



**Instytut Badań Systemowych
POLSKIEJ AKADEMII NAUK**

**Przemysław Różewski
Emma Kusztna
Oleg Zaikin**

**Modele i metody zarządzania
procesem
Otwartego nauczania zdalnego**

Warszawa - Szczecin 2008

**Przemysław Różewski
Emma Kuszina
Oleg Zaikin**

**Modele i metody zarządzania
procesem
Otwartego nauczania zdalnego**

Autorzy poszczególnych rozdziałów.

Wprowadzenie: Emma Kuztina

Rozdział 1: Przemysław Różewski, Emma Kuztina

Rozdział 2: Emma Kuztina, Przemysław Różewski

Rozdział 3: Przemysław Różewski

Rozdział 4: Emma Kuztina

Rozdział 5: Przemysław Różewski

Rozdział 6: Przemysław Różewski, Emma Kuztina, Oleg Zaikin

Rozdział 7: Emma Kuztina, Przemysław Różewski

Rozdział 8: Emma Kuztina, Oleg Zaikin, Przemysław Różewski

Zakończenie: Przemysław Różewski



**INSTYTUT BADAŃ SYSTEMOWYCH
POLSKIEJ AKADEMII NAUK**

**Przemysław Różewski
Emma Kusztina
Oleg Zaikin**

**Modele i metody zarządzania
procesem
Otwartego nauczania zdalnego**

Warszawa - Szczecin 2008

**INSTYTUT BADAŃ SYSTEMOWYCH
POLSKIEJ AKADEMII NAUK**

Seria: BADANIA SYSTEMOWE, tom 61

Redaktor naukowy:

Prof. dr hab. inż. Jakub Gutenbaum



**INSTYTUT BADAŃ SYSTEMOWYCH
POLSKIEJ AKADEMII NAUK**

**Przemysław Różewski
Emma Kusztnina
Oleg Zaikin**

**Modele i metody zarządzania
procesem
Otwartego nauczania zdalnego**

Warszawa - Szczecin 2008

© Instytut Badań Systemowych PAN, Warszawa 2008

© Politechnika Szczecińska, Wydział Informatyki
Szczecin 2008

Recenzenci:

Prof. dr hab. inż. Olgierd Hryniewicz

Prof. dr hab. inż. Ryszard Tadeusiewicz

Wydawca: Instytut Badań Systemowych PAN
ul. Newelska 6, 01-447 Warszawa
Sekcja Informacji Naukowej i Wydawnictw
Tel. 837-68-22

Druk: Pracownia Poligraficzna
Wydział Informatyki
Politechnika Szczecińska
ul. Żołnierska 49, 71-210 Szczecin

Nakład 500. Ark. druk. 28,12
Maj 2008 r.

ISBN 9788389475169
ISSN 0208-8029

Wprowadzenie

Otwarte i Zdalne Nauczanie (ang. *Open and Distance Learning – ODL*) jest zupełnie nowym sposobem działania organizacji edukacyjnych mającym na celu przyspieszenie i sprecyzowanie procesu aktualizacji wymaganych kompetencji na wspólnym europejskim rynku pracy (Kushtina, 2006). Podejście to ma na uwadze nie tylko zakres wiedzy i umiejętności wymaganych na określonym stanowisku roboczym, ale co jest najważniejsze, rozwój kadry inżynierskiej i badawczej. Troska o zwiększenie tempa aktualizacji wiedzy wynika z tego, że rozpoczynając od lat 80-tych XXI wieku Europa boryka się w coraz większym stopniu z problemami technologicznymi, ekologicznymi i ekonomicznymi o charakterze globalnym. Rozwiązanie tych problemów wychodzi poza granicę istniejących i najczęściej wykorzystywanych metod ich rozwiązania – w przemyśle potrzebne są nowe rozwiązania działające szybszej i bezpieczniej, istnieje konieczność skrócenia drogi od wynalazku do wdrożenia, co przekłada się na potrzebę zastosowania nowych sposobów organizacji funkcjonowania struktur przemysłowych, finansowych oraz socjalnych. W pracach A. Straszaka (Straszak, 2006), P. Sienkiewicza (Sienkiewicz, 2004), R. Tadeusiewicza (Tadeusiewicz, 2002) i wielu innych autorów zostały pokazane i przeanalizowane ilościowo przyczyny i tendencje tego zjawiska. Gospodarka oparta na wiedzy wymaga specjalistów przygotowanych do ciągłego przyswajania i generowania nowej wiedzy na podstawie analizy pojawiających się innowacji oraz zmieniających się warunków geopolitycznych, przyrodniczych, społecznych itp.

W tym kontekście konieczne staje się postawienie pytań: jaka jest rola w tej nowej sytuacji instytucji edukacyjnych, czy mają one możliwość przyspieszenia tempa procesu przygotowania nowej kadry o unowocześnionych kompetencjach, czy mogą one zapewnić dla każdego specjalisty korzystne warunki realizacji samodzielnego rozwoju w trybie „uczenia się przez całe życie”.

Generalnie rzecz biorąc, cały system i każda odrębna organizacja edukacyjna w miarę wchodzenia społeczeństwa w strefę globalizacji, potrzebują określenia nowego paradygmatu działania, misji i sposobów jej realizacji. Przyspieszony rozwój wiedzy może prowadzić do tego, że z biegiem czasu wiedza specjalisty ulega dezaktualizacji. Jest to zjawisko niepożądane i należy je wyeliminować tak, by wiedza specjalisty przyswajana po zakończeniu szkoły wyższej nie straciła swojej aktualności po kilku latach pracy zawodowej.

Powstaje pytanie, czy nabywanie aktualnej wiedzy jest przedmiotem tylko i wyłącznie zainteresowań indywidualnych czy całego społeczeństwa i jego instytucji?

Absolutna rola konkurencyjności jako głównego ogniwa rozwoju każdej jednostki gospodarczej oraz całości gospodarki nie odpowiada już celom rozwoju społeczeństwa. Bankructwo dużej firmy z powodu nie sprostanania wymaganiom konkurencji nie tylko wywołuje szereg problemów socjalnych, ale również prowadzi do straty bardzo poważnego kapitału – zgromadzonego i usystematyzowanego przez kadry i system zarządzania firmy – zasobu wiedzy. Wartość tego kapitału i korzyści z niego płynące stanowią znaczącą część wspólnego zasobu wiedzy należącego dla całego społeczeństwa. Wynika z tego, że przy obecnym stanie integracji i globalizacji wszystkich stron naszego życia, biorąc pod uwagę tylko i wyłącznie konkurencyjność, nie można mieć gwarancji dalszego postępu w organizacji współdziałania różnorodnych jednostek gospodarki kraju lub też Unii Europejskiej.

Zadanie zachowania nieulotności wspólnego kapitału wiedzy staje się ważnym problemem badawczym. Analiza podejść stosowanych w przypadku innych współdzielonych zasobów takich jak np. zbiorniki wodne, przestrzeń lotnicza pokazuje, że punktem wyjścia w każdej sytuacji jest tworzenie odpowiedniego systemu zarządzania obejmującego różne

aspekty wykorzystania zasobów (od podstaw prawnych do zasad technologicznych). Gwarancją przechowywania i możliwości wykorzystania wspólnego zasobu wiedzy powinna być również wspierana przez odpowiedni system zarządzania, dla którego zasób wiedzy występuje jako obiekt zarządzania. Głównym celem takiego systemu powinna stać się koordynacja współdziałania jednostek społecznych i gospodarczych, które tworzą i wykorzystują zasoby wiedzy. Konkurencja w takim przypadku nie straci swojej roli, tylko zmieni swoje uwarunkowania końcowe: nie tylko zysk, ale również dobra pozycja jednostki na skali objętości i aktualności tworzonej i wykorzystanej przez nią wiedzy.

Dyskutowanemu problemowi, do tej pory, została poświęcona duża uwaga zarówno ze strony organizacji rządowych różnej rangi jak i od strony instytucji badawczych. Nie zmienia to faktu, że główny ciężar przygotowania kwalifikowanej kadry inżynierskiej był i nadal będzie ponoszony przez uczelnie wyższe. Globalizacja pod każdym względem ustanawia nowe warunki koegzystencji dla szkół wyższych. Po usankcjonowaniu koncepcji Otwartego i Zdalnego Nauczania przez UNESCO (Patru i Khvilon, 2002) oraz po powstaniu Procesu Bolońskiego prawie każda jednostka edukacyjna ma przed sobą postawione wyzwanie sprostania wymaganiom operatywnego reagowania na zmiany w otoczeniu społecznym i kapitale wiedzy.

Otwarte i Zdalne Nauczanie jest zupełnie nową koncepcją organizacji nauczania w szkołach wyższych Unii Europejskiej. Podstawowa jej idea została przedstawiona w Deklaracji Bolońskiej. Wdrożenie każdej koncepcji dotyczącej nowego sposobu organizacji funkcjonowania systemu społecznego wymaga precyzyjnej analizy struktury przyszłego systemu jako obiektu zarządzania. Złożoność i skala działania ODL determinuje opracowanie odpowiedniego informacyjnego systemu nauczania, który łączy cechy tradycyjnie rozumianego pojęcia nauczania zdalnego (ang. *Distance Learning*) oraz jego nowego bardziej szerokiego ujęcia – nauczania otwartego (ang. *Open Learning*). W niniejszej pracy zostanie użyty termin Otwarty System Nauczania Zdalnego (OSNZ), mając na myśli odpowiedni system informacyjny.

OSNZ jest ideą stworzenia takiego systemu nauczania, który będzie umożliwiał poprzez sieć teleinformacyjną naukę na uniwersytetach Unii Europejskiej każdemu studentowi nie tylko niezależnie od aktualnego miejsca zamieszkania, ale również według własnej, personalizowanej drogi nauczania, co jest znacznym rozszerzeniem tradycyjnie rozumianego nauczania zdalnego.

Reasumując, możemy przyjąć, że OSNZ może być traktowany jako system informacyjny, który przeznaczony jest do zarządzania procesem otwartego nauczania zdalnego, prowadzonego przez dowolną organizację edukacyjną, spełniającą warunki Deklaracji Bolońskiej. Ze względu na wymagany stopień elastyczności takiego systemu nauczania oraz w związku z koniecznością bezpośredniej jego orientacji na wymagania rynku pracy i technologii, OSNZ jest nową klasą systemów informacyjnych nauczania. Powodzenie w opracowaniu koncepcji OSNZ pozwoli opracować metodykę wdrażania idei Deklaracji Bolońskiej w każdej organizacji edukacyjnej i jednocześnie posłuży za podstawę do określenia jakości organizacji procesu edukacyjnego.

Książka integruje swoim zasięgiem problemy nauczania ODL, które są rozpatrywane na tle zmieniającego się stanu społeczeństwa, obejmując cały zakres zagadnień, poczynając od informatycznych, a kończąc na społecznych. Wstępne rozważania, zawarte w *rozdziale pierwszym*, definiują pojęcie jakości na tle zagadnienia ODL. Zmiana organizacji edukacyjnej na przełomowym etapie przejścia od tradycyjnie rozumianego nauczania na odległość do ODL powoduje powstanie nowego paradygmatu działania instytucji edukacyjnej. Poszczególne aspekty wpływające na nowe oblicze organizacji edukacyjnej opisane są w *rozdziale drugim*. Nowa organizacja zmienia wymiarowość poszczególnych aspektów procesów składających się na działanie organizacji edukacyjnej. Dyskutowany problem

w swojej naturze jest skomplikowany, ponieważ organizacja edukacyjna zachowując własną misję nabiera cech przedsiębiorstwa działającego na tworzącym się globalnym rynku usług kształcenia.

Globalny system nauczania będzie opierał się na kooperacji, która potrzebuje standaryzacji w szerokim zakresie (produkty końcowe, procesy, struktury organizacyjne, środki komunikacji, itd.), co zostało opisane w *rozdziale trzecim*. Struktura organizacyjna oraz zasady funkcjonowania w największym stopniu odwzorują zmiany paradygmatu działania organizacji edukacyjnych, stąd też wynika konieczność ich standaryzacji. Przykładem takiego podejścia, stosownym w przemyśle, są standardy MRP. W *rozdziale czwartym* zostały przedstawione wyniki wykonanej analizy systemowej, która pozwoliła opisać hierarchiczną strukturę układów podsystemów, funkcji i modułów oraz model funkcyjny informacyjnego systemu zarządzania organizacją edukacyjną wspierający ODL.

W dalszej części książki zostały rozpatrzone problemy wykorzystania wiedzy eksperta. Tradycyjnie ekspert w kontekście systemów informacyjnych rozpatrywany był tylko i wyłącznie jako źródło wiedzy, która później przekształcana była do postaci modelu wiedzy przez inżyniera wiedzy. W *rozdziale piątym* jednak obiektem badań jest nie tylko wiedza eksperta, ale co ważniejsze struktura jego pamięci traktowana jako mechanizm gromadzenia i przetwarzania wiedzy. Celem jest zrozumienie jak zmieniają się struktury pamięci w czasie i jak można ten proces reprezentować systemowo w celu zastąpienia nauczyciela w nauczaniu asynchronicznym. Zastosowanie nowego podejścia informatycznego, które bada intelekt eksperta wykonującego podczas swojej pracy ciąg inteligentnych operacji, pozwala na opracowanie architektury systemu reprezentacji i przekazywania wiedzy opisanego w *rozdziale szóstym*.

Walidacja koncepcji przedstawionego w książce rozszerzonego ontologicznego modelu wiedzy wymaga opracowania efektywnego środowiska wymiany pomiędzy różnymi typami wiedzy. Przedstawiona w *rozdziale siódmym* koncepcja laboratorium wirtualnego pozwala na symulację i analizę procesów jakie zachodzą podczas nabywania przez studenta nowej wiedzy.

Wszystkie etapy tworzenia i przetwarzania wiedzy przez: ekspertów, nauczycieli, studentów i autorów materiałów dydaktycznych odbywają się w środowisku sieciowym. Dodatkowo, materiały dydaktyczne opracowane według modelu ontologicznego, repozytorium wiedzy traktowane jako baza materiałów dydaktycznych, programy nauczania uwzględniające personalizowaną ścieżkę nauczania, są nowymi produktami końcowymi, które są tworzone i dystrybuowane w wyniku kooperacji obywatelskiej się również w środowisku sieciowym. Sytuacja taka wymaga traktowania środowiska sieciowego jako produkcyjnej sieci produkcji niematerialnej, której organizacja potrzebuje optymalizacji ze względu na ograniczenia czasowe i kosztowe. W *rozdziale ósmym* zostało przedstawione podejście do opracowania odpowiedniego modelu optymalizacyjnego.

Bibliografia

- Kushtina E. (2006). Koncepcja otwartego systemu informacyjnego nauczania zdalnego, Wydawnictwo Politechniki Szczecińskiej, Szczecin.
- Patru M., Khvilon E. (Red.) (2002), Open and distance learning: trends, policy and strategy considerations, dokument UNESCO, kod: ED.2003/WS/50.
- Sienkiewicz P. (2004), Przewaga informacyjna w walce i biznesie, W: Straszak A., Owsiński J. (Red.), Badania operacyjne i systemowe 2004: Na drodze do społeczeństwa wiedzy, Akademicka Oficyna Wydawnicza EXIT, Warszawa, 107-113.
- Straszak A. (2006), Badania operacyjne i systemowe w wysoce z informatyzowanej globalnej gospodarce, W: E. Urbańczyk, A. Straszak, J. Owsiński (Red.), Badania operacyjne i systemowe 2006: Analiza systemowa w globalnej gospodarce opartej na wiedzy: e-Wyzwania, Akademicka Oficyna Wydawnicza EXIT, Warszawa, 31-55.
- Tadeusiewicz R. (2002). Społeczność Internetu, Akademicka Oficyna Wydawnicza EXIT, Warszawa.

5. Założenia projektowe modelu systemu informatycznego klasy LMS/LCMS

5.1. Wstęp

W wyniku gwałtownego rozwoju rynku nauczania zdalnego została utworzona specjalna klasa dedykowanych systemów informatycznych. Powstały *Systemy Zarządzania Procesem Nauczania* (ang. *Learning Management Systems – LMS*), których zadaniem jest zarządzanie procesami wymiany informacji pomiędzy wszystkimi uczestnikami nauczania zdalnego. Systematyczna ewolucja pozwoliła na osiągnięcie wysokiej skuteczności systemów LMS w zagadnieniach komunikacji, udostępniania zasobów i administracji. Jednakże nowe wyzwania rynkowe, z których najważniejsze to rosnąca istotność systemów nauczania zdalnego pracujących w trybie asynchronicznym, spowodowały powstanie *Systemów Zarządzania Zawartością Nauczania* (ang. *Learning Content Management Systems – LCMS*). Zadanie systemu LCMS polega na umożliwieniu modelowania wiedzy w trakcie procesu nauczania. Systemy LCMS w niedługim czasie stały się integralną częścią systemów LMS, tworząc systemy LMS/LCMS.

Głównym impulsem powodującym opracowanie systemów LCMS było wykreowanie nowego podejścia do budowania materiałów dydaktycznych, przeznaczonych do nauczania w trybie asynchronicznym. Zauważono, że kursy nauczania zdalnego przygotowane w tradycyjny sposób charakteryzują się ścisłą strukturą i zamkniętym kontekstem. Monolityczny charakter kursów powoduje trudności z ponownym użyciem danego materiału dydaktycznego w innej sytuacji dydaktycznej, co poważnie podnosi koszty pojedynczego kursu. Na zmianę podejścia wpływ miała również nowa organizacja procesu nauczania, przedstawiona w pracy (Kushtina i Różewski 2000) oraz (Kushtina i in., 2002), charakteryzująca się nową rolą nauczyciela, który w systemach nauczania asynchronicznego pełni rolę koordynatora, doradcy i weryfikatora wiedzy studenta. Badania przeprowadzone między innymi w obszarach pedagogiki, dydaktyki, psychologii i kognitywistyki pozwoliły zgłębić naturę wiedzy w trakcie procesu nauczania, umożliwiając wprowadzenie modułowej metody organizacji materiałów dydaktycznych w oparciu o ideę Learning Object.

Najważniejsze problemy badawcze wymagające analizy w świetle opracowania modułu LMS/LCMS pracującego w oparciu o idee Learning Object to: jak wydobyć wiedzę od eksperta, w jaki sposób i za pomocą jakiej metody reprezentacji wiedzy poddać ją formalizacji oraz jak modelować tak opisaną wiedzę. Dodatkowo ważnym problemem jest analiza kognitywnego procesu nabywania wiedzy w świetle potrzeby jego częściowej automatyzacji (Zaikin i in., 2006).

5.2. Proces wydobywania wiedzy od eksperta

Proces uzyskiwania wiedzy od eksperta może odbywać się na dwa sposoby. Pierwszy (ang. *knowledge elicitation*) polega na oparciu procesu na interakcji człowieka (eksperta) z człowiekiem (inżynierem wiedzy), podczas gdy drugi (ang. *knowledge acquisition*) opiera się na narzędziach automatycznych, czyli na współpracy człowieka z odpowiednim programem komputerowym. W literaturze istnieje również podejście, reprezentowane np. przez (Wagner i in., 2002), zakładające, że proces *wydobywania wiedzy* (ang. *knowledge elicitation*) jest częścią procesu *pozyskiwania wiedzy* (ang. *knowledge acquisition*), który zawiera jeszcze zadania reprezentacji wiedzy, implementacji i ulepszania systemów wiedzy. Jak pokazuje (Neale, 1988), pierwszy sposób (człowiek – człowiek) kładzie nacisk na subiektywne opinie eksperta. Według wielu specjalistów, powinno się eliminować inżynierów wiedzy i pozwolić ekspertom pracować bezpośrednio z komputerem. Jest to spowodowane

tym, że systemy takie wydają się bardziej efektywne i mniej zależne od poziomu umięjętności osoby (inżyniera wiedzy) przeprowadzającej dialog z ekspertem.

Zastanowić się należy nad definicją procesu wydobywania wiedzy od eksperta, bazując na dyskusji przedstawionej w publikacji (Hamilton i Breslawski, 1996). Definicja mówi, że proces wydobywania wiedzy od eksperta polega na analizowaniu i interpretowaniu wiedzy, jaką ekspert używa, kiedy rozwiązuje dany problem. Wydobywanie wiedzy polega na transformacji rozwiązania eksperta na odpowiednią formalną reprezentację, tworzoną przez inżyniera wiedzy. Proces wydobywania wiedzy od eksperta można traktować jako ekstrakcję i formalizację wiedzy uzyskanej z wewnętrznych źródeł wiedzy, umiejscowionych w umyśle eksperta.

Na jakość wiedzy uzyskanej od eksperta według (Adelman, 1989) wpływ mają następujące czynniki:

- Poziom zaawansowania eksperta w danej dziedzinie.
- Doświadczenie i umiejętności inżyniera wiedzy (w przypadku współpracy eksperta z inżynierem wiedzy). Jak pokazuje m.in. (Wagner i in., 2002), etap określenia metody uzyskania wiedzy od eksperta dostosowanej do sytuacji i osoby eksperta jest problemem złożonym.
- Sposób reprezentacji wiedzy. Wybór metody i stopień jej formalizacji ma wpływ na późniejsze możliwości przetwarzania (wnioskowania) zdobytej wiedzy.
- Metody wydobywania wiedzy. Jak pokazują (Shaughnessy i in., 2002), większość metod wydobywania wiedzy ma charakter badań jakościowych. Dane uzyskiwane są zwykle drogą wywiadu lub obserwacji. Badania ilościowe stosowane są w ograniczonym wymiarze, głównie do analizy dokumentów, w celu ekstrakcji wiedzy, np. za pomocą zbiorów przybliżonych lub metod data mining.
- Dziedzina problemowa. Badania przeprowadzone przez np. (Medsker i in., 1995) oraz (Hoffman i in., 1995) pokazują, że trudno jest znaleźć eksperta z wiedzą umożliwiającą zamodelowanie szeroko zarysowanej dziedziny. Wiedza dotycząca szeroko określonej dziedziny zawsze będzie niekompletna, co stawia pod znakiem zapytania jej sens.

Wiedza proceduralna zazwyczaj jest przechowywana w postaci reguł uzyskanych podczas wywiadu z ekspertem (za (Moody i in., 1996)). Wiedza deklaratywna zapisywana jest w systemie w postaci ram, które mogą współdziałać z siecią semantyczną. Wiedza semantyczna, reprezentowana za pomocą struktur łączących fakty, pojęcia oraz relacje, zachowywana jest w postaci sieci semantycznych, zbudowanych np. na podstawie dialogu z ekspertem.

5.2.1 Zadanie współpracy z ekspertem

Odpowiednie zbudowanie procesu interakcji jest jednym z kluczowych czynników uzyskania wiedzy wysokiej jakości. W kontekście interakcji eksperta z inżynierem wiedzy (lub odpowiednim systemem komputerowym), istotnym zagadnieniem jest zjawisko uprzedzenia (ang. *bias*). Jak pokazują (Hoffman i in., 1995), w przypadku wnioskowania przypuszczającego (ang. *probabilistic reasoning*), występują następujące problemy związane ze zjawiskiem uprzedzenia:

- prawdopodobieństwo danego zdarzenia oceniane jest na podstawie podobieństwa lub stereotypu, zamiast na podstawie częstotliwości;
- przecenienie znaczenia rzadkich wydarzeń;
- proces może być sterowany przez poznawczą dostępność informacji, a nie ze względu na jej właściwości częstotliwościowe.

W przypadku wnioskowania opartego na logice (ang. *logical reasoning*) występują następujące przekłamania, które wynikają ze zjawiska uprzedzenia:

- tendencja do przywiązywania nieuzasadnionej wagi do pierwszego uzyskanego faktu;

- za duże poleganie na danych, które zostały uzyskane w krańcowych przypadkach;
- tendencja do poszukiwania dowodów, które potwierdzą obecną hipotezę;
- tendencja do jednoczesnego wnioskowania tylko na podstawie jednej lub dwóch hipotez;
- tendencja do zbytnej pewności siebie;
- chęć uzyskania spójności nawet wtedy, gdy oznacza to zmiany lub ignorowanie istotnych informacji;
- wiara w iluzoryczne związki.

Opracowana strategia uzyskiwania wiedzy od eksperta ma duże znaczenie. Przykładowe podejście, polegające na zapewnieniu sprzężenia zwrotnego, spowoduje stosowanie przez eksperta strategii „przypuszczenia i testowania”, gdzie ekspert dochodzi do pewnego przypuszczenia, a następnie je testuje, kontynuując rekurencyjnie cykl aż do uzyskania pożądanego rezultatu. Gdy ekspert będzie pozbawiony dostępu do mechanizmu sprzężenia zwrotnego, wtedy prawdopodobnie wykorzysta strategię „planuj i implementuj”, która polega na początkowym dokładnym przeanalizowaniu problemu do momentu, gdy stwierdzi, że rezultat analizowany jest optymalny i można go zaimplementować.

W klasycznej publikacji (Hart, 1989), znaleźć można ogólne zasady, jakimi powinien kierować się inżynier wiedzy podczas swojej pracy z ekspertem:

1. bądź przygotowany;
2. zapisuj informacje;
3. bądź konkretny, a nie ogólny;
4. nawiąź nić współpracy z ekspertem;
5. spróbuj nie przeszkadzać;
6. nie narzucaj obcych narzędzi;
7. obserwuj sposób, w jaki ekspert używa swojej wiedzy.

5.2.2 Identyfikacja osoby eksperta

Identyfikacja eksperta jest procesem trudnym, czego dowodzą między innymi (Medsker i in., 1995). Każdy ekspert charakteryzuje się pewną biegłością, znawstwem (ang. *expertise*) w określonej dziedzinie, często bardzo wąskiej. Przeanalizować można typową charakterystykę postaci eksperta, powołując się na (Hoffman i in., 1995) oraz (Barrett i Edwards, 1995). Ekspertem określa się osobę, w oparciu o charakteryzujące ją kwalifikacje zawodowe (wyrażonych przez doświadczenie zawodowe i umiejętności praktyczne). Na ocenę danego eksperta wpływ mają również takie czynniki jak: wykształcenie, odbyty trening i szkolenia, dorobek naukowy, uczestnictwo w pracach międzynarodowych organizacji oraz stowarzyszeń. Eksperti są wybierani również z racji tego, że wykonują jakąś pracę i osiągnęli w niej dużą biegłość (dzieje się to głównie wtedy, gdy analizujemy poziom operacyjny, np. zadanie kierowania ciężarówką). Często proces poszukiwania eksperta polega na przeprowadzeniu wywiadu środowiskowego, mającego na celu znalezienie pracownika, który jest przez innych wskazany jako ekspert.

Jednym z aspektów związanych z osobą eksperta, przedstawionym między innymi w pracy (Wagner i in., 2002), jest paradoks doświadczenia (ang. *paradox of expertise*). Paradoks polega na tym, że dany ekspert wraz ze zwiększaniem swojej biegłości w danej dziedzinie dokonuje personalizacji swojej wiedzy. Proces personalizacji powoduje trudności eksperta w dokładnym sprecyzowaniu tego, co wie. Wiedza, jaką posiada ekspert, staje się bardzo często wiedzą ukrytą (ang. *tacit knowledge*), czyli taką, do której nie można się świadomie odwołać (Marwick, 2001).

Główną cechą eksperta jest jego biegłość w danej dziedzinie. Biegłość może być definiowana w kontekście wymiaru i organizacji pamięci, co jest skorelowane z wiekiem. Proces „formowania” eksperta jest procesem długotrwałym, szczególnie w dziedzinach, które oparte są na współdzieleniu wiedzy teoretycznej z wiedzą operacyjną, popartą praktyką (np.

medycyna). Proces nabywania biegłości jest procesem głęboko osadzonym w otoczeniu. Nie powinno się go izolować i rozpatrywać w oderwaniu od danego łańcucha nabywania wiedzy. Badania nad zagadnieniem eksperta powinno być przeprowadzane w paradygmacie nowicjusz – ekspert. Tabela 18 charakteryzuje poszczególnych uczestników łańcucha nowicjusz – ekspert, określając właściwy dla nich zakres kompetencji w oparciu o rozważania (Hoffman i in., 1995) oraz pracach Huberta Dreyfusa z uniwersytetu Berkeley (np. (Dreyfus, 1992)) omówionych w (Casti i DePauli, 2003).

Tab. 18. Przykład struktury zależności nowicjusz – ekspert
(źródło: opracowanie własne)

<i>Opis osoby</i>	<i>Charakterystyka osoby</i>	<i>Zakres kompetencji</i>
Naiwny (ang. <i>Naivette</i>)	Osoba będąca całkowitym ignorantem w dziedzinie.	-
Nowicjusz (ang. <i>Novice</i>)	Osoba nowa w danej dziedzinie.	-
Początkujący (ang. <i>Initiate</i>)	Osoba, które jest nowa w danej dziedzinie, ale przeszła już początkowe szkolenie.	Opanowuje niezależne od kontekstu reguły. Reguły takie nie uwzględniają rzeczywistych sytuacji np. umiejętności stwierdzenia, przy jakich symptomach należy podjąć określone działanie.
Terminator (ang. <i>Apprentice</i>)	Osoba zdobywająca umiejętności w danej dziedzinie np. w wyniku treningu lub szkolenia.	Uczy się rozpoznawać konkretne sytuacje, które nie można opisać obiektywnie w niezależny od kontekstu sposób np. potrafi zdecydować się na wykonanie danego działania, mimo że nie jest to spowodowane stosowną regułą.
Zaawansowany (ang. <i>Journeyman</i>)	Osoba, która potrafi wykonywać codzienne, typowe zadania, pracuje również pod nadzorem. Osiągnięty poziom umiejętności i wiedzy jest typowy dla wykwalifikowanego robotnika.	Zaczyna działać zgodnie z ogólną strategią, nie zaś według ogólnych reguł. Jego działania orientowane są nie tylko przez reguły, ale przez wyznaczony cel, np. aby osiągnąć cel potrafi zrezygnować z części reguł.
Ekspert (ang. <i>Expert</i>)	Najwyższe umiejętności w danej dziedzinie, osiągnięty poziom biegłości pozwala na radzenie sobie z rzadkimi i trudnymi przypadkami. Ekspert posiada bogatą wiedzę i umiejętności zdobyte poprzez liczne doświadczenia w pochodnych pod-domenach.	W poprzednich poziomach decyzje podejmowane były według świadomego namysłu, ekspert działa na podstawie własnego „wycucia” danej sytuacji. Działanie eksperta jest wykonywane na podstawie spontanicznego rozumienia sytuacji.
Mistrz (ang. <i>Master</i>)	Ekspert, który posiada kwalifikacje na poziomie pozwalającym mu nauczać innych, z poziomów niższych. Zdobyta wiedza i doświadczenie przekładane jest na tworzenie regulacji i standardów.	Poziom World-Class – w tym przypadku działanie nie jest traktowane jako sekwencja problemów do rozwiązania. Funkcjonuje opierając się na „siódmym zmyśle”.

Eksperti w rzeczywistych systemach pracują pojedynczo lub w grupie. Gdy zadanie jest skomplikowane i wymaga różnego typu doświadczenia jest zazwyczaj rozwiązywane przez grupę ekspertów ((Medsker i in., 1995) oraz (Hamilton i Breslawski, 1996)). Ze względu na zdobyte doświadczenie, wykształcenie, eksperci dążą do celu w różny sposób. Ponadto istotną trudnością jest możliwe rozmieszczenie ekspertów w odległych geograficznie od siebie regionach. Eksperti zazwyczaj sami wnoszą pewien stopień niepewności, używając stwierżeń „najprawdopodobniej” lub „z reguły”.

Korzystanie z grupy ekspertów podczas procesu wydobywania wiedzy jest zawsze dylematem. Pozytywem jest możliwość uzyskania lepszego, dokładniejszego zrozumienia danej dziedziny problemu. Zbudowany model ma większy poziom dokładności, większa liczba osób biorących udział w procesie przyczynia się do polepszenia jakości walidacji. Pracujący zespół ekspertów charakteryzuje się większą produktywnością i możliwością zaadresowania obszerniejszej dziedziny i rozwiązania bardziej kompleksowych problemów. Negatywy współpracy z grupą ekspertów polegają na tym, że eksperci mogą mieć trudności ze znalezieniem wspólnego stanowiska lub problemem może okazać się wspólna komunikacja. Jak pokazują (Medsker i in., 1995), wnioskowanie grupowe jest trudne do uchwycenia i w rezultacie trudno poddać je formalizacji. Problemy pracy w grupie, takie jak wzajemna niechęć członków grupy, osobiste i zawodowe konflikty, mogą stanowić poważne wyzwanie podczas sesji.

Istnieją trzy główne podejścia do zagadnienia współpracy z wieloma ekspertami (Medsker i in., 1995): (i) bazujemy na opinii tylko jednego eksperta, (ii) zbieramy opinie wielu ekspertów, ale tylko jedna jest przesłanką podczas wnioskowania, (iii) integrujemy opinie wielu ekspertów do jednego wniosku. Najkorzystniejsze wydaje się podejście trzecie, szczególnie w systemach, które mają za zadanie reprezentować trudne i skomplikowane problemy. W przypadku postawienia zadania wydobywania wiedzy w wąskim wymiarze dziedziny, od wielu ekspertów można uzyskać różne rezultaty. W takim przypadku (Bloom i Chung, 2001) radzą użyć operacji agregacji – agregowane są pojedyncze osądy, korzystając między innymi z analizy statystycznej.

Ograniczony wymiar dziedziny pozwala wykonać zadanie formalizacji wiedzy dziedziny poprzez pracę z jednym ekspertem. Problem współpracy z pojedynczym ekspertem w wąsko zdefiniowanej dziedzinie jest szeroko dyskutowany w literaturze, zarówno od strony metodologii współpracy z ekspertem, jak i modelowania uzyskanej wiedzy, np. (Hart, 1989), (Hoffman i in., 1995), (Wagner i in., 2002), (Radosiński, 2002).

Rozwiązaniem integrującym zalety podejścia bazującego na grupie ekspertów i pracy z pojedynczym ekspertem jest system eksperta podstawowego i pomocnika eksperta (ang. *primary and secondary experts*). Zasada uczeń-mistrz polega na dwuetapowym procesie uzyskiwania wiedzy. Jak pokazują (Medsker i in., 1995), zadaniem podstawowego eksperta jest walidacja całej bazy wiedzy, podczas gdy ekspert pomocniczy jest konsultantem w konkretnych aspektach problemu. Decydujący głos ma ekspert podstawowy, który musi rozwiązać częste konflikty powstałe w wyniku współpracy z ekspertem pomocniczym (ekspertów pomocniczych może być kilku).

5.2.3 Strukturyzacja wiedzy uzyskanej od eksperta

Zadanie strukturyzacji wiedzy ma na celu zwiększenie jakości modelu wiedzy i wykonywane jest na etapie tworzenia modelu wiedzy danej dziedziny. Nadanie struktury związane jest z identyfikacją modelu konceptualnego dziedziny. Strukturyzacja jest metodą wyrażania wiedzy eksperta w sposób umożliwiający jej formalizację do postaci zgodnej z wymaganiami przetwarzania komputerowego i przyjętego modelu reprezentacji wiedzy. Zadanie strukturyzowania nie polega na eksplorowaniu stworzonego przez eksperta schematu

danej dziedziny, ale na asystowaniu podczas jego tworzenia. Dla przykładu, algorytm może sugerować ekspertowi następną węzeł, z którego powinna być zdefiniowana nowa relacja.

Istnieje kilka metod strukturyzacji wiedzy. Dokonana zostanie analiza 3 podejść, w oparciu o pracę (Aimeur i in., 2003), gdzie zakłada się zastosowanie modeli wiedzy opartych na modelu sieci semantycznych. Ponadto analizowane metody nie pozwalają na tworzenie całkowicie dowolnych relacji pomiędzy pojęciami, sprowadzając tworzenie konceptualnego schematu dziedziny do tworzenia modelu drzewa. Możliwe jest wykonanie modyfikacji poprawiającej ten problem.

- *Metoda strukturyzacji oparta na strategii przeszukiwania w głąb*

W omawianej metodzie strukturyzacji ekspert rozpoczyna tworzenie grafu od węzła bazowego. Węzeł bazowy może być interpretowany jako węzeł już utworzonej sieci semantycznej. Ekspert, z możliwą pomocą inżyniera wiedzy, tworzy połączenie (relację) pomiędzy węzłem bazowym a jego potomkiem. Następnie, uwaga eksperta jest kierowana bezpośrednio na utworzonego potomka, ekspert nie jest proszony o wstępne określenie wszystkich potomków węzła bazowego. Proces wydobywania wiedzy przebiega w ten sam sposób dla kolejnych węzłów. Za każdym razem tworzona jest relacja pomiędzy węzłem a jego potomkiem. Następnie proces powtarzany jest w odniesieniu do potomka, który staje się węzłem bazowym, itd. Proces jest powtarzany, dopóki ekspert nie jest w stanie połączyć pojęcia, nad którym obecnie myśli, z żadnym innym pojęciem. Gdy osiągnięty jest ten punkt, ekspert wraca do poprzedniego obiektu i z niego kontynuuje proces.

Podejście umożliwia ekspertowi podążanie za daną ideą, bez żadnych opóźnień powodowanych przez konieczność analizy danego pojęcia w różnych kontekstach. Nie ma ryzyka zagubienia, ponieważ cała analiza wykonywana jest w ramach jednego wniosku i nie ma tak zwanych konceptualnych przemieszczeń (ang. *conceptual jump*) w ramach modelu konceptualnego. Odległość pomiędzy analizowanymi pojęciami jest zawsze równa 1. Wadą jest możliwość utracenia początkowej koncepcji organizacji schematu. Ekspert po powrocie do korzenia może nie być w stanie odzyskać początkowej koncepcji, jaką miał w zamyśle.

- *Metoda strukturyzacji oparta na strategii przeszukiwania wszerz*

Ekspert rozpoczyna pracę od węzła bazowego, dodając kolejno do schematu konceptualnego każdego z potomków węzła bazowego poprzez określenie relacji pomiędzy węzłem bazowym a każdym z jego potomków. Następnie ekspert traktuje każde pojęcie (węzeł) połączone relacją z węzłem bazowym jako nowy węzeł bazowy i określa dla niego wszystkich potomków. Krok ten jest powtarzany, dopóki nie zostanie określona struktura całego schematu konceptualnego.

Zaletą podejścia jest możliwość skoncentrowania się eksperta nad konkretnym pojęciem i możliwość analizy wszystkich asocjacji danego pojęcia przed kolejnym krokiem działania algorytmu. Ekspert nie wraca do analizowanego konceptu, każde pojęcie analizowane jest jednokrotnie. Niedogodnością jest wystąpienie konceptualnych przemieszczeń (ang. *conceptual jump*), szczególnie dotkliwych, jeżeli odległość pomiędzy poszczególnymi pojęciami (węzłami) jest duża. Im dłuższy jest dystans pomiędzy węzłami, tym większa się ryzyko, że ekspert straci kontekst, co spowoduje opóźnienie i nieścisłości. Objawem jest między innymi niezrozumienie wcześniej stworzonych relacji, szczególnie, gdy dany schemat ma dużą głębokość (zawiera dużą liczbę poziomów).

- *Metoda strukturyzacji oparta na metodzie HAKE (Hybrid Algorithm for Knowledge Elicitation)*

Algorytm HAKE został zaproponowany przez (Aimeur i in., 2003). Algorytm stanowi połączenie metody przeszukiwania w głąb i wszerz. Algorytm ma na celu wyeliminowanie wad obu przedstawionych wcześniej metod. Praca algorytmu rozpoczyna

się od podania przez eksperta węzła bazowego i określenia wszystkich potomków korzenia wraz z relacjami łączącymi korzeń z potomkami. Następnie ekspert koncentruje się na pierwszym potomku i tworzy podgraf zawierający wszystkie pojęcia związane z pojęciem reprezentowanym przez analizowany węzeł. Jest to możliwe do uzyskania, gdy traktuje się analizowanego potomka jako korzeń dla algorytmu przeszukiwania w głąb. Gdy zbudowany zostanie podgraf dla pierwszego potomka, to sam proces jest powtarzany dla każdego następnego tak, aby stworzyć podgrafy dla wszystkich potomków. Poziom, od którego rozpoczniemy stosowanie metody przeszukiwania wszcz, jest zależny od intuicji i intencji inżyniera wiedzy.

Inne podejście do strukturyzacji polega na modelowaniu koncepcyjnym, opartym na strukturze sieci semantycznych. Metoda została opisana w książce (Graves, 2002) i zakłada następujące kroki działania:

- wyliczenie pojęć w danej dziedzinie i ich relacji złożonych: identyfikacja wszystkich pojęć w danej dziedzinie;
- powiązanie pojęć z danej dziedziny poprzez zapisanie prostych zdań opisujących relacje: semantyczne związki mogą być wyrażone w postaci prostych zdań twierdzących, które przedstawiają związek pomiędzy dwoma pojęciami;
- wybór najważniejszych pojęć z listy: niektóre pojęcia mogą być zbyt ogólne dla danej dziedziny, a ich użycie może powodować zmniejszenie jakości modelu;
- zapisanie podstawowych pojęć jako węzłów schematu koncepcyjnego: każde z pojęć, które zostały zidentyfikowane, traktowane jest jako samodzielny węzeł sieci semantycznej;
- wykreślenie prostych zdań jako krawędzi grafu: pomiędzy pojęciami budowana jest relacja wynikająca z analizy zdania opisującego;
- dodanie do krawędzi oznaczeń liczebności: pozwala to uzupełnić powstałą sieć semantyczną o wartości liczbowe charakterystyczne dla danej dziedziny.

5.2.4 Typologia metod wydobywania wiedzy od eksperta

Istnieje wiele różnych metod wydobywania wiedzy od eksperta. Ich podział opiera się na wyróżnieniu trzech sytuacji (Hoffman i in., 1995): (i) co ekspert zazwyczaj robi (analiza zadań, jakie wykonuje ekspert), (ii) co ekspert mówi, że robi (różne typy wywiadów) oraz (iii) co ekspert robi, gdy poddamy go działaniu nowej, zaaranżowanej przez nas sytuacji (różnego rodzaju preparowane techniki obserwacji). Metody wydobywania wiedzy od eksperta dzielą się na następujące kategorie:

- (1) *Bezpośrednie techniki wydobywania wiedzy*: pozwalają na odkrycie, jaką wiedzę stosuje ekspert i jakich metod używa do rozwiązywania problemów w konkretnej dziedzinie. Techniki bezpośrednie oparte są na interakcji pomiędzy ekspertem a inżynierem wiedzy.
- (2) *Pośrednie techniki*: pozwalają na pozyskiwanie wiedzy z analizy tekstu, raportów. Współcześnie w tej klasie wyróżnimy następujące podklasy:
 - a. techniki oparte na zastosowaniu komputera (ang. *machine-aided techniques*): ekspert prowadzi dialog z oprogramowaniem (zazwyczaj wyposażonym w elementy sztucznej inteligencji), które w sposób półautomatyczny i interakcyjny buduje model wiedzy, ukrywając przed ekspertem złożoność symbolicznego języka, jakim się posługuje do budowy modelu;
 - b. techniki maszynowego uczenia (ang. *machine learning techniques*): automatyzują część procesu zdobywania wiedzy, bazując na zastosowaniu metod sztucznej inteligencji (ang. *data mining*).

Typologię opracowano na podstawie analizy następujących publikacji (Waterman, 1986), (Hoffman i in., 1995), (Hart, 1989), (Radomiński, 2001), (Wagner i in., 2002), (Wagner i in., 2003) oraz (Aimeur i in., 2003). Na dyskutowaną typologię składa się:

1. *Analiza typowych zadań* podczas tej analizy jest analizowane, co ekspert robi, gdy wykonuje swoje normalne, rutynowe zadania.
 - a. *Analiza dokumentacji*: zamiast bezpośredniej obserwacji, analizie podlegają dokumenty opisujące obserwowany proces.
 - b. *Analiza wykonywania działania (zwana również analizą pracy, analizą strukturalną i opisem zadania)*: koncentruje się na ciągłej analizie działania eksperta poprzez różne techniki obserwacji. Przykładem jest myślenie na głos podczas rozwiązywania problemów (ang. *think aloud problem-solving*) zwane również analizą protokołu (ang. *protocol analysis*). Osoba rozwiązująca dany problem lub wypełniająca dane zadanie jest poproszona o słowny komentarz swoich poczynań adekwatny do wykonywanych czynności. Werbalny przekaz jest zapisywany, przygotowana zostaje transkrypcja nazywana protokołem, która jest analizowana za pomocą określonego schematu kodowania (Wagner i in., 2002).
2. *Wywiady* – czyli analiza tego co ekspert mówi, że robi.
 - a. *Nieustrukturyzowany wywiad*: przybiera formę otwartego dialogu, w którym inżynier wiedzy zadaje otwarte pytanie w celu formalizacji wiedzy eksperta i ekstrakcji przesłanek, jakimi kieruje się ekspert podczas wnioskowania i podejmowania decyzji.
 - b. *Ustrukturyzowany wywiad*: Wywiad jest przygotowywany z wyprzedzeniem, ustalana jest agenda oraz cele każdej z sesji. Rola inżyniera wiedzy i eksperta jest jasno określona.
3. *Preparowane techniki (ang. contrived techniques)*: polegają na pewnej zmianie rzeczywistych sytuacji tak, aby postawić eksperta w nowych warunkach i wymusić na nim kreatywne działanie w kierunku, jaki nam odpowiada. Celem jest poznanie tego, co zrobi ekspert, gdy zostanie postawiony w sytuacji wymagającej od niego nowego podejścia do danego problemu/zagadnienia.
 - a. *Grupowe podejmowanie decyzji*: dla małej grupy osób zostaje postawiony problem, który jest rozwiązywany np. za pomocą techniki burzy mózgów. Problem jest tak konstruowany, że stawia przed uczestnikami dyskusji konieczność stworzenia kreatywnego rozwiązania.
 - b. *Zadanie oceniania i sortowania*: proces wydobywania wiedzy od eksperta polegający na analizie utworzonych przez eksperta rankingów. Metodologia bazuje na zasadach psychologicznych (za (Wagner i in., 2002)). Ekspert ocenia cechy różnych obiektów tworząc ranking, np. dystansując w ustalonej skali podobieństwa danych obiektów.
 - c. *Wymuszone przetwarzanie i problem limitowania informacji*: metoda wymuszonego przeważania polega na pewnym wymuszeniu zmian w znanych metodach postępowania poprzez zmianę procedur, sytuacji lub napływających danych. Ekspert jest bezpośrednio pouczany, aby do wykonania zadania zaadaptował określoną strategię.
 - d. *Konstruowanie grafów*: bazując, np. na grafach konceptualnych, ekspert przedstawia daną dziedzinę, konstruując adekwatny dla niej model w postaci grafu konceptualnego i dyskutując o nim z inżynierem wiedzy.
 - e. *Sortowanie kart (ang. card sorting)*: inżynier wiedzy zapisuje na kartach nazwy wcześniej zidentyfikowanych obiektów, doświadczeń i praw, a ekspert jest proszony o podzielenie ich na grupy. Następnie ekspert tłumaczy przesłanki, jakimi się kierował podczas tworzenia każdej z grup.

5.2.5 Metodologia przeprowadzania wywiadu kognitywnego

Wywiad kognitywny, analizowany np. przez (Moody i in., 1996), jest jedną z metodologii wydobywania wiedzy od eksperta. Technika zorientowana jest na wiedzę epizodyczną opartą na przypadkach, które reprezentują niepowtarzalne kombinacje sytuacji

lub zdarzeń, jakich doświadczył badany ekspert. Metodologia wywiadu kognitywnego jest skuteczna ze względu na swoje kognitywne nakierowanie na pamięć i może być z powodzeniem stosowana jako metodologia uzupełniająca dla przedstawionych powyżej metod. Na poszczególne zasady tworzenia wywiadu kognitywnego składają się:

- (1) Przymiśnienie kontekstu (ang. *context reinstatement*): łatwiej jest przymiśnić sobie konkretne zdarzenie, jeżeli przymiśnimy sobie bodźce związane z tym wydarzeniem. Jedna z zasad psychologii mówi, że wydarzenia powiązane z dużą huśtawką nastrojów są lepiej zapamiśtywane. Inżynier wiedzy prosi eksperta o przymiśnienie sobie swoich uczuć oraz stanu otoczenia podczas epizodu, jaki jest badany, (np. pory dnia, nastroju, pogody).
- (2) Utrzymanie koncentracji (ang. *focused retrieval*): główna zasada utrzymania koncentracji polega na eliminacji czynników zakłócających, jakimi są np. dźwięki, przerwy spowodowane przez inżyniera wiedzy. Ekspert powinien być skoncentrowany na swoim wywodzie. Pomaga w tym prawidłowa organizacja sesji: ciche, ustronne pomieszczenie, zamknięte oczy, itd.
- (3) Rozszerzenie uzyskiwanej wiedzy (ang. *extensive retrieval*): jeden z fenomenów pamięci mówi, że sukcesywnie odwoływanie się do tych samych obszarów pamięci w różnych sytuacjach zwiększa wielkość odzyskanej w tym procesie wiedzy. Inżynier wiedzy kreatywnie wymusza na ekspercie kolejne cykle przeszukiwania pamięci, nawet jeżeli poprzednie nie przyniosły rezultatu. W takim podejściu istnieje realne niebezpieczeństwo zadziałania zachowania przedstawionego między innymi w pracy (Loftus, 1997), polegającego na fabrykowaniu wspomnień. Proces rozszerzania uzyskanej wiedzy nie polega na kolejnym powtarzaniu tych samych pytań, ale na kreatywnym tworzeniu nowego podejścia. Można odwoływać się do pamięci, bazując na porządku chronologicznym lub poprosić eksperta o organizację wypowiedzi według porządku odwrotnego do chronologicznego. Ekspert może również odwoływać się do swojej pamięci z perspektywy trzeciej osoby.

5.3. Ontologia rozpatrywana jako model wiedzy

Ontologiczne podejście do wiedzy jest obecnie jednym z kluczowych elementów rozwijającej się idei społeczeństwa informacyjnego. Przesłanką do przyjęcia tak postawionej tezy jest powstanie i dynamiczny rozwój idei Semantic Web (Berners-Lee i in., 2001) oraz systemów biznesowych opartych na ontologii ((Fensel i in., 2001), (McGuinness, 2001)). Semantic Web umożliwia komputerom wyposażonym w mechanizmy sztucznej inteligencji analizę treści dowolnej strony WWW pod kątem wiedzy.

Termin ontologia pochodzi z dziedziny filozofii. Ontologia stanowi jeden z aspektów metafizyki, nauki stworzonej przez Arystotelesa, zajmującej się badaniem natury w ogólności (Grzegorzczak, 1997). Bazując na definicji (Lacey, 1999) można stwierdzić, że ontologia w ujęciu filozoficznym koncentruje się na badaniu bytu. Jednakże, jak pokazują między innymi (Chandrasekaran i in., 1999), (Vasconcelos i in., 2000) oraz (Fensel i in., 2001), od pewnego czasu termin ontologia jest wykorzystywany w zagadnieniach sztucznej inteligencji ze względu na spójny sposób ujęcia wiedzy. Główne kierunki wykorzystania ontologii w dziedzinie sztucznej inteligencji to (za (Fensel, 2001)): inżynieria wiedzy, przetwarzanie języka naturalnego, reprezentacja wiedzy, kooperatywne systemy informatyczne, zarządzanie wiedzą, handel elektroniczny. Ontologia znajduje również zastosowanie w zadaniach integracji informacji i tworzenia brokerów informacji (Maedche i Staab, 2000).

Zastosowanie idei ontologii w systemach nauczania zdalnego pozwoli na użycie metodologii i wyników badań dziedziny sztucznej inteligencji. Oparcie modelowania wiedzy na idei ontologii pozwoli na dokładniejsze wyrażenie problemów systemów nauczania zdalnego, w tym problemu budowy i zarządzania Learning Objects.

W dziedzinie sztucznej inteligencji ontologia jest zdefiniowana jako świadoma, formalna specyfikacja konceptów (pojęć) w danej dziedzinie i relacji pomiędzy nimi (Gruber, 1993). Ontologia jest formalną, sprecyzowaną specyfikacją współdzielonych konceptualizmów (Fensel i in., 2001). W tym kontekście, pojęcie konceptualizmu (ang. *conceptualization*) odnosi się do abstrakcyjnego modelu określonych fenomenów (konceptów) w świecie, który identyfikuje powiązania pomiędzy tymi fenomenami. Tak przedstawione wyobrażenie konceptualizmu zgodne jest z filozoficznymi korzeniami terminu. Według P. Abelarda (1079-1142), konceptualizm głosi, że uniwersalia są nie w rzeczach, lecz w umysłach, gdyż ogólne są nie rzeczy, nie nazwy, lecz pojęcia/koncepty. Termin *sprecyzowany* w definicji Fensela oznacza, że typy konceptów użytych i ich ograniczenia są znane. Natomiast termin *formalny* w definicji oznacza sprostanie konieczności maszynowego rozumienia danej ontologii.

Ontologia (dziedzinowa lub domenowa) jest wynikiem reprezentacji relatywnie małego wycinka świata i jest uzależniona od rozważanego zastosowania, w przeciwieństwie do ontologii *top-level* i ontologii reprezentacji (ang. *representational ontologies*), które odpowiednio przedstawiają ogólnie dostępne konceptualne struktury i metastruktury, (Maedche i Saab, 2000). Główną motywacją tworzenia ontologii dziedzinowej jest umożliwienie współdzielenia i ponownego wykorzystania wiedzy z określonej dziedziny pomiędzy różnymi aplikacjami i w ramach różnych zastosowań. W publikacji (Guarino, 1997) odparty jest zarzut mówiący o niemożliwości skonstruowania ontologii dziedzinowej, która sprosta wyzwaniom stawianym przez różne aplikacje.

Idea ontologii oparta jest na ogólnie akceptowanych ustaleniach, wiążących strukturę i zachowanie realnych obiektów. Przesłanki, które są podstawą do zrozumienia zagadnienia ontologii, zostały sformułowane w pracy (Chandrasekaran i in., 1999):

- w świecie istnieją obiekty;
- obiekty posiadają właściwości i atrybuty, które mogą przybierać różne wartości np. obiekt, cecha, wartość;
- obiekty mogą istnieć w różnych relacjach z innymi obiektami;
- relacje i właściwości mogą zmieniać się z upływem czasu;
- zdarzenia mogą zajść natychmiastowo w różnych okresach;
- istnieją procesy, które ciągle mają miejsce i w których uczestniczą obiekty;
- świat i jego obiekty mogą znajdować się w różnych stanach;
- zdarzenia mogą w efekcie powodować inne zdarzenia lub stany;
- obiekty mogą składać się z części.

Główne przyczyny tworzenia ontologii (Noy i McGuinness, 2001):

- dzielenie wspólnego zrozumienie struktury informacji pomiędzy osobami lub agentami internetowymi;
- umożliwienie ponownego użycie wiedzy domenowej;
- umożliwienie tworzenia świadomych przypuszczeń w danej dziedzinie;
- umożliwienie oddzielenia wiedzy dziedzinowej od wiedzy operacyjnej powiązanej z tą dziedziną;
- umożliwienie analizy wiedzy dziedzinowej.

Analiza przyczyn tworzenia ontologii pokazuje wysoki poziom zgodności z dziedziną nauczania zdalnego, szczególnie z problemem Learning Object. Podczas procesu tworzenia Learning Object kluczowym elementem jest zbudowanie modelu wiedzy danej dziedziny. Zadanie polega na rozpoznaniu i powiązaniu konceptów oraz relacji, jakie występują w określonej dziedzinie. Analiza ontologiczna wyjaśnia strukturę wiedzy dziedzinowej i pozwala na stworzenie relacji pomiędzy pojęciami oraz ustalenie metody kodowania wiedzy w odniesieniu do pojęć i zachodzących między nimi relacji (Chandrasekaran i in., 1999).

5.3.1 Inżynieria ontologii

Problemy pojawiające się podczas tworzenia i zarządzania konceptualnym schematem dziedziny można uogólnić do zagadnienia inżynierii ontologii (ang. *ontology engineering*). Termin inżynieria ontologii definiowany jest przez (Gomez-Perez i in., 2004) jako zbiór działań, które dotyczą procesu tworzenia ontologii, cyklu życia ontologii, metod i metodologii budowania ontologii oraz języków, które wspierają wszystkie wymienione powyżej czynności. Inżynieria (środowiska) ontologii umożliwia stworzenie kolekcji istotnych konceptów, pojęć z danej dziedziny oraz sformowanie ich do postaci struktury, bazując na kombinacji statystycznych i lingwistycznych danych. Środowisko inżynierii ontologii jest budowane w oparciu o paradygmat obiektowy. Stworzony model obiektowy może być analizowany i modyfikowany poprzez działanie na odpowiadającym mu obrazie konceptów i zachodzących pomiędzy nimi relacji.

Podejście stosowane w inżynierii ontologii jest znacząco różne od podejścia stosowanego podczas tworzenia tradycyjnych modeli danych, rozważanego np. w pracy (Tsichritzis i Lochovsky, 1990). Model danych reprezentuje strukturę, która ma zapewnić integralność w ramach zastosowania, dla którego model, został zaprojektowany. Model danych, jak dowodzi (Spyns i in., 2002), nie jest *a priori* projektowany w celu współdzielenia na poziomie wiedzy z innymi aplikacjami. Modele danych tworzone są dla konkretnych zastosowań. Często są wynikiem dyskusji pomiędzy projektantem a odbiorcami. W razie potrzeby, rozszerzenie funkcjonalności danego modelu dokonuje się odpowiedniej modyfikacji np. w oparciu o edycję plików XML lub struktur tabel w bazie danych.

Największym wyzwaniem inżynierii ontologii, podobnie jak zagadnienia tworzenia Learning Object, jest spełnienie postulatu uniwersalności. Model danych jest zorientowany na określone zastosowanie i konkretną implementację, a jakość jest oceniana przez jak najlepsze przystosowanie do wybranego zastosowania. Ontologia, w przeciwieństwie do modelu danych, powinna być jak najbardziej ogólna i niezależna. Jednocześnie ontologia powinna oddawać zawartość koncepcyjną danej dziedziny. Jak dowodzą (Borst i in., 1997), ontologia powinna osiągnąć jak najwyższy poziom ogólności w przekazywaniu detalicznej i specjalistycznej wiedzy. Paradoks ten jest trudny do rozwiązania, ponieważ należy określić granice poziomu ogólności (wszystkie rozważania dotyczą obszaru wyznaczonego przez granice określonego paradygmatu). Wyznacznikiem jakości ontologii, na który bezpośredni wpływ ma stopień ogólności, jest zapewnienie prawdziwej wiedzy na temat danej dziedziny w taki sposób, aby była ona dostępna dla różnych aplikacji i zastosowań w tej dziedzinie.

5.3.2 Ontologiczny opis dziedziny

Wyrażanie konceptualnego schematu dziedziny w postaci ontologii opiera się na procesie konceptualizacji dziedziny, bazując na klasach, instancjach, relacjach, funkcjach i aksjomatach, jakie są wyróżnione w dziedzinie (Visser i in., 1997). Zazwyczaj proces wymaga również stworzenia hierarchii klas oraz przypisania im atrybutów. W szczególności konceptualizacja zakłada stworzenie zbioru konceptów (pojęć) $\{c_1, \dots, c_i, \dots, c_n\}$, przedstawiających daną ontologię. W danym zbiorze c_i jest: przedstawieniem klasy, przedstawieniem instancji, przedstawieniem relacji, przedstawieniem funkcji lub przedstawieniem aksjomatu.

Według (Visser i in., 1997) oraz (Heflin i Hendler, 2000) ontologia definiowana jest jako następująca entka:

$$\Omega = \langle CD, ID, RD, FD, AD \rangle^2.$$

² Znak Ω jest między innymi używany w publikacji (Nawarecki i in., 2003)

Dokując identyfikacji poszczególnych elementów (Koprowska i Juszczyzyn, 2003), (Gawlik i Juszczyzyn, 2003):

- *CD* – zbiór definicji klas, przedstawia koncepty używane do opisu obiektów świata rzeczywistego;
- *ID* – zbiór definicji instancji, czyli zbiór określonych wystąpień obiektów świata rzeczywistego zdefiniowanych w zbiorze *CD*;
- *RD* – zbiór definicji relacji, zdefiniowanych na zbiorze *CD*. Relacje zdefiniowane w *RD* podzielone są na relacje, które należą do taksomicznych struktur dziedziny (relacje strukturalne) i te, które w nich nie uczestniczą (relacje niestrukturalne);
- *FD* – zbiór definicji funkcji działających na zbiorze konceptów, których wynikiem jest koncept. Zbiór definicji funkcji może być traktowany jako zbiór reguł wnioskowania;
- *AD* – zbiór definicji aksjomatów.

Często stosowanym zabiegiem, użytym np. pracy w (Koprowska i Juszczyzyn, 2003), jest ograniczanie wymiaru rozpatrywanej ontologii do entki:

$$\Omega = \langle CD, ID, RD \rangle.$$

Zbiory *FD* i *AD* są pomijane, a ontologia tak ograniczona nazywana jest *ontologią lekką* (ang. *lightweight ontologies*). Model wiedzy ontologii lekkiej wyraża się jedynie w zbiorze konceptów, instancji i łączących je relacji. Łatwo znaleźć analogię do prezentowanych wcześniej klasycznych definicji ontologii, stosowanych w sztucznej inteligencji. Modelowanie konceptualnego schematu dziedziny w oparciu o ontologię lekką prowadzi do pewnych uproszczeń, które w rezultacie poprawiają przejrzystość procesu modelowania. Ekspert nie jest zmuszany do sztucznego poszukiwania fenomenów, które mogą się składać na zbiór *AD*. Ontologia lekka, w pewien sposób, odwzorowuje klasyczne myślenie o wiedzy (pojęcie, relacja), które jest między innymi wykorzystywane w koncepcie sieci semantycznych.

5.3.3 Analiza operacji przekształcania informacji w wiedzę

Kluczowym czynnikiem w dyskusji o każdym modelu wiedzy, w tym ontologii, jest zrozumienie istoty operacji abstrakcji. Wyróżniamy dwie składowe operacji abstrakcji (Codd, 1972): agregację i uogólnienie. (Smith i Smith, 1977) definiują źródłowe pojęcie abstrakcji jako proces, w którym niektóre detale, cechy, właściwości, zostają celowo pominięte. Ukrycie szczegółów umożliwia skupienie się na ogólnych, kluczowych cechach obiektu. Proces abstrahowania - pojęcie filozoficzne – zdefiniowane w pracy (Lacey, 1999), polega na powstawaniu koncepcji na bazie powtarzalnych prezentacji pewnych jakości lub na podstawie abstrahowania czynników determinujących z określanego przedmiotu. Określenie, jakie elementy zostaną pominięte, dokonywane jest mając na uwadze sytuację, konkretne zastosowanie, jak również wolę analityka. Celem jest udostępnienie/pokazanie detali/cech/właściwości, które są powiązane z danym, istotnym dla danego modelu/procesu zastosowaniem/przeznaczeniem, jednocześnie ignorując pozostałe nieistotne cechy.

Często mamy do czynienia z sytuacją, gdy analiza rzeczywistości uwidacznia zbyt dużą liczbę szczegółów, aby zastosować pojedynczą abstrakcję. W takim przypadku dekomponuje się szczegóły do postaci hierarchii poziomów i grup. Każdy poziom lub grupa odpowiada pewnemu założonemu stopniowi szczegółowości. W takim rozumieniu abstrakcji zasadne jest odniesienie jej do pamięci semantycznej, zdefiniowanej np. przez (Anderson, 2000) lub (Maruszewski, 2002), która także ma budowę hierarchiczną. Można przyjąć, że tam, gdzie tworzy się hierarchię bazując na analizie cech semantycznych, buduje się model w oparciu o zastosowanie operacji abstrakcji, np. w celu zbudowania taksonomii pojęć.

Abstrakcja występuje w dwóch podstawowych formach, jako operacja agregacji i uogólnienia. Według (Codd, 1972), operacja agregacji odnosi się do formy abstrakcji,

w której zależność pomiędzy obiektami jest przeniesiona na obiekt wyższego poziomu. Podczas tworzenia agregacji wiele cech zależności jest ignorowanych, wybrane cechy są natomiast agregowane do postaci skupiska. Agregacja, definiowana przez (Tsichritzis i Lochovsky, 1990), jest abstrakcją tworzącą obiekt nadrzędny na podstawie swoich obiektów składowych.

Operację uogólnienia – według (Codd, 1972) – można zdefiniować jako abstrakcję, w której zbiór podobnych obiektów sprowadzony jest do postaci obiektu ogólnego. Podczas uogólniania możliwe jest utracenie indywidualnych różnic pomiędzy obiektami. (Tsichritzis i Lochovsky, 1990) traktują uogólnienie jako operację zliczania zbioru konkretów lub typów do jednego ogólnego typu. Ponadto uogólnienie, prowadzące od konkretnego do typu, nazywane jest bardzo często klasyfikacją – w przeciwieństwie do uogólnienia kilku typów w jeden typ. (Smith i Smith, 1977) uogólnieniem definiują abstrakcję, która umożliwia traktowanie klasy pojedynczych obiektów jako ogólny, pojedynczy, zdefiniowany obiekt. Autorzy w swojej pracy bardzo mocno akcentują ważność abstrakcji - uogólnienia, przytaczając między innymi zastosowanie tego mechanizmu w codziennym życiu, np. w nabywaniu umiejętności, posługiwaniu się językiem naturalnym. Każdy z nas rozpoczyna od obserwacji konkretnych egzemplarzy, na podstawie których nabywa wiedzę na temat klasy, która jest reprezentowana przez egzemplarze. Uogólnienie pozwala na dziedziczenie cech – obiekty potomne dziedziczą cechy obiektu bazowego.

Konceptualny schemat dziedziny jest strukturą, która wyraża wiedzę eksperta w postaci ontologii. Ekspert definiuje elementy ontologii korzystając z operacji abstrakcji. Każde z pojęć jest abstrakcją posiadającą określoną głębokość pewnego konceptu dziedziny. Operacja agregacji i uogólnienia wpływa na ustalenie relacji pomiędzy pojęciami oraz na zbudowanie wymiaru każdego z pojęć – poprzez określanie kontekstu.

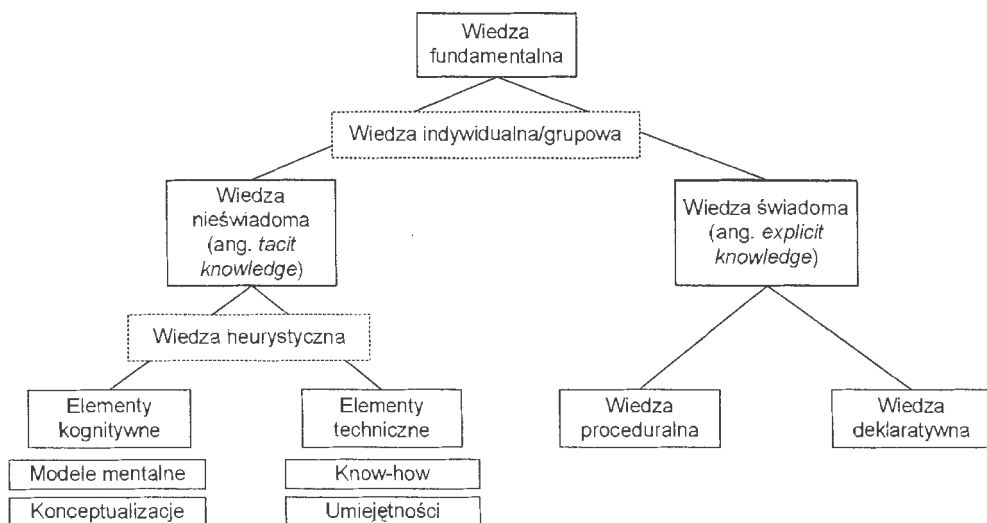
5.3.4 Wiedza fundamentalna i operacyjna

W nauczaniu akademickim ważną czynnością jest rozróżnienie wiedzy fundamentalnej i operacyjnej. Wyszczególnienie obszarów dedykowanych danemu typowi wiedzy pozwala na zastosowanie odpowiedniej strategii i metodyki nauczania. Wymóg rozróżnienia wiedzy wynika z konieczności odpowiedniego dostosowania procesu „uczenia się – nauczania”, który jest inny dla wiedzy fundamentalnej, a inny dla wiedzy operacyjnej. Trudności pojawiają się w konieczności efektywnego godzenia obu typów wiedzy, ponieważ na każdy z kursów akademickich składa się zarówno wiedza fundamentalna, jak i operacyjna. W nauczaniu akademickim, zarówno uniwersyteckim, jak i politechnicznym, wiedza fundamentalna przeważa.

Wiedzę rozpatrywaną jako obiekt i cel nauczania można podzielić na dwa podstawowe rodzaje: fundamentalno-teoretyczną i operacyjną (dokładniejsze omówienie w pracy (Kushtina i Różewski, 2003)). Wiedza fundamentalna odwzorowuje myślenie konceptualne, w wyniku którego mogą być sformułowane nowe paradygmaty, problemy, założenia zadań, zasady zachowania, itp. Wiedza operacyjna jest konieczna do realizacji scenariuszy, algorytmów wykonania operacji. Sytuacje, z jakimi spotyka się człowiek w swoim codziennym działaniu, bazują na jednoczesnym wykorzystaniu tych dwóch rodzajów wiedzy w różnych proporcjach – zależnie od poziomu złożoności. Istniejące metody reprezentacji wiedzy i technologie dają możliwość tworzenia wystarczająco efektywnego systemu nauczania wiedzy operacyjnej (komputerowe symulatory, systemy ekspertowe, itd.). Jest to wykonywalne, ponieważ możliwe jest adekwatne łączenie ilościowych ocen zdobytych umiejętności (szybkość, dokładność) z odpowiadającą zadaniu teoretyczną bazą wiedzy. Nauczanie wiedzy fundamentalnej jest wciąż utrudnione, ponieważ brakuje efektywnych metod ilościowych, określających przyrost wiedzy fundamentalnej.

Wiedza fundamentalna w ujęciu wielu badaczy, w tym np. (Polanyi, 1983), dzieli się na wiedzę ukrytą – nieświadomą (ang. *tacit knowledge*) oraz wiedzę świadomą (ang. *explicit*

knowledge). Wiedza ukryta, jak to przedstawia (Carvalho i in., 2000), jest subtelną, osobistą wiedzą, angażującą własny system wierzeń, rozumienia świata i jego wartościowania. Wiedza nieformalna powiązana jest z własnym doświadczeniem pozwalającym na wykonywanie różnych zadań. Wiedza świadoma (formalna) jest wyrażana poprzez język i przekazywana jako informacja powiązana z procedurami, bazami danych, patentami. Prawdziwa wartość wiedzy nieświadomej leży w jej złożoności. Jednakże, jak pokazuje (Tece, 1998) analizując koszt transferu wiedzy, im wiedza jest bardziej sformalizowana, tym bardziej ekonomiczne jest jej przesyłanie. Wiedza taka jest jednoznacznie interpretowana, ma wyraźniejszą strukturę i zawiera mniej niejasności.



Rys. 47. Taksonomia wiedzy fundamentalnej (opracowanie własne na podstawie (Vasconcelos i in., 2000))

Rysunek 47 przedstawia wielowymiarową strukturę wiedzy zawartą w pojęciu wiedzy fundamentalnej. Student osiągnąć musi zarówno wiedzę, którą można wyrazić w sposób formalny, jak i wiedzę, którą trzeba poddać pracochłonnemu procesowi przygotowania (transformacji, tłumaczenia), ponieważ jest wyrażona w sposób nieformalny. Istnieje szereg metod wyrażania wiedzy proceduralnej i deklaratywnej. Przykłady można znaleźć w pracy (Mulawka, 1997) i (Knosala, 2002). Dostęp do wiedzy nieświadomej można uzyskać np. poprzez proces formalizacji polegający na współpracy inżyniera wiedzy z ekspertem. Jednakże wymagania reprezentacji wiedzy fundamentalnej potrzebują opracowania odpowiedniego modelu pozwalającego na reprezentację podstawowych pojęć o głębokości uzależnionej od celów nauczania.

5.3.5 Zestawienie modeli reprezentacji wiedzy w kontekście wymagań modelowania Learning Object

Bazowy model wiedzy przygotowany do pracy w środowisku nauczania zdalnego powinien opierać się na strukturach poznawczych (pojęciach). Jednostką modelu powinno być pojęcie – koncept. Model integruje w swojej strukturze: jednostkę, operację na jednostkach, system wnioskowania z niezbędnym systemem odniesienia oraz zakres dziedziny, co jednoznacznie pozwala na stworzenie ontologii dziedziny. Opierając się na takich założeniach, model ontologiczny zapewni spójną komunikację na poziomie wiedzy dzięki wymianie komponentów wiedzy.

Określić można, jakie są wymagania modelowania konceptualnego schematu dziedziny w odniesieniu do modeli wiedzy:

- Model reprezentacji wiedzy powinien bazować na graficznym paradygmacie reprezentacji wiedzy.
- Model reprezentacji wiedzy powinien umożliwiać wydzielenie poszczególnych obiektów, składających się na dany system wiedzy i powiązanie ich relacjami (określenie ontologii).
- Model, bazując na operacji abstrakcji, powinien umożliwić wydzielenie jednostki podstawowej modclowanego świata, np. konceptu. Na poziomie semantycznym jednostka powinna być jednoznaczna i adekwatna do kognitywnych uwarunkowań człowieka.
- Wymagania środowiska nauczania zdalnego określają zapewnienie pewnego stopnia formalności zapisu, aby możliwe było umieszczenie rezultatów modelowania w systemie informatycznym klasy LMS/LCMS i opisanie ich za pomocą jednego ze standardów metadanych np. IEEE LOM.
- Model wiedzy musi pozwalać na modelowanie wiedzy fundamentalnej, która oparta jest na pojęciach i umieszczona powinna zostać w pamięci długoterminowej studenta.
- Sformalizowany system, przeznaczony dla przedstawienia wiedzy w danej dziedzinie, powinien powiązać wiedzę dziedzinną z metodyką jej nauczania oraz językiem manipulacji modelem wiedzy.
- Ponieważ jedną z głównych cech ontologii jest osadzenie w konkretnej dziedzinie, model wiedzy powinien potrafić efektywnie modelować kontekst danego obiektu wiedzy.

Określenie modelu wiedzy najlepiej dostosowanego do wymagań modelowania konceptualnego schematu dziedziny poprzedzić należy dyskusją na temat problemu modelowania wiedzy. Problem modelowania wiedzy opiera się na zagadnieniu reprezentacji wiedzy. Zagadnienie reprezentacji wiedzy jest szeroko analizowane już od początku badań dotyczących logiki. Badania nabrały nowego wymiaru wraz z pojawieniem się i późniejszą ewolucją prac w zakresie sztucznej inteligencji.

W pierwszej kolejności należy przedyskutować podstawowe metody reprezentacji wiedzy przedstawione w tabeli 19. Model regułowy i model sieciowy tworzą podstawy klasyfikacji modeli reprezentacji wiedzy. Ze względu na swoje cechy modele te są przeznaczone do innych zastosowań. Model regułowy, dzięki łatwości przeprowadzenia wnioskowania, jest podstawowym mechanizmem stosowanym w systemach ekspertowych. Bazując na faktach opisanych za pomocą reguł, przy wykorzystaniu zasady *modus ponens*, możliwe jest wnioskowanie w przód lub w tył. Ograniczeniem jest konieczność ścisłej formalizacji rozpatrywanego świata do postaci predykatów i reguł. Zapis taki jest mało przyjazny dla człowieka, ale równocześnie ze względu na matematyczną postać, jest bardzo dobrze przystosowany do pracy w środowisku komputerowym.

Model sieciowy jest oparty na innej idei. Wiedza ujęta jest w postaci struktury, której architektura determinuje znaczenie poszczególnych składników modelu. System wiedzy w modelach sieciowych opiera się na pojęciach zgodnych w swej naturze z aparatem poznawczym człowieka. Podejście charakteryzuje się dużą elastycznością, dlatego ważnym elementem jest precyzyjne określenie dziedziny.

Brak precyzyjnych formalizmów powoduje trudności z komputerową analizą tworzonych systemów wiedzy, bazujących na modelu sieci semantycznych. Jedno z możliwych rozwiązań to wykorzystanie opracowanej przez Charlesa S. Peirce'a ponad 100 lat temu logiki stanowiącej model sieciowy, tworzony w oparciu o grafy egzystencjalne (Roberts, 1973), (Higgins i in., 2001). Grafy egzystencjalne są graficznym, symbolicznym środowiskiem reprezentacji wiedzy. Opracowana notacja symboliczna ma siłę logiki pierwszego rzędu. Przykładowym modelem reprezentacji wiedzy, opartym na idei grafów egzystencjalnych, są grafy konceptualne (Sowa, 1979).

**Tab. 19. Zestawienie podstawowych metod reprezentacji wiedzy
(źródło: (Różewski, 2004))**

	<i>Jednostka atomowa</i>	<i>Opis dziedziny</i>	<i>Metoda wnioskowania</i>	<i>Algorytmy wnioskowania</i>	<i>Zastosowanie</i>
<i>Model Regułowy</i>	Fakty (predykat)	Reguły, twierdzenia	Modus ponens	Wnioskowanie w przód i wnioskowanie w tył	Bazy wiedzy systemów ekspertowych
<i>Model Sieciowy</i>	Pojęcia	Relacja pomiędzy pojęciami	Wnioskowanie polega na „poruszaniu się” po grafie, (Mulałka, 1996)	Na podstawie inspekcji sieci wyprowadza się różne konkluzje	Sieci semantyczne

Idea tworzenia Learning Object w oparciu o integrację pojęć z jednej dziedziny wymaga wykorzystania sieciowego modelu wiedzy. Analizie należy poddać główne metody modelowania sieciowego wiedzy: model sieci semantycznych i model sieci neuronowych, w oparciu o tabelę 20. Podział obu dyskutowanych modeli zarysowuje się już na początku analizy. Oba modele powstały jako wyniki badań nad mechanizmem pamięci. Sieci semantyczne koncentrowały się na aspektach poznawczych, odbywających się w umyśle człowieka, podczas gdy sieci neuronowe zbudowane są na podstawie analizy rzeczywistych procesów fizycznych, chemicznych i biologicznych odbywających się w mózgu i stanowią próbę odwzorowania rzeczywistych, umieszczonych w nim struktur. Podejście stosowane w przypadku sieci semantycznych wywodzi się z nauk o poznaniu, kognitywistyki. Natomiast podejście polegające na modelowaniu procesów za pomocą sieci neuronowych nazywane jest koneksjonizmem (Nęcka, 2003). Z przedstawionych w poprzednich rozdziałach rozważań, między innymi na temat ontologii, wynika koncentracja w dalszej części analizy, na modelach bazujących na sieciach semantycznych.

Model sieci semantycznych, będący modelem referencyjnym sieciowej reprezentacji wiedzy, stanowi graficzną reprezentację wiedzy opartą na kognitywnym, poznawczym ujęciu otaczającej nas rzeczywistości. Sieci semantyczne powstały w wyniku badań przeprowadzonych przez Quillian'a (Quillian, 1968) na temat struktury i budowy pamięci ludzkiej. W podstawowej formie sieci semantycznej węzły odzwierciedlają obiekty, natomiast połączenia pomiędzy węzłami reprezentują zależności semantyczne. Sieć semantyczna istnieje zawsze wtedy, gdy informacja jest przedstawiona za pomocą grafu, co pokazuje (Griffith, 1982). Badania psychologiczne, ściślej badania w dziedzinie nauk kognitywnych, przez wiele lat były czynnikiem rozwoju sieci semantycznych. Jak pokazuje (Gordon, 2000), modele wiedzy oparte na sieciach semantycznych są zarówno dobrze rozumiane przez ludzi, jak również możliwe jest dostosowanie sieci semantycznych do automatycznego przetwarzania. Pewne sieci semantyczne zostały zaprojektowane, aby modelować przypuszczalne, kognitywne mechanizmy poznawcze człowieka (np. mapy skojarzeń). Celem projektowym innej grupy badawczej było osiągnięcie komputerowej skuteczności reprezentacji wiedzy (np. knowledge grid (Zhuge, 2002)).

**Tab. 20. Zestawienie sieciowych modeli reprezentacji wiedzy
(źródło: (Różewski, 2004))**

	<i>Wyznacznik procesu modelowania</i>	<i>Sposób przechowywania wiedzy</i>	<i>Atomowa jednostka</i>	<i>Struktura</i>	<i>Mechanizm</i>	<i>Podstawowe zadania</i>
<i>Model Sieci Semantycznej</i>	Metafora działania pamięci semantycznej	Oparty na relacjach pomiędzy węzłami	Pojęcie	Grafu	Abstrakcyjnego odwzorowania, będący modelem instrumentalistycznym	Wizualizacja zależności semantycznych
<i>Model Sieci Neuronalnej</i>	Metafora działania mózgu	Oparty na numerycznych wagach przypisanych do wewnętrznych połączeń	Neuron	Grafu warstwowego	Mocno rozproszona reprezentacja dokonywanych w sposób równoległy transformacji (obliczeń)	Problem klasyfikacji

Idea sieci semantycznych jest zbyt uniwersalna i przez to bardzo skomplikowana. Dla konkretnych aplikacji podstawowa koncepcja uległa adaptacji. Ewolucji ulega zrozumienie pojęcia konceptu i relacji, bazowych komponentów każdego z modeli wiedzy. Koncept stanowi logiczną jednostkę modelu wiedzy, podczas gdy relacja jest mechanizmem tworzenia złożonych struktur. Przedefiniowaniu ulegają rola i działanie konceptu i relacji według wymagań danej aplikacji.

Koncept w ujęciu formalnej analizy konceptów (ang. *Formal Concept Analysis*) rozumiany jest jako jednostka procesów umysłowych, głównie procesu myślenia. Formalna analiza konceptów jest matematycznym modelem wiedzy, bazującym na filozoficznym rozumieniu pojęcia konceptu, opisanym w (Cole i Tilley, 2003) oraz (Ganter i Wille, 1999). Formalizacja bazuje na przekonaniu, że ludzkie procesy myślowe i komunikacyjne zawsze są umieszczone w określonym kontekście, który determinuje konkretne znaczenie poszczególnych konceptów. Formalna analiza konceptów koncentruje się na formalizacji konceptów poprzez formalizację kontekstu.

W modelu map konceptualnych (ang. *Conceptual Maps*) Novak'a (Novak, 1991), koncept definiowany jest jako dostrzegalna regularność w zdarzeniach lub obiektach, wyznaczana przez nazwę (etykieta). Zależności pomiędzy konceptami budowane są poprzez tworzenie twierdzeń łączących kilka konceptów (co najmniej dwóch) do formy sensownego stwierdzenia. Stwierdzenia takie nazywane jest semantyczną jednostką (ang. *semantic units*). Koncepty rozmieszczane są w postaci hierarchii, gdzie na samej górze są najbardziej ogólne koncepty, natomiast na dole znajdują się koncepty najbardziej dokładne, adekwatne dla danej dziedziny. Zawartość i struktura mapy wyznaczana jest przez ekonomię poznawczą (ang. *cognitive economy*). Ekonomia poznawcza rozumiana jest jako semantyczna organizacja lokalizacji każdego z pojęć w schemacie pojęciowym. Ekonomia poznawcza polega na tym, że pojęcie – agregat innych pojęć, jest w hierarchii pojęć umieszczone wyżej po to, aby swoim zasięgiem objąć wszystkie zależne od niego pojęcia. Kolejnym uwarunkowaniem map konceptualnych jest możliwość grupowania wiedzy (ang. *knowledge clustering*). Zasada wywodzi się z teorii ram i polega na umożliwieniu opisanego abstrakcyjnego lub realnego

obiektu za pomocą pewnej części mapy. Idea map konceptualnych opiera się na teorii psychologicznej Davida Ausubela (Ausubel, 1963), której główne założenie sprowadza się do stwierdzenia, że nauczanie polega na dołączaniu nowych konceptów do istniejących już w umyśle studenta struktur poznawczych, co zostało nazwane nauczaniem przez rozumienie (ang. *meaningful learning*) i jest przesłanką działania map konceptualnych.

Nie wszystkie połączenia konceptów z relacjami są na pierwszy rzut oka sensowne, co trudno ocenić w sposób formalny. W przypadku grafów konceptualnych (ang. *Conceptual Graphs*) poprawność jest zapewniona poprzez wprowadzenie formy kanonicznej jako klasy grafów, które powstały na podstawie kanonu. Problem określania kontekstu został w grafach konceptualnych rozwiązany poprzez zbudowanie struktury kanonu przedstawionego w (Cyre, 1997) i (Ellis, 1995). Kanon jest punktem wyjścia dla każdego grafu konceptualnego w danym kontekście. Definiuje semantyczne ograniczenia i zapewnia wymaganą informację na temat konkretnej dziedziny zastosowania. Kanon definiowany jest poprzez następujące elementy: hierarchię konceptów (uporządkowaną relacjami), hierarchię zdefiniowanych relacji, zbiór znaczników indywidualnych oraz funkcję mapującą, która wiąże elementy zbioru indywidualnych znaczników z hierarchiami konceptów i relacji. Wszystkie wygenerowane z kanonu grafy konceptualne, nazywane grafami kanonicznymi, bazują na zasobach kanonu i są poprawne (prawdziwe) w danej dziedzinie. Model grafów konceptualnych, zaproponowanych przez John F. Sowa (Sowa, 2000), (Sowa, 1984) zawiera pewną liczbę operacji (Ellis, 1995), które pozwalają uzyskiwać nowe grafy (grafy kanoniczne) na podstawie kanonu, z wykorzystaniem następujących operacji kanonicznych: kopiowanie, ograniczenie, uproszczenie, połączenie, stopienie.

Wiele z metod reprezentacji wiedzy wykształciło własne sposoby umożliwiające formalne ustalenie kontekstu. Sieci semantyczne nie pozwalają na dokładne zarysowanie semantyki, co zostało wykazane między innymi przez (McDermott, 1981). Sieci semantyczne są zazwyczaj używane do reprezentacji znaczenia obiektów, bez postawienia formalnych granic wnioskowania. Powoduje to trudności z analizą komputerową, ponieważ nie można deterministycznie zadeklarować analizowanej przestrzeni wiedzy – kontekstu. Kontekst wyznacza ramy wiedzy nadającej się do interpretacji, ustanawia granice, w obrębie których przeprowadzone jest wnioskowanie i wszelkie inne operacje na wiedzy opisanej za pomocą modelu.

Wiedza jest w modelu formalnej analizy konceptów zapisana w formie tabelarycznej. Wiedza zapisana w formie tabeli reprezentuje wieloznaczny kontekst (Wille, 1996). W celu uzyskania jednoznacznie spolaryzowanych konceptów trzeba dokonać transformacji do jednowymiarowego kontekstu (tabeli) za pomocą konceptualnego skalowania (ang. *conceptual scaling*). Należy określić, który z atrybutów jest istotny i jak powinien być on transformowany do jednowymiarowego obszaru. Formalny kontekst definiuje się jako $K := (G, M, I)$, gdzie G – jest zbiorem obiektów, M – jest zbiorem atrybutów, natomiast I stanowi binarną relację pomiędzy obiektami i atrybutami taką, że $I \subseteq G \times M$. W wielu sytuacjach konieczne jest analizowanie multi-kontekstu zamiast pojedynczego kontekstu. W takim przypadku należy dokonać syntezy kilku zdefiniowanych kontekstów, mających wspólny mianownik, do postaci jednego wspólnego kontekstu.

Kontekst, w ujęciu map tematycznych (ang. *Topic Maps*), rozumiany jest jako lokalizacja wiedzy w strukturze zasobów danej organizacji. Wiedza nie jest abstrakcyjną wartością, ale występuje w postaci plików lub dokumentów. Mapy tematyczne (ISO/IEC 13250, 2000) zbudowane są z tematów oraz relacji pomiędzy tematami i zasobami. Każdy z tematów umieszczony w relacji odgrywa w niej pewną rolę, która jest zdefiniowana przez typ roli. Typowy diagram mapy tematycznej podzielony jest na dwie części. Pierwszą możemy nazwać dziedziną tematu, drugą dziedziną zasobów. Tematy i powiązania pomiędzy tematami tworzą sieć semantyczną, rozciągniętą nad zasobami i skojarzoną z nimi za pomocą

relacji wystąpienia. Kontekst wyznaczony jest nie tylko na poziomie semantycznym, ale również odwzorowany jest na poziomie zasobów.

Analiza możliwości rozszerzenia kontekstu modelu wiedzy w odniesieniu nie tylko do zasobów, ale również do umiejętności i zdolności pracowników, została przeprowadzona w ramach prac nad modelem mapy umiejętności (ang. *skill maps*) (Abramowicz i in., 2002). Mapy umiejętności, bazujące na mapach tematycznych, mają dodaną dodatkową warstwę umiejętności. Mapy umiejętności powstały, ponieważ mapy tematyczne są niedostosowane do analizowania umiejętności i wiedzy pracownika np. w trakcie przeszukiwania repozytorium wiedzy w postaci map tematycznych. Trzecia warstwa przechowuje personalizowane informacje na temat posiadanych umiejętności pracownika oraz informacje o tym, jak zostały one nabyte.

W modelu wizualizacji/reprezentacji wiedzy wymagane jest zapewnienie wysokiego stopnia komunikacji i interakcji pomiędzy modelem, a pracującymi z nim profesjonalistami, często nieposiadającymi wiedzy na temat modelowania wiedzy. Ekspert, aby zapewnić efektywną pracę, powinien mieć komfortowe środowisko pracy, oparte na prostych zasadach dotyczących modelu wiedzy i efektywnym języku manipulacji wiedzą. Zaproponowane środowisko powinno również współgrać z psychologicznymi uwarunkowaniami nauczania.

Modelem najlepiej dostosowanym do zagadnienia wizualizacji modelowania Learning Object są *mapy konceptualne*. Związki semantyczne, łączące poszczególne pojęcia bezpośrednio wynikają z koncepcji nauczania danej wiedzy i są reprezentacją sposobu poruszania się, wnioskowania w danej dziedzinie nauczyciela i eksperta. Mapy konceptualne pozwalają na dokładne określenie dziedziny, w jakiej przeprowadzane jest modelowanie, umożliwiając elastyczne manipulowanie konceptami. Wizualizacja danego wycinka dziedziny jest bezpośrednio transformowana na edukacyjne podejście do nauczania danej wiedzy bez potrzeby pośrednich transformacji.

5.4. Koncepcja języka modelowania wiedzy dziedzinowej

Do przekazywania wyników współpracy aktorów uczestniczących w procesie „uczenia się - nauczania” potrzebny jest język formalny, który daje możliwość uzyskania jednoznacznego porozumienia pomiędzy aktorami. Przygotowany język powinien umożliwić opis wiedzy zależnie od kontekstu, jak również zapewnić automatyzację procesu tworzenia konceptualnego schematu dziedziny. Jednym z wyznaczników projektowych dla omawianego języka jest specyfika procesu nauczania zdalnego. Dlatego potrzebne jest przeprowadzenie identyfikacji procesu nauczania zdalnego. Pozwoli to wyróżnić i dokładnie określić procedury i operacje oraz aktorów składających się na ten proces.

W tradycyjnym nauczaniu podstawowym sposobem przedstawienia i przekazywania wiedzy jest język naturalny. Różnego rodzaju sztuczne języki symboliczne oraz środki medialne są wykorzystywane jako dodatkowe możliwości po to, aby wzmocnić semantykę wyrazu języka naturalnego, zarówno podczas wygłaszania wykładów, jak i w procesie przygotowywania materiałów dydaktycznych (Kushtina i Rózewski, 2003). Komputerowe środowisko, z punktu widzenia szeregu czynników ergonomicznych i psychologicznych (Gregory i Colman, 2002), tworzy duże ograniczenia w wykorzystaniu języka naturalnego w tej samej objętości i jakości, jak tego potrzebuje proces nauczania i właściwy mu wykonawczy proces kierowania. Z drugiej strony, komputerowe środowisko tworzy praktycznie nieograniczone możliwości wykorzystania symbolicznych/sztucznych języków i środków medialnych.

W nauczaniu zdalnym i tradycyjnym treści długoterminowego i krótkoterminowego planowania w większym stopniu zbliżone są do siebie. Istotna różnica pojawia się na poziomie realizacji planów, czyli podczas wypełniania operacji bezpośredniego przekazu wiedzy od nauczyciela do studenta. Przyczyną tych różnic jest nie tylko brak bezpośredniego

kontakty, ale także inne środowisko nauczania (cybernetyczna przestrzeń), do którego niemożliwe jest przeniesienie tradycyjnych metod polegających na wykorzystaniu w pełnym zakresie języka naturalnego.

Przy dowolnym sposobie organizacji nauczania nauczyciel nie jest jedynym źródłem wiedzy – równorzędną rolę odgrywają książki, media, otoczenie, z którymi komunikacja odbywa się za pomocą nieograniczonego języka naturalnego. Dlatego opracowując język reprezentacji, przekazywania oraz manipulacji wiedzą w warunkach nauczania zdalnego konieczne jest, aby korespondował on z językiem naturalnym i językami przedstawiania wiedzy właściwymi innym źródłom wiedzy. Innymi słowy, konieczne jest, aby nowa wiedza zdobyta poza systemem nauczania tradycyjnego, mogła być dołączona do systemu wiedzy studenta tworzonego w trakcie nauczania.

Analizując paradygmat kognitywistyczny, przedstawiony w pracy (Heylighen, 1990), można wyróżnić dwa aspekty języka manipulacji wiedzą: aspekt statyczny i dynamiczny. Aspekt dynamiczny występuje w procesie przetwarzania informacji. Polega na wykonywaniu transformacji w celu przeprowadzenia analizy. Analogiczny proces zachodzi podczas manipulacji wiedzą w procesie nauczania, np. podczas zwiększania semantycznej głębokości pojęcia. Aspekt statyczny reprezentowany jest poprzez ideę reprezentacji, która pełni rolę stabilnej struktury, pozwalającej na przetwarzanie.

Środowisko nauczania zdalnego nie pozwala na wykorzystanie języka naturalnego w pełnym wymiarze jako narzędzia manipulacji i przekazywania wiedzy. Z tego wynika przesłanka opracowania specjalistycznego, symbolicznego języka o ograniczonej semantyce. Ze względu na przedstawione wcześniej argumenty, język manipulacji wiedzy przystosowany do potrzeb nauczania zdalnego powinien umożliwić (Kusztina i Różewski, 2003):

- (a) korespondencję z językiem naturalnym i językami reprezentacji wiedzy, pochodzącymi z innych źródeł (np. wiedzą wyrażoną za pomocą map konceptualnych lub grafów konceptualnych);
- (b) wystarczający poziom jednoznaczności odczytu struktur;
- (c) wystarczającą semantyczną wyrazistość, która pozwala na tworzenie złożonych struktur;
- (d) korekty zawartości struktury w zależności od kontekstu;
- (e) tworzenie złożonych struktur na bazie prostych;
- (f) połączenie odrębnych struktur w sieć semantyczną z ograniczoną semantyką łączy;
- (g) połączenie w ramach jednego modelu obiektywnej wiedzy z dziedziny przedmiotowej i metodyki jej nauczania.

Każde z wymienionych zadań może być wykonywane na różnym poziomie reprezentacji wiedzy, jak to pokazuje (Brachman, 1979). Poziom reprezentacji wiedzy określa strukturę, formę podstawowych prymitywów i operatorów oraz wyszczególnia zbiór operacji i praw, jakimi kierujemy się na danym poziomie w procesie wnioskowania i manipulacji wiedzą. Najniżej umieszczony jest poziom implementacyjny. Na tym poziomie istnieją tylko struktury danych, na podstawie których budowane są formy logiczne poziomu drugiego. Drugi w kolejności poziom – logiki, pozwala na zrozumiałe i racjonalne podzielenie wiedzy. Następny poziom – epistemologiczny, pozwala na umieszczenie jednostek konceptualnych w strukturze dziedziczenia i wzajemnych zależności. Poziom konceptualny pozwala na ustanowienie niezależnego od języka zbioru elementów konceptualnych, z którego wszystkie wyrażone koncepty mogą być wywodzone. Ostatni z poziomów, poziom lingwistyczny, uzależnia podstawowe struktury modelu, np. prymitywy, od języka. Na tym poziomie można oczekiwać, że wraz ze wzrostem adekwatności modelu poszczególne elementy będą zmieniać swoje znaczenie.

Na poziomie reprezentacji wiedzy zaproponowane jest użycie dwóch struktur: *jednostki atomowej* – pojęcia oraz *struktury sieciowej* – konceptualnego schematu dziedziny. Główne przesłanki przemawiające za takim podziałem pochodzą z dziedziny kognitywistyki. Nauka

o poznaniu pozwala wyodrębnić podstawową jednostkę myślową, używaną przez człowieka – pojęcie. Poziom logiki oparty jest na sformułowaniu szeregu praw manipulacji wiedzą, zarówno na poziomie schematu konceptualnego dziedziny, jak i na poziomie konkretnego pojęcia.

Bazując na wcześniejszych założeniach dotyczących idei ontologii wiedzy dziedzinowej można stwierdzić, że identyfikacja i formalizacja wiedzy w danej dziedzinie sprowadza się do zadania zbudowania ontologii danej dziedziny. Z definicji ontologii wynika, że wiedza zawarta w danej ontologii pochodzi z jednej dziedziny i zawiera się w jednym paradygmacie (traktowanym jako granica). Wiedza, jaka znajduje się w danym obszarze tematycznym, charakteryzowanym przez dziedzinę, może być przedstawiona jako suma ontologii $\Omega_1 \cup \Omega_2 \cup \Omega_3 \cup \Omega_4 \cup \dots$, gdzie każda z ontologii należy do kolejnego agenta lub aktora, umieszczonego i działającego w ramach danego systemu wiedzy. W przypadku nauczania zdalnego obszar ontologii można usystematyzować według następującej zależności: $\Omega_S \subset \Omega_N \subset \Omega_E$. Największy zasób wiedzy z danej dziedziny posiada ekspert, następnie nauczyciel, zaś student charakteryzuje się relatywnie najmniejszym zasobem wiedzy z dziedziny nauczania.

Możemy wyróżnić dwie składowe procesu budowy ontologii (Visser i in., 1997). Pierwsza to konceptualizacja dziedziny, natomiast druga to wyjaśnienie, wyrażenie konceptualizacji. Konceptualizacja dziedziny polega na określeniu podejścia do wyodrębnienia pojęć w danej dziedzinie. Ekspert, operując symbolicznym językiem opisu, dokonuje konceptualizacji wiedzy do postaci pojęć, w oparciu o przedstawione struktury. Opracowanie konceptualnego schematu dziedziny, będącego modelem ontologicznym, jest wynikiem procesu konceptualizacji, który polega na identyfikacji pojęć i stworzeniu semantycznych relacji pomiędzy wyróżnionymi pojęciami.

5.4.1 Opis struktury pojęcia

Rzeczywistość definiowana jest przez zróżnicowany i nieskończenie wielki zbiór informacji i bodźców docierających do człowieka. Kognitywistyka zakłada naturalną zdolność umysłu do kategoryzacji informacji z otoczenia i z pamięci ludzkiej do postaci pojęć. Pojęcie rozumiane jest jako struktura reprezentacji umysłowej, która zawiera opis istotnych właściwości pewnej kategorii (klasy) (Marszewski, 2002). Wiedza w umyśle przechowywana jest za pomocą pojęć. Jest to możliwe do zaobserwowania szczególnie wtedy, gdy odniesiemy się do wiedzy abstrakcyjnej, która często nie posiada reprezentacji fizycznej, ale stanowi zbiór konceptów pewnej idei. Nauczanie wiedzy fundamentalnej (bazującej na abstrakcyjnych pojęciach) opiera się na zapewnieniu komunikacji pomiędzy uczestnikami procesu na poziomie pojęć. Możliwe jest wykorzystanie metafor i innych metod pedagogicznych.

Pojęcie jest rozumiane jako nominacja klasy obiektów posiadających wspólne cechy (Kushtina i Różewski, 2003) i traktowane jako jednostka logiczna konceptualnego schematu dziedziny, czyli element wiedzy atomowej. Pojęcie, o nazwie $N(\phi)$, definiowane jest jako para:

$$\phi = \langle X, T \rangle,$$

gdzie:

X – stanowi zbiór informacji, składający się na opis pojęcia. W przypadku systemów LMS/LCMS niewskazane jest ograniczenie tego pola do samej nazwy lub identyfikatora (ID). Praktyczniejszym rozwiązaniem jest stworzenie struktury w języku metadanych (np. w oparciu o standard DublinCore), zawierającej w sobie informację pozwalającą na przyszłe rozszerzenie użycia danego pojęcia. Celem jest uzyskanie struktury zdolnej do migracji pomiędzy różnymi systemami zdalnego nauczania. Pojęcie wyposażone w tak sformułowany opis posiada wszystkie zalety podejścia semistrukturalnego (Abiteboul i in., 2001).

T – tablica opisująca głębokość pojęcia, $T = [\hat{t}_{ij}]$. Każde z pojęć jest pewną abstrakcją, składającą się na dany koncept reprezentujący pojęcie. Wielkość tablicy wyraża istotność danego pojęcia w określonej dziedzinie.

← Uogólnienie (IS_A)

Nazwa Pojęcia	Objekt 1	Objekt 2	...	Objekt i
Cecha 1				
Cecha 2		t_{ij}		
...				
Cecha j				

↑ Agregacja (PART_OF)

Rys. 48. Głębokość pojęcia wyrażona za pomocą abstrakcji w formie tablicy (źródło: (Różewski, 2004))

Opracowanie struktury macierzowej pojęcia opiera się na wyborze i wykorzystaniu istniejących definicji pojęć. Do tego celu można zastosować dwa podejścia: intensjonalne i ekstensjonalne. Każde z tych podejść jest punktem wyjścia do wyszczególnienia właściwości obiektu definiowanego, poszukiwania agregatu definiujących cech i tworzenia schematów klasyfikacyjnych. Przedstawiona na rysunku 48 struktura konceptu łączy w sobie oba podejścia.

Formalnie zawartość, objętość i głębokość wiedzy można opisać w sposób struktury macierzowej pojęcia (Kusztina i in., 2006):

$$G = \|g_{ij}\|, i = \overline{0, i^*}, j = \overline{0, j^*},$$

gdzie:

$\hat{G}, i = 0, j = 0$ – nazwa pojęcia (termin);

$O_i, i = \overline{1, i^*}, j = 0$ – nazwy obiektów zaliczonych do klasy z nazwą \hat{G} (nazwa kolumn);

$W_i, i = 0, j = \overline{1, j^*}$ – nazwa wspólnych cech obiektów klasy \hat{G} (nazwa wierszy);

$g_{ij}, i = \overline{1, i^*}, j = \overline{1, j^*}$ – nazwa cechy j - tej dla i - tego obiektu.

wtedy:

Krotka $\langle \hat{G}, W_1, W_2, \dots, W_{j^*} \rangle$ opisuje treść (zawartość) wiedzy odpowiadającej terminowi

pojęcia \hat{G} . Krotka $\langle \hat{G}, O_1, O_2, \dots, O_{i^*} \rangle$ opisuje objętość wiedzy odpowiadającej terminowi

pojęcia \hat{G} . Zbiór wartości wszystkich cech wszystkich obiektów $\{g_{ij}\}$ jest opisem głębokości

wiedzy odpowiadającej terminowi pojęcia \hat{G} . Dodawanie nowych elementów do zbioru

$I = \overline{1, i^*}$, przy zachowaniu treści pojęcia, oznacza rozszerzenie badanej klasy obiektów.

Dodawanie lub usuwanie elementów ze zbioru $J = \overline{1, j^*}$ oznacza zmianę treści pojęcia.

Przecięcie $\delta = I \cap J \neq 0$ jest miarą dopuszczalnej tolerancji różnych postaci pojęcia, które odpowiadają granicom badanej dziedziny. Przy $\delta = I \cap J = 0$ mamy do czynienia z sytuacją, gdy to samo słowo w różnych dziedzinach wiedzy oznacza różne rzeczy, zjawiska.

Głębokość semantyczna każdego pojęcia może być opisana jako tablica (rys. 48). Wiersze tablicy odpowiadają liczbie wspólnych atrybutów obiektów, a liczba kolumn mówi o liczbie obiektów zaliczonych do klasy określonej przez koncept pojęcia. Szare pola składają się na kontekst danego pojęcia, natomiast elementy t_{ij} stanowią opis danego pojęcia i określają jego głębokość semantyczną w danej dziedzinie. Każdy z elementów t_{ij} jest traktowany jako zmienna lingwistyczna. Definicja elementu tablicy T przedstawia się następująco:

$$T[t_{ij}] = \begin{cases} N(\phi), & \text{gdy } i = 1 \wedge j = 1 \\ \text{cecha } i, & \text{gdy } i \neq 1 \wedge j = 1 \\ \text{obiekt } j, & \text{gdy } i = 1 \wedge j \neq 1 \\ t_{ij}, & \text{w przeciwnym przypadku.} \end{cases}$$

Wszystkie elementy tablicy pochodzą z jednej dziedziny, czyli zawierają się w określonej ontologii $\{N(\phi) - \text{nazwa pojęcia, obiekt } i, \text{cecha } j, t_{ij}\} \in \Omega$, dla $i = 1, \dots, I$, $j = 1, \dots, J$.

Tab. 21. Abstrakcja składająca się na pojęcie Queuing Network (źródło: (Różewski, 2004))

Queuing Network Pojęcie	Open Connection -oriented (Supply Chain) Obiekt 1	Open Random-oriented (Jackson Network) Obiekt 2	Closed Connection -oriented Obiekt 3	Closed Random-oriented (Closed Jackson Network) Obiekt 4
Processing node Cecha 1	QS	QS	QS	QS
Channels Cecha 2	Physical, Information, Telecommunications, technological, transmission Line	Physical, Information, Telecommunications, technological, transmission Line	Physical, Information, Telecommunications, technological, transmission Line	Physical, Information, Telecommunications, technological, transmission Line
Configuration Cecha 3	Star, Ring, Buss, Mixed	Star, Ring, Buss, Mixed	Star, Ring, Buss, Mixed	Star, Ring, Buss, Mixed
Connections Cecha 4	Deterministic	Random	Deterministic	Random
Population Cecha 5	∞	∞	N	N

Operacja uogólnienia i agregacji może być użyta do zbudowania modelu abstrakcji określonego pojęcia, jak to pokazują (Wong i Mylopoulos, 1977) oraz (Tsichritzis i Lochovsky, 1990). Metodologia bazuje na wykorzystaniu operacji abstrakcji PART_OF i IS_A. Pojęcie PART_OF wyraża fakt, że pewien typ obiektu jest agregatem innych typów. Pojęcie IS_A mówi o tym, że pewien typ obiektów jest uogólnieniem innego typu obiektów. Zastosowanie przedstawionej metodologii pozwala na budowanie abstrakcji. Abstrakcja może być traktowana jako próba pozwalająca na zrozumienie obiektu złożonego na podstawie analizy obiektów składowych. Jak dowodzi (Tsichritzis i Lochovsky, 1990) agregacja i uogólnienie mogą służyć do opisu struktury i klasyfikacji typów: „(...) strukturę typu ogólnego można wyrazić jako agregat typów składowych, a agregaty można klasyfikować według typów ogólnych. Klasyfikację odzwierciedla hierarchia uogólnień, zaś strukturę typu – hierarchia agregacji”. Przedstawiona forma abstrakcji integruje w sobie obie formy do

postaci tablic, gdzie elementy pionowe tworzone są w oparciu o agregację, a poziome – w oparciu o uogólnienie.

5.4.2 Opis struktury konceptualnego schematu dziedziny

Proponowany model konceptualnego schematu dziedziny, który jest formą konceptualizacji wiedzy w danej dziedzinie, zostanie omówiony w oparciu o typowe cechy sieci semantycznych, przedstawione w książce (Maruszewski, 2002). Główne założenia przedstawionej struktury wiedzy wywodzą się z idei map konceptualnych. Podobnie jak sieci semantyczne, konceptualny schemat dziedziny nie jest w żaden sposób próbą odwzorowania pewnej rzeczywistej struktury umieszczonej w mózgu. Stanowi jedynie abstrakcyjne odwzorowanie, będące modelem instrumentalistycznym, dostosowanym do wymagań modelowania wiedzy dziedziny, a więc budowania ontologii. Pojęcia zorganizowane są w oparciu o zależności hierarchiczne. Pojęcie położone niżej w hierarchii dziedziny ma wartość semantyczną po pojęciu nadrzędnym. Pojęcie albo przynależy do kategorii nadrzędnej albo zawiera w sobie kategorię podrzędną. Głównym wyznacznikiem budowy konceptualnego schematu dziedziny jest ekonomia poznawcza. Ekonomia poznawcza gwarantuje rozmieszczenie pojęć w taki sposób, że pojęcie – agregat innych pojęć, jest w strukturze wyżej po to, aby swoim zasięgiem objąć wszystkie związane z nim pojęcia i zmniejszyć liczbę potrzebnych relacji.

Konceptualny schemat dziedziny budowany jest w oparciu o wcześniej przedstawione procedury współpracy z ekspertem. Ekspert ma za zadanie wyznaczyć granicę dla danej ontologii w określonej dziedzinie oraz napełnić strukturę ontologii wiedzą. Założyć można dwie sytuacje:

- (1) Konceptualny schemat dziedziny budowany jest na podstawie współpracy z wieloma ekspertami. Połączeniu ulegają poszczególne ontologie ekspertów w ramach jednej wspólnej ontologii, zbudowanej pod kątem określonej dziedziny. W takim podejściu istnieje wiele niebezpieczeństw związanych ze współpracą z grupą ekspertów i zagadnieniem łączenia ontologii.
- (2) Konceptualny schemat dziedziny budowany jest na podstawie współpracy z jednym ekspertem. Oznacza to, że konceptualny schemat dziedziny wyrażony jest przez ontologię zbudowaną przez eksperta w danej dziedzinie.

Konceptualny schemat dziedziny zawsze koncentruje się na wiedzy z jednej dziedziny, może być zatem wyrażony jako ontologia Ω . Poczynmy kilka założeń:

- ontologia opisuje wiedzę fundamentalną (jako sieć pojęć z danej dziedziny);
- ontologia jest budowana przez eksperta/ekspertów z danej dziedziny;
- węzłami ontologii są pojęcia;
- określone są typy relacji łączących pojęcia;
- ontologia posiada strukturę grafu niekierowanego;
- pojęcia nie mogą się powtarzać w ramach ontologii;
- ekspert buduje ontologię oraz określa wymiar każdego z pojęć.

Proces definiowania ontologii należy rozpocząć od określenia składników ontologii.

Definicja 1.

Koncept jest to para $\phi = \langle X, T \rangle$ (dokładniejsza definicja umieszczona została w rozdziale 5.4.1).

Definicja 2.

Relacją nazywamy semantyczne połączenie pomiędzy dwoma pojęciami, które występują w danej ontologii. Zbiór relacji wygląda następująco: $R = \{IS_A, PART_OF, \emptyset\}$.

Relacje IS_A według (Van Eynde i Gibbon, 2000) pokrywa szeroki wachlarz różnego typu relacji, takich jak dziedziczenie, implikacja i włączenie. Najbardziej popularnym zastosowaniem relacji IS_A jest budowa taksonomii. Gdy chociaż jeden element tablicy

$T_1 = [\hat{t}_{ij}]$, opracowanej dla pojęcia o nazwie $N(\phi_1)$, może być przedstawiony za pomocą tablicy $T_1 = [\hat{t}_{ij}]$ (nazwa pojęcia $N(\phi_3)$), wtedy pojęcie ϕ_3 jest połączone z pojęciem ϕ_1 za pomocą relacji IS_A.

Relacja PART_OF jest bazą do utworzenia jednego z typów hierarchii (całość - części) (Sowa, 2000). Jeżeli $N(\phi_1) \subset N(\phi_2)$ oraz $T_1 = [\hat{t}_{ij}] \subset T_2 = [\hat{t}_{ij}]$, wtedy pojęcie ϕ_2 jest połączone z pojęciem ϕ_1 za pomocą relacji PART_OF.

Definicja 3.

Ontologia jest to para $\Omega = \langle S, \Pi \rangle$, gdzie $S = \{\phi_i\}, i = 1, \dots, n$ stanowi zbiór pojęć z danej dziedziny, natomiast $\Pi : S \times S \rightarrow R$ jest mapowaniem pary konceptów do zbioru połączeń R. Definicja jest zbieżna z rozważaniami przedstawionymi w artykule (Camara i in., 2002).

Przykład mapowania:

Dla zbioru pojęć S zawierającego następujące elementy $S = \{bit, bajt\}$ można zbudować następujące mapowanie:

$$\Pi = (bit, bajt) = PART_OF,$$

gdzie pomiędzy pojęciem *bit* a pojęciem *bajt* istnieje relacja PART_OF.

Definicja 4.

Ontologia w postaci $\Omega = \langle S, \Pi \rangle$ nie jest podatna na manipulacje komputerowe. Korzystniej jest dokonać transformacji do perspektywy grafu nieskierowanego G_Ω . Formę ontologii w postaci zadanej perspektywy definiujemy:

$$G_\Omega = (V, E),$$

gdzie:

$V = \{v_i\}$ – zbiór wierzchołków grafu ($i = 1, 2, \dots, n$). Każdy z wierzchołków odpowiada jednemu pojęciu ontologii.

$E = \{e_j\}$ – zbiór krawędzi ($j = 1, 2, \dots, m$), jakie występują pomiędzy pojęciami. Krawędź pomiędzy wierzchołkiem v_i i v_j zdefiniowana jest jako relacja symetryczna: $\{v_i, v_j\}$.

Macierz incydencji $A = \|a_{ij}\|$ utworzona dla grafu G_Ω posiada wymiar $n \times n$, gdzie n – całkowita liczba pojęć w ontologii. Definicja dowolnego elementu macierzy:

$$a_{ij} = \begin{cases} 1, & \text{dla } \{i, j\} \in E \\ 0, & \text{dla } \{i, j\} \notin E. \end{cases}$$

Definicja 5.

Transformację ($\Omega \rightarrow G_\Omega$) z ontologii określanej jako Ω do postaci grafu G_Ω zdefiniować można następująco:

$$a_{ij} = a_{ji} = \begin{cases} 1, & \text{jeżeli } \Pi(s_i, s_j) \\ 0, & \text{w przeciwnym przypadku.} \end{cases}$$

Transformację ($G_\Omega \rightarrow \Omega$) z ontologii określanej jako G_Ω do postaci Ω zdefiniować można następująco:

$$\Pi(s_i, s_j) = \begin{cases} \mathfrak{K}, & \text{jeżeli } a_{ij} = 1 \\ \emptyset, & \text{w przeciwnym przypadku,} \end{cases}$$

gdzie:

\mathfrak{K} – może być dowolnym elementem zbioru $\{IS_A, PART_OF, \emptyset\}$.

Ujawniają się tutaj ograniczenia zaproponowanej transformacji. Macierz incydencji, wypełniona tylko zerami i jedynkami, nie potrafi przenosić informacji o typie relacji. Podczas procesu transformacji użytkownik jest zobowiązany samodzielnie ustalić strategię obsługi symbolu \aleph . Przyjęta strategia może zakładać indywidualną analizę każdego z przypadków lub zastosowanie inteligentnych mechanizmów, opartych o wewnętrzne heurystyki.

5.4.3 Język manipulacji wiedzą

Język manipulacji wiedzą tworzy protokół umożliwiający komunikację pomiędzy aktorami biorącymi udział w procesie nauczania zdalnego a samym systemem wiedzy. Aktorzy, między innymi inżynier wiedzy i ekspert, podczas swojej codziennej pracy prowadzą ciągłą interakcję z systemem wiedzy. Stworzenie efektywnego języka manipulacji pozwoli osiągnąć wysoką jakość tworzonych materiałów oraz zwiększy efektywność pracy. Mało efektywne (komunikatywne) narzędzie spowoduje znaczny spadek jakości, ponieważ praca z systemem oparta jest głównie na interakcji ze środowiskiem komputerowym.

Koncepcja języka manipulacji wiedzą dostosowanego do uwarunkowań projektowanego systemu różni się od istniejących standardów takich jak np. Semantic Web. Rysunek 49 pokazuje język manipulacji wiedzą na tle języka manipulacji danymi i informacją. Dyskutowane języki różni przede wszystkim mechanizm strukturyzacji, co związane jest z różnymi jednostkami organizacyjnymi, różnym poziomem stosownych abstrakcji i różnymi procedurami oceny jakości (np. zastosowanie entropii). Należy sobie uzmysłowić, że opracowanie funkcjonalnego rozwiązania działania proponowanego języka wymagałoby stworzenia kompilatora, który pozwala odejść z poziomu rozwiązania aplikacyjnego na poziom standardu.

	(dane)	(informacja)	(wiedza)
	SQL	XML	Język manipulacji wiedzą
Jednostka organizacyjna	Rekord/tabela	Znacznik/dokument	Pojęcie/konceptualny schemat dziedziny
Mechanizm strukturyzacji	Model relacyjny	Semistrukuralny model	Model pojęciowy
Poziom realizacji	System Zarządzania Bazą Danych (np. Oracle)	Systemy personalizacji treści (np. Smart Servers)	↑

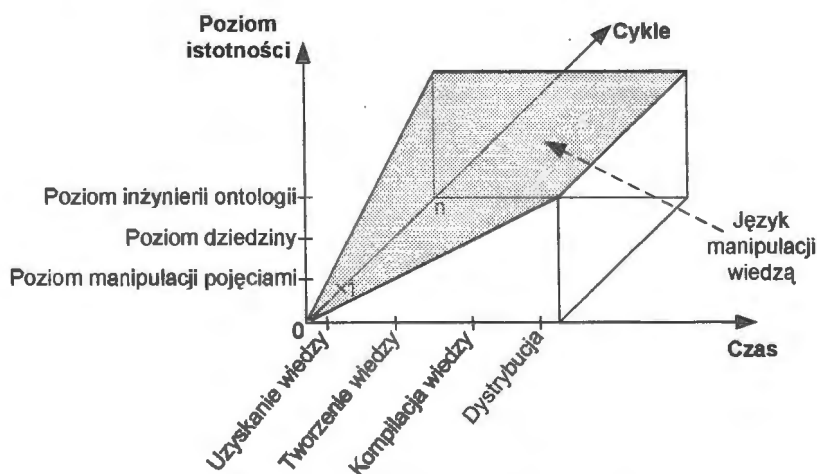
Semantic Web,
 Knowledge Interchange
 Format (KIF)

Rys. 49. Języki opisu i manipulowania danymi/informacją/wiedzą
 (źródło: opracowanie własne)

W procesie zarządzania wiedzą można wyróżnić pewne podstawowe czynności. Analizowane działania określają wymiar języka manipulacji wiedzą, gdy zostaną zestawione z wymaganiami nauczania zdalnego, opartego na koncepcji Learning Object. Wyczerpujący przegląd i analizę działań związanych z zarządzaniem wiedzą można znaleźć w publikacji (Holsapple i Joshib, 2002) oraz (Rubenstein-Montano i in., 2001). Do dalszej analizy wybrane

zostały działania, które pozwalają na integrację rozwiązań pochodzących z inżynierii wiedzy, inżynierii ontologii i nauczania zdalnego.

Z typowego procesu zarządzania wiedzą, tworzonego pod kątem korporacji, wyodrębnić można schematy, które są gotowe do zastosowania w procesie zarządzania wiedzą opartym na konceptualnym schemacie dziedziny. W podejściu zaproponowanym przez (Alavi, 1997) wyodrębnione zostały następujące etapy zarządzania wiedzą: (i) pozyskanie wiedzy, (ii) indeksacja, (iii) filtracja, (iv) dołączenie niezbędnych grafik, klasyfikacja, katalogowanie, integracja, mapowanie zewnętrznych i wewnętrznych zasobów, (v) dystrybucja, (vi) zastosowanie. W kontekście nauczania zdalnego znaczące jest wyodrębnienie osobnego etapu (iv) przeznaczonego do zbudowania metafory komputerowej danej wiedzy i umieszczenia jej w repozytorium. Podejście przedstawione przez (Liebowitz, 2000), wyodrębnia następujące kroki: (i) transformacja informacji w wiedzę, (ii) identyfikacja i weryfikacja wiedzy, (iii) zapis i zabezpieczenie wiedzy, (iv) organizacja wiedzy, (v) wyszukiwanie i zastosowanie wiedzy (vi) kompilacja wiedzy, (vii) nauczanie wiedzy, (viii) dystrybucja. W podejściu Liebowitza (Liebowitz, 2000) ważnym elementem jest stworzenie procedury rozciągającej się pomiędzy etapami (ii – iv), która umożliwi dokładny zapis wiedzy. Etap (ii) jest miejscem, gdzie ekspert identyfikuje i weryfikuje wiedzę. Niezbędne czynności związane z ustaleniem praw autorskich i zapisem wiedzy, zgodnie z obowiązującymi standardami, odbywają się na etapie (iii). Ostatni (iv) etap procedury, w odniesieniu do ekonomii Learning Object, jest interpretowany jako organizacja wiedzy do postaci ontologii.



Rys. 50. Wymiary języka manipulacji wiedzą
(źródło: (Różewski, 2004))

Właściwe rozumienie języka manipulacji wiedzą wymaga oderwania się od jednowymiarowego podejścia, stosowanego w literaturze do opisu procesu zarządzania wiedzą. Analizując zadania, które stoją przed językiem manipulacji wiedzą w wymiarze zarządzania wiedzą opartym na konceptualnym schemacie dziedziny, można wyróżnić trzy wymiary problemu (rys. 50). Proces zarządzania wiedzą, jak to zostało pokazane w przytoczonych powyżej przykładach (Alavi i Liebowitz), składa się z kolejno następujących po sobie etapów, które tworzą pewien wymiar wzdłuż osi czasu. Na rysunku zostały wyróżnione schematycznie tylko niektóre, uogólnione etapy: uzyskania, tworzenia, kompilacji i dystrybucji wiedzy. Proces zarządzania wiedzą nigdy nie jest procesem

jednorazowym, szczególnie w systemach nauczania zdalnego, których jedną z głównych cech jest cykliczna iteracja systemu. Cecha ta determinuje następny wymiar, który odnosi się do kolejnych cykli pracy. Ostatni wymiar, poziom istotności, jest wynikiem zaproponowanego w rozprawie podejścia do wiedzy, polegającego na wyodrębnieniu poziomu pojęć dziedziny i inżynierii ontologii. W początkowych, operacyjnych cyklach działanie aktorów polega na budowaniu systemu wiedzy. Kolejne cykle pracy koncentrują się na rozbudowie i strategicznym planowaniu, dzięki czemu podstawowy system wiedzy jest rozwijany i ulepszany.

5.5. Poglądy naukowe na temat modelowania procesu nabywania wiedzy

Proces nabywania wiedzy jest głęboko osadzony w strukturze umysłu. Człowiek przez całe życie zdobywa nową wiedzę. Zrozumienie sposobu przekazywania i składowania wiedzy pozwoli na skuteczniejsze radzenie sobie z ograniczeniami środowiska i człowieka. Poznanie podstawowych zależności i uwarunkowań, jakie wynikają z budowy umysłu człowieka i jego procesów poznawczych, ma bezpośredni wpływ na proces projektowania i przyszłości użytkowania materiałów dydaktycznych. Szczególna uwaga powinna być poświęcona dziedzinie kognitywistyki jako płaszczyźnie integrującej naszą wiedzę na temat ludzkich mechanizmów poznawczych oraz problemowi nabywania i przetwarzania wiedzy, jako głównym procesom związanym z nauczaniem.

5.5.1 Działanie umysłu jako przesłanka procesu nabywania wiedzy

Postulat zrozumienia działania umysłu leży u podstaw modelowania procesu nabywania wiedzy. Problem naukowy zrozumienia działania mózgu jest głównym pytaniem badawczym kognitywistyki. Powołując się na (Duch, 1998), można z całą stanowczością stwierdzić, że jest to największe wyzwanie stojące przed człowiekiem. Wymiar podejścia wyraża się w interdyscyplinarnym charakterze stosowanych badań. Badania nad umysłem wymagają połączenia rezultatów różnych dziedzin nauki, takich jak: matematyka, statystyka, informatyka, sztuczna inteligencja, cybernetyka, biocybernetyka, psychologia, neuropsychologia, psychofizyka, biofizyka, neurobiologia, biologia, biochemia.

Dusza, umysł, mózg od dawien dawna stanowiły intrygujący temat prac badawczych, głównie z dziedzin filozofii i religii. Dualizm duszy i ciała był przedmiotem rozważań między innymi Arystotelesa, Platona, Kartezjusza i innych wielkich filozofów. Problem, który ich nurtował, związany był ze zrozumieniem, jak materialny obiekt (mózg) jest odpowiedzialny za tak abstrakcyjne i ulotne pojęcia, jak dusza i wiedza. Szczególnie interesujący był fenomen poznania, efektem którego jest wiedza. Poznanie, według (Kiejzik i Sapeńko, 2000), jest właściwe jedynie dla istoty myślącej, a więc posiadającej umysł. Poznanie to proces zachodzący pomiędzy podmiotem a przedmiotem poznania, którego wynikiem jest stworzenie dedykowanego autonomicznego świata niesprowadzalnego do żadnego z przedmiotów ani podmiotów, jakie były źródłem poznania.

O ile zapatrywanie się na mózg jako na źródło umysłu jest szeroko akceptowane, o tyle problem dusza – mózg jest ciągle dyskutowany. To ciekawe zagadnienie przez wieki było analizowane i stało się przyczyną wielu niesnasek i nieporozumień. Antologia problemu przedstawiona jest w pracy (Trąbka, 2000). Problemu dusza – mózg nie powinno się rozpatrywać inaczej niż na polu filozoficznym. Jest to spowodowane poglądem wielu współczesnych filozofów, w tym K.C. Poppera, uważających, że dusza jest synonimem umysłu. Przez wiele lat było to hamulcem prac nad umysłem. Dopiero zastąpienie obrazu duszy świadomością spowodowało lawinowe przyspieszenie pracy nad zagadnieniem umysłu. Problem duszy pozostał jeszcze naukowo nierozwiązany.

Podejście do mózgu jako źródła świadomości pokazane jest między innymi w pracy (Damasio, 2000). Problemem jest ustalenie perspektywy obserwacji i badań. Każdy z nas posiada indywidualną, właściwą tylko sobie świadomość, do której ma dostęp. Niemożliwe jest dokonywanie weryfikowalnych badań umysłu, nie mówiąc o świadomości. Dyskusyjne również jest założenie, że obraz mózgu, jaki pojawia się w wyniku badań naukowych, ma cokolwiek wspólnego z umysłem. Jednakże, poznawcze rezultaty badań nad mózgiem skłaniają badaczy do kontynuowania analizy zachowań mózgu, jak to opisuje (Duch, 2000). Badania neurobiologiczne odkrywają coraz więcej tajemnic mózgu zarówno na poziomie funkcji komórek nerwowych, jak i obwodów neuronalnych. Przyszłość rozstrzygnie, czy zrozumienie pracy mózgu pozwoli nam na odkrycie tajemnicy własnego ja.

Ogólnie można powiedzieć, że proces transformacji danych do postaci wiedzy rozpoczyna się od spostrzeżenia lub wrażenia. Następnie zebrane przez aparat percepcyjny dane kodowane są najpierw do postaci wymaganej przez pamięć krótkoterminową, a w ostateczności pamięć długoterminową. Informacja umieszczona w pamięci długoterminowej traktowana jest jako wiedza umieszczona w umyśle. Trzymając się takiego podejścia, traktuje się umysł jako mechanizm analizy i przetwarzania danych. Nie rozpatruje się zaś zagadnień związanych z emocjami w kontekście procesu zdobywania wiedzy.

5.5.2 Proces zapamiętywania rozważany jako główny składnik procesu nauczania

Jednym z istotniejszych procesów mechanizmu „uczenia się – nauczania” jest proces zapamiętywania. Proces zapamiętywania można rozpatrywać jako kodowanie informacji pochodzącej ze świata zewnętrznego do postaci zgodnej ze strukturą pamięci ludzkiej. Aspekt pamięci, jaki analizujemy, abstrahując od jej zdolności do zapamiętywania sekwencji zdarzeń w postaci pewnego rodzaju wewnętrznego „filmu”, przejawia się w podobieństwie pamięci do wielkiej encyklopedii. Jak zauważył (Maruszewski, 2002), encyklopedia taka składa się z ogromnego zbioru pojęć i równie dużego zbioru odsyłaczy do tych pojęć. Każda pozycja zapisywana jest za pomocą prostych pojęć, które tłumaczone są przez pojęcia niższego poziomu. Słowo „zapisywać” zostało użyte nieprzypadkowo. Odwołanie się do faktów zawartych w pamięci może być utożsamiane ze znalezieniem adresu do odpowiedniego rejestru pamięciowego. Ponadto w rejestrach pamięciowych często wyszukuje się adresów do adresów.

Procesowe traktowanie pamięci odróżnia się od podejścia do pamięci rozumianej jako zdolność, ponieważ daje wyraźnie lepsze możliwości formalizacji. Za (Sternbergiem, 2002) można stwierdzić, że procesowe traktowanie pamięci polega na rozróżnieniu w trakcie jej działania szeregu podprocesów, zależnych od siebie w czasie. W pamięci występują trzy podstawowe rodzaje operacji (Maruszewski, 2002), które możemy zdefiniować następująco:

- (1) *Operacja kodowania wiedzy* – informacje z otoczenia kodowane są do postaci śladów pamięciowych. Podczas tego wieloetapowego działania operuje się na różnych jednostkach i wielkościach w zależności od miejsca, w którym odbywa się kodowanie. Wyróżnić można między innymi zamianę bodźców na sygnały elektryczne, a sygnałów elektrycznych na ślady pamięci. Zachodzi również konwersja pomiędzy systemami, w której obrazowe dane z etapu spostrzegania zamieniane są na dane dyskretne.
- (2) *Operacja przechowania wiedzy* – wiedza umieszczona jest w strukturach pamięciowych. Działa tutaj zasada uzależniająca czas przechowania wiedzy w pamięci do jakości dostępu do niej. Im informacja składająca się na wiedzę jest dłużej przechowywana w pamięci, tym jest większe prawdopodobieństwo, że będzie ona inna od informacji pierwotnej. Wpływać na to mogą inne informacje umieszczone w pamięci, które interferują z pierwotnie umieszczoną informacją, generując inną wiedzę.
- (3) *Operacja odtwarzania wiedzy* – odwołanie do informacji umieszczonych w pamięci, aby uzyskać dostęp do wcześniej zapamiętanej wiedzy. Za regułą można przyjąć, że wiedza

umieszczona w pamięci jest inna od tej samej wiedzy, ponownie odzyskanej. Wiele ciekawych przykładów manipulowania naszą pamięcią zademonstrowanych jest w publikacji (Loftus, 1997). Umysł potrafi samodzielnie spreparować sobie nieprawdziwe wspomnienia lub wiedzę za pomocą sugestii. Jednocześnie trzeba zaznaczyć, że nie jest to niczym złym. Umysł ma wbudowaną zdolność ekonomicznego zarządzania i optymalnego przechowywania informacji. Zdolność ta powstała w drodze ewolucji i pozwala człowiekowi na automatycznie filtrować i grupować „atakujące” zewsząd informacji. Oznacza to, że niektóre informacje mogą być utwalone wielokrotnie w pamięci i w niezmienionej formie można je odzyskać ponownie, podczas gdy inne informacje będą tworzone na nowo w procesie odtwarzania z mniej lub bardziej fragmentarycznych danych.

Należy wówczas przeanalizować teraz zachowanie współczynnika stopnia zapamiętania dla przypadku, kiedy nowa wiedza pokrywa się z wiedzą już posiadaną. Jeżeli wiedza, jaką człowiek chce zapamiętać, pokrywa się w pewnym stopniu z wiedzą, jaką już posiada, to jest bardzo duże prawdopodobieństwo, że nastąpi skuteczne jej zapamiętanie. Gdy wiedza wejściowa częściowo pokrywa się z wiedzą już posiadaną, wtedy nowa wiedza może zostać zapamiętana na wiele sposobów zależnych od relacji z wiedzą umieszczoną już w pamięci długoterminowej:

- Operacja asymilacji – oznacza, że nowa wiedza została dołączona do dotychczasowych struktur wiedzy.
- Operacja akomodacji – struktury wiedzy zostały zmodyfikowane w taki sposób, aby zacząć uwzględniać nową wiedzę. Może wystąpić konieczność budowania nowych autonomicznych struktur w przypadku, gdy dane porcja wiedzy jest całkowicie nowa.
- Odrzucenie wiedzy i inne możliwości.

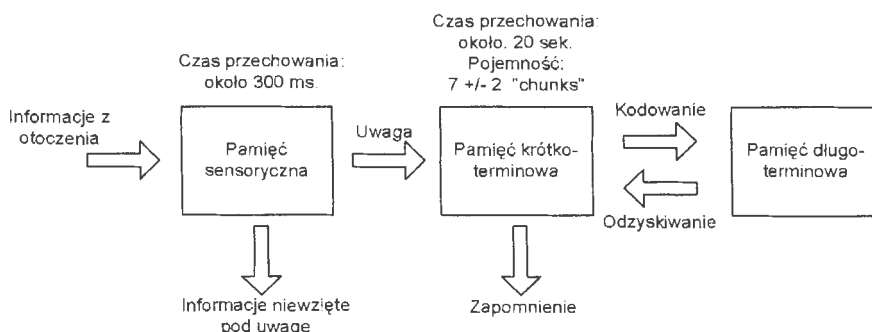
5.5.3 Model przepływu informacji pomiędzy światem zewnętrznym a umysłem

Przytaczane w rozdziale rozważania oparte są na modelu przepływu informacji pomiędzy światem zewnętrznym a umysłem (ang. *Information Processing Model*), który jest wynikiem zastosowania podejścia procesowego do rozumienia pamięci. Przedstawione zagadnienie jest dokładnie wyjaśnione w pracach (Anderson, 2002), (Maruszewski, 2002), (Pinker, 2002) oraz w przewodnim artykule (Atkinsona i Shiffrina, 1968). Analizowane podejście do zrozumienia działania umysłu zakłada, że składa się on z trzech sekwencyjnie po sobie występujących modułów. Każdy moduł charakteryzuje się innymi cechami. Wszystkie razem są odpowiedzialne za przepływ wiedzy i jej analizę w umyśle człowieka pod wpływem bodźców zewnętrznych i wewnętrznych. Każdy z proponowanych modułów procesu pamięciowego ma inną charakterystykę, działa na innych jednostkach i ma inne algorytmy działania. Rozważane moduły to:

- pamięć sensoryczna (ang. *Sensore Memory – SM*);
- pamięć krótkoterminowa (ang. *Short-term Memory – STM*);
- pamięć długoterminowa (ang. *Long-term Memory – LTM*).

Model procesu myślowego, przedstawionego na rysunku 51 zakłada, że bodźce ze środowiska zewnętrznego lub ciała ludzkiego dostają się najpierw do pamięci sensorycznej. Gdy bodźce w pamięci zostaną rozpoznane (wzbudzą zainteresowanie) przesyłane są do pamięci krótkoterminowej. Bodźce, które nie wzbudziły zainteresowania, zostają usunięte, dalej nie są już rozpatrywane. W pamięci krótkoterminowej bodźce zamienione na informację ulegają procesowi analizy. Pamięć ma ograniczoną pojemność – elementy, które się w niej nie znalazły lub tracą miejsce bez umieszczenia w pamięci długoterminowej, zostają bezpowrotnie zapomniane. Gdy dana porcja informacji jest zakodowana, czyli przekształcona do formy informacji rozumianej przez pamięć długoterminową, zostaje następnie umieszczona w pamięci długoterminowej w formie wiedzy. W pamięci długoterminowej

wiedza może przebywać w nieskończoność, jednakże prawdopodobieństwo pomyślnego odwołania się do niej ponownie maleje z kwantem czasu.



Rys. 51. Procesowy model pamięci ludzkiej
(źródło: (Różewski, 2004))

5.5.3.1 Pamięć sensoryczna

Na pamięć sensoryczną składa się pamięć wzrokowa (ikoniczna), pamięć słuchowa i inne rodzaje pamięci związane ze zmysłami: dotyku, smaku, zapachu. Dane ze wszystkich zmysłów są w pamięci sensorycznej przetwarzane na impulsy elektryczne (w takiej postaci informacja przemieszcza się w mózgu). Pamięć sensoryczna ma większą pojemność od pamięci krótkoterminowej. Pamięć ta nie interpretuje znaczenia poszczególnych sygnałów, skupia się na przechowywaniu informacji o fizycznych właściwościach bodźców.

Celem jest przesłanie ważnej informacji do pamięci krótkoterminowej. Nie zawsze jest to możliwe z powodu zalewu danych, które są przetwarzane przez pamięć sensoryczną. Niektóre informacje są ignorowane, np. gdy odbiegają znacznie od naszych oczekiwań lub zawierają błąd. Dlatego wskazane jest stosowanie różnego rodzaju technik mających na celu podniesienie prawdopodobieństwa przesłania informacji do następnego modułu pamięci. Ludzie mają skłonność do mocniejszego skupienia uwagi na bodźcach, gdy występują w nim ciekawe elementy lub atrybuty, które odwołują się do ich poprzedniej wiedzy lub wzbudzają pozytywne zainteresowanie.

5.5.3.2 Pamięć krótkoterminowa

Uczeni rozpatrują pamięć krótkoterminową dwojako. Pierwsze podejście traktuje pamięć krótkoterminową jako etap pośredni w dostępie do pamięci długoterminowej, podczas którego informacja jest dekodowana i kodowana (zależnie od sytuacji) do postaci kompatybilnej ze strukturami pamięci długoterminowej. Drugi pogląd, przedstawiany między innymi przez (Baddeley, 1986) oraz (Baddeley i Hitch, 1974), zakłada specjalną rolę pamięci krótkoterminowej, wynikającą z tego, że jej zawartość jest powiązana z tym, o czym myślimy w danym momencie. Stąd pamięć krótkoterminowa nazywana jest inaczej pamięcią roboczą (ang. *Working Memory*). W literaturze tym terminem nazywany jest również pewien obszar pamięci długoterminowej (Ericsson i Kintsch, 1995). W dalszych rozważaniach wymiar pamięci roboczej zostanie jednak ograniczony do pamięci krótkoterminowej, ponieważ powiązania z pamięcią długoterminową występują tylko w pewnych rzadkich przypadkach.

Najważniejszą cechą pamięci krótkoterminowej jest jej limitowana pojemność. Ogranicza ona dostęp do pamięci trwałej. Oznacza to, że ilość informacji, wiedzy, jaką jesteśmy w stanie analizować w danym momencie czasu, jest ograniczona przez wielkość naszej pamięci krótkoterminowej. Pewne oszacowanie pojemności pamięci krótkoterminowej zostało przedstawione przez (Miller, 1956) i zrewidowane przez (Cowan, 2001).

Celem Millera było znalezienie ograniczeń ludzkich zdolności w przetwarzaniu informacji. Badał on trzy aspekty naszych ograniczeń: osąd absolutny (ang. *absolute judgement*), uwagę i pamięć krótkoterminową. Osąd absolutny odnosi się do naszej zdolności rozróżniania bodźców. Przykładem jest zdolność rozróżniania tonów o różnych częstotliwościach. Zagadnienie uwagi dotyczy zdolności człowieka do rozróżnienia obiektów w sytuacji, gdy analizowany jest zbiór obiektów, posługując się tylko jednym, chwilowym rzutem oka. Najistotniejszym rezultatem badań Millera jest wniosek dotyczący pojemności pamięci krótkoterminowej. Miller ucieka od miar pojemności pochodzących z teorii informacji, czyli bitów. Spowodowane jest to tym, że podstawowy paradygmat teorii informacji stwierdza, iż w teorii informacji nie analizuje się znaczenia przypisywanego danej informacji (Simmonds, 1999). Miller zaproponował mierzenie pojemności pamięci krótkoterminowej za pomocą jednostek zwanych kęsami informacji (ang. *chunk*). Według (Simon, 1974) kęs można zdefiniować jako zbiór konceptów, które są mocno ze sobą powiązane i równocześnie są znacznie słabiej powiązane z innymi konceptami, jakie są w tym samym czasie używane. Istnienie kęsów zostało udowodnione empirycznie w przypadku gry w szachy przez (Chase i Simon, 1973). Kęsy są tworzone na podstawie wiedzy uzyskanej z pamięci długoterminowej, która pozwala na pogrupowanie danych pojęć. Po stworzeniu kęsa, nowo utworzona relacja może być przeniesiona do pamięci długoterminowej. Ponieważ kęsy są formowane na podstawie nie tylko danych napływających z aparatu percepcyjnego, ale również na podstawie wiedzy z pamięci długoterminowej, nie powinna istnieć granica wielkości kęsu. Jednakże, aby uformować dany kęs, wszystkie potrzebne dane muszą znaleźć się w pamięci krótkoterminowej, która ma ograniczoną pojemność. Szerzej zagadnieniu wielkości kęsu jest analizowane przez (Gobet i Simon, 1996), (Gobet i Simon, 1998). Na przykładzie wiedzy formowanej przez mistrza i początkującego gracza w szachy, utworzona została teoria wzorców (ang. *template theory*) zakładająca, że ekspert potrafi w ramach jednego kęsu zgromadzić znacznie większy obszar wiedzy w dziedzinie, w jakiej jest mistrzem. Przedstawione są argumenty dowodzące, że na mistrza (eksperta) i początkującego gracza (nowicjusza) nie działają te same ograniczenia ilościowe i jakościowe podczas formowania kęsów w tej samej dziedzinie.

Istnieje również pogląd, promowany między innymi przez (Nęcka, 2003), mówiący o tym, że rozmiar pamięci krótkoterminowej jest bezpośrednio związany z inteligencją danego człowieka. Wniosek taki prowadzi do następującej konkluzji: im więcej kęsów może człowiek umieścić w swojej pamięci krótkoterminowej, tym jest inteligentniejszy.

Oszacowanie przez Millera pojemności pamięci krótkoterminowej wynosi 7 ± 2 chunks/kęsów i jest znane pod nazwą „Zasada 7 ± 2 ” lub „Zasada magicznej liczby siedem”. Według (Cowan, 2001), ograniczenie Millera traktowane powinno być jako figura retoryczna, a nie realne ograniczenie pojemności. Badania Cowana pokazały, że w przypadku dorosłych ludzi występuje ograniczenie pojemności do 3 ± 5 kęsów. Istnieją przypadki, które poszerzają rozpatrywany zakres do 2 ± 6 kęsów. Badania eksperymentalne wykonane przez (Henson, 1998) pozwoliły na przygotowanie oszacowania określającego zależność liczby kęsów znajdujących się w pamięci krótkoterminowej od stopnia ich ponownego poprawnego przywołania. Opracowane wyniki pokazują, że przy sześciu kęsach umieszczonych w pamięci krótkoterminowej poprawność ponownego ich odzyskania jest na poziomie 50 procent.

Kiedy materiał, jaki ma być zapamiętany, jest różnorodny (częściowo mówiony, pisany, itp.) oraz sytuacja nie jest koherentna, wtedy informacja jest lepiej zapamiętywana. Dowodzi to, że mechanizm pamięci krótkoterminowej potrafi działać na różnych poziomach organizacji dla różnych materiałów. Podniesienie pojemności pamięci krótkoterminowej można osiągnąć poprzez organizowanie informacji w hierarchiczne struktury lub grupy powiązane związkami np. klastry.

Zasada 7±2 (zmodyfikowana według ustaleń przedstawionych przez Cowana) jest istotna podczas projektowania wszelkiego rodzaju interakcji człowieka z komputerem. Niestety, nie jest ona należycie rozumiana. Jak podaje (Doumont, 2001), ślepe trzymanie się zasady 7±2 prowadzi do kuriozalnych ograniczeń, np. ograniczenia liczby punktów na każdym slajdzie (np. do 7). Istota zasady 7±2 sprowadza się do oszacowania pojemności pamięci krótkoterminowej, co przekłada się na zbiór informacji, jaki może być rozpatrywany przez człowieka w przeciągu jednego cyklu pojęciowego trwającego około 15÷20 sek. (według innego opracowania 4÷5 sek. (Maruszewski, 2002)). Czas przechowywania jest oszacowaniem okresu, w jakim przechowywana jest informacja podczas jednego cyklu percepcyjnego. Zatem nie ma sensu kierować się ograniczeniami pamięci krótkoterminowej w horyzoncie czasu jednego wykładu. Zasadne jest natomiast ograniczenie wielkości Learning Object do wielkości pamięci krótkoterminowej studenta.

5.5.3.3 Pamięć długoterminowa

Cała wiedza, jaką posiada człowiek, składowana jest w pamięci długoterminowej. Naukowcy zgodni są co do szeregu cech, jakie posiada pamięć długoterminowa. Pierwsza z nich mówi o tym, że organizacja wiedzy w pamięci długoterminowej powinna zapewnić efektywny dostęp do interesujących fragmentów wiedzy, co przejawia się uprzywilejowaniem niektórych obszarów wiedzy oraz zwielokrotnieniem miejsca składowania danej wiedzy. Umysł ludzki zapisuje nowe informacje w pamięci długoterminowej w sposób zorganizowany, grupując je w struktury, biorąc za kryterium ich wartość znaczeniową.

Zapis nowych informacji do pamięci długoterminowej może zabrać sporo czasu z powodu konieczności wmontowania nowej informacji w istniejące schematy pojęciowe, które składają się na wiedzę, co wymaga wykrycia związków nowej informacji z wiedzą już istniejącą. Wiedzę w pamięci długoterminowej można przechowywać w formie zgodnej z wymaganiami pamięci semantycznej, proceduralnej i epizodycznej. Podział ten jest poczyniony ze względu na format przechowywanych informacji. Cechy poszczególnych klas pamięci są następujące (Maruszewski, 2002):

- *Pamięć epizodyczna* – zapisywane w niej są doznania zmysłowe, których człowiek był bezpośrednim uczestnikiem. Informacja porządkowana jest za pomocą znaczników czasowych. Wszystkie przechowywane informacje ułożone są na osi czasu. Informacja przechowywana w pamięci epizodycznej jest zabarwiona przez kontekst wystąpienia danego zdarzenia. Wpływa to na stosunek do danego wydarzenia.
- *Pamięć semantyczna* – rejestruje informacje na podstawie danych pośrednich, które pochodzą z ekstrakcji wiedzy z zewnętrznych źródeł. Nośnikiem informacji jest zazwyczaj język naturalny. Poprawność danych jest warunkowana przez odniesienie do myśli społecznej, która uwiarygodnia i potwierdza dane. To, co inni uważają za poprawne, jest przez nas również akceptowane jako poprawne, chociaż są od tego wyjątki. Pamięć semantyczna ma kluczowe znaczenia podczas procesu zapamiętywania, ponieważ zawiera wiedzę o świecie rzeczywistym. Wiedza reprezentowana jest za pomocą struktur, które łączą w sieć fakty, pojęcia oraz relacje.
- *Pamięć proceduralna* – jest wynikiem adaptacji człowieka do uwarunkowań środowiska. Jest w swej naturze autonomiczna, pracuje w sposób dla nas nieświadomy. Pomaga dostosować się do wymagań otoczenia. Mechanizm ten np. wpływa na nasze zachowanie, aby ochronić nas przed zagrożeniem.

Wiedza w pamięci przechowywana jest w postaci fenomenów nazwanych pojęciami (Piłat, 1999). Pojęcie nie powinno być utożsamiane z terminem, ponieważ – jak pokazuje (Lorenzen, 1997) – w danym pojęciu abstrahujemy od formy brzmieniowej terminu. Często do wyrażenia tego samego pojęcia używamy różnych słów (terminów). Wydaje się, że odpowiedniejszą nazwą mogącą zastąpić nazwę *pojęcie* jest *koncept*. Można przyjąć, że

myślenie pojęciowe jest bardzo zbliżone do myślenia konceptualnego. Odwołując się do dokładnej analizy zagadnienia pojęcia przedstawionego przez Maruszewskiego można stwierdzić, że pojęcie zapewnia z jednej strony – ekonomię poznawczą dzięki redukcji różnorodnych informacji przetwarzanych przez umysł, z drugiej zaś – jest formą komunikacji.

Można za Chomskym i Jackendoffem (Jackendoff, 1990) rozróżnić dwa światy: wewnętrzny i zewnętrzny oraz analogicznie dwie struktury pojęcia i języka wewnętrznego (oznaczanych *W*) oraz zewnętrznego (oznaczonych symbolem *Z*). Z jednej strony używa się języka *Z* do komunikacji z otaczającym nas światem (innymi ludźmi), gdzie semantyka i gramatyka języka *Z* jest znana i tworzy język naturalny. Możliwe jest zbudowanie efektywnych struktur (pojęcia *Z*), wyrażając w sposób ścisły nie tylko konkretne informacje, wiedzę, ale również uczucia i emocje. Język naturalny jest najbardziej efektywną formą komunikacji na poziomie struktur *Z*.

Celem nauczania jest zapamiętanie danej informacji jako właściwej dla nas wiedzy za pomocą struktur *W* w pamięci długoterminowej. Język *W* używany jest do komunikacji pomiędzy naszymi wewnętrznymi procesami i pamięcią roboczą. Lingwistyka generatywna i bazujące na niej poglądy naukowe zakładają kodowanie naszej wiedzy w umyśle za pomocą skończonych zbiorów jednostek elementarnych i skończonego zbioru zasad ich łączenia. Każda z informacji, przechodząc cały cykl pamięciowy poprzez pamięć sensoryczną i krótkoterminową, kierowana jest do pamięci długoterminowej. Istotne jest, aby przygotowane struktury języka *Z* były jak najlepiej dostosowane i jak najlepiej współgrały ze strukturami *W* odbiorcy. Kluczowym czynnikiem jest zrozumienie procesu transformacji, jaka zachodzi podczas przekształcania struktur *Z* na struktury *W*.

Proces zamiany struktur *Z* w struktury *W* nazywamy procesem zapamiętywania. Zapamiętywanie to ściśle indywidualny proces możliwy do analizy tylko na poziomie psychologicznym. Pojęcia uczenia się i zapamiętywania są różne – uczenie jest odpowiedzialne za modyfikację zachowań (podejście behawiorystyczne), natomiast zapamiętywanie prowadzi do zapisu nowych informacji w pamięci w postaci wiedzy. Na zapamiętywanie wpływa kilka czynników określających dany materiał, który chcemy zapamiętać. Za (Maruszewski, 2002) oraz (Anderson, 2000) można stwierdzić, że stopień organizacji, sensowności, objętości oraz szybkość, z jaką napływa dany materiał, są ściśle skorelowane z procesem zapamiętywania. Z drugiej strony cechy indywidualne człowieka, w tym nastawienie emocjonalne w danej sytuacji, są również ważnym czynnikiem wpływającym na zapamiętywanie. Jednostkowe zdolności tworzenia sensownych grup danych (klastrów) oraz bogactwo umieszczonych w pamięci schematów poznawczych wyraźnie ułatwiają zapamiętywanie.

Ujęcie pamięci długoterminowej w kontekście pamięci deklaratywnej i proceduralnej (często uogólnionej do klasy pamięci niedeklaratywnej) pozwala na dokładniejszą analizę miejsca struktur *W* w umyśle. Pamięć deklaratywna odpowiada między innymi za wiedzę abstrakcyjną. Podejście deklaratywne zakłada, że wiedza w danej dziedzinie jest zbiorem specyficznych dla tej dziedziny faktów (Bazewicz, 1993). Natomiast pamięć niedeklaratywna pozwala nam na wykonywanie powtarzających się czynności takich jak pisanie na klawiaturze. W tym kontekście korzystanie z wiedzy polega na stosowaniu ogólnych procedur manipulacji dowolnego rodzaju faktami w odniesieniu do stworzonego zbioru faktów. Za (Squire i Kandel, 2000) można stwierdzić, że informacje w pamięci deklaratywnej przechowywane są za pomocą struktur *W*, czyli w postaci abstrakcyjnych lub konkretnych reprezentacji angażujących język *W*.

5.5.4 Kognitywne style uczenia się

Chcąc osiągnąć jak najlepszą skuteczność przekazu, należy starać się dostosować tworzony materiał do cech poznawczych studenta. Każda grupa ludzi różni się jednak pod

względem cech percepcyjnych na poziomie jednostkowym. Najprostszym podziałem jest rozróżnienie klasy preferującej wizualizację dźwiękową i klasy preferującej wizualizację graficzną. Różnice te zostały sklasyfikowane w ramach stylów kognitywnych, które definiuje się jako charakterystykę indywidualnego podejścia do przetwarzania informacji z otoczenia do postaci struktur poznawczych (myślowych) człowieka. Style kognitywne często są nazywane stylami uczenia się. Definicja stylów kognitywnych, przedstawiona przez (Liu i Ginthera, 1999), odnosi się do indywidualnych, stałych i charakterystycznych predyspozycji w postrzeganiu, zapamiętywaniu, organizowaniu, przetwarzaniu, myśleniu i rozwiązywaniu problemów.

Dokładny przegląd, przygotowany przez Liu i Ginter (Liu i Ginthera, 1999), charakteryzuje 19 różnych stylów kognitywnych. Wspólne dla każdego ze stylów są następujące założenia:

- Style kognitywne są w swej naturze niezienne. Dlatego trening nie powoduje ich zmiany.
- Zbieżność stylów kognitywnych z określonymi typami zadań powoduje pozytywną lub negatywną polaryzację motywacji. Niektóre zadania edukacyjne są w swej naturze słabo akceptowane przez zbiorowość określoną konkretnym stylem kognitywnym.

Można wyróżnić dwie podstawowe klasy stylów kognitywnych. Pierwsza orientowana na prawą półkulę mózgu, określana jest w języku angielskim jako (ang. *global-holist/field dependent*), natomiast druga – orientowana na lewą półkulę – nazwana jest (ang. *focused-detailed/field independent*). Pierwszą klasę można interpretować w kontekście holistycznym. Oznacza to, że stosowane podejście zakłada, iż żaden element nie będzie rozpatrywany w oderwaniu od systemu, w jakim się znajduje, czyli na wszystkie zagadnienia patrzeć należy w sposób ogólny, unikając szczegółowości. Powoduje to silne uzależnienie badanego strumienia informacji od sytuacji i otoczenia. Większość tego typu analiz odbywa się w prawej półkuli mózgu, która – za (Dryden i Vos, 2000) – odpowiedzialna jest za odbiór muzyki, obrazy, wyobraźnię oraz rytm. Przeciwnościem takiej postawy jest klasa druga, która koncentruje się na detalach. Mocno zaawansowane analizy, wykonywane zazwyczaj w lewej półkuli, przeważają w takich dziedzinach jak matematyka, logiczne myślenie, liczenie i szeregowanie.

W powyższych klasach stylów kognitywnych charakterystycznym czynnikiem jest sposób przetwarzania informacji. Foell i Fritz (Foell i Fritz, 1995) określają klasę pierwszą jako mniej złożoną. Strumień informacji przetwarzany jest w sposób bierny na zasadzie powiązanego strumienia znaczeń. Prezentowane idee są akceptowane bez modyfikacji. Przedstawiciele tej klasy preferują metody nauczania, które kładą nacisk na interakcję student – nauczyciel. Lubią również działania edukacyjne, które akcentują socjalny aspekt działania. Klasa druga jest wysoce zindywidualizowana. Procesy poznawcze zawierają takie elementy jak tworzenie hipotez. Podejścia tego typu używane jest do problemów, które są niejasne i przez to absorbujące. Zadania z matematyki i nauk ścisłych najlepiej odpowiadają osobom określonym tym stylem kognitywnym. Osoby takie lubią pracować samodzielnie, najbardziej odpowiadają im zajęcia wymagające abstrakcyjnego myślenia i posiadające bezosobową formę.

Powołując się na dane opracowane przez (Liu i Ginther, 1999) można stwierdzić, że 20 procent nastolatków amerykańskich to słuchowcy, ponad 40 procent to wzrokowcy, a pozostali najlepiej uczą się poprzez ruch i dotyk. Ma to bezpośrednie przełożenie na sposób projektowania materiałów. Jak zauważa (Rowntree, 1997), prawidłowe określenie profilu studenta jest jednym z najważniejszych kroków etapu przygotowywania materiałów dydaktycznych, szczególnie dla nauczania zdalnego. W innym opracowaniu, przygotowanym przez (Valenta i in., 2001), przeanalizowana jest zależność stylu kognitywnego studenta do jego ogólnego nastawienia do nauki zdalnej. Z przeprowadzonych badań wynika, że studenci należący do klasy danego stylu nauczania charakteryzują się jednakowym stosunkiem do nauczania zdalnego. Badania przeprowadzone przez (Foell i Fritz, 1995) ostrzegają, że

korelacja pomiędzy stylami kognitywnymi a strumieniem informacji może być zmniejszona i zanieczyszczona przez niedostatki środowiska. Żaden styl kognitywny nie jest ani lepszy ani gorszy – tak konkluduje (Dryden i Vos, 2000). W każdej grupie akademickiej, kulturowej, bez względu na płeć, można znaleźć przedstawicieli wszystkich stylów kognitywnych.

Mnogość stylów kognitywnych oraz ich równoważność prowadzi do opracowywania rozwiązań, które uwzględniają wszystkie style kognitywne podczas nauczania. Każdy uczy się z przewagą jednego ze stylów kognitywnych. Prawidłowe rozpoznanie stylu nauczania i dynamiczne dostosowanie do niego materiałów dydaktycznych zwiększa skuteczność procesu nauczania. Dobre dopasowanie powoduje większe zadowolenie z rezultatów nauczania. Istnieją rozwinięte metody śledzenia poczynąń studenta. Możliwe jest też analizowanie czasu, jaki student przeznacz na przebywanie w danej sekcji kursu. Funkcje systemu pozwalają badać, których modułów najczęściej używa student i z jakiej funkcjonalności korzysta. Wszystkie te zabiegi pozwalają na zbudowanie profilu studenta, który można później analizować. Niestety, tylko z analizy zachowań studentów w środowisku systemu nauczania zdalnego bardzo trudno jest stwierdzić, jaki styl kognitywny charakteryzuje studenta. Jednym z możliwych rozwiązań zmierzających do pogłębienia wiedzy o studencie jest zastosowanie testu lub ankiety. Przykładowe rozwiązanie zaproponowane jest w pracy (Zajac, 2003). Ankieta składająca się z 74 pytań pozwala na zakwalifikowanie studenta do jednej z następujących metod uczenia się:

- *Metoda hipertekstowa* – student samodzielnie eksploruje wiedzę poprzez system odnośników. Wymaga to od studenta samodzielności i aktywnego uczestnictwa w procesie nauczania.
- *Metoda prezentacyjna* – sekwencja przygotowanych obrazów przedstawiana jest na zasadzie pokazu. Student biernie uczestniczy w procesie, który jest w stanie przekazać uprzednio sformatowany materiał.
- *Metoda z przewodnikiem* – komputerowy system doradczy służy pomocą i wskazówkami podczas procesu nauki. Student monitorowany jest przez system, który sugeruje pewne działania i cały czas kontroluje pracę studenta.
- *Metoda interakcyjna* – system prowadzi dialog ze studentem, któremu powierzane są zadania do rozwiązania. Student wykazuje się abstrakcyjnym myśleniem. Pracuje zarówno z obrazem, jak i z tekstem.

Prawidłowe rozpoznanie stylu kognitywnego studenta pozwala na wyraźne zwiększenie skuteczności działania danego systemu nauczania. Jednakże związana z tym konieczność opracowania materiałów dydaktycznych w różnych wersjach, przewidzianych dla różnych stylów kognitywnych, czyni cały mechanizm bardzo kosztownym. Prowadzi to do zaawansowanych prac zmierzających do rozbicia monolitycznych kursów do postaci modułów, łatwych do edycji i zarządzania. Mechanizmy sztucznej inteligencji pozwalają na dynamiczną adaptację środowiska nauczania do potrzeb danego studenta. Odpowiednie stymulanty modyfikowane są według wyników analizy, np. dla wroko-wca zwiększają się możliwości obsługi grafiki i tekstu.

5.6. Podsumowanie

Zastosowanie metod inżynierii wiedzy i inżynierii ontologii dla dziedziny nauczania zdalnego zmienia metodologię tworzenia materiałów dydaktycznych. Zmieniają się aktorzy uczestniczący w procesie oraz przedefiniowaniu ulegają role, jakie pełnią. Wszystkie zaistniałe zmiany muszą być przeanalizowane w świetle wymagań i pedagogicznych uwarunkowań procesu „uczenia się – nauczania”. Pewnych związków i procedur nie możemy utracić np. podczas dążenia do zwiększenia poziomu automatyzacji procesu. Równocześnie, nowe spojrzenie na poszczególne aspekty procesu, np. na te wynikające z rezultatów kognitywistyki, pozwala na przeorganizowanie procesu nauczania.

Przedstawione w rozdziale rozważania dotyczą szeroko pojętego modelowania wiedzy i mają na celu opracowanie podstaw konceptualnych i naukowych pozwalających zbudować moduł systemu LMS/LCMS pracujący na poziomie Learning Object. W tym celu przeanalizowano proces współpracy inżyniera wiedzy z ekspertem. Proces ten pozwala na wydobycie od eksperta wiedzy i zapisanie jej w postaci umożliwiającej przetwarzanie komputerowe. Zapis wiedzy wykonywany jest w oparciu o podejście ontologiczne, gdzie ontologia stanowi podstawowy model wiedzy. Do modelowania i zarządzania ontologią danej dziedziny został zaproponowany język modelowania dziedziny wyposażony w opis struktury pojęcia, opis konceptualnego schematu wraz z odpowiednimi funkcjami i procedurami. Powiązanie przedstawionego podejścia do modelowania procesu nabywania wiedzy z procesem „uczenia się – nauczania” odbywa się w oparciu o kognitywistykę. Szczególnie istotnym zagadnieniem jest sposób działania pamięci w ramach modelu informacyjnego umysłu.

5.7. Bibliografia

- Abiteboul S., Suciu D., Buneman P. (2001). Dane w sieci WWW, Wydawnictwo Mikom, Warszawa.
- Abramowicz W., Kowalkiewicz M., Zawadzki P. (2002a). Tell me what you know or I'll tell you what you know. Skill map ontology for information technology courseware. In: Khosrowpour M. (Ed.), 13th IRMA International Conference "Issues & Trends of Information Technology Management in Contemporary Organizations (Seattle, USA)", Wydawnictwo IRM Press, Hershey, 7-10.
- Adelman L. (1989). Measurement issues in knowledge engineering, *IEEE Transactions on Systems, Man, Cybernetics*, 19(3), 483-488.
- Aimeur E., Brassard G., Gambs S. (2003). Towards a New Knowledge Elicitation Algorithm, In: IJCAI'03 Workshop on Knowledge Representation and Automated Reasoning for E-Learning Systems, Mexico, 5-10.
- Alavi M. (1997). KPMGPeatMarwick U.S.: One Giant Brain, Wydawnictwo Harvard Business School (Case), No. 9-397-108.
- Anderson J.R. (2000). Cognitive Psychology and Its Implications, 5th edition, Worth Publishing, New York
- Atkinson R., Shiffrin R. (1968). Human memory: A proposed system and its control processes. W: K Spence K., Spence J. (Red.), The psychology of learning and motivation: Advances in research and theory. Vol. 2, Wyd. Academic Press, New York.
- Ausubel D.P. (1963). The Psychology of Meaningful Verbal Learning. Wydawnictwo Grune and Stratton, New York.
- Baddeley, A. D. (1986) Working memory, Wyd. Oxford, Clarendon.
- Baddeley A. D., Hitch G. (1974). Working memory, W: Bower G.A., (Red.), The Psychology of Learning and Motivation, pp. 47-89, Wyd. Academic Press, New York.
- Barrett A.R., Edwards J.S. (1995). Knowledge Elicitation and Knowledge Representation in a Large Domain With Multiple Experts. *Expert Systems With Applications*, 8(1), 169-176.
- Bazewicz M. (1993). Wstęp do systemów informatycznych i reprezentacji wiedzy, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław.
- Berners-Lee T., Hendler J., Lassila O. (2001). The Semantic Web: A new form of Web content that is meaningful to computers will unleash a revolution of new possibilities. *Scientific American*, May.
- Bloom P.C., Chung Q.B. (2001). Lessons Learned from Developing a Mission-Critical Expert System with Multiple Experts through Rapid Prototyping, *Expert Systems with Applications*, 20(2), 217-227.
- Borst P., Akkermans H., Top J. (1997). Engineering ontologies, *International Journal of Human-Computer Studies*, 46, 365-406.
- Brachman R.J. (1979). On the Epistemological Status of Semantic Networks, In: Findlet V. (Ed.), Associative Networks: Representation and Use of Knowledge by Computers, Wydawnictwo Academic Press, New York, 3-50.
- Camara G., Fonseca F., Monteiro A.M. (2002). Algebraic Structures For Spatial Ontologies, In: Proceedings of Giscience 2002. Boulder, CO, Setembro De 2002. Anais, AAG.
- Carvalho L.C., Rodrigues M.E., Paret B.D. (2000). Tacit and Formal Knowledge and Learning in Small Business: An Exploratory Study on the Perceptions of Successful Businessmen, In: Proceedings of 4th International Conference on Technology Policy and Innovation, Curitiba, Brasil, 28-31 August, <http://in3.dem.ist.utl.pt/curitiba2000/>.
- Casti J.L., DePauli W. (2003). Gödel: życie i logika, Wydawnictwo Cis, Warszawa.
- Chandrasekaran B., Josephson J., Benjamins V. (1999). What Are Ontologies, and Why Do We Need Them?. *IEEE Intelligent Systems*, 14(1), 20-26.
- Chase W.G., Simon H.A. (1973). Perception in chess. *Cognitive Psychology*, 4, 55-81.

- Codd E.F. (1972), Further normalization of the data base relational model, In: Rustin R. (Ed.), *Courant Computer Science Symposium 6: Data Base Systems*, Wydawnictwo. Prentice-Hall, New York.
- Cole R.J., Tilley T.A. (2003), Conceptual Analysis of Software Structure, In: *Proceedings of 15th International Conference on Software Engineering and Knowledge Engineering SEKE'03*, Knowledge Systems Institute, 726-733.
- Cowan N. (2001), The Magical Number 4 in Short-term Memory: A Reconsideration of Mental Storage Capacity, *Behavioral and Brain Sciences*, 24(1), 87-185.
- Cyre W.R. (1997), Capture, Integration, and Analysis of Digital System Requirements with Conceptual Graphs, *IEEE Transactions on Knowledge and Data Engineering*, 9(1), 8-23.
- Damasio A.R. (2000), Jak mózg tworzy umysł. W: (2003) Świat Nauki - Tajemniczy Umysł, Wydanie Specjalne, WSiP, Warszawa, No.1, 4-10.
- Doumont J.L. (2001), Magical Numbers: The Seven-Plus-or-Minus-Two Myth, *IEEE Transactions of Professional Communication*, 45(2), 123-127.
- Dreyfus L.H. (1998), Education on the Internet: Anonymity vs. Commitment, *The Internet and Higher Education*, 1(2), 113-124.
- Dryden G., Vos J. (2000), Rewolucja w uczeniu, Wyd. Moderski i S-ka, Poznań
- Duch W. (1998), Czy jest kognitywistyka?, *Kognitywistyka i Media w Edukacji*, 1(1), 9-51.
- Ellis G. (1995a), Compiling Conceptual Graphs, *IEEE Transactions on Knowledge and Data Engineering*, 7(1), 68-81.
- Ericsson K.A., Kintsch W. (1995), Long-term working memory, *Psychological Review*, 102(2), 211-245.
- Fensel D., Horrocks I., Harmelen F., McGuinness D.L., Patel-Schneider P.F. (2001), OIL: An Ontology Infrastructure for the Semantic Web, *IEEE Intelligent Systems*, 16(2), 38-44.
- Foell N.A., Fritz R.L. (1995), Association of Cognitive Style and Satisfaction With Distance Learning, *Journal of Industrial Teacher Education*, 33(1).
- Ganter B., Wille R. (1999), *Formal Concept Analysis: Mathematical Foundations*, Wydawnictwo Springer Verlag, Berlin.
- Gawlik J., Juszczyzyn K. (2003), Tworzenie ontologii z wykorzystaniem narzędzi programowych, W: Bubnicki Z., Grzech A. (Red.), V Krajowa Konferencja "Inżynieria Wiedzy i Systemy Ekspertowe", Wrocław, 11-13 czerwiec, 2, 302-309.
- Gobet F., Simon H.A. (1998), Expert chess memory: Revisiting the chunking hypothesis, *Memory*, 6, 225-255.
- Gobet F., Simon H.A. (1996), Templates in chess memory: A mechanism for recalling several boards, *Cognitive Psychology*, 31, 1-40.
- Gomez-Perez A., Corcho O., Fernandez-Lopez M. (2004), *Ontological Engineering: with examples from the areas of Knowledge Management, e-Commerce and the Semantic Web*, seria: Advanced Information and Knowledge Processing, Wydawnictwo Springer.
- Gordon J. L. (2000), Creating knowledge maps by exploiting dependent relationships, *Knowledge Based Systems*, 13(2-3), 71-79.
- Graves M. (2002), *Projektowanie baz danych XML: Vademecum profesjonalisty*, Wydawnictwo Helion, Gliwice.
- Gregory R.L., Colman A.M., (Red.), (2003), *Czucie i percepcja*, Wydawnictwo Zysk i S-ka, Poznań.
- Griffith R.L. (1982), Three principles of representation for semantic networks, *ACM Transactions on Database Systems*, 7(3), 417-442.
- Gruber T.R. (1993), A translation approach to portable ontologies, *Knowledge Acquisition*, 5(2), 199-220.
- Guarino N. (1997), Understanding, building and using ontologies, *International Journal of Human-Computer Studies*, 46, 293-310.
- Grzegorzczak A. (1997), *Logic - a human affair*, Wydawnictwo Scholar, Warszawa.
- Hamilton D.M., Breslawski S. (1996), Knowledge Acquisition for Multiple Site, Related Domain Expert Systems: Delphi Process and Application, *Expert Systems with Applications*, 11(3), 377-389.
- Hart A. (1989), *Knowledge acquisition for expert systems*, 2th edition, Wydawnictwo Kogan Page, London.
- Heřlin J., Hendlr J. (2000), Dynamic Ontologies on the Web, In: *Proceedings of American Association for Artificial Intelligence Conference AAAI-2000*, Wydawnictwo AAAI Press, Menlo Park, 443-449.
- Henson R.N.A. (1998), Short-Term Memory for Serial Order: The Start-End Model, *Cognitive Psychology*, 36(2), 73-137.
- Heylighen F. (1990), *Representation and Change. A Metarepresentational Framework for the Foundations of Physical and Cognitive Science*, Wydawnictwo Communication & Cognition, Belgium, Ghent.
- Higgins D., Heuveln B., Hatfield E., Kilpatrick D., Wong L. (2001), A Java implementation for Peirce's existential graphs, *The ACM Journal of Computing in Small Colleges*, 16(3), 101-107.
- Hoffman R.R., Shadbolt N., Burton A.M., Klein G.A. (1995), Eliciting knowledge from experts: A methodological analysis, *Organizational Behavior and Human Decision Processes*, 62(2), 129-158.

- Holsapple C.W., Joshib K.D. (2002), Knowledge manipulation activities: results of a Delphi study, *Information & Management*, 39, 477–490.
- ISO/IEC 13250 (2000), Information technology – SGML Applications – Topic Maps, ISO/IEC 13250, International Organization for Standardization, Geneva.
- Jackendoff R. (1990), Czym jest pojęcie. czy człowiek może je uchwycić?, W: Chlewiński Z. (Red.), (1999), Modele umysłu. Wybór prac. Wydawnictwo Naukowe PWN, Warszawa.
- Kiejzik L., Sapeńko R. (2000), Filozofia w schematach pojęciowych. Dla laików i nie tylko, Wyd. Adama Marszałka, Toruń.
- Knosala R. (Red.) (2002), Zastosowania metod sztucznej inteligencji w inżynierii produkcji, Wydawnictwo PWN, Warszawa.
- Koprowska M., Juszczyński K. (2003), Łączenie ontologii w środowisku sieci semantycznych, W: Bubnicki Z., Grzech A. (Red.), V Krajowa Konferencja "Inżynieria Wiedzy i Systemy Ekspertowe", Wrocław, 11-13 czerwiec, tom 2, 294-301.
- Kushina E., Różewski P., Zaikin O., (2006), Extended ontological model for distance learning purpose, Practical Aspects of Knowledge Management, PAKM2006, Lecture Notes in Artificial Intelligence No. 4333, 155-165.
- Kushina E., Różewski P. (2003), Opracowanie Podejścia do Tworzenia Formalnego Opisu Dziedziny Wiedzy Teoretycznej, W: Tom wydawniczy Instytutu Badań Systemowych Polskiej Akademii Nauk, Badania Systemowe, 33, 29-40.
- Kushina E., Różewski P., Zaikin O., Tadiusiewicz R. (2002), Distance Learning Organization based on General Knowledge Model. In: Proceedings of the 8th Conference of European University Information Systems EUNIS'02, University of Porto, Portugal, 401- 406.
- Kushina E., Różewski P. (2000) Podejście do projektowania Courseware oparte na schemacie kognitywnym, W: Materiały V Sesji Naukowej Wydziału Informatyki Politechniki Szczecińskiej, Wydawnictwo Informa. Polska, Szczecin, 243-250.
- Lacey, A.R. (1999), Słownik filozoficzny. Wydawnictwo Zysk i S-ka, Poznań.
- Liebowitz J. (2000), Building Organizational Intelligence: A Knowledge Management Primer, Wydawnictwo CRC Press, Boca Raton.
- Liu Y., Ginther D. (1999), Cognitive Styles and Distance Education, *Online Journal of Distance Learning Administration*, 2(3).
- Loftus E.F. (1997), Fabrykowanie wspomnień, W: (2003) Świat Nauki - Tajemniczy Umysł, Wydanie Specjalne, WSiP, Warszawa, 1, 78-84.
- Lorenzen P. (1997), Myślenie metodyczne. Wyd. IFiS PAN, Warszawa.
- Maedche A., Staab S. (2000), Discovering Conceptual Relations from Text, In: Technical Report 399, Institute AIFB, Institute AIFB, Karlsruhe University, 76128 Karlsruhe, Germany, 400, 321-325.
- Maruszewski T. (2002), Psychologia poznania. Sposoby rozumienia siebie i świata, Gdańskie Wydawnictwo Psychologiczne, Gdańsk.
- Marwick, A. D. (2001), Knowledge management technology. *IBM System Journal*, 40 (4), 814-830.
- McDermott D. (1981), Artificial Intelligence Meets Natural Stupidity. In: Haugeland J. (Red.), *Mind Design: Philosophy, Psychology, Artificial Intelligence*, Wydawnictwo MIT Press, Cambridge.
- McGuinness D.L. (2001), Ontologies and Online Commerce, *IEEE Intelligent Systems*, 16(1), 8-14.
- Medsker L., Tan M., Turban E. (1995), Knowledge Acquisition from Multiple Experts: Problems and Issues, *Expert Systems with Applications*, 9(1), 35-40.
- Miller G. A. (1956), The magical number seven, plus or minus two: Some limits on our capacity for processing information, *Psychological Review*, 63.
- Moody, J., Will, R., Blanton, E. (1996), Enhancing Knowledge Elicitation using the Cognitive Interview, *Expert Systems With Applications*, 10(1), 127-133.
- Mulawka J.J. (1997), Systemy ekspertowe, Wydawnictwo Naukowo-Techniczne, Warszawa.
- Nawarecki E., Dobrowolski G., Kisiel-Dorohiniński M. (2003), Komponentowa organizacja wiedzy w zdecentralizowanych systemach informacyjno-decyzyjnych, W: Bubnicki Z., Grzech A., V Krajowa Konferencja pt. "Inżynieria Wiedzy i Systemy Ekspertowe". Wrocław, 11-13 czerwca, Vol. 2, 225-236.
- Neale I.M. (1988), First generation expert systems: A review of knowledge acquisition methodologies, *Knowledge Engineering Reviews*, 3, 105-146.
- Nęcka E. (2003), Inteligencja. Geneza - Struktura - Funkcje, Gdańskie Wydawnictwo Psychologiczne, Gdańsk
- Novak J.D. (1991), Clarify with concept maps: A tool for students and teachers alike, *The Science Teacher*, 58(7), 45-49.
- Noy N.F., McGuinness D.L. (2001), *Ontology Development 101: A Guide to Creating Your First Ontology*, Knowledge Systems Laboratory Stanford University.
- Pinker S. (2002), Jak działa umysł, Wyd. Książka i Wiedza, Warszawa.
- Piłat R. (1999), Umysł jako model świata, Wyd. IFiS PAN, Warszawa.

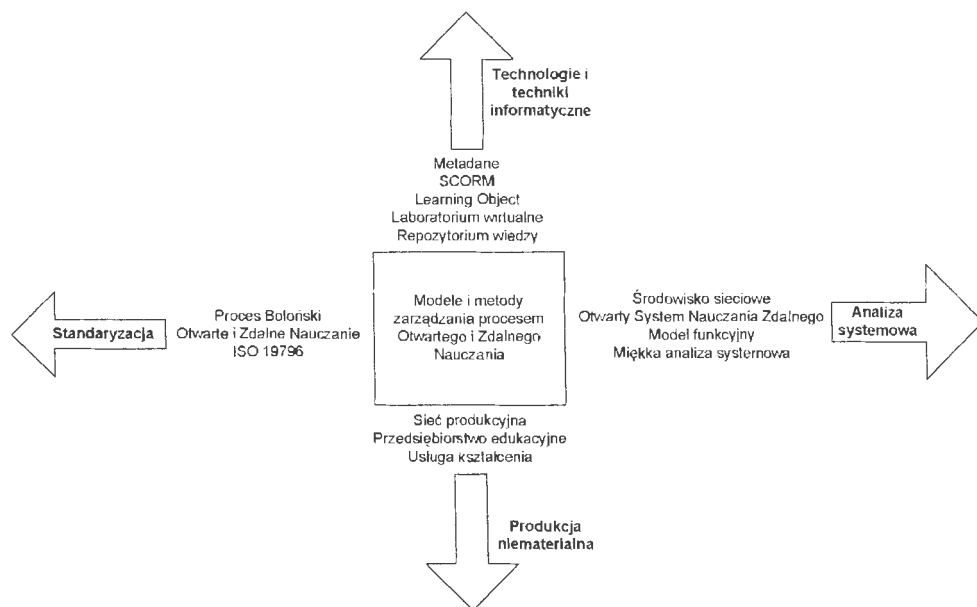
- Polanyi M. (1983), *The Tacit Dimension*, Wydawnictwo Routledge & Kegan Paul, London.
- Quillian M.R. (1968), *Semantic Memory*, W: Minsky M. (Red.), *Semantic Information Processing*, Wydawnictwo MIT Press, Cambridge.
- Radosiński E. (2001), *Systemy informatyczne w dynamicznej analizie decyzyjnej*, Wydawnictwo PWN, Warszawa – Wrocław.
- Roberts.D.D. (1973), *The Existential Graphs of Charles S. Peirce*, Wydawnictwo Mouton and Co.
- Rowntree D. (1997), *Preparing Materials for Open, Distance and Flexible Learning*, Wyd. Kogan Page, London.
- Różewski P. (2004), *Metoda projektowania systemu informatycznego reprezentacji i przekazywania wiedzy dla nauczania zdalnego*, Rozprawa doktorska, Wydział Informatyki Politechniki Szczecińskiej.
- Rubenstein-Montano B., Liebowitz J., Buchwalter J., McCaw D., Newman B., Rebeck K., *The Knowledge Management Methodology Team* (2001), *A systems thinking framework for knowledge management*, *Decision Support Systems*, 31, 5–16.
- Shaughnessy J.J., Zechmeister E.B., Zechmeister J.S. (2002), *Metody badawcze w psychologii*, Gdańskie Wydawnictwo Psychologiczne, Gdańsk.
- Simmonds A. (1999), *Wprowadzenie do transmisji danych*, Wyd. Komunikacji i Łączności, Warszawa.
- Simon H.A. (1974), How big is a chunk?, *Science*, 183, 482-488.
- Smith J.M., Smith D.C.P. (1977), Data base Abstractions: Aggregation and Generalization, *ACM Transactions on Database Systems*, 2(2), 105-133.
- Sowa J.F. (2000), *Knowledge Representation: Logical, Philosophical and Computational Foundations*, Wydawnictwo Brooks Cole Publishing Co., Pacific Grove, CA.
- Sowa J.F. (1984), *Conceptual Structures: Information Processing in Mind and Machine*, Wydawnictwo Addison-Wesley, Reading, Massachusetts.
- Sowa J.F. (1979), *Semantics of Conceptual Graphs*, In: *Proceedings of 17th Conference "Annual Meeting of the Association for Computational Linguistics"*, La Jolla, California, 39-44.
- Spyns P., Meersman R., Jarrar M. (2002), Data modelling versus ontology engineering, *ACM SIGMOD Record*, 31(4), 12-17.
- Squire L.R., Kandel E.R. (2000), *Memory: From Mind to Molecules*, Wyd. Freeman & Co, New York.
- Sternberg R.J. (2002), *Cognitive Psychology*, 3rd edition, Wyd. Wadsworth Publishing, New York.
- Teece D.J. (1998), Capturing Value from Knowledge Assets: The New Economy, Markets for Know-How and Intangible Assets, *California Management Review*, 40(3), 55-79.
- Trąbka J. (2000), *Dusza mózgu*, Wyd. WAM, Kraków.
- Tsichritzis D.C., Lochovsky F.H. (1990), *Modele danych*, Wydawnictwo Naukowo-Techniczne, Warszawa.
- Van Eynde F., Gibbon D. (2000), *Lexicon Development for Speech and Language Processing*, Wydawnictwo Kluwer Academic Publishers, Dordrecht.
- Valenta A., Theriault D., Dieter M., Mrtek R. (2001), Identifying Student Attitudes and Learning Styles in Distance Education, *Journal of Asynchronous Learning Networks (JALN)*, 5(2).
- Vasconcelos J, Kimble C., Gouveia F.R. (2000), A design for a Group Memory System using Ontologies. In: *Proceedings of 5th UKAIS Conference*, University of Wales Institute, Cardiff, McGraw Hill, 246-255.
- Visser P.R.S., Jones D.M., Bench-Capon T.J.M., Shave M.J.R. (1997), An Analysis of Ontology Mismatches: Heterogeneity versus Interoperability, In: *Working notes of the Spring Symposium on Ontological Engineering AAAI'97*, Stanford University, 164-172.
- Wagner W.P., Chung Q.B., Najdawi M.K. (2003), The Impact of Problem Domains and Knowledge Acquisition Techniques: A Content Analysis of P/OM Expert System Case Studies, *Expert Systems with Applications*, 24(1), 79-86.
- Wagner W.P., Otto J.R., Chung Q.B. (2002), Knowledge Acquisition for Expert Systems in Accounting and Financial Problem Domains, *Knowledge-Based Systems*, 15(8), 439-447.
- Waterman D.A. (1986), *A Guide to Expert Systems*, Wydawnictwo Addison-Wesley, Reading, MA
- Wille R. (1996), *Conceptual Structures of Multicontexts*, In: *The 4th International Conference on Conceptual Structures*, number 1115 in *Lecture Notes on Computer Science*, Wydawnictwo Springer Verlag, Berlin, 23-39.
- Wong H.K.T., J Mylopoulos J. (1977), Two Views of Data Semantics A Survey of Data Models in Artificial Intelligence and Database Management, *Infor*, 15(3), 344-382.
- Zaikin O., Kusztina E., Różewski P. (2006), Model and algorithm of the conceptual scheme formation for knowledge domain in distance learning, *European Journal of Operational Research*, 175(3), 1379-1399.
- Zajac M. (2003), Wykorzystanie technik Sztucznej Inteligencji do indywidualizacji procesu nauczania w systemie klasy LCMS, W: *Materiały z III Konferencji i Warsztatów Politechniki Warszawskiej pod tytułem „Uniwersytet Wirtualny: model, narzędzia i praktyka”*, 5-7 czerwca, Warszawa.
- Zhuge H. (2002), A Knowledge Grid Model and Platform for Global Knowledge Sharing, *Expert Systems with Applications*, 22(4), 313-320.

9. Zakończenie

Edukacja jako instytucja społeczna istniała od zawsze i przez długi czas opierała się na prawie niezmiennych zasadach. Tempo rozwoju związanego z globalizacją spowodowało jednak, że te zasady się zmieniły (np. uczenie się przez całe życie, personalizacja). Sformułowany został nowy paradygmat działania systemu edukacyjnego oraz zmieniona (rozszerzona) została docelowa grupa jego odbiorców. Można również zauważyć nowe miejsce systemu nauczania w rozwoju gospodarki światowej, pokazane m.in. w korelacji państw bogatych z wysokim poziomem wykształcenia ich obywateli. Wszystkie te czynniki powodują, że w dyskusji na temat systemów edukacyjnych należy zmierzyć się ze zmianą paradygmatu, co oznacza, że ciągle istnieje konieczność zachowania pierwotnej misji przy zamianie metod i technik nauczania.

Systemy edukacyjne na poszczególnych kontynentach, ze względu na wolny, globalny przepływ pracowników, ulegają standaryzacji. Autorzy pokazali co najmniej dwa poziomy standaryzacji systemów edukacyjnych. Pierwszy poziom jest reprezentowany przez koncepcję Otwartego i Zdalnego Nauczania (ang. Open and Distance Learning). W ramach tej koncepcji powstaje standaryzowane środowisko nabywania kompetencji na poziomie podstawowym, które zapewnia także możliwość ich późniejszego rozwoju. Drugi poziom to Proces Boloński integrujący we wspólny system edukacyjny, organizacyjny i treściowy, kraje Europy. Przedstawione kierunki standaryzacji są nieuniknione. Jako przykład tego działania można podać obecnie stosowany system punktowy ECTS.

W książce świadomie poruszony został szeroki zakres materiału, ponieważ zmiana paradygmatu działania systemu edukacyjnego nie może obejść się bez badań naukowych. Przedstawiony zakres badań naukowych tworzy nową dziedzinę, której wymiar przedstawiony został na rysunku 99.



Rys. 99. Kierunki dalszej analizy zagadnień przedstawionych w książce
(źródło: opracowanie własne)

Kierunki dalszych badań, bazujące na rysunku 99, mogą być następujące:

- Standaryzacja
Opracowanie standardów które opisują nie tylko aspekt informatyczny systemów nauczania zdalnego ale również informacyjny.
- technologie i techniki informatyczne
Opracowanie systemów pozwalających na personalizację oraz zarządzanie na poziomie semantycznym.
- Analiza systemowa
Wykorzystanie modeli kompetencji i metod teorii gier oraz modelowania ontologicznego i metod reprezentacji wiedzy do analizy systemowej słabo formalizowanych procesów opartych na przetwarzaniu wiedzy.
- Produkcja niematerialna
Opracowanie algorytmów i standardów sieci informacyjnej, pracującej na poziomie wiedzy i kompetencji.

Głównym celem autorów było pokazanie metodologii budowy systemu informacyjnego nauczania zdalnego posiadającego następujące właściwości:

- otwartość: dostosowanie systemu informacyjnego do wymagań rynkowych;
- inteligencja: wielopoziomowe zarządzanie wiedzą;
- adaptacyjność: personalizowany cykl życia studenta;
- wydajność: optymalizacja sieci produkcyjnej.

Przedstawiony w książce materiał składa się na nowy kierunek badań naukowych, który w swej naturze jest wielodyscyplinarny. Autorzy zakładają, że już niedługo zostanie on ujęty w ogólnie przyjętej taksonomii naukowych kierunków.

Książka poświęcona jest następującym zagadnieniom: koncepcja europejskiego systemu edukacyjnego, koncepcja otwartego i zdalnego nauczania, jakość w systemie edukacyjnym, sieciowe środowisko nauczania zdalnego, uwarunkowania kognitywne nauczania zdalnego, organizacja i struktura systemów informacyjnych w nauczaniu zdalnym, standardy i organizacje zajmujące się zagadnieniem nauczania zdalnego, modele zarządzania otwartym systemem nauczania zdalnego, modele systemu informatycznego klasy LMS/LCMS, modelowanie wiedzy w nauczaniu zdalnym, laboratorium wirtualne jako przykład inteligentnego systemu informacyjnego, modele sieci informacyjnej w przedsiębiorstwie edukacyjnym.

ISSN 0208-8029

ISBN 9788389475169

Instytut Badań Systemowych PAN
tel. (4822) 3810241 / 3810273 e-mail: biblioteka@ibspan.waw.pl