



Politechnika Poznańska
Wydział Informatyki i Telekomunikacji

Streszczenie rozprawy doktorskiej

Metody wielokryteriewego wspomagania decyzji
inspirowane innymi poddyscyplinami sztucznej
inteligencji

Krzysztof Martyn

Promotor: dr hab. inż. Miłosz Kadziński, prof. PP

Poznań, 2023

Wprowadzenie

Problemy decyzyjne uwzględniają różne punkty widzenia na jakość rozważanych wariantów. Te punkty są sformalizowane jako kryteria oceny. W rzeczywistych problemach zazwyczaj nie istnieje opcja, która posiada najlepsze oceny na wszystkich kryteriach. Prowodzi to do sytuacji, w której istnieje wiele potencjalnie najlepszych rozwiązań i od preferencji decydenta zależy, które z nich uzna za najbardziej korzystne. Decydent musi więc wzbogacić przebieg procesu decyzyjnego o informację preferencyjną, która odzwierciedla jego system wartości. Głównym zadaniem inteligentnych systemów wspomagania decyzji jest wykorzystanie takich preferencji w celu wypracowania spójnej rekomendacji dla danego problemu.

Problemy decyzyjne można podzielić na trzy główne typy: wybór, ranking (porządkowanie) oraz sortowanie (klasyfikacja porządkowa). Wybór polega na wskazaniu podzbioru najbardziej preferowanych opcji. Ranking dotyczy szeregowania wariantów od najlepszego do najgorszego. Z kolei sortowanie polega na przypisaniu wariantów do predefiniowanych klas, które są uporządkowane pod względem preferencji.

W ramach różnych poddyscyplin sztucznej inteligencji zostało zaproponowanych wiele narzędzi wspierających użytkowników w przetwarzaniu i analizie danych. W ramach wielokryterialnego wspomagania decyzji (ang. *Multi-Criteria Decision Aiding* – MCDA) zaproponowano metody i techniki, które wypracowują wiarygodną rekomendację w oparciu o dobrze ugruntowane podstawy matematyczne. Z kolei uczenie maszynowe (ang. *Machine Learning* – ML) koncentruje się na rozwijaniu algorytmów uczących się na podstawie danych. Służą one do wykrywania występujących w nich wzorców oraz predykcji dla nowych, niewidzianych na etapie uczenia danych. W szczególności modele głębokich sieci neuronowych są w stanie przetworzyć duże zbiory danych i na ich podstawie rozwiązywać złożone problemy. Wreszcie metody eksploracji Internetu pozwalają na ocenianie stron internetowych, bazując na znajdujących się na nich informacjach oraz hiperłączach.

Wielokryterialne wspomaganie decyzji oraz uczenie maszynowe pozwalają na przeanalizowanie różnych opcji i zarekomendowanie decydentowi sposobu rozwiązania problemu decyzyjnego. Główne cele i założenia tych dyscyplin, a co za tym idzie metody i ich możliwości, różnią się. Po pierwsze, MCDA w pełni skupia się na użytkowniku, jego wiedzy i preferencjach. Rozwiązanie problemu jest zależne od jego osądów, dotyczących wariantów oraz dostarczonej informacji preferencyjnej. Przez ich eksploatację podejścia wspomagania decyzji odkrywają priorytety użytkownika. Z kolei ML jest głównie nastawione na model, skupiając się na eksploracji danych poprzez ich analizę i odkrywaniu występujących w nich wzorców. Głównym celem uczenia maszynowego jest rozwiązanie problemu, optymalizującego jakąś cechę rozwiązania, np. w postaci minimalizacji funkcji straty. Te różne cele mają swoje przełożenie na charakterystykę metod, wielkości rozważanych problemów oraz udziału decydenta w rozwiązaniu problemów.

Wykorzystywane w MCDA modele preferencji są inspirowane rzeczywistymi sposobami podejmowania decyzji przez ludzi. Z tego względu metody MCDA są łatwo interpretowalne; ich rekomendacje są wyjaśnialne, a proces przetwarzania można uzasadnić. ML skupia się na nieliniowych modelach, pozwalających na odkrywanie abstrakcyjnych oraz złożonych wzorców i zależności w danych. Pozwala to na uzyskanie wysokiej skuteczności predykcyjnej, ale ogranicza możliwości w analizie wpływu danych wejściowych na ostateczną decyzję.

Ograniczenia i możliwości różnych obszarów sztucznej inteligencji były motywacją do przeprowadzenia badań w ramach tej rozprawy doktorskiej. Zaobserwowano, że wykorzystanie w metodach MCDA inspiracji z uczenia maszynowego, głębokich sieci neuronowych czy eksploracji zasobów Internetu mogą pozwolić na rozwiązywanie nowych, bardziej złożonych problemów decyzyjnych. Przeprowadzone badania odbywały się w trzech obszarach badawczych, które zostały opisane w pięciu publikacjach, z czego na dzień 31 maja 2023 roku trzy zostały zaakceptowane do druku w międzynarodowych czasopismach.

Metody wspomaganie decyzji inspirowane głębokimi sieciami neuronowymi

W ciągu ostatnich lat nastąpił znaczący wzrost ilości gromadzonych i przetwarzanych danych. Dostępne są obszerne zbiory danych, które zawierają zarówno dane historyczne dotyczące problemów decyzyjnych, jak i informacje o podjętych w przeszłości decyzjach. Kluczowym czynnikiem dla przedsiębiorstw gromadzących te dane jest możliwość przeanalizowania ich w sposób zrozumiały, tj. umożliwiający zweryfikowanie poprawności wyciągniętych wniosków. Od lat metody MCDA dostarczają narzędzi do analizy i wspomaganie procesu podejmowania decyzji. Te podejścia są łatwe w interpretacji i zapewniają wiarygodne wyjaśnienie swoich rekomendacji.

Zdobywanie informacji preferencyjnej w postaci bezpośredniego dialogu z decydentem powoduje, iż tradycyjne metody MCDA zostały zaprojektowane, aby uczyć się z niewielkich zbiorów danych. Te informacje preferencyjne odzwierciedlają rzeczywisty system wartości decydenta, który często charakteryzuje się wysoką spójnością. W takiej sytuacji zazwyczaj preferencje są dezagregowane do wartości parametrów metody za pomocą programowania matematycznego. Metody te zawodzą jednak w sytuacjach, gdy informacja preferencyjna jest bogata i silnie niespójna.

Natomiast głębokie sieci neuronowe od początku miały na celu radzenie sobie z dużymi zbiorami danych uczących, obciążonych szumem i niespójnościami. Dużą uwagę poświęcono tu kwestii optymalizacji procesu treningu oraz zmniejszenia czasu obliczeń. Do treningu wykorzystywane są zaawansowane techniki statystyczne oraz optymalizacyjne, pozwalające w efektywny sposób przeszukać przestrzeń parametrów w celu znale-

zienia najbardziej pasującego modelu. Większość obliczeń w sieciach neuronowych polega na operacjach na macierzach, przez co mogą być wykonywane równolegle na dedykowanych układach sprzętowych takich jak jednostki przetwarzania graficznego (GPU) czy tensorowego (TPU). Natomiast techniki takie jak distributed learning pozwalają na uczenie się na zbiorach danych niemieszczących się na jednej maszynie obliczeniowej.

W ostatnim okresie znacząco wzrósł wolumen kolekcjonowanych danych i decyzji, które muszą zostać przeanalizowane w sposób automatyczny i zrozumiały dla użytkownika. To spowodowało rozwój badań w obszarze uczenia preferencji, które czerpie z obu dziedzin. Pozwalają one na łatwe skalowanie wraz z rosnącą liczbą informacji, zapewniając przy tym możliwość interpretacji modelu.

W ramach niniejszej rozprawy doktorskiej zaproponowano schemat uczenia się parametrów metod na podstawie dużej ilości niespójnych danych referencyjnych. Opracowane techniki rozwiązują problem sortowania, korzystając z procedury opartej na progach rozdzielających klasy. Przedstawiono osiem metod uczenia preferencji w postaci sieci neuronowych, które bazują na wysoce interpretowalnych metodach MCDA. Obejmują one operator OWA, całkę Choquet, addytywną funkcję wartości, odległość od idealnej i anty-idealnej opcji oraz, metody bazujące na relacji przewyższania i preferencji istniejącej pomiędzy parami wariantów.

Przykładowo zaproponowane metody ANN-Ch-Pos., ANN-Ch-Constr. oraz ANN-Ch-Uncons. bazują na modelu preferencji w postaci całki Choquet. Ta pierwsza dopuszcza jedynie na pozytywne interakcje między kryteriami oraz dodatnie wagi kryteriów. W pozostałych dwóch możliwe są zarówno interakcje pozytywne, jak i negatywne. W ANN-Ch-Constr są one jednak ograniczone w taki sposób, aby suma współczynnika interakcji pomiędzy parą kryteriów oraz wagami każdego kryterium z tej pary była nieujemne. Dodatkowo wagi kryteriów również muszą być dodatnie. Natomiast w ANN-Ch-Uncons. nie ma ograniczeń na wartości wag oraz współczynników interakcji. Metody te są reprezentowane jako sieci neuronowe zawierające od jednej do dwóch warstw liniowych specjalnie dostosowanych do wyżej wymienionych wymogów metod.

Bardziej skomplikowane architektury zostały zaproponowane choćby dla metod ANN-UTADIS oraz ANN-PROMETHEE. Ta pierwsza zawiera łącznie pięć warstw, zaś ta druga – sześć. Warstwy te zostały zaprojektowane w taki sposób, aby móc odtworzyć dowolny monotoniczny kształt cząstkowych funkcji wartości lub preferencji. Zaproponowane architektury przestrzegają ograniczeń na monotoniczność kryteriów, co pozwala na uzyskiwanie interpretowalnego modelu preferencji. Ponadto, możliwe jest dostarczanie wyjaśnień decyzji oraz informacji o wpływie poszczególnych kryteriów. Opracowane metody pozwalają uniknąć definiowania hiperparametrów takich jak punkty charakterystyczne czy kształt funkcji preferencji. Zamiast tego zastosowano bardziej ogólne funkcje pozwalające na lepsze dopasowanie się do danych wejściowych, jednocześnie zachowując oryginalną ideę metod MCDA.

Aby efektywnie przetwarzać duże zbiory danych w akceptowalnym czasie, wykorzystane są algorytmy optymalizacji dedykowane dla uczenia głębokiego. Przykładowo, w celu przyspieszenia procesu trenowania i uwolnienia go od zależności od kolejności rozważanych wariantów, zastosowano algorytm Batch Gradient Descent. Następnie zastosowano technikę augmentacji danych poprzez dodawanie szumu gaussowskiego do danych treningowych w każdej epoce uczenia. Dzięki temu uzyskano poprawę odporności modelu na zakłócenia, jego zdolności do generalizacji oraz redukcję nadmiernego dopasowania do danych uczących.

Przedstawione metody prezentują w pełni wyjaśnialny model preferencji, co zostało zilustrowane na przykładzie problemu Employee Rejection / Acceptance. Opracowane modele pozwalają na określenie roli poszczególnych kryteriów oraz podzbiorów kryteriów. Ponadto dostarczają wglądu w to, jak wpływ oceny wariantów na poszczególnych kryteriach wpływa na ostateczną decyzję. Dodatkowo możemy ocenić, które różnice w ocenach są pomijalnie małe, a które są znaczące a nawet krytyczne. Następnie modele umożliwiają określenie, jak silna powinna być koalicja kryteriów, aby można było stwierdzić, że jedna opcja jest co najmniej tak dobra jak inna. W ramach tych metod stosowana jest również łatwa do zrozumienia i przejrzysta procedura sortowania oparta na progach, która umożliwi klasyfikację, porównując całościowe wyniki wariantów z progami rozdzielającymi klasy.

Sprawdzono konkurencyjność rozwiązań zaproponowanych w ramach rozprawy, przeprowadzając szereg eksperymentów. Dotyczą one dziewięciu referencyjnych zbiorów danych, które są typowo wykorzystywane w problemach uczenia preferencji. Zbiory te zawierają ponad tysiąc opcji oraz problemy wymagające porównania kilku milionów par wariantów. Przeprowadzono analizę tych zbiorów w celu oceny spójności informacji preferencyjnych. Analizy wykazały, że wszystkie badane zbiory danych zawierały niespójne preferencje, ale liczba tych niespójności znacznie się różniła między różnymi problemami. W celu dostrojenia wartości hiperparametrów dla zaproponowanych metod sprawdzono dla każdego rozważanego problemu, jaki jest optymalny ich zestaw za pomocą eksperymentów wykorzystujących technikę grid search.

Do określenia skuteczności algorytmów, użyto dwóch miar jakości klasyfikacji. Pierwszą jest standardowy błąd klasyfikacji (błąd zero-jedynkowy (0/1)) odnoszący się do liczby wariantów, które model sklasyfikował nieprawidłowo. Drugą jest pole pod wykresem krzywej ROC (ang. Area Under Curve – AUC), ujmująca, ile zmian w rankingu, powstałym na podstawie globalnych ocen, należy dokonać, aby uzyskać w pełni spójne rozwiązanie.

Dodatkowo, przetestowano trzy różne scenariusze rozwiązywania postawionego problemu dla każdego ze zbiorów danych, aby ocenić, jak dobrze różne metody radzą sobie z uogólnianiem wiedzy. Scenariusze te obejmowały niewielką liczbę danych treningowych w porównaniu do danych testowych, równą wielkość obu zbiorów danych oraz sytuację,

w której zbiór treningowy był znacząco większy od zbioru testowego.

W ramach tych eksperymentów najlepsze wyniki z zaproponowanych metod pod względem błędu 0/1 zostały osiągnięte dla modeli ANN-UTADIS oraz ANN-Ch-Uncons. Natomiast dla miary AUC dodatkowo wysoką skuteczność wykazała metoda ANN-PROMETHEE. Wysoka jakość dla miary AUC wynika z faktu, iż metody bazujące na relacjach preferencji i przewyższania poprawnie odtwarzają większość relacji między parami wariantów, natomiast gorzej sobie radzą w przypadku klasyfikacji. Biorąc pod uwagę trudność problemów, wynikającą z niespójności informacji preferencyjnej, zaobserwowano, iż wszystkie metody osiągają niższe skuteczności dla problemów bardziej niespójnych. Przy porównaniu jakości metody UTADIS zaproponowanej w tej pracy doktorskiej z metodami opartymi na programowaniu matematycznym, zastosowany w tej pracy sposób znajdowania parametrów metody wykazuje statystycznie lepszą skuteczność dla danych niereferencyjnych niż rozwiązania oparte na programowaniu matematycznym. Ponadto, porównano wariant metody UTADIS zaproponowany w tej pracy z metodami opartymi na programowaniu matematycznym. Zastosowany w tej rozprawie sposób znajdowania parametrów metody wykazuje statystycznie lepszą skuteczność dla danych niereferencyjnych niż pozostałe.

Metody wspomaganie decyzji inspirowane uczeniem maszynowym

Wspólną cechą metod uczenia maszynowego jest możliwość odtwarzania bardzo skomplikowanych przekształceń danych wejściowych w celu uzyskania jak największej skuteczności predykcyjnej. W rzeczywistych sytuacjach mogą istnieć kryteria, dla których nie ma jednoznacznego kierunku preferencji. Często zdarza się, iż istnieje zakres ocen preferowanych, a te powyżej i poniżej są mniej istotne dla użytkownika. Co więcej, wykorzystanie wysoce złożonych przekształceń do odwzorowania danych zmniejsza jego interpretowalność i może prowadzić do przeuczenia się modelu. W związku z powyższym, wiele modeli wykorzystuje techniki regularyzacji, mające na celu ograniczenie złożoności modelu.

Powyższe obserwacje były motywacją do stworzenia dwóch metod modelowania kryteriów niemonotonicznych dla potrzeb addytywnej funkcji wartości. Pierwsza z nich kontroluje złożoność modelu poprzez minimalizację zmian kierunku monotoniczności. Zaproponowano różne typy kryteriów monotonicznych takie jak zysk, koszt, kryteria monotoniczne z obszarem wypłaszczenia preferencji, a także kryteria niemonotoniczne A- i V-kształtne oraz o dowolnym przebiegu. W celu określenia kształtu cząstkowych funkcji wartości wykorzystywane są zmienne binarne, które sterują m. in. ich kierunkiem monotoniczności, normalizacją oraz złożonością. Aby znaleźć parametry modelu, należy rozwiązać dedykowany problem mieszanego całkowitoliczbowego programowania liniowego.

Drugim sposobem modelowania kryteriów niemonotonicznych jest wykorzystania zło-

zenia dwóch komponentów, niemającego i nierosnącego. W trakcie optymalizacji możliwe jest wykorzystanie tylko jednego z nich lub ich kombinacji. Pozwala to na zaprezentowanie dowolnej funkcji monotonicznej i niemonotonicznej, dostarczając przy tym wyjaśnienia jej kształtu. Do zamodelowania takiego typu kryterium nie ma potrzeby wykorzystywania zmiennych binarnych, co prowadzi do prostszego problemu programowania liniowego niż w poprzednim sposobie. Jednakże powoduje to możliwość powstawania dowolnie skomplikowanych funkcji, jeśli będzie tego wymagała złożoność rozwiązywanego problemu.

Wynikiem rozwiązania problemu programowania matematycznego jest pojedyncza reprezentatywna instancja. Taki model dostarcza jednoznacznych przypisań do klas wraz z uzasadnieniem wpływu każdej oceny na wynikową decyzję. Dodatkowo pozwala on na analizę i interpretację modelu, dostarczając informacji, jakie wartości musiałyby ulec zmianie tak, aby klasyfikacja również się zmieniła.

Przypisania uzyskane przy użyciu reprezentatywnego modelu są konfrontowane z wynikami analizy odporności. Pozwala ona sprawdzić, jak zmienia się rekomendacja dla spójnych instancji modelu, gdy złożoność modelu jest ograniczona do minimalnej możliwej wartości. Wyniki tej analizy przyjmują postać możliwych przypisań wariantów niereferencyjnych do klas. Oznaczają one zbiór klas, do których dany wariant może być przypisany przez co najmniej jedną spójną instancję modelu sortowania. Możliwość takiego przypisania sprawdza się poprzez rozwiązanie oryginalnego problemu programowania matematycznego wraz z dodatkowymi ograniczeniami, wymuszającymi minimalną możliwą złożoność oraz przydziału wariantu do konkretnej klasy przez założoną metodę sortowania. Jeśli istnieje rozwiązanie dla tak sformułowanego problemu, oznacza to, że dany wariant może być przypisany do określonej klasy.

W niniejszej rozprawie doktorskiej został przedstawiony także nowy problem sortowania z wieloma powiązаныmi ze sobą decyzjami. W tym problemie każdy wariant jest oceniany pod względem wielu atrybutów decyzyjnych, które obejmują klasy uporządkowane według preferencji. Decydent przypisuje zbiór wariantów referencyjnych do klas na każdym atrybucie decyzyjnym. Klasy te oznaczają poziom jakości lub ryzyka na wcześniej zdefiniowanej skali dla wszystkich decyzji. Problem ten jest zainspirowany problemami klasyfikacji wieloetykietowej, polegającymi na przypisaniu do obiektu podzbioru etykiet.

Zaproponowany dla tego problemu sposób rozwiązania polega na zbudowaniu zbioru powiązanych ze sobą modeli preferencji po jednym dla każdej decyzji. Wykorzystują one zbiór ograniczeń wewnątrz każdej decyzji oraz ograniczenia łączące modele dla różnych decyzji. Te pierwsze zapewniają odpowiednie relacje pomiędzy wartościami wariantów wykorzystywanych do klasyfikacji na pojedynczym atrybucie decyzyjnym. Natomiast te drugie odpowiadają relacjom między całkowitymi wartościami tego samego wariantu dla różnych decyzji.

Użyteczność zaproponowanych metod zademonstrowano na przykładzie rzeczywistego

problemu dotyczącego zarządzania ryzykiem podczas produkcji i przetwarzania nanomateriałów. Rozważanymi wariantami były różne scenariusze ekspozycji na nanomateriał, dla których należało zdecydować, w jakim stopniu jest wymagany dany środek ostrożności. Zostały wzięte pod uwagę dwa przypadki. W pierwszym z nich skoncentrowano się na problemie sortowania związanych z noszeniem maski oddechowej, gdzie cząstkowe funkcje wartości powinny być jak najmniej złożone. Model reprezentatywny wskazał, iż kryteria, które dotyczą limitów wykrywania nanomateriału, ich zdolności do przenoszenia przez powietrze oraz czas ekspozycji mają na większy udział w użyteczności globalnej wariantów natomiast kryteria mówiące o ilości nanomateriału, częstotliwość ekspozycji oraz kontroli inżynierskiej miały niewielki wpływ na wymagalność maski oddechowej.

W drugim przypadku uwzględniono również decyzje odnośnie używania wyciągu laboratoryjnego z oraz bez filtra HEPA oraz używania odkurzacza z filtrem HEPA. W tym wypadku kryteria niemonotoniczne zostały zaprezentowane jako złożenie monotonicznych składowych. Kryteria mówiące o zdolności do przenoszenia przez powietrze, limitów wykrywania nanomateriału oraz czasie ekspozycji na niego miały największy wpływ na klasyfikację. Uzyskane cząstkowe funkcje wartości były podobne dla wszystkich atrybutów decyzyjnych w szczególności dla tych, w których wykorzystywany jest filtr HEPA. Najbardziej różniły się dla decyzji dotyczących używania wyciągu laboratoryjnego z oraz bez filtra HEPA potwierdzając ich komplementarność.

Metody wspomaganie decyzji inspirowane eksploracją zasobów Internetu

Podczas podejmowania decyzji często nie ocenia się każdej z opcji niezależnie, a bierze się pod uwagę, jak dobra jest ona w zestawieniu z innymi. Zazwyczaj odbywa się to poprzez porównywanie wariantów parami i badanie relacji występujących między nimi, a następnie zagregowanie tych przesłanek do ostatecznego rozwiązania problemu. W MCDA powstało wiele metod wykorzystujących tę ideę. W tym kontekście najbardziej popularne są rodziny metod ELECTRE oraz PROMETHEE, bazujące odpowiednio na relacji przewyższania oraz preferencji.

Relacje te można podzielić na dwie grupy, wartościowaną (rozmytą) oraz binarną. Zbiór wszystkich relacji pomiędzy wariantami można przedstawić w postaci grafu skierowanego, gdzie wierzchołkami są warianty, a łuki odpowiadają relacjom. W rzeczywistych przypadkach zarówno relację przewyższania, jak i preferencji rzadko bezpośrednio wskazują jakiś wariant jako najlepszy lub pozwalają na uszeregowanie wariantów w jednoznaczny sposób, spełniający własności porządku. Z tego powodu konieczne jest wykorzystanie dodatkowych technik eksploatujących te relacje w celu uzyskania rekomendacji wariantów najbardziej preferowanych lub rankingu.

Istniejące metody eksploatacji relacji uznają wszystkie warianty za jednakowo istotne

i bycie lepszym niż relatywnie słaby wariant jest uwzględniane w takim samym stopniu jak przewyższanie wariantu dobrego czy trudnego do przewyższania. Dodatkowo, techniki te nie pozwalają na kontrolę ich wyniku poprzez zastosowanie pośrednich preferencji. W tym celu należy dokonać zmian we wcześniejszych etapach wspomagania decyzji.

Te spostrzeżenia były motywacją dla zaproponowania dwóch rodziny metod, PrefRank oraz ScoreBin, służących do analizy różnych typów relacji. Były one inspirowane zarówno metodą Net Flow Score, która uwzględnia zarówno siły i słabości wariantów oraz algorytmami analizy grafów, zaproponowanych oryginalnie w ramach eksploracji zasobów Internetu.

Metody PrefRank służą do analizy wartościowanej (rozmytej) relacji preferencji, zaś ScoreBin do przetwarzania binarnej relacji przewyższania. Poszczególne metody w ramach obu tych rodzin różnią się schematem ważenia podczas agregacji porównań parami. Pozwalają one ująć różne aspekty wariantu takie jak trudność i łatwość w przewyższaniu lub preferencji grafie. PrefRank I (ScoreBin I) jest inspirowany metodą PageRank (TrustTank) i uznaje wariant za silny, jeżeli jest on preferowany nad (przewyższa) inne silne opcje. Drugi wariant obu tych rodzin wzoruje się na algorytmie HITS i uznaje, że wariant jest dobry, jeżeli jest preferowany nad (przewyższa) wiele opcji słabych. W PrefRank III (ScoreBin III), którego inspiracją jest metoda Salsa, wariant jest silny, jeżeli jest on preferowany nad (przewyższa) takie opcje, które są gorsze od innych silnych opcji. Ostatecznie ScoreBin IV przyjmuje, że wariant jest dobry, jeżeli przewyższa warianty, które trudno jest przewyższyć.

Dodatkowo rodzina metod ScoreBin uwzględnia opcjonalną informację preferencyjną pozwalającą na podanie przez decydenta podzbioru wariantów silnych i słabych. Taka informacja przekłada się na wartość bonusu lub kary wariantu, którego dotyczy oraz wpływa również na inne warianty poprzez zależności w grafie przewyższania. Oprócz tego decydent może zdecydować o wielkości minimalnego wpływu, jaki warianty będą miały na siły i słabości innych wariantów. Wartości tych parametrów wpływają na ranking wariantów, pozwalając decydentowi na większą kontrolę nad ostatecznym wynikiem. Z tego powodu zaproponowano metodę analizy odporności, sprawdzającą możliwe pozycje wariantów w rankingu w zależności od wartości bonusów lub kar. Wykorzystuje ona symulacje Monte Carlo do określenia procentu instancji, w których wariant był na określonej pozycji w rankingu. Dodatkowo analiza ta dostarcza informacji o tym, jakie przedziały wartości parametrów powinny zostać wybrane, aby wariant znalazł się na danej pozycji w rankingu

Zaproponowane metody zostały porównane pod względem podobieństwa zwracanego przez nie wyniku z innymi metodami eksploatacji relacji takimi jak NFS, ELECTRE I oraz Qualification Distillation, która bazuje na procedurze destylacji znanej z ELECTRE III. Analiza ta została wykonana dla różnej wielkości symulowanych problemów. Wyniki pokazały, że rankingi w przypadku metod PrefRank oraz NFS są do siebie bardzo

podobne. Natomiast w przypadku metod eksploatacji relacji przewyższania najbardziej podobne do siebie były metody bazujące na podobnych koncepcjach czyli ScoreBin I z IV, ScoreBin II z III oraz NFS z Qualification Distillation. Natomiast rekomendacje uzyskiwane dla ELECTRE I znacząco różniły się od pozostałych metod.

Obie rodziny metod zostały również przetestowane w rzeczywistych problemach. PrefRank zastosowano do oceny specjalnych stref ekonomicznych w Polsce. Wszystkie warianty tej metody wskazały, że strefa Kostrzyn i Słubice jest najbardziej preferowana pod względem wzrostu finansowego i tworzenia nowych miejsc pracy. Metody ScoreBin zostały zastosowane do identyfikacji najlepiej zarządzanego parku technologicznego w Polsce, który przynosi największe zyski oraz wspiera rozwój przemysłu, oraz badań.

Podsumowanie

Niniejsza rozprawa doktorska dotyczy nowych metod wielokryteriowego wspomaganie decyzji, które są inspirowane innymi poddyscyplinami sztucznej inteligencji. Określono trzy główne obszary badawcze związane z metodami, łączącymi MCDA z uczeniem maszynowym, głębokimi sieciami neuronowymi oraz eksploracją zasobów Internetu. Efektem tych badań było powstanie pięciu oryginalnych publikacji. Prace te wykazały, iż wykorzystanie technik z różnych obszarów może pozwolić na tworzenie nowych metod radzących sobie z coraz większymi i bardziej złożonymi problemami decyzyjnymi.

Na główny wkład tej rozprawy składa się kilka elementów. Po pierwsze, zaproponowano algorytmy uczenia preferencji do znajdowania wartości parametrów wybranych metod MCDA na podstawie dużego, wysoce niespójnego zbioru przykładowych decyzji. Modele te zostały zaimplementowane w formie wysoce interpretowalnych sieci neuronowych, które rozwiązują problem sortowania. Dodatkową zaletą tego rozwiązania jest to, iż model jest w stanie lepiej dostosować cząstkowe funkcje metod do danych bez konieczności ich arbitralnego definiowania przez decydenta.

Po drugie, dla modelu preferencji w postaci addytywnej funkcji wartości, przedstawiono dwa nowe sposoby modelowania kryteriów niemonotonicznych o dowolnym kształcie. Pierwszy z nich pozwala na kontrolowanie złożoności funkcji poprzez minimalizację liczby zmian monotoniczności. Zaproponowano sposób przedstawienia różnych typów kryteriów, zarówno monotonicznych, jak i niemonotonicznych w postaci ograniczeń problemu mieszanego całkowitoliczbowego programowania matematycznego. Natomiast drugi sposób zapewnia interpretowalność funkcji niemonotonicznej poprzez jej rozkład na dwie monotoniczne składowe. Dzięki temu możliwe jest zamodelowanie dowolnego kształtu bez ograniczeń na jego złożoność.

Następnie zaproponowano sposób modelowania problemu sortowania z wieloma wzajemnie powiązаныmi atrybutami decyzyjnymi. Problem ten polega na przypisaniu wariantu do jednej z wcześniej zdefiniowanych klas dla każdego atrybutu decyzyjnego. Za-

proponowany model konstruuje osobne modele sortowania dla każdego atrybutu decyzyjnego, uwzględniając zarówno zależności wewnątrz decyzji, jak i między nimi. W rezultacie pozwala on na dobranie dla każdego wariantu najbardziej adekwatnej kombinacji decyzji.

Kolejnym elementem rozprawy były dwie nowe rodziny eksploatacji (PrefRank oraz ScoreBin) rozmytej i binarnej relacji preferencji lub przewyższania. Rozwiązują one problem rankingu oraz wyboru, wyznaczając siły i słabości wariantów. Bazują przy tym na algorytmach oceniających strony internetowe na podstawie hiperłączy. W ramach każdej z rodzin zaproponowano kilka wariantów różniących się od siebie wagami, jakie przypisują alternatywom, definiując ich wkład w mocne i słabe strony opcji, z którymi są powiązane. Dodatkowo został zaproponowany sposób uwzględnienia holistycznej informacji preferencyjnej dotyczącej tego, czy dana opcja jest uznana za silną lub słabą. Pozwala to na podwyższenie lub obniżenie jakości wybranego podzbiory wariantów, a przez ich relacje z pozostałymi wariantami także na wywarcie wpływu na osiągnięte przez nie wyniki.

W ramach rozprawy doktorskiej przeprowadzono eksperymenty mające na celu ocenę jakości zaproponowanych rozwiązań oraz porównanie ich wyników z innymi metodami powszechnie stosowanymi w rozważanych problemach. W szczególności, konkurencyjność zaproponowanych rozwiązań uczenia preferencji została przetestowana na dziewięciu zbiorach danych różniących się zarówno liczbą wariantów, jak i ich trudnością. W ramach eksperymentów wykazano, iż niektóre zaproponowane metody osiągają wyższą skuteczność predykcji pod względem miary AUC i błędu 0/1 niż zaproponowane wcześniej metody uczenia preferencji.

Następnie użyteczność metod modelowania niemonotonicznych kryteriów zostały przedstawione na przykładzie problemu analizy ryzyka podczas produkcji nanomateriałów. Rozważono ten problem w dwóch scenariuszach rozważając pojedynczą decyzję oraz wiele atrybutów decyzyjnych. W opinii specjalistów dziedzinowych zaangażowanych w te zastosowania zaproponowane metody pozwoliły na znalezienie satysfakcjonujących rozwiązań.

Wreszcie metody eksploatacji relacji preferencji i przewyższania zostały przetestowane pod względem podobieństwa wyników z innymi metodami eksploatacji. Dodatkowo przydatność tych metod została zaprezentowana na dwóch rzeczywistych problemach oceny specjalnych stref ekonomicznych oraz parków technologicznych w Polsce.

Przedstawione w tej rozprawie doktorskiej badania mogą stanowić punkt wyjścia do potencjalnych przyszłych badań. Po pierwsze, chociaż rozważane problemy były już znacznej wielkości, obejmujące tysiące wariantów lub miliony porównań parami, w wielu obszarach uczenia maszynowego rozważa się znacznie większe problemy. Warto byłoby więc przetestować zaproponowane rozwiązania dla problemów o rozmiarach typowych dla takich dziedzin zastosowań.

Po drugie, wykorzystanie głębokich sieci neuronowych daje możliwości przetestowa-

nia skuteczności wielu technik zaproponowanych w tymże obszarze. Metody takie jak transfer learning, active learning, federated learning lub blockchain mogą znaleźć zastosowanie w problemach decyzyjnych, związanych z wieloma powiązаныmi decyzjami lub decyzjami grupowymi. Możliwe jest też opracowanie metod uczenia preferencji z wykorzystaniem sieci neuronowych, bazując na innych metodach MCDA, choćby stosujących profile charakterystyczne lub graniczne do zdefiniowania klas.

Zarówno metody oparte na sieciach neuronowych, jak i zaproponowane sposoby modelowania kryteriów niemonotonicznych mogłyby być wykorzystane w problemach rankingu. W tym celu informacja preferencyjna przyjmowałaby postać porównań parami wariantów i nie byłoby konieczności stosowania sortowania opartego na progach. Rozważając modele kontrolujące stopień złożoności kryteriów niemonotonicznych, istnieje możliwość rozszerzenia ich na transformacje wielomianowe, które są istotne w rzeczywistych problemach.

Wreszcie w metodach PrefRank i ScoreBin obliczanie wartości sił i słabości odbywa się w podobny sposób. Możliwe jest jednak wykorzystywanie różnych kombinacji tych metod jednocześnie i zbadanie różnych typów agregowania takich wyników. Podobnie w przypadku metod inspirowanych sieciami neuronowymi możliwe byłoby połączenie wielu architektur w jedną i agregowanie wyników do jednej miary jakości. Ostateczne decyzje mogłyby być podejmowane na podstawie głosowania większościowego lub ważonego, gdzie wagi byłyby ustalane w trakcie procesu uczenia.