeba od fundamentalnego stwierdzenia: zachowanie sieci zależne jest od współczynników wagowych w we wszystkich jej neuronach (patrz rys. 1.3). Jeśli zatem ustali się te współczynniki, a potem przeegzaminuje się sieć, pokazując jej wszystkie elementy zbioru uczącego i dla każdego z nich wyznaczając wartość błędu, to można ocenić, czy ta sieć dobrze działa, czy nie. Jako syntetyczna ocena jakości działania sieci neuronowej może posłużyć suma kwadratów błędów popełnianych przez sieć na wszystkich jej wyjściach i dla wszystkich przykładów zbioru uczącego. Gdy się tę sumę kwadratów błędów obliczy, to otrzyma się liczbę, którą można uznać za sumaryczną ocenę jakości działania sieci dla tego właśnie zestawu współczynników wagowych w . Dla innego zestawu współczynników błąd będzie inny (rys. 1.6).



Rys. 1.6. Zależność błędów popełnianych przez sieć od jej parametrów

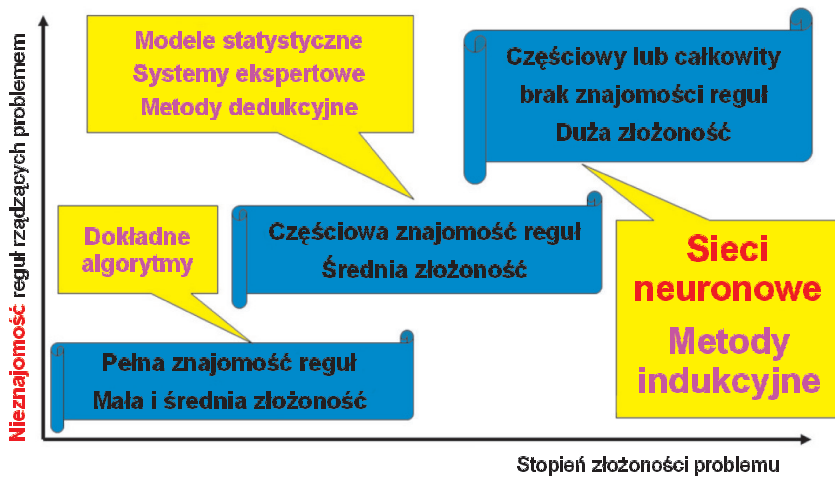
Gdy treść rysunku 1.6 stanie się zrozumiała, to zrozumiemy także rysunek 1.7 pokazujący, w jaki sposób algorytm uczenia sieci neuronowej pozwala znaleźć docelowo takie miejsce, które gwarantuje najmniejszą wartość popełnianego przez sieć błędu, czyli po prostu najlepsze dopasowanie jej parametrów do zadania, które jest rozwiązane. Kluczowe znaczenie ma fakt, że odpowiednie algorytmy uczenia sieci (na przykład najbardziej znany algorytm *backpropagation*) są w stanie każdorazowo wskazać kierunek najszybszego spadku błędu, który staje się drogowskazem dalszego postępowania (stosownej zmiany wag we wszystkich neuronach sieci).



Rys. 1.7. Uczenie sieci neuronowej jako przemieszczanie się po powierzchni błędów połączone ze zmianą wag

Zalety sieci neuronowych

Uczenie sprawia, że wystarczy pokazać sieci wystarczająco dużo zadań wraz z ich poprawnymi rozwiązaniami, a sieć tak dostosuje zasady swego działania do specyfiki zadania, że będzie je niezawodnie poprawnie rozwiązywać. Stwarza to jedyną w swoim rodzaju możliwość stosowania sieci neuronowych do rozwiązywania takich zadań, w przypadku których nie potrafimy znaleźć dobrych rozwiązań algorytmicznych. Ilustruje to poglądowo rysunek 1.8. Na rysunku tym zadania informatyczne, które mogą być rozwiązywane sklasyfikowano ze względu na dwa kryteria (umieszczone umownie na osiach zaznaczonego układu współrzędnych). Pokazano zróżnicowanie ze względu na stopień złożoności (traktowany wprawdzie bardziej w sposób jakościowy niż ilościowy, ale z możliwością odróżnienia problemów łatwiejszych i trudniejszych), a także zróżnicowanie uwzględniające stopień nieznaności reguł rządzących danym problemem. To ostatnie jest szczególnie ważne w przypadku sieci neuronowych, ponieważ ich unikatową właściwością jest możliwość rozwiązywania takich problemów, w przypadku których reguły rządzące problemem są całkowicie nieznanne. Sieci neuronowe są prawdopodobnie najlepszym znanym obecnie narzędziem do rozwiązywania problemów metodą indukcji, to znaczy metodą opierającą się wyłącznie na analizie konkretnych przykładów, w których przejawia się działanie jakiejś nieznannej reguły. System indukcyjny analizuje przedstawiane mu przykłady poprawnych rozwiązań, automatycznie buduje na ich podstawie model, będący empiryczną rekonstrukcją tej nieznannej reguły, której brak uniemożliwia stosowanie innych podejść, a następnie rozwiązuje inne problemy, uogólniając odpowiednio wiedzę uzyskaną na podstawie tych szczegółowych przykładów. Sieci neuronowe są właśnie takimi systemami.



Rys. 1.8. Obszar zastosowań, w którym sieci neuronowe dominują nad innymi rozwiązaniami

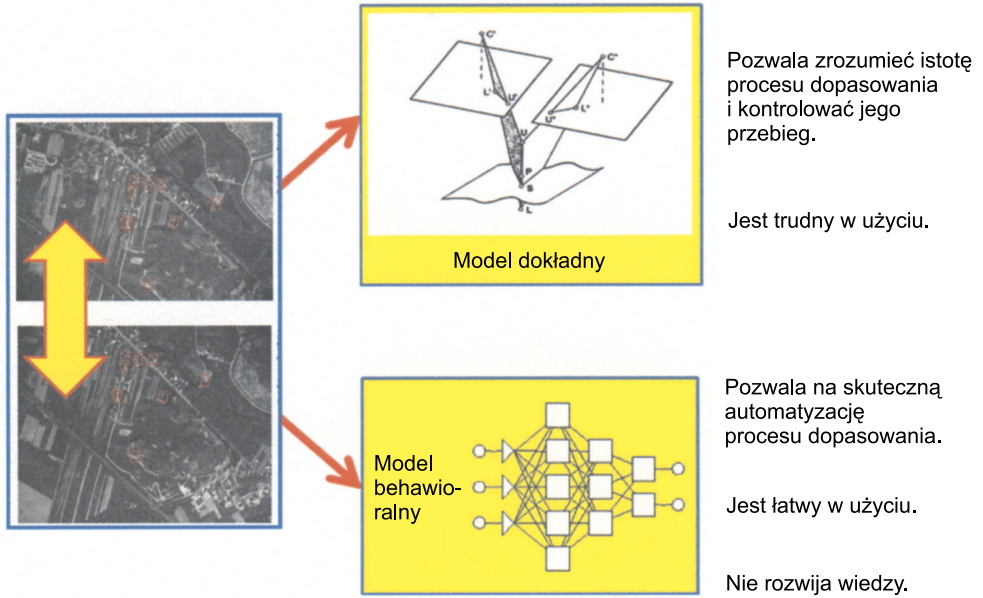
Dodatkową zaletą sieci neuronowych jest to, że z ich pomocą można tworzyć modele dowolnych systemów. Model wydaje się pojęciem bardzo abstrakcyjnym, oderwanym od praktyki, mało przydatnym. Jest jednak inaczej. Mając model jakiegoś systemu albo procesu, możemy na tym modelu sprawdzać konsekwencje różnych działań, zanim je podejmiemy w rzeczywistości. Dobry model jest więc podstawą projektowania, bieżącej kontroli, sterowania, diagnostyki nieprawidłowości, prognozowania i wielu innych zadań, których poprawne wykonanie jest warunkiem osiągnięcia rozmaitych celów, w tym także celów bardzo praktycznych.

Mówiąc, że sieci neuronowe są znakomitym narzędziem do tworzenia modeli, mamy na myśli głównie jedną ich ogromną zaletę: otóż budują one modele przeróżnych systemów, opierając się wyłącznie na zachowaniu tych systemów. Takie modele nazywa się zwykle modelami behawioralnymi.

Modele behawioralne systemów można tworzyć, nie dysponując żadną wiedzą na temat natury zjawisk i procesów występujących w tych systemach, a także nie robiąc na ten temat żadnych założeń. Przytoczone stwierdzenie stanie się bardziej zrozumiałe, jeśli spojrzymy na rysunek 1.9. Pokazano na nim rozważany w tej książce proces dopasowywania zdjęć lotniczych i dwa sposoby jego modelowania – metodami tradycyjnymi, odwołującymi się do geometrii procesu pozyskiwania zdjęć, oraz z wykorzystaniem sieci neuronowej. Zalety neuronowego modelu są widoczne.

Oczywiście ta garść luźnych uwag przedstawiających wybrane zagadnienia związane z techniką sieci neuronowych, używaną w tej książce, zdecydowanie nie wyczerpuje tematu. Ale o właściwościach (a zwłaszcza o zaletach) sieci neuronowych napisano już całe tomy, więc nie warto tutaj pisać o tym zbyt wiele. Zachęcam więc Czytelników, żeby wyposażeni w ten mikroskopijny zasób wiedzy, jaki dostarczyły ostatnie

stronice tego wstępu, śmiało wkroczyli do kolejnych rozdziałów monografii, w których – odwrotnie niż w tym wstępie – ogólnych ujęć będzie bardzo niewiele, natomiast znajdzie się mnóstwo dokładnie opisanych szczegółów.



Rys. 1.9. Porównanie sposobów modelowania procesu dopasowywania zdjęć lotniczych – metodą tradycyjną oraz przy zastosowaniu sieci neuronowej