

Rafał Michalczak
Uniwersytet Jagielloński

Sztuczne sieci neuronalne w modelowaniu rozumowań prawniczych. O problemach wynikających ze specyfiki prawa

1. Wprowadzenie

Pierwsza istotna data dotycząca rozwoju sztucznej inteligencji w ogóle, którą przywołuje się w literaturze, to rok 1943, kiedy W.S. McCulloch wraz ze swoim współpracownikiem W. Pittsem stworzyli pierwszy model neuronu. Założyli oni, że każdy z neuronów może przyjmować jedną z dwóch wartości, zaś cała sieć neuronalna zachowuje się w sposób równoważny z maszyną Turinga. Pogląd ten przetrwał pośród naukowców zastanawiających się nad sposobem funkcjonowania umysłu, stając się podstawą komputerowej metafory (tzn. postrzegania ludzkiego umysłu na wzór algorytmicznie przetwarzającego informacje komputera¹) funkcjonowania umysłu. W świetle późniejszych badań okazało się, że model ten był błędny, zaś sposób funkcjonowania umysłu jest jakościowo różny od sposobu funkcjonowania komputerów. Jednak odkrycie McCullocha oraz Pittsa było niejako pierwszym krokiem ku późniejszym badaniom sztucznych sieci neuronalnych. Zapewniło ono McCullochowi status jednego z ojców sztucznej inteligencji, zaś badania te zapoczątkowały również nurt sztucznej inteligencji związany z modelowaniem sztucznych sieci neuronowych.

Wprowadzenie niniejsze nie dąży do szczegółowego zdefiniowania problemów, którymi w kontekście prawa zajmuje się sztuczna inteligencja, nie ma również definiować jej samej. Stąd też wskazanie jedynie powyższego wydarzenia – po to tylko, aby przywołać kontekst i umiejscowić tekst w pożądanym obszarze zainteresowań.

W niniejszej pracy chciałbym skoncentrować się na problematyce zastosowania sztucznych sieci neuronalnych do modelowania rozumowań prawniczych. **W szczególności zaś chciałbym opisać, jakie problemy może napotkać ów paradygmat w zestawieniu ze specyfiką rozumowania prawniczego.** Nie ma to być bynajmniej praca inżynierska czy też informatyczna – jej głównym celem jest nakreślenie pewnej specyfiki dziedziny nauk prawnych w kontekście możliwości zastosowania technik sztucznej inteligencji do modelowania rozumowań dla niej charakterystycznych. Wybrałem kilka systemów,

¹ S. Guttenplan, *A Companion to the Philosophy of Mind*, Oxford 1995, s. 176 i n.

które służą jako ilustracja dla pewnych specyficznych cech rozumowań prawniczych, sprawiających problemy przedstawicielom nauk inżynierskich.

Na początku przedstawię ogólny opis tego, czym są sztuczne sieci neuronalne. Następnie umiejscowię je w szerszym kontekście systemów ekspertowych. Po takim wprowadzeniu postaram się pokrótce omówić kilka wybranych systemów opartych na sztucznych sieciach neuronalnych, które posłużą mi jako ilustracje specyficznych dla prawa problemów mogących się pojawić podczas aplikowania sztucznej inteligencji do prawa. Wskazując na te problemy, chciałbym w szczególności zwrócić uwagę na fakt, że jakkolwiek integracja nauk prawnych z np. dyscyplinami informatycznymi jest niewątpliwie pożądana i może być owocna, to jednak specyfika prawa sprawia, że nie jest to bynajmniej integracja prosta i niesprawiająca problemów.

2. Czym są sztuczne sieci neuronalne?

Idea leżąca u podstaw konstruowania sztucznych sieci neuronalnych (*artificial neural networks*) związana jest z próbą sztucznego odwzorowania działania ludzkiego mózgu. To zupełnie odmienny sposób przeprowadzania wnioskowania niż przy użyciu tradycyjnych, komputacjonistycznych metod. Wskazałem wcześniej, że model neuronu, którego działanie miałyby być możliwe do przedstawienia za pomocą maszyny Turinga, okazał się błędny. Sztuczne sieci neuronalne mają działać właśnie w taki odmienny, konekcyjnistyczny sposób. Chodzi o model, który w przeciwieństwie do tradycyjnego liniowego i szeregowego jest zarówno nieliniowy, jak i równoległy. Istotny jest również fakt nieodróżniania w sieciach neuronalnych pamięci danych i pamięci procesów².

Siła sieci neuronalnych leży w fakcie połączenia wielu pojedynczych neuronów, z których każdy ma w gruncie rzeczy bardzo prostą budowę. Składa się bowiem z dendrytów – włókien doprowadzających informację do komórki, ciała komórkowego oraz jednego aksonu, który wyprowadza informację dalej. Każdy poszczególny neuron może otrzymywać wiele sygnałów wejściowych, ale zawsze wytwarza jeden sygnał na wyjściu. Zdolność do uczenia się danej sieci wynika ze sposobu przekazywania sobie sygnałów pomiędzy poszczególnymi neuronami. Jeżeli któreś połączenie odpowiada rezultatowi „prawidłowemu”, wówczas jest ono częściej używane i zostaje wzmocnione – dzięki czemu jest używane jeszcze częściej. To sprzężenie zwrotne powoduje, że sieć ma zdolność uczenia się na podstawie przykładów³.

Istnieje wiele różnego rodzaju sztucznych sieci neuronalnych, różniących się chociażby ilością warstw neuronów czy też właściwościami przekazywania sygnału pomiędzy poszczególnymi neuronami. Tradycyjne ludzkie neurony działają na zasadzie wszystko albo nic, tzn. jeśli siła sygnału przekroczy pewien próg sygnał przesyłany jest dalej, w przeciwnym wypadku nie; w wypadku sztucznych sieci neuronalnych można tą właściwością (jak i wszelkimi innymi) manipulować. Istnieje również wiele technik trenowania sieci – procesu podczas którego sieć uczy się przypisywać wagi poszczególnym czynnikom⁴.

Systemy oparte o tego typu zasady działania mają niezwykle duże znaczenie w odtwarzaniu sposobów rozumowań typowych dla ludzi, takich jak rozumowanie przez analogię, rozpoznawanie wzorców czy reguł. Niestety sztuczne sieci neuronalne – jeżeli chce się je zastosować jako jedyną metodę przeprowadzania wnioskowania – mają jedną

² M. Negnevitsky, *Artificial Intelligence. A Guide to Intelligent Systems*, Essex 2005, s. 166.

³ P. Jaśkowski, *Neuronauka poznawcza. Jak mózg tworzy umysł*, Warszawa 2010, s. 20.

⁴ P. Jaśkowski, *Neuronauka poznawcza...*, s. 186 i n.

podstawową wadę: nie posiadają mechanizmu wyjaśniającego. Systemy regułowe czy też te polegające na wnioskowaniu opartym o sprawy są w stanie przedstawić reguły, które zostały zastosowane w poszczególnych krokach analizy problemu. Sztuczne sieci neuronalne zaś mogą jedynie przedstawić rezultat swojego działania. Dlatego też w praktyce, w której ważny jest prócz samego wyniku również sposób jego osiągnięcia, stosuje się systemy hybrydowe: posiadające mechanizmy wnioskowania oparte o sieci neuronalne oraz mechanizmy wyjaśniające oparte o systemy regułowe⁵.

Wskazany powyżej brak mechanizmów eksplanacyjnych nie oznacza, że z działania takiej sieci nie da się w ogóle wywnioskować, jakie reguły zostały zastosowane. Wymaga to odrębnego mechanizmu, który jednak może bez problemu prześledzić „tok rozumowania” takiej sztucznej sieci neuronalnej. To rozróżnienie jest szczególnie istotne w związku z faktem, że współczesna, ogromna moc obliczeniowa komputerów sprawia, iż coraz częściej zaczynają one wykazywać wzorce zachowań bądź wynajdować reguły, które – choć pozwalają np. skutecznie kategoryzować obiekty – są kompletnie niezrozumiałe dla ludzkich użytkowników⁶.

Chronologicznie najwcześniejszymi systemami były systemy regułowe (*rule-based system*). Reguły bowiem były stosunkowo prostymi do stworzenia i zrozumienia opisaniami, jak w kolejnych krokach zajmować się rozwiązywaniem problemu. Jako regułę należy rozumieć prostą strukturę „jeżeli-to”. Część reguły następująca po słowie „jeżeli” nazywana jest poprzednikiem, przesłanką albo warunkiem, zaś ta poprzedzona słowem „to” bywa nazywana następnikiem, wnioskiem albo działaniem. Co do zasady reguły mogą zawierać wiele poprzedników połączonych koniunkcją lub alternatywą. Mogą również składać się z bardziej skomplikowanych struktur, w których skład wchodzi obiekt połączony operatorem ze swoją wartością⁷. Można np. zanalizować zdanie „jeżeli prędkość samochodu jest wysoka, to x”, w którym „prędkość samochodu” jest obiektem, następujące później słowo „jest” – operatorem, zaś „wysoka” – wartością wskazanego wcześniej obiektu. Sposób działania takich systemów jest najbardziej spójny z powszechnymi mniemaniami na temat działania komputerów. Sprowadza się bowiem do prostego mechanizmu w zasadzie podobnego do zwykłych mechanicznych urządzeń takich jak włącznik światła: gdy naciśniesz przycisk, światło się włączy.

Kolejnym podejściem do budowania systemów ekspertowych jest podejście związane z rozumowaniem opartym na sprawach (*case-based reasoning*). Jest ono w dużej mierze związane ze zmianą paradygmatu programistycznego, tzn. z wprowadzeniem programowania obiektowego. Nie wnikając w informatyczne szczegóły, należy wskazać, że zamiana ta miała na celu łatwiejsze modelowanie programów komputerowych. Obiekt bowiem był tutaj rozumiany jako pewna struktura danych z informacjami dotyczącymi konkretnej rzeczy czy pojęcia. Każda rzecz była opisywana przez ramę (*frame*), która składa się ze slotów i odpowiadających im atrybutów. Kluczową informacją dotyczącą paradygmatu obiektowego jest tutaj fakt, że ów pojedynczy obiekt-rama zawiera wszystkie konieczne informacje na temat danego obiektu czy pojęcia⁸. Właśnie w taki sposób

⁵ M. Negnevitsky, *Artificial Intelligence...*, s. 261.

⁶ Por. system *Omega* opisywany np. przez M. Schwarzkopf, A. Konwinski, M. Abd-El-Malek, J. Wilkes, *Omega: flexible, scalable schedulers for large compute clusters*, <http://eurosys2013.tudos.org/wp-content/uploads/2013/paper/Schwarzkopf.pdf>, dostęp: 4.12.2013 r.

⁷ M. Negnevitsky, *Artificial Intelligence...*, s. 27.

⁸ M. Negnevitsky, *Artificial Intelligence...*, s. 132.

będą najczęściej reprezentowane poszczególne sprawy w metodach, które bazują na rozumowaniu opartym na sprawach.

Opisywany tutaj sposób konstruowania programów rozwiązujących problemy wiąże się z prostej obserwacji rzeczywistości. Problem jest tutaj rozwiązywany na podstawie informacji, które system zmagazynował w odniesieniu do już rozwiązanych spraw. System ma za zadanie odnaleźć podobieństwo pomiędzy poszczególnymi sprawami i wówczas zastosować takie same środki jak w poprzednim wypadku. Koncepcja ta ma tworzyć model rozumowania niejako izomorficzny do tego, w jakim ludzie rozwiązują swoje problemy. Przekładając sposób wnioskowania na nieinformatyczne pojęcia, można porównać ten sposób rozumowania do przeszukiwania kartotek. Każda osoba ma osobną teczkę, w której zawarte są wszystkie informacje na jej temat. Na ich podstawie można wyciągać dowolne wnioski, można też porównać dwie kartoteki. W związku zaś z tym, że są one ustrukturyzowane przy użyciu takich samych formularzy, bardzo łatwo jest porównać dwie konkretne cechy dwóch różnych osób poprzez proste porównanie pola o danym numerze z jednej i drugiej te czki.

Systemy, którymi chciałbym zilustrować powyższe teoretyczne opisy, nie opierają się wyłącznie na sieciach neuronalnych, lecz wykorzystują również inne metody wnioskowania, dlatego też będę je nazywał systemami hybrydowymi.

3. *SplitUp*

System, od którego chciałbym zacząć, został stworzony w 1999 r. w Australii. Dotyczył dziedziny prawa rodzinnego, a dokładniej – podziału majątku pomiędzy rozwodzących się małżonków. Dziedzina ta została wybrana, gdyż jest powszechnie uważana za pozostawiającą sędziemu dużą dyskrekcję. Ustawa bowiem wskazuje, jakie czynniki należy brać pod uwagę podczas dokonywania podziału majątku, jednak nie wskazuje, jak należy je ważyć. W związku z tym można twierdzić, że w gruncie rzeczy każdy z sędziów będzie tak naprawdę przypisywał poszczególnym czynnikom różne wagi.

Program *SplitUp* stanowił połączenie sztucznej sieci neuronalnej z systemem regułowym. Konieczność takiego połączenia wynikała ze wspomnianej już wcześniej niemożności generowania wyjaśnień przez system oparty wyłącznie o sztuczną sieć neuronalną. Było to również powiązane ze sposobem reprezentacji wiedzy. W konekcyjnym paradygmacie reguły i zasady nie są bezpośrednio reprezentowane. W typowym paradygmacie rozumowania opartego na regułach od twórcy wymaga się stworzenia listy reguł mających przedstawić wcześniej postać „jeżeli-to”. Lista ta sprawia, że mechanizm jest w stanie każdemu poprzednikowi przyporządkować następnik, chyba że dla danego poprzednika nie podaje reguły postępowania. Sprawia to, że choć systemy regułowe mogą być skuteczne, nie są w stanie radzić sobie w warunkach niepełnej wiedzy czy braku precyzyjnie określonych schematów. Dlatego też sztuczna sieć neuronalna została użyta w opisywanym systemie do odpowiedniego ważenia poszczególnych czynników (czego nie mógłby dokonać klasyczny system), zaś system regułowy został wykorzystany do przywoływania *ex post* odpowiednich reguł, którymi można by poprzeć uzyskany rezultat⁹.

Podejście, które zastosowali autorzy systemu, może nieco przypominać dziedzinę odkrywania wiedzy (*knowledge discovery*). Chcieli oni bowiem przy użyciu sztucznej sieci

⁹ A. Stranieri, J. Zeleznikow, M. Gawler, B. Lewis, *A hybrid rule – neural approach for the automation of legal reasoning in the discretionary domain of family law in Australia*, „Artificial Intelligence and Law” 1999/7, s. 155.

neuralnej, którą zastosowali do analizy danych w postaci poprzednich spraw, uzyskać nową, nieznaną wcześniej wiedzę dotyczącą wagi, jaką sędziowie przypisują poszczególnym czynnikom. Chcieli, aby system, porównując poszczególne sprawy, spróbował odtworzyć procesy decyzyjne sędziów.

Pierwszym problemem, jaki pojawił się przy konstrukcji systemu, było wybranie spraw, które zostaną wykorzystane do wytrenowania systemu. Z jednej strony przeszkodą był fakt, że większość spraw rozstrzyganych przed pierwszą instancją nie była nigdy publikowana z racji niezawierania precedensów ani ciekawych zagadnień prawnych. Z drugiej strony duża część spraw małżeńskich nie dotyczyła wyłącznie kwestii majątkowych i koncentrowała się np. na zagadnieniach związanych z opieką nad dziećmi. Sprawy takie również nie mogły zostać wykorzystane, gdyż system miał dotyczyć wyłącznie podziału majątku¹⁰.

Kolejnym problemem, na jaki natknęli się twórcy, była możliwość występowania sprzeczności pomiędzy poszczególnymi sprawami. Sprawy sprzeczne zostały zdefiniowane jako te, które przy takich samych warunkach początkowych kończą się różnymi rozstrzygnięciami. Ta wstępna definicja nie była jednak zbyt konkluzywna, wszak pojawiało się pytanie, kiedy rozstrzygnięcia się różnią. Kwestia ta musiała zostać rozstrzygnięta arbitralnie przez twórców systemu wyznaczeniem wartości różnicy między dwoma podziałami, aby uznać je za sprzeczne. Takie sprzeczne sprawy były następnie eliminowane z puli spraw. Wspierano to argumentem, że gdy w praktyce sędziowskiej dwóch sędziów całkowicie zgadza się co do relewantnych czynników, a jednak ich rozstrzygnięcia są skrajnie różne, wówczas uznaje się, iż jeden z sędziów popełnił błąd¹¹.

Na gruncie sztucznej inteligencji często stosowaną metodą radzenia sobie z problemami jest dzielenie owych problemów na mniejsze, a dzięki temu prostsze do wykonania zadania. Również w tym wypadku zastosowano tę metodę. Cały problem podzielono na 30 podproblemów, z których każdy mógł być postrzegany jako właściwie odrębny problem z zakresu drażenia danych¹². Kiedy zakończono prace nad zbieraniem i konceptualnym opracowywaniem danych i problemów, zastosowano sztuczną sieć neuronalną. Nie będę opisywał szczegółów technicznych tej sieci, zwrócę jednak uwagę na wiążące się z nią specyficzne ograniczenia.

Wskazywałem wcześniej, że sztuczne sieci neuronalne doskonale nadają się do wazania czynników dzięki niepodleganiu żadnym tendencjom czy błędom poznawczym mogącym dotykać człowieka. Ich stosowanie nie jest jednak bezproblemowe, bowiem to właśnie człowiek musi (przynajmniej w jakimś zakresie) przeprowadzić tzw. trening¹³. Mogą pojawić się dwa problemy. Z jednej strony, jeśli sieci zostanie zaprezentowana zbyt duża ilość przykładów zbyt dużą ilość razy, sieć ta zapamięta poszczególne pary wejść i wyjść, tracąc zdolność do generalizacji. Nie będzie w stanie stworzyć odpowiednio ogólnych reguł, pamiętając jedynie rozwiązania konkretnych spraw. Stanie się wówczas bardzo podobna do klasycznego systemu regułowego z listą precyzyjnych poleceń. Z drugiej strony możliwe jest wskazanie danej sieci za małej ilości przykładów bądź powtórzenie przypadków zbyt mało razy. Wówczas sieć, choć ma zdolność generalizacji, dąży raczej do hipergeneralizacji, gdyż wobec niewielkiej liczby reguł system

¹⁰ A. Stranieri, J. Zeleznikow, M. Gawler, B. Lewis, *A hybrid rule...*, s. 164.

¹¹ A. Stranieri, J. Zeleznikow, M. Gawler, B. Lewis, *A hybrid rule...*, s. 166.

¹² A. Stranieri, J. Zeleznikow, M. Gawler, B. Lewis, *A hybrid rule...*, s. 168.

¹³ Mowa tutaj wciąż o systemach, które poprzez całkowicie samodzielną naukę wykraczają poza ludzką siatkę pojęciową, czego przykładem jest przywołany system *Omega*.

stosuje je za szeroko. System taki wykazuje się, z punktu widzenia użytkownika, swoistą losowością w wybieraniu rozwiązań. Sposobem na przezwyciężenie tego problemu jest powstrzymanie się od dalszego treningu w momencie, gdy system popełnia określoną, stosunkowo małą liczbę błędów¹⁴.

Wyjaśnienia, które program był zdolny przygotowywać, odwoływały się do struktury argumentacji stworzonej przez S. Toulmina¹⁵. System zapytany o wyjaśnienie podawał dane, gwarancje (czyli reguły, jakimi się posłużył) oraz oparcie (czyli element uzasadniający gwarancję, w tym wypadku odpowiedni przepis prawny). Podawane wyjaśnienie nie było oczywiście wskazywane jako jedyne możliwe czy też najlepsze z możliwych. Z pragmatycznego punktu widzenia było ono jednak dla eksperta posiłkującego się takim programem sensowne, wskazywało mu bowiem właściwie wszystkie potrzebne informacje.

Etap ewaluacji i sprawdzania jakości systemu polegał na wybraniu trzech spraw testowych i powierzeniu ich rozwiązania ośmiu wyspecjalizowanym prawnikom oraz systemowi *SplitUp*. W jednej ze spraw wyniki zarówno wszystkich prawników, jak i systemu były identyczne. W kolejnej wyniki różniły się zwykle o 5 punktów procentowych, w jednym wypadku o 10 punktów procentowych. Ostatnia sprawa została wybrana ze względu na nieco większą złożoność. Komplikacja stanu faktycznego w tym przypadku polegała na tym, że większość obowiązków domowych była wykonywana przez płatny personel. Prawnicy różnili się w ocenach, niektórzy bowiem przyjmowali, że nawet mimo tego wkład w prace domowe małżonka, który nie pracował zawodowo, był większy aniżeli pracującego. Jednak nawet w tym wypadku maksymalna różnica, jaka wystąpiła między systemem a jednym z prawników, wynosiła 15 punktów procentowych. Sprawa ta ujawniła nadto, jak duży wpływ na rozstrzygnięcie mają osobiste poglądy i doświadczenia prawników¹⁶.

Program *SplitUp*, jak podkreślono na początku, miał zajmować się wyłącznie majątkową stroną rozwodów. W zakres jego możliwości nie wchodziły chociażby sprawy z zakresu opieki nad dziećmi. To rozgraniczenie może być dość dobrze przeprowadzone dzięki odróżnieniu sytuacji cechujących się nieostrością oraz tych, które cechują się otwartą tekstowością. O ile bowiem w wypadku podziału majątku mamy do czynienia z pojęciami nieostrymi, których granice da się jednak wyznaczyć, w wypadku opieki nad dziećmi mamy istotnie do czynienia z otwartą tekstowością. Nie tylko nie potrafimy dokładnie zidentyfikować zakresu danych pojęć, ale na dodatek nie potrafimy przewidzieć czynników, które będą miały wpływ na ich rozumienie. Ich ocena bowiem nie może polegać wyłącznie na ocenie czynników już znanych, ale musi również brać pod uwagę czynniki jedynie przewidywane i wysoce niepewne.

4. Sztuczne sieci neuronalne a odszkodowania

Wcześniejszy program mógł być wykorzystywany do przewidywania decyzji sędziowskich. W przypadku tego modelu jest podobnie. Miał on działać w dziedzinie wyliczania odszkodowań za wypadki drogowe. Omawiany system miał mieć wartość praktyczną. Podnoszono, że w momencie gdyby ubezpieczyciele wyliczali odszkodowania według takich samych kryteriów jak sędziowie (a kryteria te byłyby *explicite* znane właśnie dzięki omawianemu programowi), wówczas wysokość odszkodowań przyznawanych przez te

¹⁴ A. Stranieri, J. Zeleznikow, M. Gawler, B. Lewis, *A hybrid rule...*, s. 170.

¹⁵ S. Toulmin, *The Uses of Argument*, Cambridge 1969.

¹⁶ S. Toulmin, *The Uses...*, s. 175.

przedsiębiorstwa i przez sędziów byłaby podobna. Pozwoliłoby to w dłuższej perspektywie na zmniejszenie ilości pozwów sądowych¹⁷, czyli byłoby efektem zdecydowanie pożądanym.

Dodatkową cechą omawianego systemu miała być jego zdolność do klasyfikacji spraw. W momencie gdy sprawy były uznawane za typowe, używany był inny mechanizm wnioskowania niż w przypadku spraw nietypowych. Jako sprawę nietypową wskazywano np. wypadek, w którym szkodę na zdrowiu poniósł alkoholik. Wówczas szkoda taka była, ze względu na mniejszą użyteczność krańcową, uznawana za mniej istotną niż gdyby dotknęła niealkoholika¹⁸. Były to sprawy, w których występowały kryteria nieujęte w ostatecznej liście kryteriów.

Postępowanie mające na celu przygotowanie danych do automatycznego przetwarzania wyglądało podobnie jak w poprzednim przypadku. Na początku wybrano główne kryteria, według których można było opisać sprawy, oraz te, które zostały przywołane w uzasadnieniach poszczególnych wyroków. Następnie kryteria te zostały połączone w pewne grupy, a wewnątrz poszczególnych grup uszczegółowione. Każdej z takich szczegółowych grup przypisano arbitralnie początkowe wagi¹⁹. W przypadku gdy użytkownik stykał się ze sprawą nietypową, był proszony o samodzielne przypisanie relatywnej wagi do danego, nowego dla systemu, kryterium.

Sprawy w powyższym systemie były reprezentowane jako ciągi wartości, nie zaś jako długie ciągi reguł „jeżeli-to”, co mogło usprawniać ich przetwarzanie. Sposób działania systemu był dwuetapowy. W pierwszym etapie sztuczna sieć neuronalna oceniała wszystkie sprawy, traktując je jako typowe. Krok drugi sprowadzał się do modyfikowania przez inaczej wytrenowaną sieć wyników uzyskanych w kroku pierwszym, jeśli sprawa była uznawana za nietypową.

Do wytrenowania sieci posłużyło 210 spraw opisanych numerycznie wskazanym wcześniej sposobem. Okazało się, że taka ilość spraw była wystarczająca, by wytrenować system do oceniania wielkości odszkodowań w sprawach typowych. Podnoszono jednak, że ilość taka mogłaby być niewystarczająca do wytrenowania sieci do zadań klasyfikacyjnych, jeśli celem miała być równie wysoka precyzja. Przewidywano, że równie dobre wyniki w drugim stawianym przed systemem zadaniu osiągnięto by przy zastosowaniu około 2000 spraw przykładowych. Skuteczność, z jaką udało się przewidywać wysokość odszkodowań w sprawach testowych, była stosunkowo wysoka. System mylił się o maksymalnie 2% w odniesieniu do 70% spraw²⁰.

5. NEUROLEX

Następny model, jaki chciałbym zaprezentować, to system, który miał służyć do rewizji decyzji administracyjnych. Twórcy tego systemu podkreślają, że zastosowanie sztucznych sieci neuronalnych w dziedzinie prawa prowadzi do zupełnej zmiany podejścia do prawa. Powoduje również odejście od specyficznego, pozytywistycznego postrzegania prawa. Tutaj prawo nie jest, ale staje się. Powstaje w wyniku emergencji z pojedynczych decyzji wraz z ich ciągłymi interakcjami z wszelkimi innymi częściami systemu. Wszystkie poprzednie koncepcje, zarówno wnioskowanie z reguł, jak i wnioskowanie oparte

¹⁷ I. Borgulya, *Two examples of decision support in the law*, „Artificial Intelligence and Law” 1999/7, s. 304.

¹⁸ I. Borgulya, *Two examples...*, s. 306.

¹⁹ I. Borgulya, *Two examples...*, s. 305.

²⁰ I. Borgulya, *Two examples...*, s. 310.

na sprawach, wymagały modelowania prawa *a priori*. Systemy podążały za stworzonymi wcześniej zasadami, nie dodając tak naprawdę niczego do prawa. Tutaj jest inaczej – prawo rozumiane jako autopojetyczny system daje programowi możliwość wytwarzania własnych heurystyk (niealgorytmicznych sposobów rozwiązywania problemów, które choć bardziej zawodne, to jednak są znacznie efektywniejsze), za pomocą których będzie rozwiązywał postawione przed nim problemy.

Celem systemu *NEUROLEX* było przede wszystkim zbadanie legalności wydania decyzji, czyli stwierdzenie, czy wydana decyzja administracyjna jest zgodna z prawem, czy nie. Dodatkowo system był w stanie dokonywać przewidywań na temat prawdopodobieństwa podważenia decyzji przez sędziego. Do wytrenowania systemu posłużyło 378 orzeczeń wydawanych przez burmistrzów w sprawach związanych z porządkiem publicznym. Każda sytuacja była opisywana przez atrybuty zgodne z jedną z czterech kategorii: stan prawny, stan faktyczny, typ zarządzenia oraz dotyczące go inne akty prawne²¹.

Główne ograniczenia, jakie stanęły przed twórcami systemu, dotyczyły tak jak poprzednio braku możliwości wyjaśniania przez system podjętych decyzji. Dodatkowo jako problematyczne wskazywano ilość spraw potrzebną do właściwego wytrenowania sieci oraz rozstrzygnięcie, które z tych spraw wybrać. Prócz tego istotna również była decyzja, według jakiego kryterium wybierać atrybuty, które będą każdą z tych spraw reprezentowały²².

O tym, że brak wyjaśniania jest problemem, pisałem już wcześniej. Chciałbym zwrócić uwagę, że tę wadę w pewnym sensie można przekuć na pozytywną stronę owego systemu. Jak już wspominałem, prawo jest tutaj rozumiane jako pewien dynamiczny, regulujący się system, w którym powstają coraz to nowe reguły postępowania. Sztuczna sieć neuronalna, choć nie jest w stanie wskazać, jakich reguł użyła do uzyskania decyzji, jest jednak w stanie te reguły wygenerować. Częstokroć będą to reguły, o których nawet nie pomyślałaby osoba podejmująca decyzję. Aplikując do sieci moduł, który wskazuje przebieg poszczególnych rozumowań, można wydobyć z analizowanych spraw nowe reguły, które później nadawałyby się do przyjęcia w szerszej akceptowanych systemach regulowych.

Potrzeba dużej ilości spraw jest tym bardziej problematyczna im szersza i bardziej skomplikowana dziedzina ma być poddawana analizie. Dokładniej rzecz ujmując, należy zaznaczyć, że ilość spraw potrzebnych do wytrenowania systemu zależna jest od tego, jak dużo czynników zostanie uwzględnionych podczas opisywania tych spraw. Jeżeli zdecydujemy się opisywać sprawy tylko kilkoma atrybutami, wówczas nie będzie konieczności znajdowania dużej ilości spraw do trenowania sieci. Jeżeli jednak ilość atrybutów przysługujących sprawie będzie duża, wówczas trzeba liczyć się z koniecznością dysponowania odpowiednio większą pulą spraw. Wyznacznikiem tej ilości jest zdolność systemu do generalizowania, którą łatwiej osiągnąć przy sprawach prostszych, trudniej zaś przy sprawach wieloaspektowych.

Sprawa dotycząca wyboru orzeczeń jest nieco bardziej skomplikowana. Trudno tutaj wskazać na jakąś niepodważalną metodę – właściwie zawsze wybór ten będzie w większym lub mniejszym stopniu arbitralny, przez co będzie narażony na pewną tendencyjność. Twórcy *NEUROLEX* opierali się na orzeczeniach sądów wyższych instancji. Taka decyzja może w pewnym sensie zwiększać trafność doboru spraw, bowiem sprawy

²¹ D. Bourcier, G. Clergue, *From a rule-based conception to dynamic patterns. Analyzing the self-organization of legal systems*, „Artificial Intelligence and Law” 1999/7, s. 216.

²² D. Bourcier, G. Clergue, *From a rule-based conception...*, s. 217.

rozpatrywane przez sądy odwoławcze są zwykle w jakimś sensie reprezentatywne dla aktualnych problemów w analizowanej dziedzinie²³.

Ostatnim, właściwie najpoważniejszym problemem jest wybór atrybutów, wedle których sprawy będą opisywane. Szczególnie może to być problematyczne, jeśli wśród nich znajdują się atrybuty dotyczące stanu faktycznego. Pojawia się wówczas pytanie, skąd brać opis owego stanu. Opis, który znajduje się w rozstrzygnięciach sądowych, jest już bowiem wielokrotnie przetworzony. Dodatkowo może nie ujmować zagadnień, które chociażby nieświadomie przez osobę rozstrzygającą zostały wzięte pod uwagę. Autorzy systemu próbowali dotrzeć bezpośrednio do akt sprawy, niestety odmówiono im do nich dostępu. Jednak nawet jeśli dysponuje się całym dostępnym materiałem, jest względnie oczywiste, że nie może on zostać przetworzony w całości. Pojawia się przez to kolejny punkt, w którym tendencyjność i arbitralność twórcy może odegrać rolę. Pojawia się również problem z ilością spraw uzależnioną od ilości atrybutów, które zostaną uznane za potrzebne. Może się bowiem okazać, jeśli wybierzemy skomplikowaną dziedzinę, że po prostu nie ma w niej wystarczająco dużo rozstrzygniętych spraw²⁴.

NEUROLEX był systemem czysto eksperymentalnym, który nie był tworzony, aby w praktyce pomagać w jakichkolwiek rozstrzygnięciach. Jego konstrukcja miała niejako uzmysłowić problemy stojące przed tą dziedziną oraz wskazać na możliwe kierunki kolejnych prac.

6. Sztuczne sieci neuronalne a rozpoznawanie analogii

Jako ostatnie zagadnienie chciałbym opisać zastosowanie modelu opartego o sztuczną sieć neuronalną do nieco innego zadania niż w powyższych przypadkach. Opisywałem bowiem programy z jednej strony koncentrujące się na wyliczaniu pewnych wartości, z drugiej zaś na sprawdzaniu ważności decyzji. Ostatni system, jaki chciałbym opisać, wykorzystywany jest do tego, w czym sztuczne sieci neuronalne są właściwie najlepsze, tzn. do – ogólnie rzecz ujmując – rozpoznawania wzorców, dokładniej zaś – do wskazywania i oceniania spraw analogicznych.

Omawiany system miał działać w zakresie identyfikacji i oceny precedensów z prawa dotyczącego szkód niematerialnych. Miał wskazywać wielkość przewidywanego odszkodowania za danego typu szkody. Z racji dość jasno określonej dziedziny problemu oraz dysponowania przez twórców stosunkowo dużą bazą spraw postanowiono wykorzystać w mechanizmie wnioskującym sztuczną sieć neuronalną²⁵.

Podejście to było w pewnym stopniu podobne do prezentowanego we wcześniejszych systemach. Porównywanie spraw analogicznych i wydawanie w oparciu o nie rozstrzygnięć było główną cechą systemu. Jednak dodatkowe zastosowanie systemu było nieco bardziej eksperymentalne: chciano zbadać, jakie reguły postępowania ze sprawami wytworzy sztuczny system oraz czy reguły te będą zgodne z typowymi regułami, którymi posłużyłby się człowiek podczas ich oceny²⁶.

Na wejściu podawano sieci atrybuty dotyczące m.in. typu szkody, wagi i czasu trwania szkody oraz jej konsekwencji czy płci. Na wyjściu podawano wysokość przyznanego

²³ D. Bourcier, G. Clergue, *From a rule-based conception...*, s. 218.

²⁴ D. Bourcier, G. Clergue, *From a rule-based conception...*, s. 218.

²⁵ J. Hollatz, *Analogy making in legal reasoning with neural networks and fuzzy logic*, „Artificial Intelligence and Law” 1999/7, s. 290.

²⁶ J. Hollatz, *Analogy making...*, s. 289.

odszkodowania. Przy użyciu sieci wykonano dwa różne eksperymenty. Miały one na celu ukazanie dwóch różnych możliwości trenowania sieci neuronalnych.

W pierwszym eksperymencie wykorzystano wszystkie sprawy z bazy i sieć, która działała niejako od zera. Nie ustalano apriorycznie przybliżonych wag poszczególnych czynników. Po przeprowadzeniu tysiąca cykli treningowych wykorzystujących wszystkie 200 spraw wyekstrahowano z systemu i sprawdzono reguły, jakimi się on posługiwał.

W drugim eksperymencie wykorzystano sieć, której architektura była dokładnie taka sama jak w pierwszym wypadku. Jednak zamiast trenować ją zupełnie od zera wprowadzono podczas eksperymentu wstępne wagi dla poszczególnych połączeń między sztucznymi neuronami. Okazało się, że dzięki takiej dodatkowej wiedzy system dużo szybciej osiągnął zdolność generalizacji i wykonywał ją z większą precyzją²⁷.

Interpretując reguły, których używał system, można było wśród nich znaleźć takie, które były całkiem oczywiste z prawniczego punktu widzenia, np. fakt, że bardziej dla systemu liczył się ciężar szkody niż ilość poszczególnych szkód czy przypisanie wysokiej wagi zmniejszeniu możliwości zarobkowych. Co istotne, okazało się również, że oceny wydawane przez system były np. niezależne od płci. Oczywiście wśród reguł, którymi posługiwał się system, znalazły się i takie, które nie były proste w interpretacji, co było jednak w dużej mierze spowodowane faktem, że w puli spraw znalazły się sprawy, które można uznać za sprzeczne²⁸.

7. Podsumowanie

Podejście, które opisywałem powyżej, nie jest oczywiście przez wszystkich akceptowane i bywało bardzo często krytykowane. Jedną z linii krytyki sprowadzała się do podkreślenia, przez odwołanie do występowania trudnych spraw, że rozumowanie prawnicze nie jest procesem prostego rozpoznawania wzorców i ich klasyfikacji, zaś twierdzenie, iż każda sprawa ma jedną prawidłową odpowiedź w zależności od tego, jakie sprawy zostały wcześniej rozstrzygnięte, jest błędne²⁹. Odpowiedź na to pytanie pozostaje poza zakresem celu tego artykułu, jednak wydaje się, iż dezawuowanie jakiegoś podejścia w całości dlatego tylko, że nie jest aplikowalne do wąskiego (choć niewątpliwie interesującego) zakresu spraw, nie wydaje się w pełni uzasadnione.

Starłem się pokrótce opisać najbardziej nowatorskie podejście do systemów ekspertowych – systemy oparte o sztuczne sieci neuronalne. Ich ogromną zaletą jest sposób działania, który w pewnym stopniu (choć na razie bardzo niewielkim) przypomina sposób działania systemu poznawczego człowieka. To podobieństwo może być wykorzystane przede wszystkim w kontekście przeprowadzania wnioskowań *per analogiam* (z naciśkiem, że wciąż będzie to *analogia legis*, nie zaś *analogia iuris*, wymagająca zupełnie innego podejścia konstrukcyjnego) i *a contrario*, które mogły sprawiać problemy tradycyjnym systemom. Oczywiście przy akceptacji twierdzenia, że klasyfikacja spraw i opieranie się na podobieństwach między nimi stanowi istotną część prawniczego rozumowania.

To jednak nie zalety, choć istotne, stanowiły trzon rozważań tej pracy. Starłem się na przykładach pokazać, jak wiele problemów może wiązać się z zastosowaniem tej metody, mimo że jest ona najbardziej elastyczną metodą spośród możliwych sposobów budowania systemów ekspertowych. Podkreślenie problemów nie powinno być jednak

²⁷ J. Hollatz, *Analogy making...*, s. 294.

²⁸ J. Hollatz, *Analogy making...*, s. 295.

²⁹ D. Hunter, *Out of their minds: Legal theory in neural networks*, „Artificial Intelligence and Law” 1999/7, s. 140.

odbierane jako podstawa do odrzucenia tej metody modelowania rozumowań prawniczych. Jest to raczej zbiór zagadnień, które choć niewątpliwie istotne dla inżynierów zajmujących się tworzeniem systemów inteligentnych, stanowią największe wyzwanie dla aplikowania tych systemów właśnie w dziedzinie prawa. Kwestie wiarygodności czy rzetelności przeprowadzanych rozumowań stanowią istotne zagadnienie dla sztucznej inteligencji samej w sobie, jednak w kontekście prawniczym, w szczególności w zestawieniu ze specyfiką niektórych rozumowań prawniczych, nabierają nieco innego sensu, który starałem się tutaj wyeksplikować.

Summary

Rafał Michalczak

Application of artificial neural networks for modeling legal reasoning. On legal reasoning specific problems

The purpose of this paper is to describe the application of artificial neural networks in modeling legal reasoning. In particular, the paper will be focused on specific problems which may occur only on the ground of legal reasoning and are difficult from the artificial intelligence perspective. The focal point of the paper is not to provide technical details of analyzed systems but to point out parts of legal conceptual framework which are inconsistent with classical techniques of designing of expert system. Paper consists description of a few legal expert systems based on artificial neural networks. Each of them is the basis for presentation of particular feature of legal reasoning which are considered difficult from the AI point of view e.g. vague concepts, open-texture, analogy.

BIBLIOGRAFIA / REFERENCES:

- Borgulya, I. (1999). Two examples of decision support in the law. *Artificial Intelligence and Law 7/2–3*, 303–321.
- Bourcier, D., Clergue, G. (1999). From a rule-based conception to dynamic patterns. Analyzing the self-organization of legal systems. *Artificial Intelligence and Law 7/2–3*, 211–225.
- Guttenplan, S. (1995). *A Companion to the Philosophy of Mind*. Oxford: Oxford University Press.
- Hollatz, J. (1999). Analogy making in legal reasoning with neural networks and fuzzy logic. *Artificial Intelligence and Law 7/2–3*, 289–301.
- Hunter, D. (1999). Out of their minds: Legal theory in neural networks. *Artificial Intelligence and Law 7/2–3*, 129–151.
- Jaśkowski, P. (2009). *Neuronauka poznawcza. Jak mózg tworzy umysł*. Warszawa: Vizja Press & It.
- Negnevitsky, M. (2005). *Artificial Intelligence. A Guide to Intelligent Systems*. Essex: Pearson Education UK.
- Stranieri, A., Zeleznikow, J., Gawler, M., Lewis, B. (1999). A hybrid rule – neural approach for the automation of legal reasoning in the discretionary domain of family law in Australia. *Artificial Intelligence and Law 7/2–3*, 153–183.
- Toulmin, S. (1969). *The Uses of Argument*. Cambridge: Cambridge University Press.