

## Język i komunikacja

### Wstęp

Język i komunikacja, uważane ogólnie za istotne dla sztucznej inteligencji (AI), moim zdaniem odnoszą się do zagadnień skupiających się wokół reprezentacji języka i znaczenia, aby umożliwić przetwarzanie języka i przekazywanie znaczeń przez komputer, co stanowi obszar badania z grubsza ujęte w obszarach przetwarzania języka naturalnego (NLP) i lingwistyki obliczeniowej (CL). Niezwykłą cechą pięćdziesięcioletniej historii tych dwóch powiązanych dziedzin jest to, jak wiele z tego, co obecnie uważamy za tematy będące przedmiotem bieżącego zainteresowania, istniało od samego początku; wszystkim, czego brakowało pionierom, były prawdziwe komputery. W latach pięćdziesiątych i sześćdziesiątych Gilbert King opowiadał się za tłumaczeniem maszynowym za pomocą metod statystycznych, co dopiero teraz stało się rzeczywistością, Margaret Masterman za siłą struktur opartych na znaczeniu w programach, a Vic Yngve, pracujący nadal w momencie pisania tego tekstu, miał zaprojektować COMIT, specjalny język programowania dla NLP, i przedstawił swoje słynne twierdzenie, że ograniczenia w sposobie, w jaki komputery przetwarzają język, powinny odzwierciedlać sposób, w jaki zbudowana jest składnia języka. Ten ostatni projekt doprowadził Yngve do bezpośredniego konfliktu z Noamem Chomskym w sprawie dopuszczalnych sposobów rysowania struktur drzewa składniowego, co, jak obecnie można uznać, stanowiło decydujący moment schizmy w historii NLP w jego związku z językoznawstwem głównego nurtu. Chomsky zawsze zaprzeczał jakiegokolwiek znaczeniu obliczeń dla zrozumienia struktury języka, a ta podstawowa schizma została uleczona dopiero kilkadziesiąt lat później, kiedy Gerald Gazdar stał się pierwszym głównym lingwistą, który wyraźnie przyjął strategię obliczeniową. Ogólna zasada wyrażania różnicy między NLP i CL jest taka, że CL zawsze twierdził, że jest programem badań naukowych wykorzystującym komputery do przetwarzania języka, podczas gdy NLP składa się z aplikacji, takich jak tłumaczenie maszynowe (MT), które zostało pierwotnym zadaniem NLP i pozostaje zadaniem głównym. Obecnie istnieje wiele innych zadań NLP, które badają badacze i do których firmy sprzedają rozwiązania programowe: odpowiadanie na pytania, wydobywanie informacji, podsumowywanie dokumentów i tak dalej. Zatem NLP rzeczywiście wymaga zadania i nie jest samo w sobie programem badań naukowych, chociaż wielu uważa, że MT pozostaje zastosowaniem, w ramach którego należy testować każdą teorię CL zawartą w programach. Ważne jest także odróżnienie zadań głównych, takich jak te właśnie wspomniane, od szerokiej gamy zadań, które są definiowane wyłącznie w kategoriach teorii językoznawczych i których wyniki mogą oceniać wyłącznie eksperci, a nie naiwni użytkownicy wyników głównych zadań powyższych zadań w tym sensie, że każda kompetentna osoba dwujęzyczna może ocenić jakość wyników programu MT. Te bardziej wewnętrzne zadania podmiotu obejmują ujednoznacznianie sensu słów, oznaczanie części mowy, analizę syntaktyczną, dopasowywanie tekstu równoległego itd. Można je traktować jako sposoby testowania indywidualnych hipotez CL, a nie tworzenia użytecznych artefaktów. Lingwiści nie są jedynymi naukowcami, którzy chcą testować teorie funkcjonowania języka: robią to także psychologowie i neurofizjolodzy. Dominujący paradygmat językowy ostatniego półwiecza, Chomsky'ego, nigdy nie akceptował poglądu, że język językowy jest sposobem na sprawdzenie teorii językowych. Spór ten dotyczy tego, co stanowi dane do nauki języka i bardzo wyraźnie oddziela NLP i CL z jednej strony od właściwej lingwistyki z drugiej, przedmiotu, dla którego dane są ściśle powiązane z intuicją mówiącego, a nie z procesy obliczeniowe stosowane do danych językowych, zwykle zwane korpusami. Od 1990 r. nacisk przesunął się na wykorzystanie korpusów rzeczywistych tekstów, a nie tych wymyślonych lub napisanych przez lingwistów. Korpusy są obecnie zwykle pobierane z Internetu i stały się kanonicznymi danymi NLP i CL.

### Wczesne systemy w NLP/CL

Cechą historii NLP/CL, której nie można przecenić, jest wpływ rozwoju sprzętu, który spowodował niezwykley wzrost pojemności pamięci i mocy obliczeniowej dostępnej do eksperymentów. Jest to oczywiste, a jego wpływ na rozwój tej dziedziny można zobaczyć, analizując przypadek pracy doktorskiej Karen Spärck Jones, która prawie na pewno była pierwszą pracą, w której zastosowano techniki grupowania statystycznego do zagadnień semantycznych i pierwszą, w której wykorzystano duży zasób korpusowy, tezaurs Rogeta. Jej statystyczne algorytmy „zlepków” wymagały obliczeń dużych macierzy, których po prostu nie dało się w pełni obliczyć na maleńkich maszynach z 1964 roku. W rezultacie znaczenie tej pracy nie zostało wówczas docenione i było regularnie odkrywane na nowo, zwykle bez znajomości oryginału od tego czasu w regularnych odstępach czasu. Pierwszą pracą, która przyciągnęła szerszą uwagę AI poza głównym nurtem NLP, była praca Winograda na MIT (Winograd 1972) oparta na jego systemie SHRDLU. Jednym z powodów zainteresowania, jakie wzbudził, był wybór domeny: świat bloków MIT wykorzystywany w robotyce i badaniach planistycznych, który składał się z blatu zawierającego klocki o różnych kształtach, które można było układać jeden na drugim, a także dźwigu i skrzynki do układania klocków w, z których wszystkie były albo rzeczywiste, albo symulowane (symulowane w przypadku Winograda). Był to mały świat, o którym można było poznać każdy fakt. Winograd zaprojektował program dialogowy, w którym dyskutowano o tym świecie i manipulowano nim, odpowiadając na niejednoznaczne prośby, takie jak POSTAW CZERWONY KLOCZEK NA ZIELONYM Klocku W PUDEŁKU. System ten miał wiele wyrafinowanych funkcji, w tym implementację gramatyki językowej zaprojektowanej przez Michaela Hallidaya specjalnie do celów komunikacyjnych (w przeciwieństwie do większości ówczesnych gramatyk językowych, które były czysto abstrakcyjne). Gramatyka ta została zaprogramowana w języku proceduralnym PROGRAMMAR, który był prefiguracją języka LISP i został zaprojektowany, podobnie jak wcześniej COMMIT, jawnie do przetwarzania ciągów symboli, takich jak zdania. Zawierał także metodę budowania reprezentacji warunków prawdziwości w języku podobnym do LISP-a, które można następnie oceniać w odniesieniu do stanu świata bloków. Warunki te wyrażały treść semantyczną wypowiedzi i jeśli zdanie zostało ocenione jako PRAWDA, wówczas wartości dowolnych reprezentacji obiektów w warunkach, gdy były uruchamiane jako program, dawały oznaczenia obiektów w zdaniu, które byłyby nazwą konkretnego bloku. Była to elegancka, proceduralna implementacja rozróżnienia Gottloba Frege’a na sens i odniesienie. Podobnie jak większość systemów w tamtym czasie, nie był on dostępny do ogólnych testów i przeprowadzono go tylko na kilku zdaniach. Zalety i wady SHRDLU można dostrzec, porównując je ze współczesnym systemem ze Stanforda: systemem dialogu PARRY Colby’ego (Parkinson, Colby i Faught 1977). System ten, również zaprogramowany w LISP-ie, został udostępniony w młodym wówczas Internecie i przetestowany przez tysiące użytkowników, którzy często nie chcieli uwierzyć, że nie pisali do człowieka. Symulował pacjenta z paranoją w szpitalu dla weteranów i miał całe zainteresowanie i umiejętności konwersacyjne, których brakowało bardziej znanej, ale trywialnej ELIZY Josepha Weizenbauma. Był bardzo silny, zdawał się pamiętać, co się do niego mówiło i źle reagował, gdy wewnętrzne parametry zwane STRACHEM i ZŁOŚCIĄ stawały się wysokie. Nie powtórzyło się i wydawało się, że pragnie wnieść swój wkład do rozmowy, gdy poruszane były tematy, w stosunku do których miał paranoję: konie, wyścigi, hazard, Amerykanie włoskiego pochodzenia i mafia. W przeciwieństwie do SHRDLU nie miał gramatyki, analizy składniowej ani logiki, a jedynie bardzo szybką tabelę zawierającą około sześciu tysięcy wzorców, które zostały dopasowane do danych wejściowych.

Kontrasty pomiędzy tymi dwoma systemami ukazują kwestie, które później stały się ważniejsze w NLP: systemy powszechnie dostępne i solidne (PARRY) kontra systemy zabawkowe (SHRDLU); analizowanie gramatyki, które było kłopotliwe i rzadko skuteczne (SHRDLU), w porównaniu z dopasowywaniem wzorców powierzchniowych (w PARRY, później nazywanym ekstrakcją informacji); systemy oparte na wiedzy światowej (SHRDLU) w porównaniu z systemami (takimi jak PARRY), które nimi nie były i które w zasadzie nic „nie wiedziały” (choć PARRY byłby znacznie lepszym wyborem na towarzysza

bezludnej wyspy niż SHRDLU). John McCarthy, w którego laboratorium powstał PARRY, powiedział, że PARRY nie jest tak naprawdę sztuczną inteligencją, „ponieważ nic nie wie, nawet kim jest Prezydent”. Dzień po tym, jak to powiedział, PARRY o tym wiedział, co pokazuje słabość każdego takiego kryterium „bycia prawdziwą sztuczną inteligencją”. Rozpoczęliśmy ten rozdział krótkim spojrzeniem na próbki ważnych i proroczych wczesnych prac, a następnie pokazaliśmy dwa kontrastujące, nieco późniejsze podejścia do wydobywania treści, oceny, reprezentacji i roli wiedzy. Rozważymy teraz szereg systemów obejmujących aspekty NLP/CL od początku lat siedemdziesiątych i podzielimy je na podstawie ich powiązań z systemami językowymi (sekcja 10.3 poniżej) oraz w odniesieniu do pojęć zwykle uznawanych za kluczowe dla sztucznej inteligencji, a mianowicie logiki, wiedzy i semantyki.

### **Systemy NLP/CL w odniesieniu do językoznawstwa**

Wyraźne powiązania pomiędzy CL/NLP a właściwą lingwistyką nie są ani tak liczne, ani tak produktywne, jak można by sobie wyobrazić. Wspominaliśmy już o wczesnej schizmie pomiędzy Yngve i Chomskym w związku z naturą reprezentacji drzewiastych i, co ważniejsze, rolę procedur i zasobów przetwarzających w obliczaniu struktury syntaktycznej. Yngve twierdził, że takie obliczenia muszą uwzględniać ograniczenia pojemności pamięci struktur pośrednich, co, jak założył, odpowiadało wrodzonym ograniczeniom przetwarzania języków przez człowieka. (Przykładem jest to, które podkreślono we współczesnym twierdzeniu George'a Millera o głębokości przetwarzania językowego człowieka, zwykle znanego jako „magiczna liczba siedem plus minusz dwa”, która wskazuje liczbę niezależnych elementów – słów lub struktur syntaktycznych kodów gramatycznych – że mózg może jednocześnie utrzymywać i manipulować pamięcią.) Z drugiej strony Chomsky przypisywał wszystkie takie rozważania zwykłemu występowi językowemu. W latach sześćdziesiątych podjęto szereg prób zaprogramowania gramatyk transformacyjnych Chomsky'ego w celu analizy zdań, a największe i najdłuższe podejmowane były próby w IBM w Nowym Jorku. Były one jednakowo nieskuteczne, ponieważ analizowały niewiele lub nic poza zdaniami, dla których zostały zaprojektowane, a nawet wtedy dawały dużą liczbę odczytań, pomiędzy którymi nie można było dokonać wyboru. Ten ostatni los spotkał praktycznie wszystkie analizatory syntaktyczne, aż do nowszych osiągnięć statystycznych opisanych poniżej. Nawet na początku niektóre gramatyki (takie jak te w IBM) były projektowane specjalnie jako podstawa programów analizujących, a nie do prostych badań językowych. Później, gdy lingwiści stali się bardziej zorientowani na obliczenia, takie badania gramatyki sterowane parserem stały się ważne: najbardziej znana była gramatyka ogólnej struktury fraz (GPSG) autorstwa Gazdara i współpracowników, która stanowiła powrót do struktury fraz z gramatyki transformacyjnej w stylu Chomsky'ego. Później pojawiła się gramatyka struktury fraz sterowanej głową (HPSG) autorstwa Ronalda Kaplana i Joan Bresnan oraz gramatyka unifikacji funkcjonalnej (FUG) autorstwa Martina Kaya. FUG, podobnie jak wcześniejsza praca Winograda, został zainspirowany gramatyką Hallidaya, a także paradygmatem logiki unifikacji w przetwarzaniu gramatyki, który pojawił się wraz z powstaniem języka programowania Prolog. Badacze ci podzielali z Chomskim i w ogóle lingwistami przekonanie, że określenie struktury syntaktycznej nie jest tylko celem samym w sobie, ponieważ jest zadaniem samowystarczającym, ale jest także konieczne do określenia struktury semantycznej. Dopiero znacznie później, wraz z rozwojem technik takich jak ekstrakcja informacji (technika, którą szczegółowo opisano poniżej), powiązanie to zostało zakwestionowane w wynikach eksperymentów na dużą skalę. Jednakże związek ten został również bardzo wcześnie zakwestionowany przez zwolenników NLP, którzy postrzegali strukturę semantyczną jako pierwotną i zasadniczo niezależną od struktury syntaktycznej, jeśli chodzi o określenie treści. Badacze ci, tacy jak Roger Schank i Yorick Wilks w latach sześćdziesiątych i siedemdziesiątych, czerpali inspirację i wsparcie z gramatyki przypadków Charlesa Fillmore'a. Fillmore argumentował, początkowo w paradygmacie Chomsky'ego, że elementy czasownika w postaci przypadków mają kluczowe znaczenie dla struktury zdania (np. Agenci, pacjenci, odbiorcy działań). Jego podejście kładło większy nacisk na semantyczną treść języka niż na jego strukturę gramatyczną,

ponieważ te elementy przypadków mogły pojawiać się pod wieloma formami gramatycznymi. Podjęto setki prób obliczeniowego rozłożenia zdań na strukturę przypadków i Fillmore pozostaje prawie na pewno lingwistą mającym najbardziej wyraźny wpływ na NLP/CL jako całość. Zagadnienia reprezentacji: logika, wiedza i semantyka. Główna wizja sztucznej inteligencji (np. McCarthy i Hayes 1969) jest taka, że pewna wersja rachunku predykatów pierwszego rzędu (FOPC), wzmocniona wszelkimi niezbędnymi mechanizmami, będzie wystarczająca do zadania reprezentowania języka i wiedzy. Stanowisko to i towarzyszący mu ruch w semantyce językowej twierdzą, że logika może i powinna zapewnić semantykę leżącą u podstaw języka naturalnego i wywarła głęboki i ciągły wpływ na CL/NLP. Chociaż w dziedzinie sztucznej inteligencji i lingwistyki kontynuowano próby zaprojektowania jakiejś formy semantyki logicznej jako klucza do reprezentacji treści zdań językowych, nie udało im się stworzyć żadnego ogólnego i użytecznego programu do tłumaczenia języka angielskiego na logikę formalną. Psychologia nie wykazała także, że takie tłumaczenie na logikę odpowiadałoby sposobowi, w jaki ludzie przechowują znaczenie i manipulują nim. W długim okresie konkursów na przetwarzanie języków prowadzonych przez amerykańską Agencję Zaawansowanych Projektów Badawczych w dziedzinie Obronności (DARPA) tłumaczenie języka angielskiego na struktury FOPC pozostaje celem, ale nikt nie określił jeszcze realistycznych standardów jego osiągnięcia. Bez wątplenia pojawią się zastosowania NLP wymagające wyciągnięcia logicznych wniosków pomiędzy reprezentacjami zdań, ale jeśli stanowią one jedynie część aplikacji (np. spójność czasów w systemie rezerwacji linii lotniczych), nie jest oczywiste, że mają one cokolwiek do powiązania. ma to wspólnego z podstawową strukturą znaczeń języka naturalnego, a zatem z właściwym CL/NLP, ponieważ pierwotną funkcją struktury logicznej było uczestnictwo w wnioskowaniach. Na tym etapie dyskusji można obrać wiele możliwych dróg: Można powiedzieć, (1) że wnioski logiczne są ściśle powiązane ze znaczeniami zdań, ponieważ znajomość ich znaczeń oznacza umiejętność wyciągania wniosków, a logika jest na to najlepszym sposobem. Jasne zestawienie takiego poglądu na rolę logiki w sztucznej inteligencji podaje Thomason (2003). Można także powiedzieć (2), że poza logiką może istnieć reprezentacja znaczenia, co można znaleźć w językoznawstwie, począwszy od teorii znaczników semantycznych Jerry'ego Fodora i Jerrolda Katza, opracowanych w ramach paradygmatu transformacyjnego Chomsky'ego, a także zupełnie niezależnie w NLP, jak formy semantyki obliczeniowej. Teorie te postulują szereg znaczników semantycznych lub prymitywów, takich jak ANIMACJA, lub prymitywnych działań, takich jak MOVE, które można dołączyć do słów, aby wyrazić ich znaczenie; proces, który obecnie nazywamy zwykle „adnotacją”. Istnieje również bardziej skrajne stanowisko (3), zgodnie z którym predykaty logiki i w ogóle systemów formalnych jedynie wydają się różnić od języka ludzkiego (często akcentowane przez pisanie ich wielkimi literami, jak w (2) powyżej), ale to jest iluzją, a ich terminy są w rzeczywistości słowami językowymi, którymi wydają się być, równie podatnymi na dwuznaczność i niejasność jak inne słowa. Obie strony tej tezy argumentują Nirenburg i Wilks (2001). W punkcie (2) powyżej można wskazać na tradycję AI NLP lat siedemdziesiątych i osiemdziesiątych pojęciowego/semantycznego kodowania znaczenia (wspomnianego już w ostatniej sekcji) za pomocą języka elementów prymitywnych i rysowania (nielogicznych) wniosków z opartych na nich struktur. Najbardziej znanymi z takich systemów z lat 70. XX w. były system zależności pojęciowych Schanka oraz system semantyki preferencji Wilksa; oba zostały zaimplementowane w systemach MT, a także w szeregu innych aplikacji NLP. W systemach MT kody zawierające struktury tych prymitywnych elementów były używane jako interlingua, czyli język pośredniego znaczenia, pomiędzy tłumaczonymi językami. System Schanka opierał się na zestawie czternastu czasowników pierwotnych, a system Wilksa na zestawie około osiemdziesięciu czasowników pierwotnych różnego typu. Schank stanowczo twierdził, że jego prymitywy nie są angielskimi słowami, pomimo podobieństwa w wyglądzie (np. z angielskim słowem INGEST), podczas gdy Wilks argumentował, że może istnieć wiele zestawów prymitywów i że są one jedynie słowami uprzywilejowanymi, jak w słowniku definicje (patrz sekcja 10.5 poniżej). Pojęcie „preferencji” Wilksa zostało dobrze ugruntowane: pogląd, że czasowniki i

przymiotniki mają preferowane środki, dopełnienia itd. oraz że znajomość tych domyślnych preferencji jest główną metodą rozwiązywania niejednoznaczności i wykrywania metafor. Takie preferencje zostały później obliczone statystycznie, gdy NLP stało się szersze i bardziej empiryczne.

Schank opracował później struktury na większą skalę zwane skryptami, które stały się bardzo wpływowe jako sposób na uchwycenie ogólnego znaczenia tekstów i dialogów. Istnieją analogie między tym nurtem prac NLP a współczesnymi pracami w dziedzinie językoznawstwa, zwłaszcza Fillmore'a i George'a Lakoffa, ale w tamtym czasie bezpośredni kontakt między badaczami NLP i właściwym językoznawstwem był niewielki lub żaden. Jedną z najbardziej uderzających zmian, jakie zaszły w ciągu ostatnich dwudziestu lat, jest uświadomienie sobie przez lingwistów, przynajmniej od czasu prac Gazdara, że metody obliczeniowe mogą być dla nich najważniejsze. Ale niewątpliwie istniały wpływy ponad tym podziałem: na przykład Ray Jackendoff w 1990 roku zaproponował ustrukturyzowane sekwencje prymitywów, takie jak CAUSE GO LIQUID TO IN MOUTHOF, które reprezentują „napój”, które były praktycznie identyczne z wcześniejszymi strukturami NLP Wilksa wspomnianymi powyżej. Ponownie, ten poziom reprezentacji semantycznej pomiędzy logiką pierwszego rzędu a językiem nie tylko zakorzenił się w językoznawstwie, ale także później powrócił do sztucznej inteligencji osobliwą drogą, którą omówimy później w związku z siecią semantyczną, gdzie płytki, ale możliwy do przetworzenia nielogiczny reprezentacja zwana RDF (Resource Opis Framework) stała się podstawowym poziomem wiedzy opis w ramach nowej tradycji sztucznej inteligencji. Trzy inne tradycje reprezentacji w sztucznej inteligencji również mają bezpośredni związek z kwestiami językowymi: akty mowy, semantyka proceduralna i koneksjonizm. Akty mowy to pojęcie zaczerpnięte z prac filozoficznych Johna Searle'a, które stało się centralnym pojęciem pragmatyki obliczeniowej. Pojęcie to mogłoby umożliwić systemowi odróżnienie prośby o informacje od pozornego pytania, które w rzeczywistości jest poleceniem, np. „Czy możesz zamknąć drzwi?” Ta wypowiedź wydaje się być pytaniem, ale Searle argumentował, że należy ją przedstawić jako prośbę o podjęcie działań i zamknięcie drzwi. Ray Perrault i jego koledzy z Toronto pod koniec lat siedemdziesiątych byli pierwszą grupą, która obliczyła przekonania reprezentowane w FOPC, aby przypisać akty mowy do wypowiedzi w systemie dialogu. System Toronto został zaprojektowany jako system doradztwa kolejowego dla pasażerów i wykorzystywał ograniczone rozumowanie logiczne do ustalenia na przykład, że system wiedział, kiedy dany pociąg przyjechał i pasażer wiedział, że tak, więc pytanie „Czy wiesz kiedy przyjedzie następny pociąg z Montrealu?” nie polegałaby, jak mogłoby się wydawać, na wiedzy samego systemu o sobie, ale raczej na prośbie o ujawnienie tej wiedzy. Tłumacząc pomysły Searle'a na programy, grupa ta znalazła błędy w ich sformułowaniu, a ich opis aktów mowy jest pod pewnymi względami bardziej spójny niż oryginał. Reprezentacja aktów mowy i jej zastosowanie w systemach dialogu człowiek-komputer pozostają ważne, ponieważ zasadniczo dotyczą komunikacji, w sposób, w jaki ma to miejsce w niewielu obszarach NLP/CL. Semantyka proceduralna była początkowo nurtem teorii sztucznej inteligencji. Twierdzenie, w różnych formach, jest takie, że znaczenia symboli w obliczeniach wyrażających inteligentne funkcje same w sobie są procedurami, a nie bytami referencyjnymi deklarowanymi w konwencjonalnej semantyce formalnej. Wersje takiej teorii proceduralnej zaproponowali Terry Winograd, Bill Woods, Philip Johnson-Laird i Yorick Wilks. Na przykład w SHRDLU Winograda pojęcia takie jak poruszanie ramieniem dźwigu nie były wyrażane przez żadne prymitywne działania (jak MOVE), ale poprzez rzeczywiste procedury lub kod poruszania ramieniem. Pojęcie „znaczeń jako procedur” zostało zaatakowane przez Fodora na tej podstawie, że wszystkie takie teorie są w rzeczywistości zakorzenione w kodzie maszynowym najniższego poziomu rzeczywistych silników obliczeniowych, które rzeczywiście zapewniają przedmiotowe byty referencyjne, za pomocą swoich formalnych semantyka programu. Niektórzy zwolennicy tej teorii stanowczo temu zaprzeczali, odwołując się do zasady Scotta-Stracheya, że semantyka różnych „poziomów programu” jest niezależna, a zatem semantyka jednego nie może być semantyką drugiego:

to znaczy semantyka tłumaczeń kodu maszynowego jest nieistotna dla semantyki kodowanej przez niego akcji wyższego poziomu. Należy tu także wspomnieć o koneksjonizmie: skupisku teorii sztucznej inteligencji opierających się na koncepcji bardzo prostych jednostek obliczeniowych, połączonych w bardzo dużej liczbie i „uczeniu się z doświadczenia” poprzez przesuwanie zagregowanych wag w sieci. Rozwój ten może otworzyć drogę naprzód w wielu obszarach sztucznej inteligencji, w tym w semantyce obliczeniowej języka naturalnego. Koneksjonizm podziela wiele cech semantyki proceduralnej, które odróżniają oba od poglądów logicznych. Funkcje te obejmują integrację semantyki i składni; ciągłość między językowymi i innymi formami wiedzy światowej (i znowu nie w sensie prostego asymilacji tej pierwszej z drugą, jak to czynią niektóre podejścia logiczne i „systemy eksperckie”); oraz rodzaj wnioskowania, którego nie da się pogodzić z rodzajem wnioskowania oferowanym przez podejścia oparte na logice. Co więcej, koneksjonizm kładł nacisk na takie pojęcia, jak konkurencja między strukturami reprezentacji, tak że silniejsza, bardziej połączona struktura „wygrywa”, co można wyraźnie znaleźć w systemach semantyki obliczeniowej, takich jak Semantyka preferencji. Istotna różnica, zwłaszcza jeśli chodzi o rozwiązywanie niejednoznaczności leksykalnych, pojawia się tutaj pomiędzy tzw. podejściami subsymbolicznymi w ramach koneksjonizmu (bronionymi przez Paula Smoleńskiego) a tymi, które zwykle nazywa się lokalistycznymi (bronionymi przez Davida Waltza i Jordana Pollacka). Różnica ta ma duży wpływ na kwestię reprezentacji: w subsymbolicznym podejściu do semantyki obliczeniowej niekoniecznie można oczekiwać rozróżnienia reprezentacji dla poszczególnych sensów słów; byłyby to po prostu różne wzorce aktywacji w ramach zestawu jednostek reprezentujących cechy podsymboliczne, gdzie podobne zmysły prowadziłyby do podobnych wzorców. Z drugiej strony, lokalne podejście do semantyki obliczeniowej zakłada na początku rzeczywiste, rozróżnialne znaczenia słów w ich symbolicznych reprezentacjach, a następnie podaje kryteria ważenia służące do wyboru między nimi. W chwili pisania tego tekstu główny nurt sztucznej inteligencji nadal był mocno przywiązany do koncepcji manipulacji symbolami i wyraźnych reprezentacji jako podstawy ich rzemiosła.

### **Korpusy, zasoby i słowniki**

W latach sześćdziesiątych Margaret Masterman i Karen Spärck Jones korzystały z tezaursu Rogeta, dziurkowanego na kartach IBM, jako narzędzia do ujednoznaczniania sensu słów i prymitywnego wyprowadzania semantycznego, mimo że nie mogły wykonywać poważnych obliczeń na dostępnych wówczas komputerach. Od tego czasu obliczenia językowe na dużą skalę można było znaleźć tylko w tłumaczeniu maszynowym; w dobie wpływu metod AI na CL/NLP Boguraev stwierdził, że słowniki systemów roboczych wynoszą średnio około trzydziestu pięciu, co dało początek określeniu „systemy zabawkowe” w odniesieniu do większości opisanych wcześniej systemów. Istniały jednak ruchy mające na celu wykorzystanie znacznych korpusów tekstów do eksperymentów, chociaż wywodziły się one głównie z nauk humanistycznych i leżały w interesie studiów stylistycznych oraz statystycznych miar użycia i dystrybucji słów. Najbardziej znanym z nich był korpus języka angielskiego Brown-Oslo-Bergen, ale Brytyjski Korpus Narodowy został skonstruowany wyraźnie z myślą o potrzebach NLP, a zespół Uniwersytetu w Lancaster pod kierownictwem Geoffreya Leecha odegrał kluczową rolę w jego tworzeniu. Grupa ta stworzyła już pierwszy skuteczny element statystycznego NLP opartego na korpusach, znacznik części mowy CLAWS4, który automatycznie przypisywał kody części mowy, takie jak ADJ (od przymiotnika), do wszystkich słów w korpusie. Jednocześnie, na początku lat osiemdziesiątych, wzrosło zainteresowanie wartością dla NLP nie tylko korpusów tekstowych w ogóle, ale w szczególności słowników, zarówno jednojęzycznych, jak i dwujęzycznych. Bran Boguraev z Cambridge był jednym z pierwszych badaczy (od bardzo wczesnych prac nad Trzecim słownikiem Webstera w Systems Development Corporation w latach sześćdziesiątych), którzy starali się wykorzystać słownik w jego zakodowanej formie stosowanej przez jego wydawców, w tym przypadku Longman Dictionary of Contemporary English (LDOCE), słownika zaprojektowanego specjalnie dla

obcokrajowców uczących się tego języka. Miało to definicje o ograniczonej składni zaczerpnięte ze słownictwa składającego się z zaledwie 2000 słów. W latach osiemdziesiątych wiele uwagi poświęcono wydobywaniu na dużą skalę znaczeń obliczeniowych ze słowników nadających się do odczytu maszynowego. Wydawało się to rozsądnym sposobem przezwyciężenia problemu „systemu zabawek”, a biorąc pod uwagę, że słowniki kodują znaczenia, dlaczego nie wykorzystać ich jako środka bezpośredniego dostępu do reprezentacji semantycznych? Istotne i przydatne semantyczne bazy danych zostały zbudowane automatycznie na podstawie DOCE i szeregu innych słowników, zwykle także ze słowników dla osób uczących się języka angielskiego, ponieważ wyrażały się one w sposób bardziej jednoznaczny niż tradycyjne słowniki dla naukowców i osób szeroko wykształconych. Hierarchiczne ontologie pojęć zostały skonstruowane automatycznie, a te bazy danych definicji pozostają, wraz z tezaurusami, bazą danych komponentów dla wielu głównych systemów rozwiązywania niejednoznaczności sensu słów. Ontologię można szeroko rozumieć jako drzewiastą strukturę pojęć, która zawiera w drzewie pojęcia lub jednostki znajdujące się pod nimi, w taki sam sposób, w jaki klasa lub pojęcie „ptaki” zawiera „kanarki”, ponieważ wszystkie kanarki są ptakami. Jednak takie słowniki nie były panaceum na problem znaczenia i stało się jasne, że same słowniki wymagają znacznej wiedzy ukrytej, aby mogły być przydatne do obliczeń. Innym dość niezależnym źródłem opatrzonych adnotacjami zasobów korpusu były banki drzew, z których najbardziej znany jest Penn Tree Bank. Jest to korpus syntaktycznie ustrukturyzowany ręcznie, przy czym struktura syntaktyczna jest dodawana do tekstu w postaci adnotacji, wskazujących strukturę, a nie tylko kategorie. Jednym ze skutków szerokiego wykorzystania Penn Tree Bank do eksperymentów było uznanie używanych w tym celu tekstów, w poszczególnych sekcjach „Wall Street Journal”, jako „ubercorpora”, używanych tak często i tak często, że niektórzy uważali, że ich szczególne cechy zniekształciły badania NLP. W niedawnej przeszłości wiele energii i dyskusji włożono w wybór i „równoważenie” korpusów – tyle dialogów, tak wiele powieści i memorandumów itp. – ale ta działalność staje się nieistotna ze względu na rosnące wykorzystanie bardzo dużych części świata Sama Wide Web jako korpus, który można opatrzyć adnotacjami.

### **Metody statystyczne i ilościowe w NLP**

Wprowadzenie na dużą skalę metod statystycznych do CL/NLP jest najnowszym trendem w dziedzinie, którą w skrócie najtrudniej opisać, ponieważ w chwili pisania tego tekstu wciąż jesteśmy w tym ruchu (patrz przegląd głównych metod stosowanych w Manning i Schütze 1999). Ogólnie rzecz biorąc, metody statystyczne implikują stosowanie wyłącznie numerycznych, ilościowych metod NLP/CL, a nie metod opartych na reprezentacjach, niezależnie od tego, czy są one przypisywane przez ludzi, czy przez komputery. Ogólna stosowana strategia polega na nauczaniu się przetwarzania języka, miejmy nadzieję, w sposób, w jaki robią to ludzie, chociaż nie jest to konieczne. Na przykład w przypadku MT oznacza to naukę tłumaczenia poprzez przetwarzanie bardzo dużych korpusów rzeczywistych tłumaczeń wykonanych przez ludzi. Często przyjmuje się, że oznacza to naukę przypisywania adnotacji, oznaczanie korpusów (tego rodzaju, które właśnie omówiliśmy) za pomocą kategorii części mowy lub znaczników/elementów semantycznych i robienie tego na podstawie dużych korpusów już częściowo zaznaczonych przez ludzi. W latach sześćdziesiątych Gilbert King przewidział, że MT można przeprowadzić metodami statystycznymi, opierając się na dobrze znanej 50-procentowej redundancji znaków i słów w językach zachodnich, chociaż nie jest łatwo zrozumieć, dlaczego to drugie implikowało pierwsze. Później, jak widzieliśmy wcześniej, Spärck Jones był pionierem metod wyszukiwania informacji (IR) służących do tworzenia klasyfikacji semantycznych, które ostatecznie miały być stosowane w MT. Zauważyliśmy wcześniej, że pierwszym wyraźnym przykładem współczesnego statystycznego NLP była praca Leecha i jego współpracowników nad tagerem części mowy CLAWS4 pod koniec lat siedemdziesiątych. W tamtym czasie niewielu dostrzeżało zainteresowanie przypisywaniem kategorii części mowy do słów tekstowych. Jednak obecnie prawie wszystkie prace

związane z przetwarzaniem tekstu rozpoczynają się od fazy przypisywania części mowy, ponieważ obecnie uważa się, że (nawet przy około 98% dokładności, osiąganey zwykle na poziomie) upraszcza to wszystkie późniejsze procesy językowe. Czyni to poprzez odfiltrowanie szerokiego zakresu możliwości, które zwykle obciążały analizatory syntaktyczne. Niewątpliwy sukces takich metod pokazał, że decyzje analityczne, które wcześniej uważano za wymagające informacji syntaktycznych lub semantycznych „wysokiego poziomu”, można podejmować wyłącznie przy użyciu informacji statystycznych niższego poziomu na temat sekwencji słów. Jednak największy impuls dla statystycznego NLP nadała praca nad programem badawczym MT Fredericka Jelineka i jego grupy w IBM, którzy zastosowali metody uczenia maszynowego, które odniosły sukces w automatycznym rozpoznawaniu mowy (ASR) w języku MT, co uznano za problem czysto symboliczny i językowy. Jelinek zaczął zadawać pytanie, jakie zjawisko ma być modelowane – odpowiedź, tłumaczenie – a następnie szukać przykładów tej ludzkiej umiejętności, do której można zastosować uczenie maszynowe. Najbardziej oczywistym źródłem opisującym tę umiejętność były korpusy równoległe: teksty wyrażające to samo znaczenie w więcej niż jednym języku. Były one powszechnie dostępne, a on wziął miliony słów z tekstów kanadyjskiego Hansarda w języku angielskim i francuskim. Opisałiśmy już jedną formę, jaką może przyjąć uczenie maszynowe (ML) w NLP: W pracy CLAWS4 zjawisko (znakowanie części mowy) zostało dodane do tekstu przez ludzi adnotacjami, a następnie algorytmy ML zostały ustawione tak, aby uczyły się możliwych powiązań tagów ze słowami, a następnie byli w stanie oznaczyć nowe, niewidoczne teksty z akceptowalnym poziomem dokładności. Nazywa się to nadzorowanym uczeniem się, co oznacza, że dany jest cel uczenia się. Z kolei w pracy Jelineka MT, mimo że podano cele, których należy się nauczyć, czyli tłumaczenia tekstów równoległych, materiał szkoleniowy nie został stworzony specjalnie do tego zadania przez ludzi przypisujących kody. Dane docelowe to po prostu naturalnie występujące teksty, aczkolwiek stworzone przez ludzi. Wielu nazwałoby to słabo nadzorowanym ML. Jednakże w przypadku ML bez nadzoru nie są podawane żadne cele. We wspomnianej wcześniej pracy Spärcka Jonesa dane tezaurusowe są grupowane w istotne semantycznie grupy, które nie są w ogóle podawane z góry.

System CANDIDE Jelineka polegał najpierw na uczeniu się dopasowywania zdań w tekście francuskim i angielskim tak, aby odpowiadały ich znaczeniu. Następnie nauczył się powiązań między treścią odpowiednich/dopasowanych par zdań w języku francuskim i angielskim – tak że, powiedzmy, angielskie słowo Ex regularnie pojawiało się obok francuskich słów Fy lub Fz w różnych dopasowanych zdaniach. W międzyczasie nauczył się prawdopodobnych sekwencji słów w języku wyjściowym, powiedzmy francuskim, i dzięki nim był w stanie wykazać, że w przypadku zdań połączonych z Ex i pewnym zestawem sąsiednich słów F...F, wówczas Fy było bardziej prawdopodobnym wynikiem dla Np. w przypadku innych sekwencji sąsiadów F...F prawdopodobnym wyjściem będzie Fz. Dzięki takim metodom – w dużej mierze wywodzącym się z wcześniejszych prac tego zespołu nad transkrypcją mowy na język angielski – CANDIDE był w stanie rozróżnić możliwe ciągi słów wyjściowych w języku docelowym. CANDIDE osiągnął poziom dokładności około 50 procent poprawnie przetłumaczonych zdań, co jest niezwykle faktem, biorąc pod uwagę, że system nie posiadał żadnej wiedzy bezpośrednio językowej, takiej jak słowniki czy gramatyka. W zastosowaniu do nowych, niewidzianych wcześniej tekstów nie udało mu się jednak pokonać tradycyjnego, ręcznie kodowanego systemu MT SYSTRAN, który nie był przeszkolony do obsługi określonych rodzajów tekstu. System był jedynie punktem odniesienia, ale 50-procentowy limit sugerował, że w przypadku zadań językowych takich jak MT istnieją pewne ograniczenia w zakresie metod czysto statystycznych. Sam Jelinek rozpoczął program wyprowadzania struktur językowych (leksykonów, gramatyk itp.) tymi samymi statystycznymi metodami ML, próbując podnieść poziom sukcesu CANDIDE. Czyniąc to, zapoczątkował ruch w całym NLP, mający na celu naukę tych metod tradycyjnych struktur NLP/CL na każdym poziomie językowym. Obecnie jest zbyt wiele takich zastosowań, aby je tu przytaczać, a wprowadzenie uczenia



maszynowego do każdej części NLP ponownie przybliżyło przetwarzanie języka do centrum sztucznej inteligencji, ponieważ uczenie maszynowe jest podstawową metodologią sztucznej inteligencji. Metody ML zostały zastosowane do wyrównywania tekstów, analizy syntaktycznej, znakowania semantycznego, ujednoznaczniania sensu słów, przypisywania aktów mowy, a nawet zarządzania dialogiem. W przypadku niektórych z tych tradycyjnych zadań charakter zadania zmienił się wraz z systemami oceny i punktacji, które pojawiły się wraz ze zmianą paradygmatu. Na przykład zaledwie kilka lat temu panowało powszechne twierdzenie, że parsery składniowe zawiodły, przynajmniej w przypadku języków takich jak angielski, i że po prostu nie ma parsera, na którym można by polegać, jeśli chodzi o utworzenie poprawnej analizy niewidzianego jeszcze zdania w języku angielskim. Jednakże teraz, gdy parsery oparte na statystyce mogą uczyć się z banków drzew, takich jak wspomniany wcześniej Penn Tree Bank, i są oceniane na podstawie liczby nawiasów, które mogą poprawnie wstawić, oraz odpowiednich adnotacji struktury frazy, które mogą przypisać, problem ma jedynie charakter ilościowy i nie jest już uważane za istotne, aby utworzyć „pełną analizę”. Istnieje ogólne przekonanie, że lingwistyka statystyczna, czyli oparta na korpusie (tj. empiryczna), zaowocowała przejściem do ponownego podkreślenia powierzchownych rozważań w języku. Na przykład wspomniane właśnie płytsze wyniki analizy syntaktycznej sprawiły, że analiza syntaktyczna stała się bardziej użyteczna w przetwarzaniu językowym, ponieważ jest bardziej skuteczna i niezawodna. Można także wskazać na sukces odrębnej ekstrakcji informacji o zadaniach NLP (IE), która w szerokim ujęciu polega na wydobywaniu z tekstów struktur faktopodobnych na dużej skali do celów praktycznych, przeglądając strukturę powierzchni tekstu w poszukiwaniu wzorców, zamiast analizować jego strukturę syntaktyczną. Na przykład system IE może wyszukiwać w gazetach publicznych wszystkie fakty na temat osób w IBM, które awansowały w 2010 roku, i robić to na podstawie określonych wzorców zakodowanych dla takiego zadania lub uczyć się maszynowo na przykładach. IE stał się uznaną technologią w dużej mierze bez użycia analizy syntaktycznej i dostępu do struktur wiedzy, chociaż odegrały one rolę w niektórych udanych systemach. IE działa obecnie na poziomie ponad 95% sukcesu, który jest normą akceptowalności w językoznawstwie empirycznym. Jednakże wiele niedawnych sukcesów tego głównego nowoczesnego podejścia, ponownie opartego na uczeniu maszynowym zamiast korpusów, dotyczyło obszarów zwykle uważanych za semantyczne lub z natury „mniej powierzchowne”, takich jak ujednoznacznianie sensu słów i adnotacja wypowiedzi dialogowych z ich znaczeniem dialogu lub aktów mowy, wskazując ich funkcję w całości dialogu. W końcowej części rozdziału chciałbym rozważyć dwie alternatywne tradycje zarówno w stosunku do tradycyjnego rdzenia sztucznej inteligencji GOFAI (dobrej, staromodnej sztucznej inteligencji), jak i okresu statystycznej reakcji przeciwko niej, okresu, w którym nadal znajdujemy się w fazie dominacji. Jednym z nich jest alternatywne, statystyczne, powierzchniowe podejście do empirycznego NLP po Jelinku: tradycja IR, która jest tak stara jak sama sztuczna inteligencja. Drugim jest nowszy ruch Semantic Web, który moim zdaniem ma korzenie w NLP i IE (choć kwestionuje to jego założyciel Tim Berners-Lee).

### **Sztuczna inteligencja i wyszukiwanie informacji**

Jak zauważyliśmy na początku rozdziału, klasyczny, McCarthyński okres sztucznej inteligencji opierał się na logice lub symbolach, ale oczywiście nie był całkowicie pozbawiony liczb, ponieważ teorie widzenia AI rozkwitły w bliskim sąsiedztwie badań nad rozpoznawaniem wzorców. Chociaż symboliczne i reprezentacyjne teorie widzenia komputerowego czasami zyskiwały na znaczeniu, jak w pracach Davida Marra, niemniej jednak w gruncie rzeczy zawsze była to subdyscyplina inżynierii ilościowej. Jednak w obliczu jakiegokolwiek próby wprowadzenia metod ilościowych do klasycznej sztucznej inteligencji w latach siedemdziesiątych John McCarthy zawsze odpowiadał: „Ale skąd pochodzą te wszystkie liczby?” Od czasu opisanego właśnie powrotu metod ilościowych do NLP/CL wiemy teraz lepiej, skąd biorą się liczby; nigdzie jednak liczby nie były bardziej widoczne niż w całym odrębnej dziedzinie, jaką jest IR. IR ma podobną starożytność co sztuczna inteligencja, ale do tej pory

rzadko były one ze sobą powiązane intelektualnie, chociaż w przypadku jakiegokolwiek szerokiej definicji sztucznej inteligencji jako „modelowania inteligentnych zdolności ludzkich” można sobie wyobrazić, że IR, podobnie jak MT, byłaby objęta tym pojęciem. Jednak ani IR, ani MT nie były tradycyjnie postrzegane jako część sztucznej inteligencji. IR to zasadniczo metodologia wyszukiwania dokumentów statystycznych, polegająca na grupowaniu dokumentów na podstawie ich zawartości słownej w zestawy dokumentów powiązanych ze sobą, tak że każdy, kto chce jednego dokumentu, może chcieć zobaczyć inne w tym samym skupieniu. Z tego powodu opisaliśmy wczesne prace Spärcka Jonesa nad grupowaniem terminów z tezasurów językowych jako inspirowane technologią IR. W pewnym sensie wszystkie takie zadania klastrowania bez nadzoru są formami klasyfikacji. IR pobiera zatem dokumenty z utworzonych przez siebie grup dokumentów, podczas gdy IE wyszukuje elementy wiedzy przypominające fakty z tekstów lub według rozszerzenia, odpowiada na pytania z tekstu. IR może jedynie przekazać Ci dokumenty; jednakże rozróżnienie zaciera się, biorąc pod uwagę, że pojedyncze zdanie można uznać za mały dokument. W końcu podczerwień może nie być istniejącą wcześniej inteligentną funkcją człowieka, obecnie modelowaną przez komputery, tak jak MT, ponieważ we wcześniejszych czasach przedmechanicznych ludzie w praktyce nie byli w stanie przeprowadzać tego rodzaju poszukiwań i porównań na dużą skalę na którym spoczywa IR. I chociaż IR często pokrywa się z bibliotekoznawstwem, które wyrosło z indeksowania kart w bibliotekach, być może nie ma prawdziwej ciągłości między tymi dziedzinami, ponieważ współczesne IR obejmują operacje indeksowania i wyszukiwania, których ludzie nie byłiby w stanie przeprowadzić w normalnym życiu. Czy jakikolwiek czytelnik powinien zacząć się zastanawiać, dlaczego poruszyłem tę kwestię relacji AI do IR, dzieje się tak dlatego, że Spärck Jones w niezwykłym artykule uczynił to już w kontekście sztucznej inteligencji (2003) i argumentował, że sztuczna inteligencja może się wiele nauczyć od IR. Jej głównym celem byli badacze sztucznej inteligencji, których nazywała „strażnikami treści”. Pokróćce przedstawię jej poglądy, a następnie je podważę. Dokonując analogii w szczególności do przypadku MT, zasugeruję, że wpływ AI na IR jest być może odwrotny. Świadczą o tym zarówno ograniczenia metod statystycznych, jakie pokazał rozwój MT w ostatnich latach, jak i ciekawe odwrócenie terminologii w przepisach wykonawczych, które miało miejsce w tym samym okresie. Ważne pytania zawarte w artykule Spärcka Jonesa sprowadzają się do jednego kluczowego pytania: Jaki jest pierwotny poziom danych językowych? Jej stanowisko w tej sprawie pokazują poniższe wstępne cytaty, które oddają istotę jej poglądów:

Jednym z tych [prostych, rewolucyjnych, IR] pomysłów jest branie słów jako stoją.

(Spärck Jones 2003)

Twierdzenie AI w swojej najsilniejszej formie oznacza, że baza wiedzy całkowicie zastępuje bazę tekstową dokumentów.

(Spärck Jones 1999)

Podsumowałbym jej złożone stanowisko w następujący sposób: słowa reprezentują siebie w tym sensie, że nie można ich zastąpić żadną bardziej prymitywną reprezentacją; wszystko, co my, technicy zajmujący się komputerami, możemy dodać, to wyrafinowane powiązania między nimi. Jednak podstawowa sztuczna inteligencja błędnie stara się zastąpić słowa, wraz z ich nieuniknioną niedokładnością, dokładnymi logicznymi – lub przynajmniej nieopartymi na słowach – reprezentacjami. Nie powinniśmy postrzegać omawianych tu kwestii jako po prostu krytyki Spärck Jones (opartej na IR) podstawowej, tradycyjnej lub symbolicznej sztucznej inteligencji, ponieważ jej poglądy łączą się bezpośrednio z wewnętrznym problemem samej sztucznej inteligencji, na temat którego w tej dyscyplinie od dawna toczy się wewnętrzny dialog. I tak, zarówno szerzej, jak i w wielu jej

podobszarach. Problem polega na naturze i konieczności ustrukturyzowanych reprezentacji symbolicznych oraz ich związku z danymi, które rzekomo reprezentują. Jest to kwestia, którą omawialiśmy już powyżej w związku z propozycjami Schanka i Wilksa z lat 70. XX w. dotyczących poziomu reprezentacji języka, który nie byłby logiką, ale miałby pewne właściwości samego języka. Kluczowym odniesieniem dla poglądu, który Spärck Jones odrzuca, byłaby cytowana już praca McCarthy'ego i Hayesa (1969), a jego skrajnym przeciwieństwem byłby każdy pogląd zawierający elementy, które można nazwać koneksjonistycznym, który kładzie nacisk na prymat danych nad wszelkimi możliwymi reprezentacją tego. Z poprzednich akapitów powinno jasno wynikać, że Spärck Jones nie skupia się na całej sztucznej inteligencji, a jedynie na silnej tradycji reprezentacjonistycznej, zwykle (ale nie zawsze, jak w przypadku Schanka i innych powyżej) związanej z wykorzystaniem rachunek predykatów. Jej podstawowym argumentem jest to, że słowa pozostają swoją najlepszą interpretacją i nie można ich zastąpić jakimś innym sztucznym kodowaniem, takim jak logika, w celu przedstawienia ich znaczenia. O ile Spärck Jones naprawdę nie zamierza twierdzić, że jakkolwiek metoda analizy języka wykorzystująca statystyki i redundancję (jak te cytowane w ostatniej sekcji) jest w rzeczywistości IR, wówczas jej twierdzenie, że sztuczna inteligencja może się wiele nauczyć od IR w tym obszarze, nie ma zbyt wielu podstaw, ponieważ ma obecnie własne tradycje metodologii statystycznej, które weszły do AI/NLP w wyniku badań mowy zapoczątkowanych przez Jelineka i rodzimych prac nad uczeniem maszynowym, a nie w ogóle z IR. Adnotacje są również formami reprezentacji i nie ma wątpliwości, że dołączanie do słów nawet adnotacji bardzo niskiego poziomu, niezależnie od tego, jak je uzyskano, może dać rezultaty, które trudno byłoby sobie bez nich wyobrazić. Uderzającym przypadkiem jest użycie wspomnianych już znaczników części mowy (takich jak PROPERNOUN); mając zasoby związane ze znaczeniem słów, takie jak LDOCE, Mark Stevenson i Yorick Wilks byli w stanie ustalić, w jaki sposób same te znaczniki części mowy mogą rozwiązać niejednoznaczność znaczenia słów (przynajmniej na poziomie zwanym homografami w LDOCE) w przybliżeniu Poziom dokładności 92 procent. Biorąc pod uwagę tak proste tagowanie, prawie cała niejednoznaczność w znaczeniu słów jest w trywialny sposób rozwiązywana w odniesieniu do tego konkretnego zasobu strukturalnego, czego nie można uzyskać bez dodatkowych reprezentacji niskiego poziomu, którymi nie są jedynie same słowa

### **Sieć semantyczna i sztuczna inteligencja**

Przejdźmy teraz do ostatniej sekcji, aby połączyć ze sobą wiele rozważań z wcześniejszych części tego rozdziału, w szczególności rolę adnotacji do tekstów i możliwość interpretacji podstawowych reprezentacji sztucznej inteligencji. Niektórzy uznali wstępną prezentację propozycji sieci semantycznej (SW) autorstwa Bernersa-Lee, Hendlera i Lassili (2001) za ponowne przedstawienie programu GOFAI w nowych i modnych terminach WWW. W artykule trzej autorzy opisują system usług, takich jak umawianie wizyty lekarskiej dla starszej osoby bliskiej, co wymagałoby planowania i dostępu do baz danych dzienników lekarza i krewnego oraz ich synchronizacji. Ten rodzaj zachowań związanych z planowaniem leżał u podstaw GOFAI i nastąpiło bezpośrednio przejście (całkiem poza dyskusją na temat samych propozycji SW) od dziesięcioleci prac nad formalną reprezentacją wiedzy w sztucznej inteligencji do współczesnej dyskusji na temat ontologii – które są daleko więcej niż hierarchiczne relacje pojęć, ale są raczej reprezentacjami wiedzy w ogóle pod nową nazwą. Podstawową formą informacji w SW jest potrójny sklep: bardzo duża liczba prostych wykresów opartych na słowach i prymitywnych działaniach w tak zwanym RDF, formacie opisu zasobu. To właśnie w tym formacie duża liczba oficjalnych dokumentów (a także Wikipedia, Facebook itp.) jest udostępniana do dalszego przetwarzania w Internecie. Jeszcze jednym ogólnym sposobem opisanie SW jest WWW, ale w formie, która w pewnym sensie „rozumie” treść semantyczną sieci, w sposób, w jaki WWW po prostu tego nie robi. Nie rozumie zawartych w nim tekstów, tak jak telewizor nie wie, co pokazuje. Najlepiej widać to w pracach nad ontologiami formalnymi jako reprezentującymi treść nauki

(jak w pracy Horrocks 2005), gdzie wiele z tych samych osób przeniosło dyskusję na temat zagadnień badawczych z jednego paradygmatu – Reprezentacji Wiedzy (KR) w AI – do innej (SW). Wszystko to zostało dokonane w ramach standardowego założenia KR w AI, które sięga najwcześniejszych prac McCarthy'ego i Hayes (1969) nad systematycznym KR, które uznaliśmy za definiujące rdzeń GOFAI. Kluczowym założeniem wszystkich takich prac było to, że predykaty w przedstawieniach KR jedynie wyglądają jak angielskie słowa, ale w rzeczywistości są obiektami formalnymi, luźno powiązаныmi z odpowiadającym im angielskim, ale pozbawionymi jego dwuznaczności, niejasności i możliwości nabywania nowych znaczeń w trakcie użytkowania. Powrócimy poniżej do tego założenia, które z pewnością było ważne zarówno w oryginalnej pracy SW, jak i w niektórych treściach z niej wynikających. Niemniej jednak niewiele skomplikowanych teorii na temat KR w GOFAI faktycznie pojawia się w ich oryginalnych formach w dotychczasowych dyskusjach SW: od biegłych teorii McCarthy'ego i Hayes, późniejszej logiki autoepistemicznej McCarthy'ego i naiwnej fizyki Hayes, żeby wymienić tylko kilka wybitnych przykładów. Ciągłość celów pomiędzy GOFAI i SW nie oznacza po prostu ciągłości poszczególnych tradycji badawczych i jest to zarówno zysk, jak i strata: zysk, ponieważ pozwolił na uzyskanie prostszych schematów reprezentacji, które prawdopodobnie są obliczalne; strata z powodu braku zaawansowania w obecnych schematach rodziny języków rozumowania DAML/OIL dla SW. Podstawową kwestią jest to, czy te nowe systemy rozumowania zorientowane na SW mają siłę reprezentacyjną niezbędną dla złożoności świata, zdroworozsądkowej czy naukowej. Istniały co najmniej dwie inne tradycje wkładu w to, co obecnie nazywamy SW, a ja omówię jedną z nich: mianowicie sposób, w jaki koncepcja SW wyrosła z humanistycznej tradycji adnotacji w dokumentach. W oryginalnym artykule Scientific American przedstawiającym SW znajduje się diagram struktury SW z niskopoziomowym kodem XML na dole, sięgającym do złożonych koncepcji na wyższych poziomach, takich jak reguły, logika, dowód i zaufanie. Patrzenie wyłącznie na te etykiety wyższego szczebla spowodowało, że niektórzy krytycy i wielbiciele SW stwierdzili, że jest to projekt GOFAI pod inną nazwą, ponieważ pojęcia te były częścią rdzenia tradycyjnej sztucznej inteligencji. Jeśli jednak spojrzymy na niższe poziomy, odkrywamy przestrzeń nazw i XML, które są produktami tego, co możemy szerzej nazwać NLP, uzyskanym z adnotacji tekstów za pomocą technologii, którą możemy nadal wygodnie nazywać IE, jak w powyższych sekcjach. IE teraz niezawodnie lokalizuje nazwy w tekście, ich typy semantyczne i łączy je ze sobą za pomocą wyuczonych struktur zwanych szablonami w formy faktów i zdarzeń, obiekty praktycznie identyczne z potrójnymi magazynami RDF u podstawy SW, które nie są do końca logiczne, ale bardzo podobny do wyjścia IE. IE zaczęło od automatyzacji adnotacji, ale obecnie opracowało coś, co możemy nazwać silnikami adnotacji opartymi na uczeniu maszynowym, które uczą się dodawać adnotacje do tekstów w dowolnej formie i dowolnej domenie. Ten pogląd na SW, w którym NLP ma kluczowe znaczenie dla jego rozwoju, nie jest poglądem jedynym, jak podkreśliłem na początku, ale jest tym, który leży u podstaw większości prac nad SW w Europie. Z takiego punktu widzenia SW można postrzegać na swoim podstawowym poziomie jako konwersję z WWW tekstów za pomocą procesu adnotacji zwiększającego zrozumienie i wizję, takiego, który przenosi pojęcia znaczenia w górę klasycznego diagramu SW od dołu do dołu złożone koncepcje na górze. Jeżeli uda się to osiągnąć w ramach projektu SW – nadanie znaczenia abstrakcyjnym pojęciom poprzez procesy empiryczne łączące je z tekstem – będzie to główne intelektualne osiągnięcie sztucznej inteligencji i rozwiązanie problemu, który towarzyszył jej od samego początku początek.