

Instytut Informatyki, Automatyki i Robotyki

Seria: PREPRINTY nr 52/2006

**Zarządzanie procesem uczenia
w komputerowych systemach
wspomagających nauczanie
(rozprawa doktorska)**

Marek Woda

Promotor: Prof. dr hab. inż. Wojciech Zamojski

Słowa kluczowe:

- e-learning
- nauczanie wspomagane komputerowo
- algorytmy uczenia
- systemy agentowe

Wrocław, 24.11.2006

1	WSTĘP	3
1.1	CEL PRACY	5
1.2	TEZA	8
1.3	ZAKRES ROZPRAWY I OBSZAR BADAŃ	8
2	SYSTEM E-NAUCZANIA	10
2.1	MODEL UCZENIA	10
2.1.1	WIEDZA PRZEKAZYWANA	10
2.1.2	STUDENCI I ICH KWALIFIKACJE WSTĘPNE	16
2.2	PROCES UCZENIA I JEGO WALIDACJA	19
2.2.1	DEFINICJA I MIARY WALIDACJI PROCESU NAUCZANIA STUDENTA	21
2.2.2	DEFINICJA I MIARY WALIDACJI PROCESU NAUCZANIA GRUPY STUDENCKIEJ	22
2.3	KONSTRUKCJA PODSTAWOWEGO GRAFU WIEDZY	22
3	SYMULACYJNY SYSTEM BADANIA ADAPTACJI PROCESU NAUCZANIA	26
3.1	WPROWADZENIE	26
3.2	BUDOWA I BLOKI FUNKCJONALNE	30
3.2.1	GENERATOR DANYCH WEJŚCIOWYCH	32
3.3	SYSTEM E-NAUCZANIA W UJĘCIU AGENTOWYM	38
3.4	SYMULACJA PRACY SYSTEMU E-NAUCZANIA	43
3.5	EFEKTYWNOŚĆ PROCESU NAUCZANIA	46
4	ALGORYTMY DOBORU STRATEGII WSPOMAGAJĄCYCH PROCES NAUCZANIA	48
4.1	STRATEGIE NAWIGACYJNE	48
4.2	STRATEGIE FAZY WSTĘPNEJ	49
4.2.1	STRATEGIA PROPORCJONALNA	49
4.2.2	STRATEGIA PRZYPADKOWA	51
4.2.3	STRATEGIA PRYMITYWNA	51
4.3	STRATEGIE FAZY ADAPTACYJNEJ	53
4.3.1	STRATEGIA GLOBALNEGO OPTIMUM	53
4.3.2	STRATEGIA ZACHOWAWCZA	54
4.3.3	STRATEGIA MINIMALISTYCZNA	55
4.3.4	STRATEGIA ODNIESIENIA	55
5	WYNIKI BADAŃ EKSPERYMENTALNYCH	58
5.1	FAZA WSTĘPNA	59
5.1.1	STRATEGIA PRZYPADKOWA	60
5.1.2	STRATEGIA PROPORCJONALNA	61
5.1.3	STRATEGIA PRYMITYWNA	64
5.1.4	WNIOSKI I OMÓWIENIE WYNIKÓW FAZY WSTĘPNEJ	65
5.2	FAZA ADAPTACYJNA	68
5.2.1	ZASADY OSZACOWANIA WALIDACJI PROCESU NAUCZANIA	69
5.2.2	STRATEGIE ADAPTACJI GRUPY PIERWSZEJ	69
5.2.3	STRATEGIE ADAPTACJI GRUPY DRUGIEJ	72
5.2.4	STRATEGIE ADAPTACJI GRUPY TRZECIEJ	76
5.2.5	WYZNACZENIE LINII TRENDU	79
5.2.6	WNIOSKI I OMÓWIENIE WYNIKÓW FAZY ADAPTACYJNEJ	80
5.3	ANALIZA WYDAJNOŚCI TECHNICZNEJ SYSTEMU E-NAUCZANIA	83
6	WNIOSKI	88
7	LITERATURA	90
8	DODATKI	94
8.1	ZAPIS WYBRANYCH STRATEGII NAUCZANIA W PSEUDO JĘZYKU	94
8.1.1	STRATEGIA ZACHOWAWCZA	94
8.1.2	STRATEGIA GLOBALNEGO OPTIMUM	95
8.2	SPIS RYSUNKÓW	96
8.3	SPIS TABEL	97

1 Wstęp

Niniejsza praca poświęcona jest efektywnemu zarządzaniu procesem uczenia w komputerowych systemach nauczania, a ściślej rzecz biorąc opracowaniu algorytmów realizujących proces nauczania wykorzystujących automatyczny dobór stopnia trudności lekcji w zależności od indywidualnych cech studenta, oraz doborowi takiej architektury by podwyższyć efektywność techniczną¹ tego procesu poprzez wykorzystanie środków technicznych platformy zdalnego nauczania.

Nowa dziedzina zwana nauczaniem zdalnym, wykazała już do tej pory swą dużą użyteczność. Cierpi ona jednak na choroby wieku dziecięcego: brak jednolitej, spójnej wizji realizacji nauczania. W większości przypadków teoria nie idzie w parze z praktyką, tak też jest w przypadku nauczania zdalnego. W nauczaniu zdalnym położono nacisk na teorię nauczania, a w dziedzinie technologii pozostawiono pełną otwartość, co w wielu przypadkach negatywnie wpływa na działanie nowo tworzonych systemów. Obecnie większość nauczycieli akademickich z wielu specjalizowanych jednostek szkół różnych stopni dostrzega potrzebę ujednoczenia i usprawnienia tegoż sposobu kształcenia. Coraz częściej mówi się o tzw. systemach e-edukacji.

Efektowność kształcenia jest funkcją wielości form, metod i środków dydaktycznych [36]. Podniesienie tejże efektywności w dobie komputeryzacji i zalewu informacji może wystąpić jedynie poprzez właściwe wykorzystanie środków technicznych z klasycznymi formami i metodami nauczania prowadzące do skonstruowania odpowiednich struktur dydaktycznych zintegrowanych z nowoczesnymi technologiami i środkami prezentacji formalnej [47].

Technologia kształcenia [44] to interdyscyplinarna nauka o skuteczności edukacji, poszukująca odpowiedzi na pytanie, w jaki sposób nauczać i uczyć szybciej, lepiej i taniej w określonych warunkach. Interdyscyplinarny charakter tej technologii polega na tym, że czerpie ona przedmiot zainteresowań i metody badawcze z innych dyscyplin, jak informatyka, cybernetyka, teoria systemów czy teoria komunikacji.

Znaczna złożoność obliczeniowa algorytmów nauczania zdalnego, jak również ogromna liczba danych podlegających analizie wpływa na duże obciążenie nadzorujących kurs, gdy liczba słuchaczy przekroczy kilkanaście - kilkadziesiąt osób [62]. Wtedy to liczba osób zaangażowanych w kontrolę, planowanie, harmonogramowanie zajęć, oraz ocenę postępów słuchaczy rośnie proporcjonalnie do liczby słuchaczy. W tradycyjnej metodzie nauczania na odległość wszystkie przedstawione procesy realizowane są przez „czynnik ludzki” [6,32,44], co może powodować (i zazwyczaj powoduje) sytuacje kryzysowe, np. utrata kontroli nad nadzorem postępów w nauce danej grupy (zmęczenie prowadzącego), niedostosowanie materiałów poprzez niezajomość poziomu zaawansowania/umiejętności słuchaczy, co wiąże się z utratą ich zainteresowania/chęci nabywania wiedzy itp. Niemniej jednak wykluczenie całkowicie człowieka z procesu nauczania jest również czynnikiem niekorzystnym [48,53,56], wiąże się to m.in. z poczuciem wyobcowania studentów i braku kontroli.

Remedium na przedstawione wyżej niedogodności, oraz sposobem na zwiększenie sprawności i efektywności procesu nabywania wiedzy może być zastosowanie inteligentnego systemu agentowego [4, 9, 18, 25, 37, 50, 62-66].

W dobie dynamicznego rozwoju Internetu i łatwo dostępnego szerokopasmowego dostępu do sieci, coraz to więcej instytucji dostrzega możliwość wykorzystania tych środków do świadczenia usług edukacyjnych [61].

¹ Poprzez efektywność techniczną systemu e-nauczania rozumie się maksymalną ilość studentów korzystających równoległe z systemem.

Mimo istnienia mnogości zarówno komercyjnych (*WebCT*, *Lotus Learning Space*, *Oracle I-Learning*) jak i otwartych platform (*Modle*) zdalnego nauczania, większość z nich pełni jedynie rolę kontenera na wiedzę oraz dostarcza mechanizmy jej udostępniania [14, 17, 21, 22, 59]. Wykorzystuje się w nich jedynie połączenie różnych technik przekazu wraz z wykorzystaniem multimediiów [49]. Zatracona została podstawowa idea nauczania, a mianowicie zorientowanie na studenta, na jego cechy indywidualne [42]. Podstawowym problemem w obecnych systemach jest brak modelu studenta, oraz indywidualizacji procesu nauczania tak by był jak najbardziej *dopasowany* od cech osobowych jednostki [48, 60].

Teoria kształcenia wskazuje [30, 42, 49], że efektywność procesu nabywania wiedzy oparta jest na dostosowaniu tegoż procesu do indywidualnych cech studenta. Bazując na własnych doświadczeniach możemy wyróżnić, co najmniej kilka czynników, które warunkują efektywność przyswajania wiedzy. Są to między innymi:

- § stopień skomplikowania materiału,
- § ilość i zróżnicowanie materiału w jednostce lekcyjnej,
- § czas trwania lekcji,
- § pora nabywania wiedzy.

Uwzględnienie tychże czynników przez system wspomaganie nauczania, w toku nauki i dostosowanie ich do cech poszczególnych uczestników, może znacząco zwiększyć efektywność tego procesu [67, 72, 73].

Praktyczne zastosowanie zdalnego nauczania w Internecie wymaga opracowania specjalnych narzędzi programistycznych zwanych platformami e-nauczania (e-learningowymi).

Istnieje ponad 60 narzędzi wspomagających proces nauczania zdalnego [14, 21, 22]. Jednak umiejętność wykorzystania tych systemów, czy metod prowadzenia nauczania przy ich pomocy jest niezbyt wielka [6]. Rozróżnia się trzy główne rodzaje systemów e-nauczania:

- § CMS (Course Management Software) – systemy zarządzania treścią edukacyjną,
- § LMS (Learning Management Software) – systemy zarządzania procesem nauczania,
- § ITS (Intelligent Tutoring System) – inteligentne systemy uczące (systemy wykorzystujące techniki sztucznej inteligencji, agentów oraz algorytmy heurystyczne).

Funkcjonalność systemów e-nauczania, zorganizowana jest najczęściej w pięciu następujących modułach [5, 8]:

- § moduł zarządzania przedmiotami – pozwala na ustalanie harmonogramów dostępnych przedmiotów i udostępnienie związanych z nimi informacji, umożliwia ponadto śledzenie procesu nauki poszczególne studentów,
- § moduł zdalnego samokształcenia – umożliwia studentom korzystanie z przygotowanych zdalnych kursów oraz udostępnia informacje o wynikach,
- § moduł komunikacyjny – umożliwia synchroniczny lub asynchroniczny kontakt pomiędzy nauczycielem a studentem (komunikatory, wewnętrzny system pocztowy),
- § moduł budowy kursów – umożliwia nauczycielom tworzenie szkieletu kursów, wypełnianie ich treścią tekstową i multimedialną,
- § moduł quizów – pozwalający na opracowanie zestawu pytań, udostępnienie tych pytań studentom w trybie do samo-sprawdzenia wiedzy lub umożliwiający przeprowadzenie egzaminu.

Większość systemów jest systemami mieszanymi, niemniej jednak skupia się na zarządzaniu treścią edukacyjną, a część odpowiedzialna za zarządzanie procesem nauczania jest w nich potraktowana raczej zdawkowo.

Szczegółowy opis nawet najbardziej istotnych platform wykracza poza ramy niniejszego tekstu. Niemniej jednak autor chciałby przedstawić skrótowy przegląd wybranych platform.

Do najbardziej zaawansowanych, a zarazem najpopularniejszych, platform e-nauczania, należy zaliczyć: Angel Learning (www.angelllearning.com), Blackboard Learning System (www.blackboard.com), Desire2Learn Learning Platform (www.desire2learn.com), Moodle (moodle.org), OLAT (olat.org), Sakai (www.sakaiproject.org), WebCT Campus Edition (www.webct.com).

Wszystkie platformy, przedstawione powyżej, posiadają mniej lub bardziej rozbudowane funkcjonalności związane z zarządzaniem procesem nauczania, których podsumowanie można znaleźć w [14, 22, 26]. Obecne na rynku rozwiązania – cierpią na niedoskonałości wieku dziecięcego – platformy e-nauczania wyrosły w prostej linii z systemów zarządzania treścią, tworzonych z myślą, nie o kształceniu zdalnym, a prostym i funkcjonalnym zarządzaniu elementami portali internetowych. Wiele, kluczowych elementów, z pedagogicznego punktu widzenia zostało pominiętych – najbardziej dokuczliwym brakiem jest w tychże systemach brak dywersyfikacji studentów. Każdy student jest traktowany w ten sam, zunifikowany sposób. Co wiąże się z brakiem wyróżnienia studentów wybitnych jak również tych, którzy nie radzą sobie samodzielnie z materiałem. Niestety, żadna platforma nie oferuje:

- § możliwości określania wejściowego poziomu wiedzy studentów czy też ciągłego jego monitorowania,
- § strategii dostosowywania materiału dydaktycznego do indywidualnego studenta, tak by materiał by optymalny dla jednostki,
- § ujednoczonych mechanizmów tworzenia grafu wiedzy kursu.

W większości systemów zdalnego nauczania nacisk położono na techniczne aspekty nauczania [58], a pominięto lub potraktowano zdawkowo [14] niezmiernie ważny aspekt nauczania ukierunkowanego na jednostkę. Godnym naśladowania jest pomysł tworzenia modeli studentów [32] oraz budowania systemów adaptacyjnych.

W wielu pracach [16, 17, 19, 27, 49, 51, 53] podkreśla się brak całościowego podejścia do problemu nauczania zdalnego, między innymi na skupienie się na dostarczaniu treści dydaktycznej z pominięciem cech osobowych czy indywidualnego podejścia do studentów. Powinno się starać połączyć możliwości współczesnej techniki wraz z odpowiednim zamodelowaniem studentów o różnych umiejętnościach czy poziomach wiedzy.

Brakuje systemu, który by łączył możliwość dostosowania materiału dydaktycznego do poziomu wiedzy poszczególnych studentów wraz z kontrolowaniem postępów w nauce z dobieraniem odpowiedniego materiału. Nowopowstające systemy powinny być systemami opartymi przede wszystkim na odpowiednio zbudowanym modelu studenta [29, 31, 37, 66, 67] oraz być systemami adaptującymi się do potrzeb jednostki [27, 32, 45].

Niniejsza praca stawia sobie za zadanie połączenie wyżej wymienionych postulatów w jednym systemie, który stanowić będzie podstawę przyszłego modularnego systemu e-nauczania, mającego być odpowiedzią na ułomności obecnych rozwiązań.

1.1 Cel pracy

Celem pracy jest stworzenie koncepcji systemu e-nauczania oraz narzędzi wspomagających zarządzanie procesem uczenia. System ten ma badać możliwe strategie adaptacji procesu nauczania studenta, poprzez dostosowanie ścieżki nauki do osobowych cech studenta (grup studenckich) definiowanych przez poziomy wiedzy studentów oraz szybkość przyswajania wiedzy.

Tworzony system e-nauczania ma:

- § umożliwić samokształcenie się jego użytkowników oraz wielodostęp przy wykorzystaniu komputera PC z dostępem do Internetu, z wykorzystaniem taniego i powszechnie używanego sprzętu / oprogramowania (od strony klienckiej) – będącego w zasięgu przeciętnego użytkownika / „taniego” laboratorium,
- § minimalizować nakłady czasowe pracy (rozumiane jako czasy realizacji strategii adaptacji procesu nauczania) w oparciu o inteligentnych agentów,
- § zminimalizować poniesione koszty finansowe (rozumiane jako nakłady na konfiguracje sprzętu użytego na realizację systemu),
- § podnosić efektywność² proces e-nauczania pojedynczych studentów lub/i całej grupy studenckiej - dążyć do poprawienia uzyskiwanych wyników nauczania, tak by nie były niższe od zakładanego minimalnego poziomu lub nie były gorsze niż w przypadku losowej, a nawet deterministycznej realizacji procesu nauczania.

Cel pracy będzie realizowany w oparciu o poniższe założenia:

1. Aksjomat: istnieje podstawowy graf wiedzy (zbiór wszystkich wiadomości z danej dziedziny wiedzy w postaci grafu, czyli węzłów powiązanych ze sobą łukami) - związane z określonym przedmiotem lub dziedziną wiedzy, w którym to grafie węzły odpowiadają kwantom wiedzy, a łuki kolejności jej nabywania.
2. Dla danego (i-tego) kursu, na podstawie podstawowego grafu wiedzy, możemy wyznaczyć graf wiedzy kursu (GWK(i)) – podgraf grafu wiedzy zdefiniowany jako podzbiór węzłów i łuków, które stanowią wiedzę do opanowania, w czasie trwania kursu.
3. Możliwe jest zastosowanie architektury agentowej, wspierającej mechanizmy równoważenia obciążenia systemu e-nauczania.

Głównym celem pracy jest opracowanie metodyki konstruowania systemu wspomagającego sterowanie komputerowym kursem edukacji w sposób inteligentny, tzn. umożliwiający odkrywanie i wykorzystywanie pewnych cech osób biorących udział w kursie, które to *a priori* nie są znane, bądź były błędnie wyznaczone, podczas procesu kwalifikacji. Ma to być system komputerowy, przeznaczony dla studentów o różnych poziomach wiedzy, który zarządzał będzie procesem uczenia. Z podstawowego grafu wiedzy wybierana będzie ścieżka nauki, którą należy ukończyć by osiąść pewien fragment wiedzy z danej dziedziny. Węzły każdej ścieżki są wielopoziomowe, zależne od stopnia trudności jednostki lekcyjnej, ale sama ścieżka jest regularna³. System będzie dobierał sposób przemieszczania się wewnątrz węzłów ścieżki („optymalny” stopień trudności), w taki sposób by ukończenie lekcji przez każdego studenta spełniało kryteria zdefiniowane szczegółowo w dalszej części pracy (rozdz. 3.5).

Funkcjonowanie systemu opiera się na analizie działań studentów (m.in. historii ocen, wariacie lekcji ukończonym w poprzednim kroku) oraz sprowadza się do inteligentnego dostosowywania materiału następnej lekcji do indywidualnych studentów.

W skład systemu wchodzi algorytmy doboru stopnia trudności prezentowanych lekcji, służące do przyporządkowywania studentowi odpowiedniego stopnia trudności lekcji w zależności od:

- § poziomu wiedzy jaki reprezentuje student – w fazie wstępnej (startowej) brany jest pod uwagę początkowy stan wiedzy, w fazie adaptacyjnej poziom aktualny,

² Podnoszenie efektywności odbywa się na drodze dostosowywania poziomów trudności poszczególnych lekcji względem poziomu wiedzy ucznia przez strategie adaptacyjne.

³ Możliwe są tylko przejścia do następnej lekcji, bądź zmiana poziomu trudności wewnątrz lekcji (rys. 2.5).

- § historii studiowania (informacji o stopniach trudności na jakich student ukończył poprzednie lekcje),
- § średniej oceny z poprzednich, ukończonych pozytywnie, lekcji,
- § sumy punktów kredytowych uzyskanych w poprzednich lekcjach.

Zadaniem strategii adaptacji procesu nauczania będzie przypisanie studenta na taki stopień trudności w następnym lekcji, by spełnione były dwa kryteria:

1. Ocena uzyskana po ukończeniu jednostki lekcyjnej, była nie mniejsza niż średnia ocena studentów (na początku procesu nauczania – w fazie początkowej) o takim samym poziomie wiedzy⁴.
2. Suma punktów przyznanych za każdą ukończoną lekcję nie była mniejsza niż połowa ich maksymalnej sumy do uzyskania w całym procesie nauki.

Zaproponowane algorytmy realizują paradygmat nauczania programowanego [5, 33], czyli kształcenia według odpowiednio przygotowanego programu tj. ciągu logicznie i merytorycznie powiązanych porcji informacji z danej dziedziny wiedzy. Kształcenie ma w tym przypadku następujący cykl: przekazywanie porcji informacji (lekcji), sprawdzenie stopnia jej opanowania (test kompetencji). Wybrano paradygmat nauczania programowanego gdyż w naturalny sposób posiada związek nauki z praktyką [4,10,13].

Nauczanie programowane narodziło się na fali tzw. "technicznego myślenia". Było uwieńczeniem dążeń, by proces dydaktyczny ulegał indywidualizacji i automatyzacji. Autorem koncepcji, która znalazła zastosowanie w dydaktyce był B. F. Skinner. Najważniejszym elementem nauczania programowanego jest program rozumiany jako odpowiednio uporządkowane następstwo poleceń, które są przekazywane za pośrednictwem maszyny dydaktycznej lub podręcznika programowanego i wykonywane przez uczącego się człowieka. Zależnie od charakteru drogi uczenia się i oczekiwanych odpowiedzi wyróżnia się programy liniowe, rozgałęzione i mieszane [46]. W tym przypadku skorzystamy z programu rozgałęzionego. System decyduje, na jaką ścieżkę i na jaki stopień trudności skierować studenta, w zależności od jego wiedzy i historii nauki. Najważniejsze paradygmaty nauczania programowanego to:

1. Materiał dydaktyczny dzielić należy na małe porcje, zwane kwantami wiedzy (jednostkami lekcyjnymi), które studenci opanowują stosunkowo szybko.
2. Pytania, w teście kompetencji, mającym miejsce po każdej lekcji, nie mogą być zbyt trudne, aby nie zniechęcać do pracy.
3. W trakcie testu kompetencji studenci powinni być informowani, czy ich odpowiedzi są prawdziwe, czy błędne. Odpowiedź prawdziwa jest wzmacniana pozytywnie, fałszywa lub niepełna – negatywnie.
4. Wszyscy przechodzą kolejno przez wszystkie lekcje ze ścieżki nauczania, lecz każdy to czyni w odpowiednim dla siebie tempie.
5. Na stopniach „łatwiejszych”, dostarczana jest znaczna liczba wskazówek ułatwiających udzielanie odpowiedzi, odpowiednio na „trudniejszych” ich liczba jest stopniowo ograniczana.

Ze względu na brak możliwości wykorzystania rzeczywistego systemu edukacji oraz użytkowników w postaci studentów do badania strategii nauczania posłużono się symulacją jako próbą odzwierciedlenia rzeczywistości.

⁴ Przy założeniu, że *NIE STOSUJE SIĘ* nawigacji przypadkowej (w chwilach czasu $t > t_0$) tj. umieszczania wszystkich użytkowników na najniższym z możliwych poziomach trudności danego węzła.

Dla celów symulacji zachowania się systemu edukacji stworzono generator grup studenckich pozwalający na zdefiniowanie dowolnie dużej grupy testowej tj. grupy studenckiej o skończonej liczności, o dowolnym rozkładzie poziomów wiedzy jej członków, a następnie wykorzystanie jej dla dowolnie długiego, skończonego, procesu nauki.

Korzystając z przyjętego modelu studenta (opisanego w rozdziale *student i grupy studenckie*), przetestowane będą różne strategie doboru materiału w zależności od poziomu wiedzy studenta.

1.2 Teza

Jeżeli w komputerowym systemie wspomaganie procesu nauczania (zwanym systemem wspomaganie e-nauczania) opartym o strategię nawigacyjną (adaptacji procesu nauczania), zdefiniowanym szczegółowo poniżej:

- § istnieją modele e-edukacji oraz komputerowa implementacja systemu gromadzącego wiedzę w postaci grafu wiedzy kursu, po którym można się poruszać wg przyjętych strategii,
- § zastosuje się odpowiednie strategię (algorytmy) adaptacji procesu nauczania dla poszczególnych grup studenckich,
- § zastosuje się architekturę agentową e-systemu i wprowadzi się mechanizmy równoważenia obciążenia.

to dla danego grafu wiedzy kursu

- § możliwe jest wybranie strategii, zwiększającej efektywność uczenia, która poprawi efektywność e-systemu poprzez ograniczenie czasu potrzebnego do opanowania danego materiału dla studenta, grupy studenckiej, zobrazowane np. poprawą rozkładu ocen (statystyka), m.in. średniej i odchylenia standardowego wyników nauki (w postaci wyników testów kompetencji) dla grupy,
- § możliwe jest poprawienie wydajności technicznej⁵ systemu e-learningu poprzez równoważenie obciążenia systemu (ang. load balancing).

1.3 Zakres rozprawy i obszar badań

W rozprawie przedstawiony jest system edukacji o znanym *podstawowym grafie wiedzy* oraz o zdefiniowanych procesach nauczania, przewidzianych dla studentów o indywidualnych cechach osobowych oraz dla grup studenckich o parametrach osobowych będących „uśrednieniem” cech indywidualnych.

Do najważniejszych aspektów pracy należy przedstawienie koncepcji systemu e-edukacji i narzędzi wspierających proces nauczania, których jakość jest weryfikowana w warunkach symulacji.

⁵ Definiowanej jako max ilość studentów, równocześnie korzystających z systemu e-nauczania, bez zauważalnego spowolnienia jego działania

Symulacyjny System badania Adaptacji procesu Nauczania jest narzędziem wspomagającym, powstałym z braku możliwości przebadania rzeczywistych obiektów, systemem umożliwiającym m.in.:

- § skonstruowanie podstawowego grafu wiedzy (PGW),
- § wyznaczenie grafu wiedzy kursu (GWK(i)) w postaci ścieżek nauczania,
- § kwantyfikację wiedzy,
- § zdefiniowanie procesu nauczania,
- § ewaluację parametrów procesu nauczania,
- § zwiększenie efektywności zużycia zasobów systemowych poprzez wykorzystanie agentów.

W rozprawie zostanie zaprezentowany podział wiedzy na elementy, jak również zasady udostępniania tejże wiedzy. Opisany będzie proces walidacji nauczania i monitorowania procesu nauki. Przedstawiona będzie również architektura systemu, oparta o inteligentnych agentów, których zadaniem jest zwiększenie efektywności technicznej systemu (rozumianej przez zwiększenie maksymalnej ilości studentów równolegle korzystających z systemu e-nauczania, bez zauważalnego spowolnienia jego działania). Agenci, nie tylko równoważą obciążenie e-systemu, ale również zaangażowani są w proces uczenia (m.in. poprzez kwantyfikacje wiedzy, dostarczanie materiału dydaktycznego, dobór i realizację odpowiedniej strategii adaptacji nauczania etc.).

Konstruowany system będzie systemem adaptacyjnym (na jego potrzeby stworzone zostaną heurystyczne strategie „*podnoszenia skuteczności*” procesu uczenia) – dostosowującym się do cech studentów, wykorzystującym techniki zdobywania wiedzy i dobierający algorytm uczenia do cech i wyników studentów.

System ten będzie działać jako inteligentny asystent wykładowcy, wykorzystujący inteligentnych agentów (m.in. agentów studenta) zbierających dane o poszczególnych studentach i przekazujących je do analizy w procesie dostosowania trudności materiału do „możliwości”⁶ poszczególnych studentów.

Przetworzone wyniki, uzyskane w procesie symulacji procesu e-nauczania, będą zagregowane i na ich podstawie wybrana będzie najlepsza z dostępnych, strategia adaptacji procesu nauczania.

⁶ „możliwości” należy rozumieć przez poziom wiedzy studenta oraz zdolność do nabywania wiedzy (parametr niemierzalny)

2 System e-nauczania

2.1 Model uczenia

2.1.1 Wiedza przekazywana

W niniejszym podrozdziale zdefiniowane zostaną podstawowe terminy wykorzystywane w rozprawie.

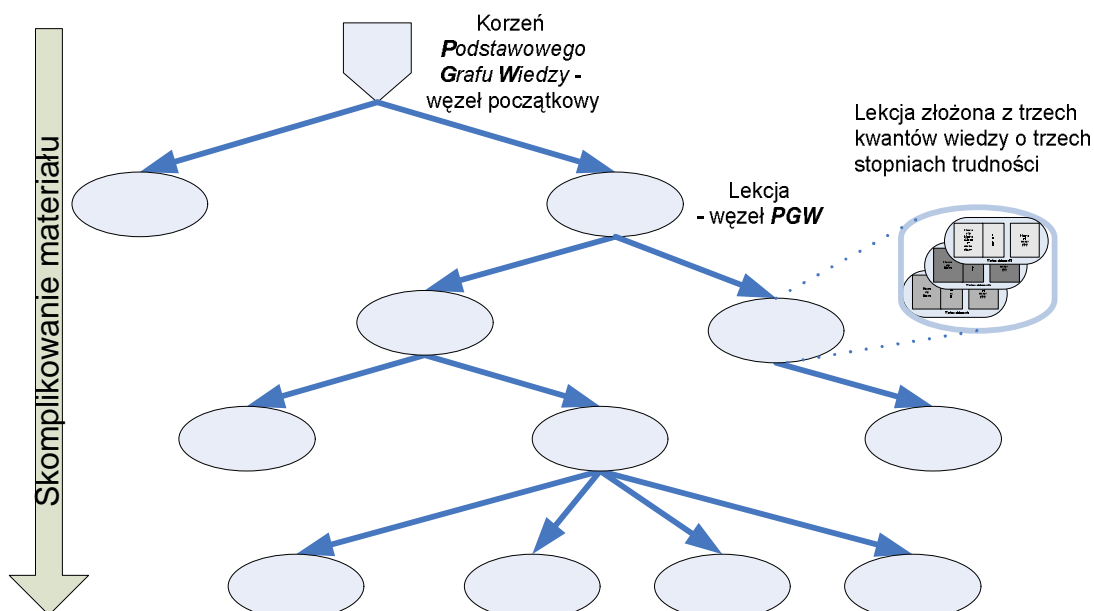
Definiuje się:

System e-nauczania (2.1), zwany e-systemem, w skład którego wchodzi następujące elementy:

- § wiedza w postaci grafu,
- § testy kompetencji,
- § dane historyczne,
- § strategie nauczania,
- § zasoby sprzętowe.

$$e - system = \{ \text{wiedza}(\text{graf}), \text{testy}_{komp}, \text{dane}_{hist}, \text{strategie}_{adapt}, \text{zasoby} \} \quad (2.1)$$

Wiedza jest reprezentowana w postaci grafu skierowanego, bez nawrotów i rozgałęzień (do sąsiednich gałęzi leżących na tym samym poziomie w płaszczyźnie poziomej), wiedza zawarta jest w lekcjach (złożonych z kwantów wiedzy, elementarnych porcji wiedzy), których przejście (rozumiane jako nabywanie wiedzy) jest monitorowane, a nabyta wiedza podlega walidacji („wstępnej” w fazie wstępnej jak i „końcowej” w testach kompetencji na podstawie, których dokonywany jest wybór odpowiedniego stopnia trudności kwantu wiedzy następnej lekcji).



Rys. 2.1 Reprezentacja wiedzy w postaci grafu skierowanego

Graf wiedzy kursu (2.2) – jest to graf skierowany o strukturze hierarchicznej⁷ trójwymiarowej - dodatkowy wymiar to głębokość, którego wierzchołki symbolizują lekcje.

$$K_{gw} = (L(K_{gw}), H(K_{gw})) \quad (2.2)$$

gdzie:

$L(K_{gw})$ – niepusty skończony zbiór elementów zwanych lekcjami,

$H(K_{gw})$ – skończony zbiór uporządkowanych par różnych elementów zbioru $L(K_{gw})$,
zwanych krawędziami grafu.

Krawędzie (gałęzie grafu) wskazują możliwy kierunek przemieszczenia się po grafie skierowanym (grafie wiedzy kursu). Należy zwrócić uwagę, że przemieszczanie będzie rozważane na dwu poziomach:

- § zewnętrznym (poziom grafu – przemieszczanie między lekcjami),
- § wewnętrznym (poziom ścieżki nauczania – przemieszczanie między kwantami wiedzy).

Korzeniem wejściowym grafu wiedzy nazywa się węzeł, który reprezentuje najbardziej ogólne informacje dotyczące dostarczanej wiedzy. Graf wiedzy można umieścić w układzie współrzędnych (rys. 2.4). Wtedy to korzeń posiadał będzie współrzędne $x = 0$, $y = 0$, $z = 1$. Przyjmuje się, że graf wiedzy jest dany, a sama *konstrukcja nie stanowi przedmiotu pracy*. Niemniej jednak konieczne jest przytoczenie definicji, aby dalsze rozważania miały sens. W dalszej części pracy przedstawiony będzie proponowany algorytm tworzenia Podstawowego Grafu Wiedzy (rys. 2.12).

Przyjmuje się, że graf wiedzy powinien mieć odpowiedni kształt, tzn.

- § korzeń „u szczytu”,
- § od korzenia w dół grafu, znajdują się na informacje elementarne, podstawowe zagadnienia, problemy, reprezentowane przez lekcje,
- § na drodze w dół grafu wiedzy prowadzą krawędzie, powiązane z lekcjami o rosnącej złożoności (stopniu skomplikowania),
- § każdy węzeł może posiadać więcej niż jedną wersję lekcji, uszeregowaną w osi z, gdzie lekcja najtrudniejsza znajduje się najbliżej początku układu współrzędnych (najbliżej obserwatora).


Materiał kursu (złożony z **kwantów wiedzy**) – to zbiór informacji (przygotowanych przez ekspertów z danej dyscypliny wiedzy) zawierającej tekst, wzory, rysunki, dotyczący danego działu. Zorganizowany jest w **podstawowy graf wiedzy**, digraf o strukturze hierarchicznej⁸ trójwymiarowej (3D), dodatkowy wymiar to **stopień trudności**.

Lekcja – złożona z elementarnych porcji wiedzy zwanych kwantami wiedzy ($I^{(i)}$). Lekcja reprezentowana jest przez **węzeł** (rys.2.2) grafu, opisana przez (czyt. obejmującą):

⁷ (zob. założenia) każdy (następujący po sobie w płaszczyźnie pionowej) węzeł (kwant wiedzy) połączony incydentnym przejściem z następnym (położonym poniżej w hierarchii), posiada w sobie zawarte informacje bardziej złożone od węzła poprzedniego, w sensie merytorycznym, a nie tylko ilościowym, tzn. kwanty położone wyżej dotyczą zazwyczaj innych (prostszych) zagadnień, które będą reprezentowane poniżej jako osobne węzły.

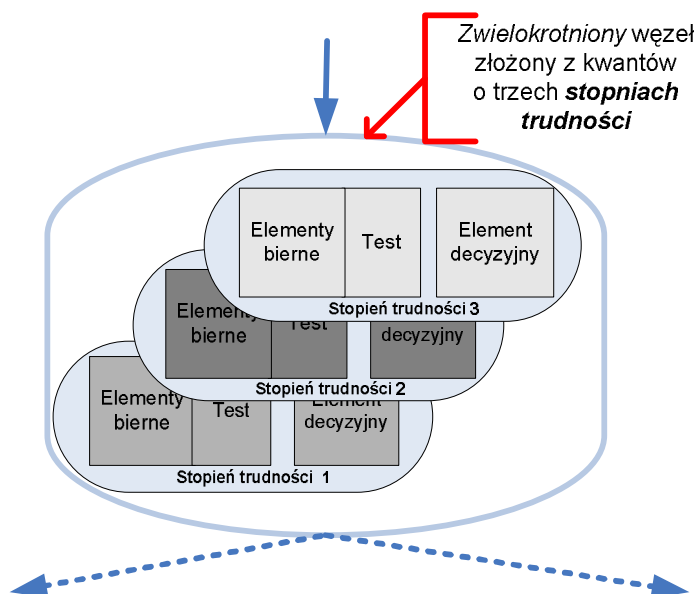
⁸ Uwaga terminologiczna. NIE MA żadnego standardowego języka teorii grafów, a każdy autor ma swoje własne słownictwo – Robin J. Wilson - Wprowadzenie do teorii grafów, PWN, Warszawa 2002

- § element wiedzy,
- § test kompetencji (test kontrolny),
- § element decyzyjny – który w oparciu o uzyskany wynik testu (przy przyjętym algorytmie nauczania) kieruje na adekwatny stopień trudności danej lekcji.



Rys. 2.2 Reprezentacja węzła grafu jako kwantu wiedzy (jednostki lekcyjnej)

Kombinacje poszczególnych, następujących po sobie węzłów tworzą ścieżki. Rozważając budowę grafu wiedzy, należy zwrócić uwagę, że każda **lekcja** posiada więcej niż jeden „ekwiwalent” w osi Z. Ekwiwalent każdej lekcji w osi Z zwany jest kwantem wiedzy, i określony jest **stopniem trudności** (d_{fact}), który jest *trudnością* danego kwantu (2.3). Poszczególne lekcje odpowiadają wiedzy niezbędnej do przyswojenia danej partii materiału, natomiast kwanty wiedzy w lekcji reprezentują tę samą wiedzę, ale o różnym stopniu trudności, łuki zaś odpowiadają „kierunkowi przemieszczania”⁹ – wyborowi następnych (odpowiednich) węzłów. Każdy kwant wyposażony jest w możliwość przeprowadzenia testów kompetencji i w oparciu o uzyskany wynik następuje wybór adekwatnego łuku skierowanego.



Rys. 2.3 Idea „z wielokrotnionego” węzła złożonego z lekcji o trzech stopniach trudności

Stopień trudności należy interpretować w sposób następujący: lekcje o najłatwiejszym stopniu trudności, (tj. najłatwiejsze) położone są płaszczynie Z najdalej od obserwatora (rys. 2.3).

$$l^{(i)} = \left\langle \text{wariant}(d_{fact})^{(i)}, \text{test}(d_{fact})^{(i)}, \text{pkt}(d_{fact})^{(i)}, \text{element_decyzyjny}^{(i)} \right\rangle \quad (2.3)$$

⁹ Przez kierunek nauczania rozumie się kierunek przechodzenia z węzła na węzeł, czyli kolejność realizowania (jednostek lekcyjnych się w ścieżce nauki) procesu nauczania.

Położenie każdej jednostki lekcyjnej w grafie wiedzy, można ustalić za pomocą trzech współrzędnych:

x – położenie w płaszczyźnie poziomej zaczynając od lewej strony

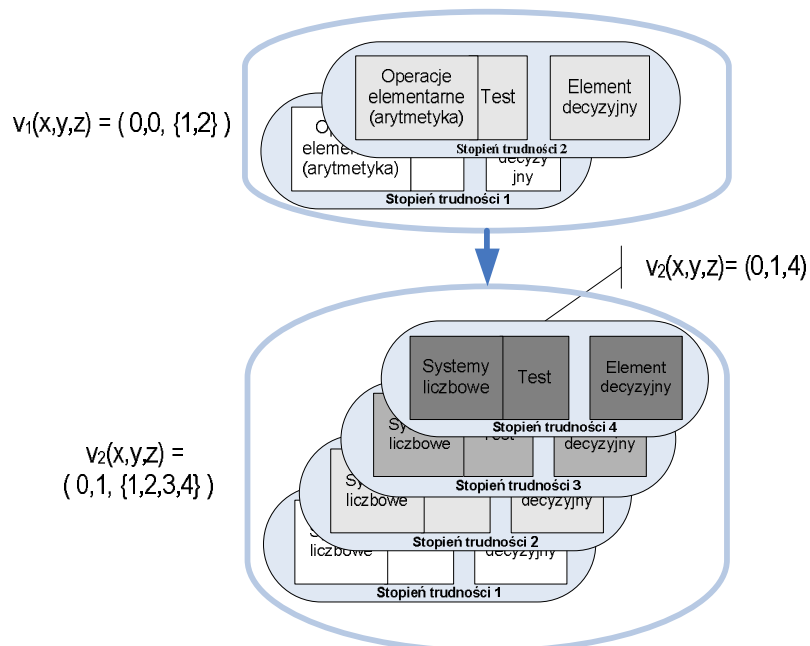
y – położenie w płaszczyźnie pionowej licząc od korzenia

z – zagłębienie w osi z^{10} – stopień trudności lekcji, najbardziej wewnętrzna lekcja posiada stopień trudności 1 i przeznaczona jest dla studenta o najniższym poziomie wiedzy.

Rozważając fragment grafu wiedzy jak na poniższym rysunku, lekcja reprezentowana przez węzeł „systemy liczbowe” (rys. 2.4) posiada współrzędne:

$$v_i = \begin{cases} x = 0 \\ y = 1 \\ z \in \{1, 2, 3, 4\} \end{cases} \quad (2.4)$$

Z powyższego zapisu wynika, że lekcja „Systemy liczbowe” posiada cztery stopnie trudności i jest drugą lekcją, licząc od korzenia grafu.



Rys. 2.4 Fragment podstawowego grafu wiedzy kursu

Każdej jednostce lekcyjnej (kwantowi wiedzy) w węźle, zostały przypisane **punkty kredytowe** (*pkt*), które stanowią istotny wyznacznik w procesie walidacji nauczania. Punkty kredytowe odpowiadają bezpośrednio stopniom trudności jednostek lekcyjnych. Tzn. za

¹⁰ Lekcje połączone ze sobą *lukami*, w wymiarze Z , reprezentują wiedzę o różnym stopniu trudności oraz wielkości (w sensie ilościowym reprezentowanych przez parametry węzła), ale dotyczących tego samego zagadnienia.

ukończenie podstawowej (najprostszej jednostki lekcyjnej student otrzymuje 1 punkt kredytowy, odpowiednio za ukończenie lekcji o trudności 2 – dwa punkty kredytowe).

Poprzez analogie do nauczania klasycznego, stopnie trudności możemy porównać z zadaniami ze zbioru zadań. W których to, większość zadań do zrealizowania, traktowana jest jako niezbędne minimum do opanowania jakiejś partii materiału, zadania z gwiazdką (*), traktowane są jako zadania dla profilów z poszerzonym materiałem z danej dziedziny, natomiast zadania z dwoma gwiazdkami (**), jako zadania dla osób startujących w olimpiadach tematycznych.

Ścieżkę nauczania (2.5) w grafie wiedzy, definiuje się jako podgraf, przez którego węzły należy przejść, aby uzyskać minimalną wiedzę z danej dziedziny wiedzy. Przy czym przejście (przemieszczanie wewnętrzne) z węzła do węzła odbywa się:

1. Zgodnie z góry ustalonym kierunkiem.
2. Po uzyskaniu ustalonej oceny w teście kompetencji.
3. Przejście do następnego węzła może nastąpić po zaliczeniu lekcji

- § podstawowej (warunek **konieczny**),
- § o wyższym stopniu trudności (przypadek **możliwy**).

Poniżej reprezentacja ścieżki nauczania $P_{(z)}$:

$$P_{(z)} = \langle W(l)_{(z)}, K_{wew(z)}, test_k(d_{fact})_{(z)}, \sum pkt(d_{fact})_{(z)} \rangle \quad (2.5)$$

gdzie:

$W(l)_{(z)}$ – niepusty zbiór lekcji ścieżki, podzbiór zbioru wszystkich lekcji grafu wiedzy,

$K_{wew(z)}$ – zbiór kwantów wiedzy danej ścieżki nauczania,

$test_k(d_{fact})_{(z)}$ – zbiór testów kompetencji ścieżki,

$\sum pkt_k(d_{fact})_{(z)}$ – suma możliwych do uzyskania punktów kredytowych, indeks $k = \{1, 2, x\}$ określa liczbę wariantów trudności lekcji.

przy czym:

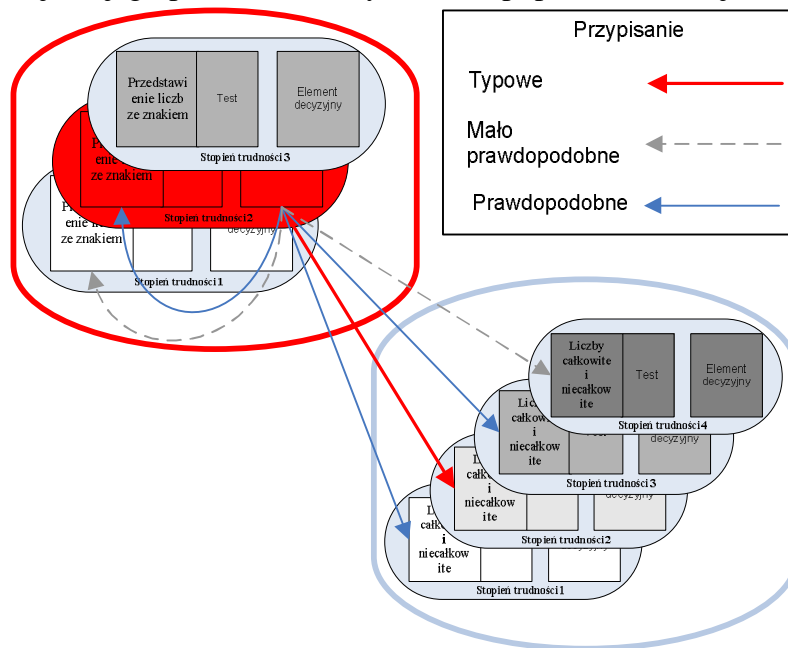
$$W(l) = \{ l^{(1)}, l^{(2)}, l^{(3)}, \dots, l^{(n)} \}$$

Przejście z węzła do węzła (jednostki lekcyjnej) w grafie wiedzy kursu następuje sekwencyjnie, w kierunku od korzenia grafu (materiał najbardziej ogólny) do korony grafu (materiał najbardziej złożony). Przez przemieszczanie się (nawigacja wewnętrzna – w ścieżce), rozumieć należy dobieranie stopnia trudności lekcji w zależności od ustalonych parametrów (m.in. umiejętności studenta, historii opisującej, na jakich stopniach trudności zostały ukończone poprzednie lekcje). Nie należy rozumieć przemieszczania (wewnętrznego) jako przemieszczania w płaszczyźnie x, y – gdyż one realizowane jest na poziomie grafu i jest przemieszczeniem zewnętrznym. Przemieszczanie to jest określone z góry przez wybór odpowiedniej ścieżki nauki.

Ukończenie procesu nauki, czyli zaliczenie wszystkich lekcji należących do ścieżki, o minimalnym (1) stopniu trudności, gwarantuje zdobycie *minimalnej wiedzy wymaganej do zaliczenia* fragmentu kursu.

Możliwe scenariusze przejść z węzła bieżącego do węzła następnego w kolejnym kroku nauczania obrazuje (rys. 2.5). Najbardziej prawdopodobne jest przypisanie na taki sam poziom trudności lekcji w następnej lekcji, jeśli test kompetencji został zaliczony. W przeciwnym przypadku nastąpi przypisanie w obrębie bieżącej jednostki lekcyjnej, na ten sam poziom trudności lub niższy (jeśli jest to kolejna nieudana próba zaliczenia testu kompetencji).

Jak widać z rysunku możliwe jest też przypisanie studenta na wyższy poziom trudności w kolejnym kroku. Ma to miejsce wtedy dany student uzyskuje znacząco wyższe oceny, od średniej znamiennej dla jego poziomu wiedzy, w kilku poprzednich lekcjach.



Rys. 2.5 Możliwe przypisania stopnia trudności w węzłach w następnym kroku nauki

Proces nauczania – to nadzorowane i sterowane, przez przyjętą strategię nauczania, przejście przez ścieżkę, wybraną z grafu wiedzy. Sterowanie ruchem odbywa się w płaszczyźnie X, Y, Z i oparte jest o **strategie nawigacji**, które decydują o wyborze stopnia trudności (następnej) lekcji.

Jednym z zadań tych algorytmów, jest przypisanie studentów w oparciu o ich aktualny „poziom wiedzy” na dostępne stopnie trudności lekcji w każdym węzle ścieżki nauki. Dokładniejszy opis tego działania, zamieszczony będzie w dalszej części niniejszej rozprawy.

Wybór ścieżki w podstawowym grafie wiedzy wraz ze zbiorem wyników testów kwalifikacyjnych określa się jako **j-tą realizację procesu nauczania**.

Strategie adaptacji nauczania – to algorytmy nawigacji wewnątrz ścieżki nauki, realizujące proces uczenia. Odpowiedzialne za przypisywanie studentów na odpowiednie stopnie trudności lekcji w kolejnych węzłach ścieżki. Przypisywanie realizowane jest przez strategie adaptacji, tak by dobór materiału był adekwatny¹¹ do wiedzy (a co za tym idzie umiejętności) studenta oraz według kryteriów, które będą przedstawione (wraz z rozważaniami dotyczącymi tychże algorytmów) w dalszej części pracy.

Strategia przypisywania stopnia trudności do poziomu wiedzy studenta w ścieżce nauki, jest:

¹¹ Dobór takiego stopnia trudności każdej lekcji, by był w korelacji z umiejętnością studenta i dawał, w całym procesie nauki, nie mniejsze niż zakładane minimum średnie ocen i sumy liczby punktów kredytowych.

- § dobierana dla jego indywidualnych cech, tak by była optymalna,
- § uwzględnia doświadczenie innych studentów (zatem doświadczenia innych będą wpływać na wybór „drogi”) – system będzie miał naturę adaptacyjną.

Przypisywanie studentów w kolejnych lekcjach, na odpowiednie stopnie trudności może odbywać się w dwojaki sposób:

- § przeniesienie z lekcji o wyższych stopniu trudności na łatwiejszą w kolejnym węźle, gdy w poprzednich lekcjach na ustalonych stopniach trudności, oceny uzyskiwane w testach kompetencji były mniejsze niż ustalone,
- § przeniesienie z łatwiejszych na trudniejsze, gdy oceny uzyskiwane w testach kompetencji były wyższe niż zakładane.

W skrajnych przypadkach przeniesienie może nastąpić o więcej niż jeden stopień trudności. Przykładowo, gdy w fazie startowej zwrócono uwagę, a w późniejszych krokach potwierdzono, że student o zadanym *a priori*, wysokim, poziomie wiedzy nie uzyskuje korelujących z tym poziomem ocen, przy przejściu do następnego węzła może zostać przypisany dwa stopnie trudności niżej.

Przyczyną takiej sytuacji z reguły jest błędne wyznaczenie poziomu wiedzy. Sytuacja ta zostanie wykryta przez strategię nawigacyjną (a nadzorca kursu powiadomiony).

Analogicznie, gdy student w kolejnych lekcjach będzie uzyskiwać oceny wykraczające poza średnią, jaką charakteryzują się studenci o tym samym poziomie wiedzy, może zostać umieszczony na wyższym stopniu trudności w kolejnej lekcji.

2.1.2 Studenci i ich kwalifikacje wstępne

Studenci, będący obiektami procesu nauczania, posiadają szereg indywidualnych cech osobowych, m.in. przez stan początkowy posiadanej wiedzy, stan wiedzy po ukończeniu kursu, indywidualne zdolności, umiejętność przyswajania wiedzy, umiejętności manualne, które predestynują ich przyswajania wiedzy w sposób szybki bądź wolny. Niestety te cechy są niemierzalne z punktu widzenia systemu e – edukacji, a jedynym wyznacznikiem, który może być w łatwy sposób określony to poziom wiedzy danego studenta¹². W rozprawie ograniczono się do badania nabytej wiedzy w zależności od początkowej wiedzy (wymiernej cechy).

Wskaźnik u_{inq} porządkuje wszystkie możliwe poziomy wiedzy (2.6) studentów w grupie (2.7), w sposób następujący: im większa liczba reprezentująca ten wskaźnik tym wyższy jest poziom wiedzy studenta.

$$u_{inq(i)} \in \{u_{min}, \dots, u_{max}\} \quad (2.6)$$

gdzie:

u_{min} – najmniejsza wartość liczbowa odpowiadająca najniższemu możliwemu poziomowi wiedzy studenta,

u_{max} – największa wartość liczbowa odpowiadająca najwyższemu poziomowi wiedzy.

¹² Cechy grupy studenckiej są „pochodną” cech jej członków

Każdy student¹³ u , opisany szóstką (2.7), posiada początkowy poziom wiedzy, wyznaczony przed wzięciem udziału w kursie¹⁴.

$$u_{(i)} = \left\langle \text{dane osobowe}, u_{inq}, \overline{ocena_{(u_{inq})}^{(u)}}, \overline{pkt_{(u_{inq})}^{(u)}}, historia(stos) \right\rangle \quad (2.7)$$

gdzie:

$\overline{ocena_{(u_{inq})}^{(u)}}$ – średnia ocen typowa dla studenta o poziomie wiedzy u_{inq} ,

$\overline{pkt_{(u_{inq})}^{(u)}}$ – średnia suma punktów kredytowych uzyskiwanych w procesie nauki przez studenta o poziomie wiedzy u_{inq} ,

$historia(stos)$ – dane historyczne (oceny, liczby punktów kredytowych, warianty trudności poprzednich lekcji) bieżącej ścieżki nauki gromadzone na stosie.

Analogicznie grupę studencką (2.8) możemy opisać:

$$g^{(i)} = \left\langle U, opis_grupy, typ, \overline{ocena_{(u_{inq})}^{(g)}}, \overline{pkt_{(u_{inq})}^{(g)}} \right\rangle \quad (2.8)$$

gdzie:

$U \hat{I} \{u_{(1)}, u_{(2)}, \dots, u_{(n)}\}$ – niepusty zbiór studentów,

$typ \hat{I} \{gr_{(1)}, gr_{(2)}, \dots, gr_{(n)}\}$ – typ grupy (definiowany na podstawie ilości studentów o danych poziomach wiedzy stanowiących grupę),

$opis_grupy$ – tekstowy opis grupy zawierający m.in. informacje nt. poziomów wiedzy studentów, liczbę studentów etc.

Wyznaczając cechy studenta należy szczególnie zwrócić uwagę na ich prawidłowy dobór dla każdego studenta, nieodpowiednie ich dobranie może doprowadzić do błędnego rozpoznania danego studenta jako np. słabego studenta i zastosowania błędnej strategii nauczania [6].


Poziom wiedzy, każdego studenta może się zmieniać w czasie trwania procesu nabywania wiedzy (procesie nauki). W przyjętym modelu – poziom wiedzy studenta jest wyznaczany przed rozpoczęciem nauki, w procesie rekrutacji podobnym do procesu rekrutacji na studia wyższe, gdzie na podstawie sumy punktów (z pewnymi wagami) za poszczególne oceny ze świadectwa maturalnego, podejmowana jest decyzja czy dana osoba została na nie przyjęta. Skorzystanie z takiej formy wyznaczania poziomu wiedzy jest niebezpieczne z merytorycznego punktu widzenia, gdyż różne „szkoły” korzystają z różnych systemów nauczania i oceniania. Dlatego to tworzone strategie adaptacji procesu nauczania będą umożliwiały weryfikowanie bazowego poziomu wiedzy studenta, na końcu procesu nauki.

W nauczaniu mogą brać udział studenci połączeni w większe jednostki grupy. Grupą nazywać się będzie zbiór studentów, o różnych poziomach wiedzy, biorących udział w kursie. W tym miejscu należy przyjąć założenie, że w kursie komputerowym może brać udział ograniczona liczba uczestników zorganizowana w grupy. Ograniczenie to, wynika ze złożoności obliczeniowej systemu adaptacji nauczania oraz ograniczonej dostępności zasobów komputerowych. Liczność grupy jest zawsze znana i opisana liczbą skończoną.


Intuicyjnie zakłada się, że oceny uzyskiwane przez studentów pozostają w korelacji z poziomem wiedzy studenta, co pozostaje też w zgodzie z doświadczeniem praktycznym wyniesionym z prowadzenia zajęć ze studentami.

¹³ Użytkownikiem jest wykładowca nadzorujący przy pomocy inteligentnych system e-nauczania.

¹⁴ Rzeczywisty poziom wiedzy MOŻE SIĘ różnić od wyznaczonego w chwili t-1 (przed rozpoczęciem kursu). Weryfikacja rzeczywistego poziomu wiedzy użytkownika ma zostać wykryta przez algorytmy przyporządkowania.



Rys. 2.6 Rozkładów ocen końcowych z laboratorium UC – studenci zaoczni (lata 2001 - 2004)



Rys. 2.7 Przykład rozkładów ocen końcowych z laboratorium UC – studenci dzienni (lata 2001 - 2004)

Analiza autora pracy, ocen zajęć z lat akademickich 2001-2004, pokazała, że grupy studentów zaocznych charakteryzują się niższą liczbą studentów o wysokim i średnim poziomie wiedzy, w stosunku do grup dziennych, co z reguły przekładało się na niższe oceny końcowe¹⁵ (z tego samego przedmiotu).

¹⁵ Liczność grup, zakres materiału, liczba i czas trwania zajęć ta sama.

* *pkt* – punkty kredytowe

Porównując wyniki grup „dziennych” i „zaocznych” (rys. 2.6, 2.7) łatwo można zaobserwować różnice w rozkładach ocen. W większości przypadków wspólną cechą jest kształt rozkładu zbliżony kształtem do wykresu normalnego (rozkład dzwonowy), z tą różnicą, że grupy dzienne mają zazwyczaj umiejscowiony szczyt rozkładu blisko maksymalnych do uzyskania ocen (maks. wartości osi X). Szczególnym przypadkiem, który może występować w obu rodzajach grup, niemniej obserwowanym rzadko, jest rozkład *bimodalny* (dwu-dzwonowy).

Konstruując model studenta przyjęto również założenie, że im niższy poziom wiedzy reprezentuje dany student tym mniejsze prawdopodobieństwo uzyskania maksymalnej oceny. Na potrzeby niniejszej pracy przyjęto następującą konwencję, studenci będą organizowani w trzy rodzaje grup zróżnicowanych „jakościowo”. Dwa z nich odpowiadają rzeczywistym grupom spotykanym w kształceniu akademickim:

§ grupom studentów studiujących na studiach dziennych (grupa pierwsza rys. 5.1) ,

§ grupom studentów studiujących na studiach zaocznych (grupa trzecia rys. 5.1)

Trzecim badanym rodzajem grupy jest grupa mieszana.

2.2 Proces uczenia i jego walidacja

Weryfikacja procesu akwizycji wiedzy w czasie trwania kursu, następuje każdorazowo w teście kompetencji, odbywającym się po ukończeniu danej lekcji. Warunkiem koniecznym przejścia do kolejnej jednostki lekcyjnej jest zaliczenie wariantu bazowego (najłatwiejszej) lekcji w węzle. W wyniku **testu kompetencji** studentowi zostaje przyznana ocena *note* w postaci liczby rzeczywistej dodatniej należącej do zbioru liczb rzeczywistych z przedziału $\{0,1\}$, która określa stopień przyswojenia materiału lekcji.

Wskaźnik *note* porządkuje możliwe oceny (2.9) do uzyskania w teście kompetencji, w sposób następujący im większa liczba reprezentująca ten wskaźnik tym więcej punktów uzyskał dany student.

$$note \hat{I} \{ note_{min}, note_{max} \} \quad (2.9)$$

gdzie:

$note_{min}$ – student uzyskał minimalną ocenę,

$note_{max}$ – student uzyskał maksymalną ocenę.

Wartość liczbowa wskaźnika *note* kwalifikująca do zaliczenia danego kwantu wiedzy, zależna jest od poziomu wiedzy studenta i poziomu trudności kwantu, na którym przeprowadzany jest test kompetencji.

Zakres wartości przyjmowany przez wskaźnik *note*, wykorzystany w pracy dobrany był tak by uprościć obliczenia. Zakres tych wartości może być w późniejszym okresie zaadaptowany do potrzeb lokalnego, systemu oceniania (skali ocen), w zależności od przyjętej konwencji (cyfry, litery, procenty itp.) poprzez odpowiednie (proporcjonalne bądź inne) zamapowanie.

Proces walidacji nabywania wiedzy, realizowany jest zarówno dla grupy studenckiej jak i studenta, odbywa się każdorazowo po ukończonej jednostce lekcyjnej w ramach testu kompetencji.

Walidacja procesu nauczania ma na celu udokumentowanie (zgodnie z założeniami), że strategie adaptacji procesu nauczania, rzeczywiście prowadzą do zaplanowanych postępów¹⁶ w nabywaniu wiedzy.

Danymi wejściowymi są wyniki, każdego studenta z grupy, uzyskane w testach kompetencji (wraz uzyskaną liczbą punktów kredytowych, na podstawie, których wystawiana jest ocena.

Typ walidacji	Student	Grupa
Bieżąca	$note_{(u^{(i)})}^{(t)} \geq note_{(u^{(i)})}^{(t-1)}$ $pkt_{(u^{(i)})}^{(t)} \geq pkt_{(u^{(i)})}^{(t-1)}$	Brak ¹⁷
Lekcji	$note_{(u^{(i)})}^{(t)} \geq note_{(u^{(i)})}^{(t-x)}$ $pkt_{(u^{(i)})}^{(t)} \geq pkt_{(u^{(i)})}^{(t-x)}$	$\overline{note}_{(g^{(i)})}^{(t)} \geq \overline{note}_{(g^{(i)})}^{(t-x)}$ $\overline{pkt}_{(g^{(i)})}^{(t)} \geq \overline{pkt}_{(g^{(i)})}^{(t-x)}$
Trendu	$note_{(u^{(i)})}^{(t)} \geq \overline{note}_{(u^{(i)})}$ $pkt_{(u^{(i)})}^{(t)} \geq \overline{pkt}_{(u^{(i)})}$	$\overline{note}_{(g^{(i)})}^{(t)} \geq \overline{note}_{(g^{(i)})}$ $\overline{pkt}_{(g^{(i)})}^{(t)} \geq \overline{pkt}_{(g^{(i)})}$

Tab. 2.1 Zestawienie wzorów walidacji (bieżącej, lekcji i trendu) dla studenta i grupy studenckiej

gdzie:

$$t \in \{1, \dots, z\}, x = 1, 2, \dots$$

$note_{(u^{(i)})}^{(t)}$ – ocena uzyskana przez studenta w lekcji bieżącej,

$pkt_{(u^{(i)})}^{(t)}$ – liczba punktów kredytowych uzyskana przez studenta w bieżącej lekcji

$note_{(u^{(i)})}^{(t-x)}$ – ocena uzyskana przez studenta w lekcji $(t-x)$,

$pkt_{(u^{(i)})}^{(t-x)}$ – liczba punktów kredytowych uzyskana przez studenta w lekcji $(t-x)$,

$\overline{note}_{(u^{(i)})}$ – średnia ocen z ukończonych przez studenta lekcji,

$\overline{pkt}_{(u^{(i)})}$ – średnia liczba punktów kredytowych z ukończonych przez studenta lekcji,

$note_{(g^{(i)})}^{(t)}$, $pkt_{(g^{(i)})}^{(t)}$, $note_{(g^{(i)})}^{(t-x)}$, $\overline{note}_{(g^{(i)})}$, $\overline{pkt}_{(g^{(i)})}$ – analogicznie dla grupy.

Uzyskanie minimalnej oceny i liczby punktów kredytowych uprawnia do zaliczenia danego węzła (o zadanym poziomie) i przejścia do następnej jednostki lekcyjnej w ścieżce nauczania.

¹⁶ Przez postępy rozumiemy spełnienie głównego kryterium optymalności procesu nauczania

¹⁷ Walidacja bieżąca grupy, nie ma wpływu na działanie strategii, dlatego też została nieuwzględniona.

Warunkiem koniecznym do przejścia do następnego węzła jest ukończenie najprostszego wariantu trudności lekcji w bieżącym węźle przez zaliczenie testu kompetencji z oceną pozytywną, co za tym idzie uzyskanie przynajmniej jednego punktu kredytowego.

2.2.1 Definicja i miary walidacji procesu nauczania studenta

Walidacja procesu nauczania dla każdego studenta odbywa się trzyetapowo:

- § Po każdej jednostce lekcyjnej dokonywana jest **walidacja bieżąca** (2.10) polegająca na porównywaniu oceny bieżącej (oraz liczby punktów kredytowych otrzymanych w teście kompetencji) z wynikami $(n-1)$ jednostki lekcyjnej. Badane jest czy ocena z bieżącej lekcji / otrzymana wartość punktu kredytowego za ukończoną lekcję są lepsze lub równe wynikom z poprzedniej lekcji, a na podstawie tego porównania, podejmowane są odpowiednie działania.

$$note_{(u^{(i)})}^{(t)} \geq note_{(u^{(i)})}^{(t-1)}, pkt_{(u^{(i)})}^{(t)} \geq pkt_{(u^{(i)})}^{(t-1)} \quad (2.10)$$

- § W czasie trwania całego procesu nauki dokonywana jest **walidacja lekcji** (2.11) – zarówno ocena każdego studenta z testu kompetencji jak oraz liczba punktów kredytowych, porównywane są z wynikami $(t-x)$ lekcji poprzedzających. Badane jest czy ocena z bieżącej lekcji / otrzymana wartość punktu kredytowego za ukończoną lekcję są lepsze lub równe wynikom $(t-x)$ kroku, a na podstawie tego porównania, podejmowane są odpowiednie działania.

$$note_{(u^{(i)})}^{(t)} \geq note_{(u^{(i)})}^{(t-x)}, pkt_{(u^{(i)})}^{(t)} \geq pkt_{(u^{(i)})}^{(t-x)} \quad (2.11)$$

- § Po zakończonym procesie nauki przeprowadzana jest **walidacja trendu** (2.12) – wyznaczany jest trend (przez porównanie ze średnią oceną studentów), wykazujący czy dany student otrzymywał wyniki spełniające kryterium optymalności, oraz czy jego poziom wiedzy się zmieniał się w czasie nauczania. Badane jest czy ocena / liczba punktów kredytowych (z każdej lekcji) były lepsze lub równe wynikom średniej oceny / liczby punktów kredytowych (typowym dla studenta o danym poziomie wiedzy).

$$note_{(u^{(i)})}^{(t)} \geq \overline{note_{(u^{(i)})}}, pkt_{(u^{(i)})}^{(t)} \geq \overline{pkt_{(u^{(i)})}} \quad (2.12)$$

2.2.2 Definicja i miary walidacji procesu nauczania grupy studenckiej

Podobnie jak ma to miejsce w przypadku poszczególnych studentów, proces walidacji nabywania wiedzy dla grupy odbywa się etapowo. Dla grupy studenckiej pominięty został etap walidacji bieżącej (odbywającej się po każdym teście kompetencji jednostki lekcyjnej) ze względu na brak istotnego wpływu na działanie strategii dla grupy.

- § W czasie trwania całego procesu nauki dokonywana jest **walidacja lekcji** (2.13) – zarówno średnia oceny grupy z testu kompetencji jak i średnia liczba punktów kredytowych, porównywane są z wynikami $(t-x)$ lekcji poprzedzających. Badane jest czy średnia ocena z bieżącej lekcji / średnia wartość punktów kredytowych grupy za ukończoną lekcję jest lepsza lub równa wynikom z poprzednich $(t-x)$ lekcji, a na podstawie tego porównania, podejmowane są odpowiednie działania.

$$\overline{note_{(g^{(i)})}^{(t)}} \geq \overline{note_{(g^{(i)})}^{(t-x)}}, \overline{pkt_{(g^{(i)})}^{(t)}} \geq \overline{pkt_{(g^{(i)})}^{(t-x)}} \quad (2.13)$$

- § Podobnie jak to miało miejsce dla pojedynczego studenta, po zakończonym procesie nauki przeprowadzana jest **walidacja trendu** (2.14) dla grupy studenckiej – wyznaczany jest trend (przez porównanie średniej ocen / punktów kredytowych z bieżącej lekcji ze średnią oceną / średnią liczbą punktów kredytowych grupy o zadanym rozkładzie poziomów wiedzy), wykazujący czy grupa studencka wygenerowała wyniki spełniające kryterium optymalności, oraz czy poziom wiedzy grupy się zmieniały się w czasie procesu nauczania.

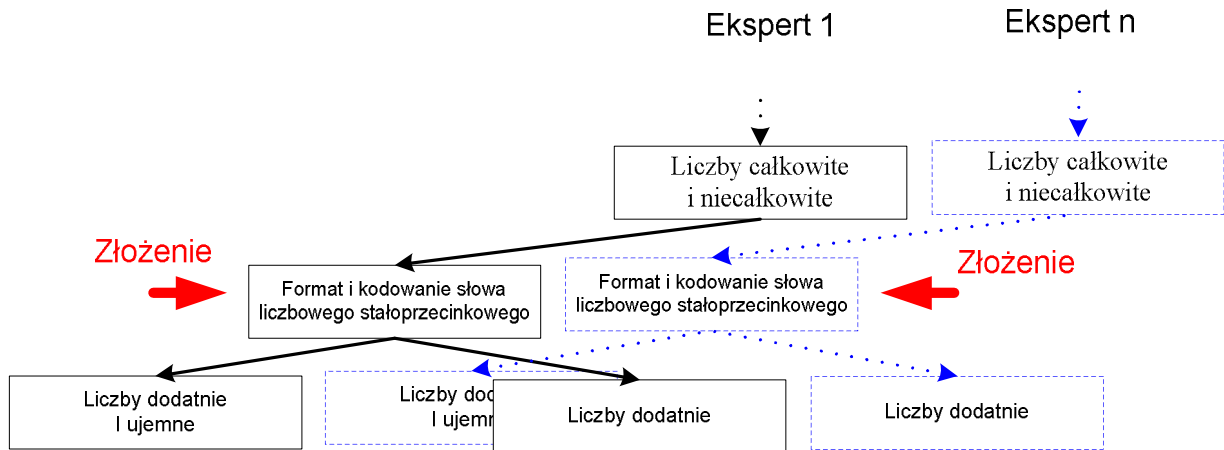
$$\overline{note_{(g^{(i)})}^{(t)}} \geq \overline{note_{(g^{(i)})}}, \overline{pkt_{(g^{(i)})}^{(t)}} \geq \overline{pkt_{(g^{(i)})}} \quad (2.14)$$

- § Walidacja bieżąca dla grupy, nie ma wpływu na działanie strategii adaptacji, dlatego też została nieuwzględniona.

2.3 Konstrukcja Podstawowego Grafu Wiedzy

Grafy, składające się na podstawowy graf wiedzy, konstruowane są przez niezależnych ekspertów przy wsparciu administratora kursu¹⁸. Gdy dysponujemy odpowiednio dużą liczbą ekspertów, zalecane jest podzielić ich na grupy. Poszczególne grupy będą tworzyć zbiory lekcji, stanowiące spójną i logiczną całość. Następnie utworzą oni przejścia między lekcjami, przy pomocy specjalisty od tworzenia grafów i w wyniku konsultacji pomiędzy sobą (wewnątrz grupy), dające w efekcie końcowym graf skierowany.

¹⁸ Osoby o wykształceniu informatycznym, nadzorującej działanie systemu e-nauczania.



Rys. 2.8 Idea powstawania podstawowego węzła grafu wiedzy PGW

Nałożenie na siebie grafów da w rezultacie *podstawowy graf wiedzy* (PGW). Należy wziąć jednak pod uwagę, że lekcja *eksperta n* w każdym węzle, nie musi być umiejscowiona w tym samym położeniu w płaszczyźnie Z (tj. mieć taki sam stopień trudności). W kolejnym kroku konsultacje, wpłyną na określenie położenia kolejnej lekcji w płaszczyźnie Z, co może zaowocować tym, że lekcje pochodzące od poszczególnych ekspertów będą znajdować się w kolejnych węzłach na innym poziomie trudności w płaszczyźnie Z.

```

for each path
  for each vertex
    get all e-lesson_difficulty_factor
    calculate ultimate e-lesson_difficulty_factor for given vertex
    store e-lessons_difficulty_factor
    sort ascending by e-lessons_difficulty_factors
    return order_of_lessons in vertex of Primary Knowledge Tree
  proceed to next vertex
    
```

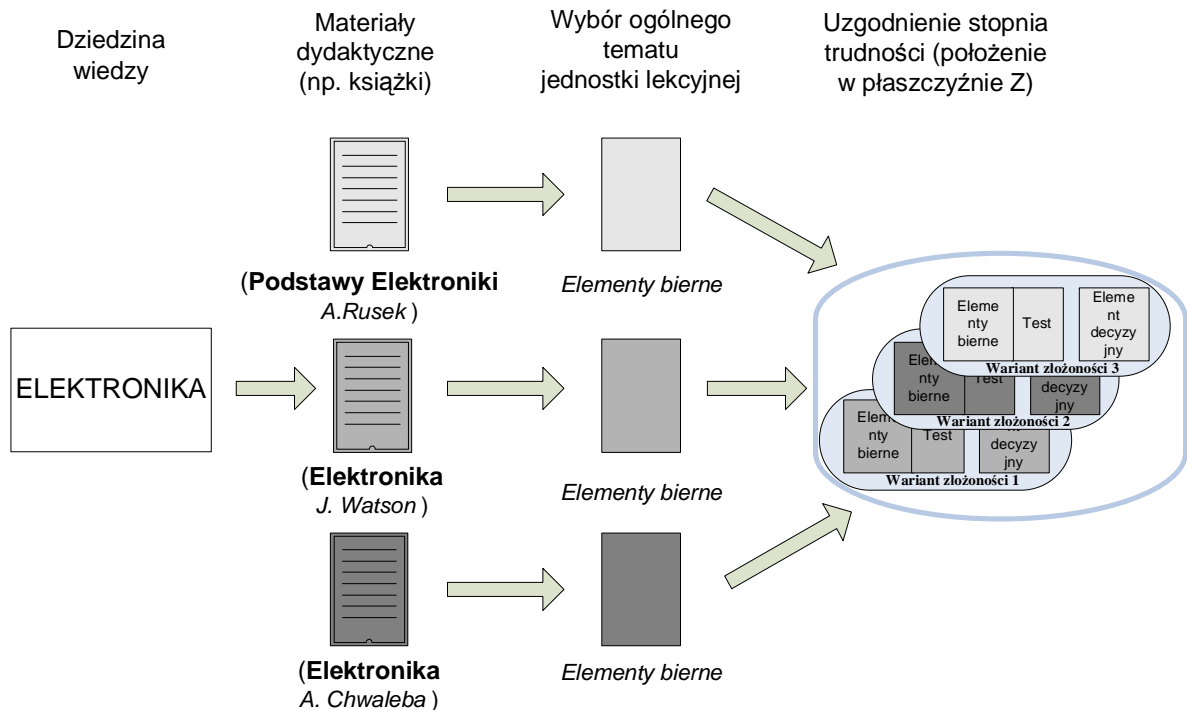
Rys. 2.9 Algorytm rozmieszczania węzłów w płaszczyźnie Z

O głębokości (płaszczyzna Z) położenia w *podstawowym grafie wiedzy* decyduje obiektywna trudność lekcji, zwana w rozprawie stopniem trudności lekcji, uzgodniona przez grupy eksperckie. Kiedy brakuje zgodności podczas uzgadniania położenia w płaszczyźnie Z, każdy ekspert wyznacza arbitralnie poziom trudności danej lekcji, a algorytm (2.9) realizuje automatyzację rozmieszczenia lekcji w węzle.

Ścieżka [n]	Węzeł [m]						
	[1]	[2]	[3]	...	[12]	...	[m]
[1]	Wsp. węzła	Wsp. węzła	Wsp. węzła				
...	Wsp. węzła	Wsp. węzła	Wsp. węzła	Wsp. węzła	Wsp. węzła	Wsp. węzła	Wsp. węzła
[n]	Wsp. węzła	Wsp. węzła	Wsp. węzła	Wsp. węzła	Wsp. węzła		

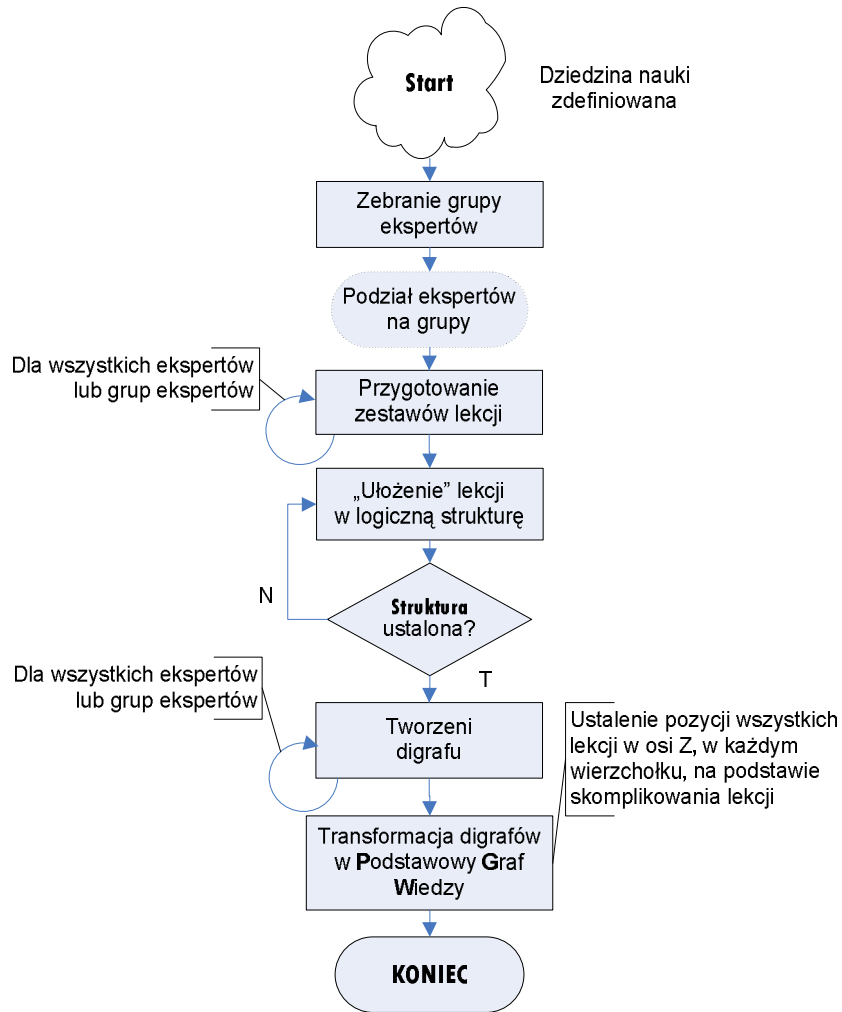
Rys. 2.10 Tablica ścieżek kursu

Gdy podstawowy graf wiedzy jest gotowy, należy wydzielić z niego ścieżki nauki, które przechowywane są w tablicy ścieżek (rys. 2.10). Dla przypomnienia, za *ścieżkę nauki* będziemy uważać zbiór wierzchołków powiązanych ze sobą, i odległych od siebie o nie więcej niż jeden węzeł, tworzących wiedzę, którą powinno się nabyć, by opanować pożądany fragment materiału.



Rys. 2.11 Przykład tworzenia węzła o różnych stopniach trudności

Wykorzystanie wiedzy eksperckiej, a następnie „odrzuć” rozgałęzień grafu i pozostawienie jedynie stopni trudności lekcji, w postaci zwielokrotnionych węzłów daje w rezultacie ścieżki nauki. Część ścieżek nauki pokrywa się z już istniejącymi w tablicy – stanowią one podzbiór już istniejących, dzięki czemu nie istnieje potrzeba ponownego ich zamieszczania. Strategie adaptacji wykorzystują tę wiedzę, podczas procesu nauczania do pomijania lekcji, które zostały uprzednio ukończone we wcześniejszych fazach nauki.



Rys. 2.12 Algorytm tworzenia Podstawowego Grafu Wiedzy

Powyższy rysunek (rys. 2.12) obrazuje skrócony algorytm tworzenia podstawowego grafu wiedzy. Pominięte zostały kroki tworzenia tablicy ścieżek kursu.

3 Symulacyjny System badania Adaptacji procesu Nauczania

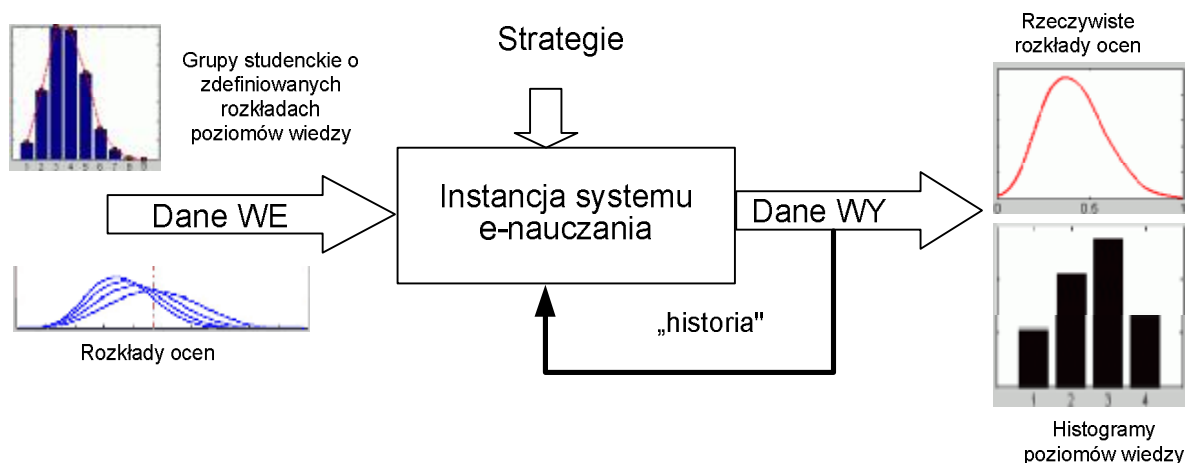
3.1 Wprowadzenie

Istnieją, co najmniej dwie metody, pozwalające przeanalizować przydatność działania strategii adaptacji procesu nauczania.

Pierwszą, trudniejszą w realizacji metodą, ze względu na czas trwania i pracochłonność jest sprawdzenie poprawności działania strategii w praktyce z *rzeczywistymi studentami*. W takim przypadku należy dysponować reprezentatywną i przekrojową grupą studentów, na których zastosowane zostaną strategie nauczania. Spowoduje to wygenerowanie danych liczbowych, których obróbka i późniejsza analiza pozwoli na określenie czy dana strategia nauczania działa poprawnie czy powinna być zmodyfikowana lub też odrzucona. Niestety ze względów czasowych jak również organizacyjno-operacyjnych nie sposób tego dokonać. Drugą, częściej stosowaną, zazwyczaj w projektach programistycznych jest *metoda symulacyjna*. Aby móc przetestować strategię, w sposób odpowiadający rzeczywistości należy dysponować modelem studenta / grup studenckich. Na podstawie którego wygenerowane zostają dane wejściowe, gdzie po podaniu ich do zasymulowanej instancji systemu edukacji (w której działają strategie adaptacji) możliwe jest uzyskanie wartości zbliżonych wartościami liczbowym uzyskiwanych przez rzeczywistych studentów w procesie nauczania.

Generowanie danych liczbowych zbliżonych do tych, które generują prawdziwi studenci jest rzeczą niezmiernie ważną aczkolwiek bardzo trudną, gdyż każdy użytkownik jest jednostką o dużej indywidualności, co za tym idzie małej przewidywalności, a na jego działanie w systemie ma wpływ szereg czynników zewnętrznych.

Zbudowanie Symulacyjnego Systemu badania możliwości Adaptacji procesu Nauczania (SSAN), ma umożliwić przebadanie różnych „strategii”¹⁹ nauczania zarówno indywidualnego i grupowego, w oparciu o zdefiniowane modele nauczania, bez angażowania rzeczywistych studentów. Symulator ten, ma przede wszystkim zastąpić badanie rzeczywistych procesów nauczania oraz wspomóc w procesie tworzenia i testowania strategii adaptacji nauczania. System pozwala na wybranie najlepszej strategii adaptacji nauczania, na podstawie statystycznej obróbki wyników. Poniższy diagram obrazuje koncepcję działania symulatora:



Rys. 3.1 Koncepcja działania symulacyjnego systemu badania adaptacji procesu nauczania

¹⁹ Przez strategię należy rozumieć algorytmy, dostosowujące poziom trudności materiału nauczania do poziomu wiedzy studenta.

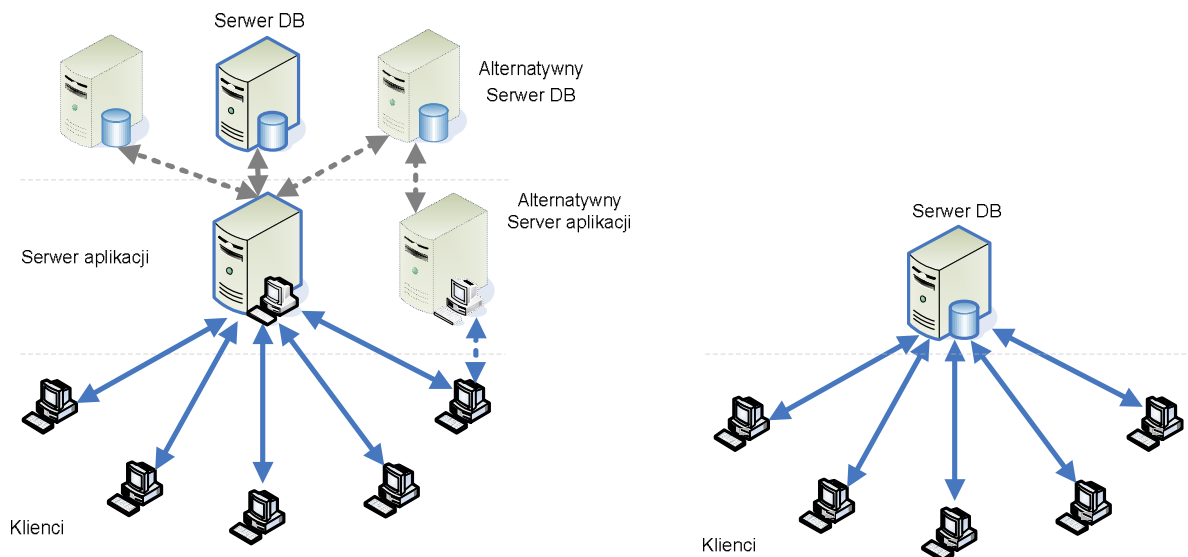
Działanie symulacyjnego systemu badania adaptacji procesu nauczania, zwanego w dalszej części pracy symulatorem (rys. 3.1) opiera się na:

- § generowaniu danych wejściowych w postaci grup studenckich i znamionym im rozkładów ocen,
- § utworzenie i symulowanie działania instancji systemu e-nauczania,
- § przetwarzaniu wyników jakie powstają po zastosowaniu strategii nauczania na grupach studenckich w procesie nauczania („historia”),
- § generowanie danych wyjściowych w postaci rzeczywistych rozkładów ocen i histogramów poziomów wiedzy.

System edukacji można zaimplementować w klasycznej architekturze klient-serwer jak i architekturze rozproszonej (rys.3.2), która jest bardziej przydatna ze względu na znaczne obciążenie centralnego serwera przy dużej liczbie uczestników procesu nauczania.

W oparciu o model klient-serwer projektowana jest obecnie większość systemów zdalnego nauczania. W tej architekturze występuje podział na stronę określoną jako *klient*, zlecającą pewną usługę (np. dostęp do bazy danych) oraz stronę nazywaną serwerem, której zadaniem jest realizacja tej usługi. Serwer przechowuje dane, przyjmuje zgłoszenia od klientów i realizuje dostęp do pewnego zasobu. Zadaniem jego jest ułatwienie użytkownikowi sieci jego pracy. Klasyczny model dwuwarstwowy, niesie za sobą liczne ograniczenia:

- § ilość równoczesnych zapytań do bazy danych,
- § duże obciążenie współdzielonego łącza,
- § znaczna liczbą obliczeń przez centralny procesor(-y),
- § znacząca zajętość pamięci serwera przez procesy obsługi systemu,
- § znaczne czasy odpowiedzi systemu We/Wy.



Rys. 3.2 Architektury: trójwarstwowa i dwuwarstwowa

Coraz większe zainteresowanie zdalnym nauczaniem, owocujące dużą liczbą studentów i co za tym idzie obciążeniem systemu edukacji. Systemy zdalnego nauczania, powinny zatem cechować się dużą skalowalnością. Niestety klasyczna architektura klient-serwer nie może sprostać takim wymaganiom. Rodzi się, zatem potrzeba wprowadzenia trzeciej warstwy, która byłaby niezależna zarówno od serwera jak też od aplikacji klienckiej, a odpowiadałaby za przetwarzanie funkcjonalne samej informacji. W ten sposób aplikacja kliencka nie

komunikowałyby się z bazą danych, a nawet nie musiałyby wiedzieć o jej istnieniu, a komunikowałyby się jedynie z komputerem pośredniczącym, na którym zainstalowany byłby serwer aplikacji. Serwer ten wykonuje procedury na żądanie aplikacji klienckiej, a one odwołują się do bazy danych. Może on także oprócz odwoływania się do bazy samodzielnie realizować pewne operacje. Może on dokonywać pewnych obliczeń numerycznych, a nawet inicjować realizowanie pewnych operacji bazodanowych na kilku serwerach baz danych jednocześnie. Warstwa aplikacyjna jest wtedy odpowiedzialna za spójność danych posadowionych na kilku serwerach oraz za to, aby aplikacja kliencka nie "wnika" w to, gdzie fizycznie znajdują się dane, do których się odwołuje. W ten sposób warstwa środkowa (aplikacyjna) stanowił odrębną płaszczyznę programową w architekturze klient/serwer, z własnym środowiskiem. Architektura *trójwarstwowa* jest modyfikacją architektury klient serwer, w której klient może zwracać się ze zleceniami obsługi do wielu serwerów. Architektura trójwarstwowa (ang. *three-tier architecture* lub *three-layer architecture*) – to architektura typu klient-serwer, w której interfejs użytkownika, przetwarzanie danych i składowanie danych są rozwijane w postaci osobnych modułów, zwykle na oddzielnych platformach.

Widać więc, że w łatwy sposób posługując się architekturą klient-serwer możemy przeskalować swoje myślenie od poziomu prostego systemu do modelu trójwarstwowego, za pomocą, którego tworzone są duże systemy informatyczne.

Wykorzystanie architektury trójwarstwowej w powiązaniu z towarzyszącą jej techniką równoważenia obciążenia (ang. *load balancing*) pomiędzy wiele rozproszonych zasobów systemowych (procesorów, komputerów, dysków, połączeń sieciowych lub innych zasobów) wydaje się być remedium na problemy wydajnościowe.

Niestety, technika równoważenia obciążenia w pełnym tego słowa znaczeniu wiąże się ze znacznymi wydatkami na zwielokrotnioną infrastrukturę (sprzęt, łącza itp.) jak i dodatkowe oprogramowanie zarządzające. Zazwyczaj instytucje edukacyjne nie posiadają wystarczających środków na rozbudowę takiego zaplecza technicznego. Alternatywą do architektury trójwarstwowej jest architektura rozproszona. Podstawową jej wadą jest stopień skomplikowania i czasochłonność realizacji. Wiele maszyn i urządzeń sieciowych wchodzących w skład takiego rozwiązania, zwiększają prawdopodobieństwa wystąpienia uszkodzenia – i z pewnością znacznie rośnie awaryjność całego systemu (większa niż systemu scentralizowanego). Administracja rozproszonym systemem jest poważnym wyzwaniem i wymaga stosowania specjalnego oprogramowania wspomagającego procesy zarządzania. Zapewnienie odpowiedniego poziomu bezpieczeństwa systemu jest trudnym zadaniem a wymiana wersji oprogramowania może być poważnym problemem logistycznym. Rozproszenie systemu może spowodować konieczność zwiększonej wymiany informacji oraz nadmiernego ich przechowywania (z drugiej strony jest to czynnik zmniejszający ryzyko utraty danych w razie awarii). Rezultatem wyżej wymienionych wad jest konieczność zatrudnienia wysoko wykwalifikowanego personelu potrafiącego utrzymywać system.

Obecnie wykorzystanie samej architektury trójwarstwowej czy rozproszonej nie jest najlepszym rozwiązaniem, i w opinii autora tej pracy remedium na przedstawione problemy może być wykorzystanie systemu bazowanego na agentach. Poniżej przedstawiono kilka istotnych zalet systemu agentowego:

- § redukcja ruchu w sieci – praca po stronie klienckiej bez konieczności ciągłej wymiany danych,
- § równoważenie / minimalizowanie obciążenia strony serwerowej – poprzez przenoszenie obciążenia obliczeniowego na stronę kliencką,
- § działanie adaptacyjne – akcje podejmowane przez agenta uzależnione są od stanu systemu na którym się znajduje,

- § odporność na przerwy w pracy sieci / całkowity brak połączenia z siecią – zdolność agenta do działania bez stałego połączenia serwerem, komunikacji z innymi agentami,
- § elastyczność – zmiana sposobu działania agenta wiąże się z wygenerowaniem nowego kodu i wysłaniem go w miejsce przeznaczenia, a nie ze zmianą całego środowiska klienckiego.

Działanie Symulacyjnego Systemu badania możliwości Adaptacji procesu Nauczania, opiera się o popularne oprogramowanie, dostępne dla każdego użytkownika jak również ma niewygórowane wymagania sprzętowe (tab. 3.1). Jak powszechnie wiadomo skalowalność to zdolność systemu do podolania rosnącym oczekiwaniom dotyczącym liczby korzystających z niego użytkowników, ilości zgromadzonych danych oraz operacji, które są przezeń realizowane.

Strona	Wymagania	
	Sprzętowe (Hardware)	Programowe (Software)
Kliencka	<ul style="list-style-type: none"> - Stacja robocza klasy PC, - Procesor: > 2 GHz (lub odpowiednik), - Pamięć robocza: > 256 MB - Połączenie sieciowe: stałe > 128 Kbit/s 	<ul style="list-style-type: none"> - System operacyjny: Windows 2000/XP - Środowisko uruchomieniowe: Java Runtime w wersji 5.0 lub Microsoft .Net 1.1 lub wyższe
Serwerowa	Konfiguracja MINIMALNA ²⁰ : <ul style="list-style-type: none"> - serwer jednoprocessorowy taktowany zegarem 2,8 GHz wspierający technologię HyperThreading - pamięć robocza: 1 GB - połączenie sieciowe: stałe > 10 Mbit/s 	<ul style="list-style-type: none"> - System operacyjny: Windows 2000 / 2003 Server - Serwer aplikacji/WWW: Apache / Tomcat, MS IIS 5.0 / ASP .NET - Przeglądarka internetowa: IE / Opera / Firefox
	Konfiguracja ZALECANA: <ul style="list-style-type: none"> - serwer dwu procesorowy taktowany zegarem 2,8 GHz (lub jednoprocessorowy wspierający technologię HyperThreading) - pamięć robocza: > 2 GB - połączenie sieciowe: stałe > 100 Mbit/s 	<ul style="list-style-type: none"> - System operacyjny: 2003 Server - Serwer aplikacji/WWW: Apache / Tomcat, MS IIS 6.0 / ASP .NET - Przeglądarka internetowa: IE / Opera / Firefox

Tab. 3.1 Wymagania sprzętowo-programowe systemu e-nauczania

Podwyższenie wydajności systemu edukacji możemy osiągnąć na dwa sposoby:

- § poprzez zwiększenie wydajności sprzętu (skalowalność wertykalna), co rozważanym przez nas przypadkiem jest niemożliwe ze względów finansowych,
- § w wyniku podziału usług oferowanych przez system między komputery systemu (wraz z wykorzystaniem jednostek programowych zwanych agentami), na czym się w tej rozprawie skupimy.

²⁰ Konfiguracja serwera sprzętowa uzależniona jest od wariantu architektury, a mianowicie od rozlokowania agentów na poszczególnych maszynach w instancji systemu edukacji.

3.2 Budowa i bloki funkcjonalne

Analiza schematu blokowego (rys. 3.3) pozwoli przybliżyć koncepcję działania systemu e-nauczania oraz poznać jego składowe. Do podstawowych bloków funkcjonalnych systemu SSAN należą:

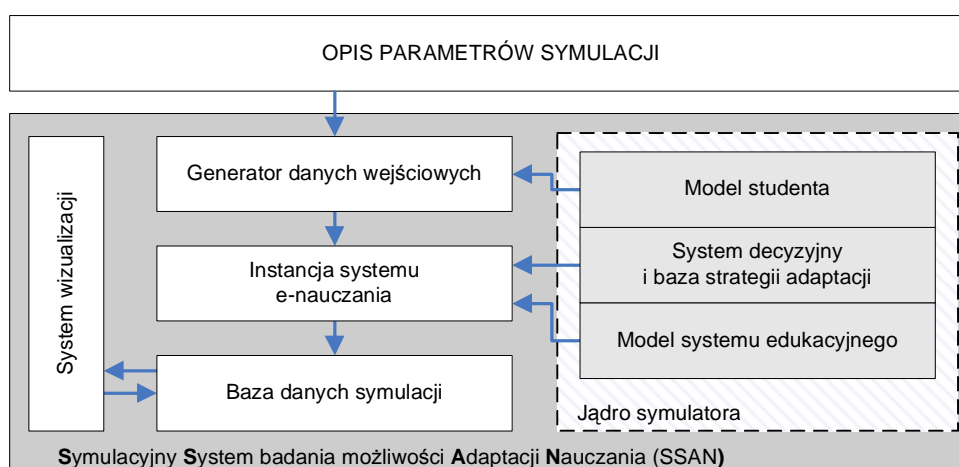
- § generator danych wejściowych,
- § instancja systemu edukacyjnego,
- § moduł decyzyjny z bazą strategii adaptacji procesu nauczania,
- § system wizualizacji wyników procesu nauczania,
- § baza danych symulacji.

Dzięki w/w podsystemom tworzącym SSAN potrafimy zdefiniować i wybrać model nauczania, a dany fragment wiedzy przedstawić w postaci „grafu” jak również dobrać zasady udostępniania wiedzy oraz poruszania się po ścieżce nauki, a następnie, uruchomić nauczanie (proces nabywania wiedzy przez) studentów, wraz z ich oceną i dostosowywaniem poziomu trudności każdej jednostki lekcyjnej w zależności od ich indywidualnych cech osobowych jak i postępów w nauce.

Z braku prawdziwych studentów, którzy byłiby źródłem danych wejściowych, blok generatora danych wejściowych tworzy grupy studenckie złożone ze studentów, (generowanych w oparciu o model zapisany w jądrze symulatora) i dostarcza do *instancji*²¹ systemu e-nauczania. Instancja systemu zawiera model przekazywania wiedzy w postaci Podstawowego Grafu Wiedzy wraz ze zdefiniowanymi ścieżkami nauczania.

Po uprzednim dostarczeniu wymaganych parametrów wejściowych, jądro symulatora, ma które składają się model studenta (grup studenckich), model systemu edukacyjnego oraz podsystem decyzyjny odpowiedzialny za realizacji procesu nauczania w oparciu o wybraną strategię adaptacji, inicjuje instancję systemu e-nauczania,. Wymagane parametry wejściowe to:

- § liczba i licznosc grup studenckich,
- § rozkład poziomów wiedzy studentów w grupach,
- § ilość lekcji w ścieżce,
- § ilość stopni trudności w węzłach.



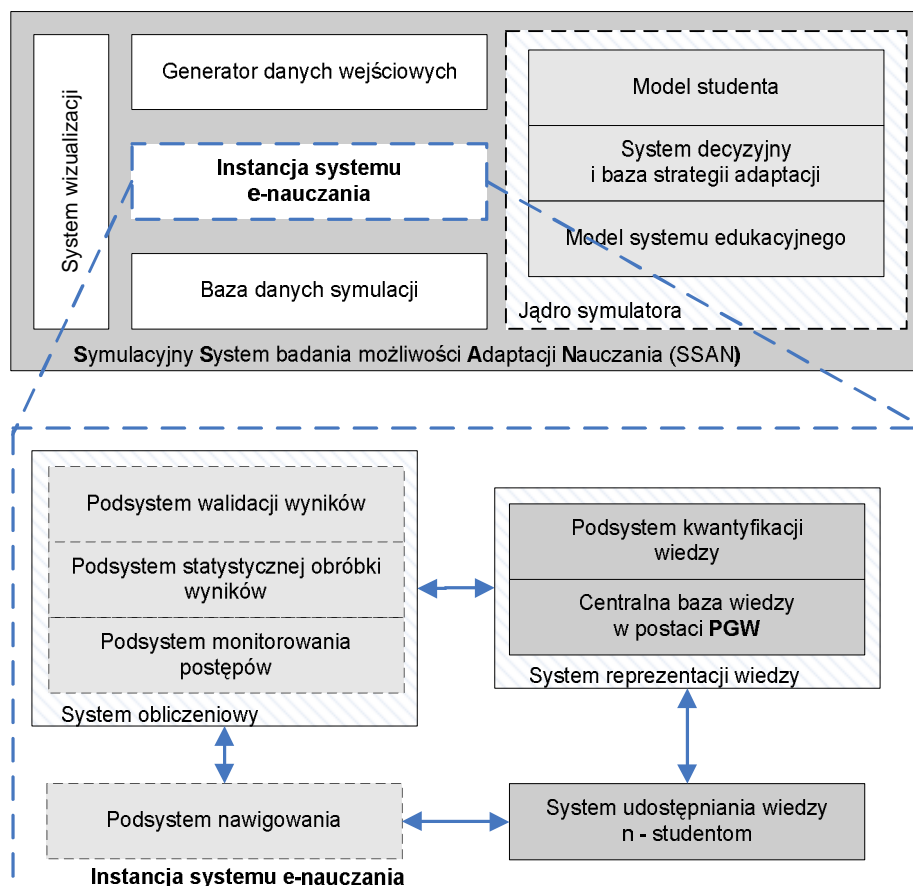
Rys. 3.3 Ogólny schemat blokowy SSAN

²¹ Instancja systemu e-nauczania to zaimplementowany, działający (wewnątrz symulatora) model systemu e-nauczania (zdefiniowany w rozdziale 2)

Powyższe parametry przekazywane są do generatora danych wejściowych, który wykorzystując informacje pobrane z jądra symulatora rozpoczyna działanie instancji systemu edukacji (i rozpoczyna fazę wstępną prace symulatora).

Baza danych wizualizacji to miejsce, gdzie przechowywane są dane i wyniki powstające w instancji systemu edukacyjnego. Blok systemu wizualizacji odpowiedzialny jest za pobieranie danych z bazy danych symulacji a następnie za ich wizualizacje do postaci wykresów i tabel.

Istotną częścią symulatora jest instancja modelu systemu e-nauczania (rys. 3.4), bez której nie byłoby możliwe zasymulowanie środowiska nauczania, w którym działają, na zdefiniowanych grupach studenckich, strategie adaptacji.



Rys. 3.4 Schemat blokowy instancji systemu e-nauczania

W instancji systemu edukacyjnego zdefiniowano i zaimplementowano:

§ system obliczeniowy wraz z:

- podsystemem walidacji – tłumaczenie uzyskanych wyników na stopnie studentów oraz grup w zależności, np. od różnych poziomów wiedzy wstępnej lub przyjętych kryteriów sterowania procesem uczenia oceny,
- podsystemem monitorowania postępów studentów (grup studenckich),
- podsystemem statystycznej obróbki wyników,

§ system reprezentacji wiedzy wraz z:

- centralną bazą wiedzy w postaci PGW,
- systemem kwantyfikacji wiedzy,

§ system udostępniania wiedzy n - studentom,

§ podsystem nawigacji

System obliczeniowy to część systemu e-nauczania, najbardziej pochłaniająca zasoby komputerowe. Z tego powodu będzie zaimplementowana w architekturze agentowej.

3.2.1 Generator danych wejściowych

Do sprawdzenia poprawności działania algorytmu potrzebne są dane – wygenerowane przez rzeczywistych studentów albo w przypadku niniejszej rozprawy pochodzące z innego źródła. Autor nie dysponował niestety możliwością posłużenia się rzeczywistymi studentami, gdyż wykraczało to poza jego możliwości czasowe i logistyczne. Alternatywą dla żywych studentów, pozostało utworzenie, najpierw modelu studenta, a następnie działającego generatora / symulatora wirtualnych studentów.

Moduł generatora danych wejściowych, jest zasadniczym elementem symulatora, umożliwia on generowanie grup studenckich o zadanych profilach, w oparciu o zdefiniowany model matematyczny. Jego zadaniem jest też zbieranie danych, które przekazywane są do systemu wizualizacji wyników (gdzie przetwarzane są do postaci wykresów i zestawień tabelarycznych). Należy wziąć pod uwagę, że konstruując tenże generator grup studenckich zostały wprowadzone pewne *uproszczenia*. Zakładając, że zbiór użytkowników ma być grupą reprezentatywną należy wygenerować taką próbkę, której rozkład parametru charakteryzującego (u_{inq} – poziom wiedzy użytkownika) każdego użytkownika będzie zbliżony do wykresu krzywej Gaussa²².

Ze względu na to, że rozkład normalny generuje wartości rzeczywiste nie mógł zostać bezpośrednio użyty do generowania poziomów wiedzy studentów, którzy opisani są wartościami dyskretnymi z zakresu $\langle 1; 9 \rangle$. Do tego celu został użyty *rozkład dwumianowy* (3.1). Rozkład dwumianowy zmiennej losowej jest rozkładem dyskretnym i dla zera oraz wartości dodatnich całkowitych mniejszych niż n odpowiednia zmienna losowa przyjmuje wartości niezerowe.

Rozkład dwumianowy opisany jest wzorem:

$$y = f(x | n, p, k) = \binom{n}{k} p^k (1-p)^{n-k} \quad (3.1)$$

gdzie:

$k = 1, 2, 3, \dots, n$ - liczba wystąpienia „sukcesów”,

n - liczba doświadczeń,

p - prawdopodobieństwo wystąpienia sukcesów ($q = 1 - p$).

²² Większość rzeczywistych zjawisk obserwowanych na co dzień ma rozkład zbliżony do krzywej dzwonowej, a zatem rozkład Gaussa przybliża rzeczywiste zjawiska w stopniu co najmniej dostatecznym, dlatego też będziemy na nim bazować.

przy czym:

$$\binom{n}{k} = \frac{n!}{k!(n-k)!} \quad (3.2)$$

Ocena, którą otrzymuje dany student każdorazowo po skończonej lekcji uzyskiwana jest w teście kompetencji i opisywana jest wartością z zakresu $\langle 0,1 ; 0,9 \rangle$. Dlatego to, do opisanie niej został wybrany rozkład Beta, opisany wzorem:

$$y = f(x|a,b) = \frac{1}{B(a,b)} x^{a-1} (1-x)^{b-1} \quad (3.3)$$

gdzie:

a, b – parametry (zawsze większe od zera),

$B(a,b)$ – funkcja beta.

przy czym:

$$B(a,b) = \int_0^1 t^{a-1} (1-t)^{b-1} dt \quad (3.4)$$

Do zobrazowania rozkładu ocen został wybrany rozkład Beta, który też dzięki odpowiedniemu doborowi parametrów a, b może przypominać kształtem rozkład Gaussa. Jak już to było wspomniane we wstępie, rozkład normalny dosyć dobrze opisuje wiele zjawisk świata rzeczywistego, takich jak wzrost ludzi, czy ich współczynnik inteligencji. Jednostki znacznie odbiegające od średniej należą do zupełnych rzadkości. Podobnie ma się rzecz z ocenami maksymalnymi i minimalnymi uzyskiwanymi przez poszczególnych studentów.

W tabeli (tab. 3.2) przedstawiono współczynniki rozkładu beta używane do generowania rozkładów ocen dla studentów charakteryzującymi się poziomami wiedzy z zakresu $u_{inq} \in \langle 1;9 \rangle$ dla czterech wariantów trudności lekcji $d_{fact} = \langle 1;4 \rangle$. Parametry z tabeli zostały wykorzystane do wygenerowania grup studenckich do symulacji systemu e-nauczania.

Trudność u_{inq}	$d_{fact} = 1$		$d_{fact} = 2$		$d_{fact} = 3$		$d_{fact} = 4$	
	a	b	a	b	a	b	a	b
1	2	4	2,5	6	3	8	3,5	10
2	3	4,5	3,5	6,5	4	8,5	4,5	10,5
3	4	5	4,5	7	5	9	5,5	11
4	5	5,5	5,5	7,5	6	9,5	6,5	11,5
5	6	6	4,5	5	3,5	4,5	3	4
6	11,5	6,5	9,5	6	7,5	5,5	5,5	5
7	11	5,5	9	5	7	4,5	5	4
8	10,5	4,5	8,5	4	6,5	3,5	4,5	3
9	10	3,5	8	3	6	2,5	4	2

Tab. 3.2 Tabela współczynników a, b rozkładu Beta dla użytkowników reprezentujących różne poziomy wiedzy oraz dla czterech stopni trudności kwantu wiedzy

Parametry tabeli:


u_{inq} – poziomy wiedzy studentów z grupy testowej (par. rozkładu dwumianowego, który kształt będzie odzwierciedlał „nasylenie” studentami o danym poziomie wiedzy),

a, b – parametry rozkładu Beta, odzwierciedlającego rozkład ocen studenta z danym poziomem wiedzy u_{inq} ,

d_{fact} – stopień trudności kwantu wiedzy w węźle.

Przyjęto, że w zależności od u_{inq} (poziomu wiedzy użytkownika), generowana będzie ocena. Z obserwacji rzeczywistego procesu nauczania wynika, że im wyższym poziomem wiedzy charakteryzuje się student tym prawdopodobieństwo uzyskania przez niego lepszej oceny jest większe. Prawidłowość ta została zapisana w modelu studenta.

Wykorzystanie tej prawidłowości oraz wymóg generowanie studentów o różnych poziomach wiedzy, stworzyło potrzebę utworzenie zmiennej losowej, która mogłaby zobrazowywać taką zależność.




Rys. 3.5 Bazowy rozkład prawdopodobieństwa ocen dla studenta o poziomie wiedzy x wraz ze zmodyfikowanymi rozkładami odpowiadającymi 4 stopniom trudności lekcji

Model studenta opisany jest dwoma zmiennymi losowymi – poziomem wiedzy i rozkładem prawdopodobieństwa możliwych do uzyskania ocen (poziom wiedzy ma istotny wpływ na uzyskiwane oceny). Można, więc określić zmienną losową dwuwymiarową. Uzyskanie takiej zmiennej, generowanej na podstawie dwu rozkładów prawdopodobieństwa (beta i dwumianowego) jest rzeczą niełatwą. Przegląd literatury [15, 17, 23, 29, 31, 32, 35, 43, 63, 71-73] nie wniósł żadnej, prostej, alternatywy w celu rozwiązania zaistniałego problemu. W celu uproszczenia²³, powstała nieskomplikowana procedura umożliwiająca generowania wartości liczbowych (ocen) na podstawie wartości poziomu wiedzy każdego studenta.

W modelu przyjęto²⁴, że w zależności od stopnia trudności jednostki lekcyjnej rozkład bazowy możliwych do uzyskania przez studenta ocen o danym poziomie wiedzy, jest modyfikowany (rys. 3.5) w zależności od liczby stopni trudności lekcji, tak by odzwierciedlał wpływ trudności lekcji na uzyskanie oceny studenta (o danym poziomie wiedzy). Odpowiednio, profil (rozkład) bazowy ocen każdego studenta przypisany jednostce lekcyjnej o najniższym stopniu trudności. Każdy następny stopień trudności implikuje zmianę kształtu rozkładu bazowego (rys. 3.6).

²³ Celem pracy samym w sobie nie jest generator „studentów”.

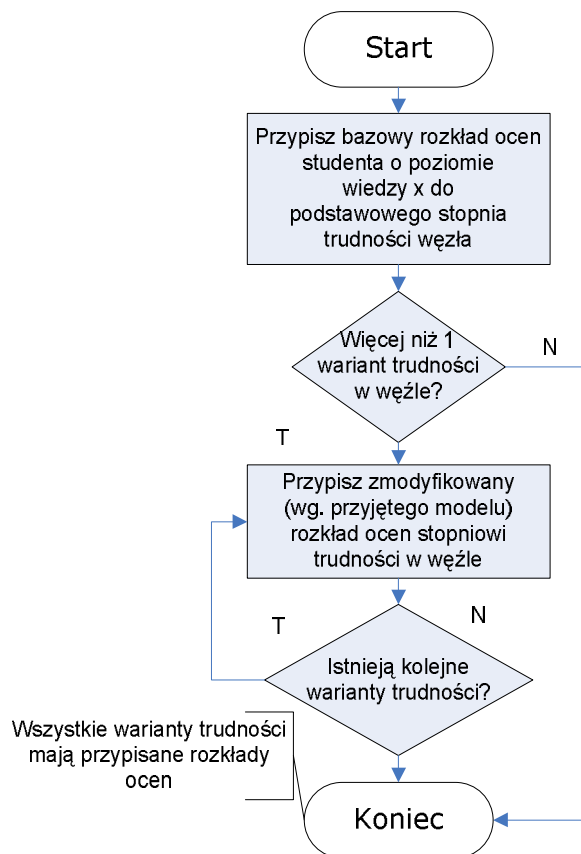
²⁴ Należy zwrócić uwagę, że student o poziomie x posiada bazowy profil (możliwych do uzyskania) ocen inny niż student o poziomie wiedzy y



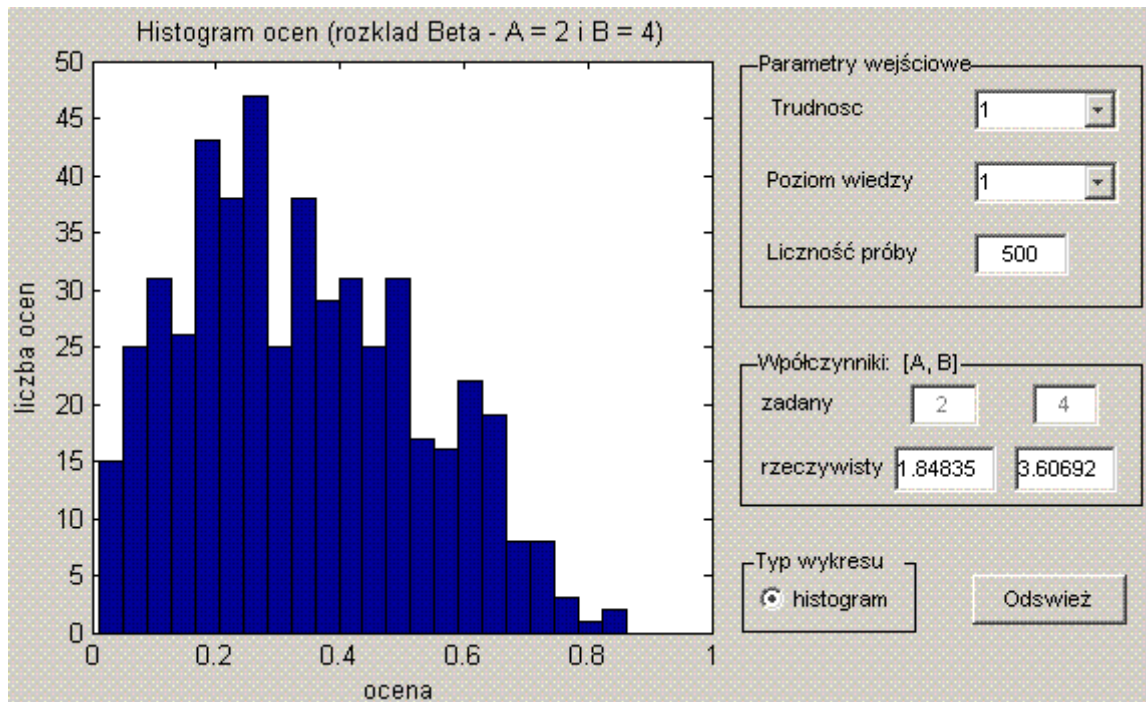
Rys. 3.6 Rozkładu prawdopodobieństwa ocen, a stopnie trudności jednostki lekcyjnej

Powyższy rysunek (rys. 3.6) przedstawia rozkłady ocen studenta o poziomie wiedzy x.

Bazowy rozkład prawdopodobieństwa został zmodyfikowany dla czterech stopni trudności jednostki lekcyjnej w węźle. Na rysunku (rys. 3.7) został przedstawiony uproszczony algorytm przypisywania rozkładów ocen do stopni trudności jednostki lekcyjnej węzła.



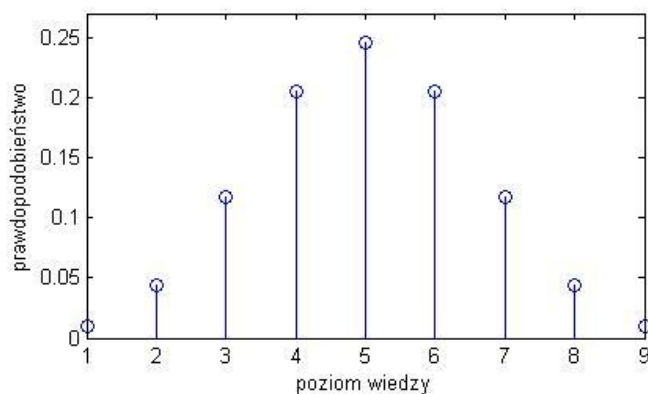
Rys. 3.7 Uproszczony algorytm przyporządkowywania rozkładów ocen jednostki lekcyjnej



Rys. 3.8 Praca generatora danych wejściowych – histogram ocen uzyskany przez grupę studencką o liczności 500.

Rysunek (rys.3.8) przedstawia wyniki pracy symulatora. Pokazane zostało generowanie danych wejściowych w postaci grupy studenckiej (wsp. a, b pochodzą z tab. 3.2)

Proces generowania grup studenckich²⁵ opiera się o takie dobranie pary parametrów (n, p) by otrzymany wykres odzwierciedlał żądane rozłożenie studentów grupy o poszczególnych poziomach wiedzy (jak na przykład na rys. 3.9). Poniżej przykład rozkładu dla typowej grupy studenckiej z przewagą studentów o średnim poziomie wiedzy.

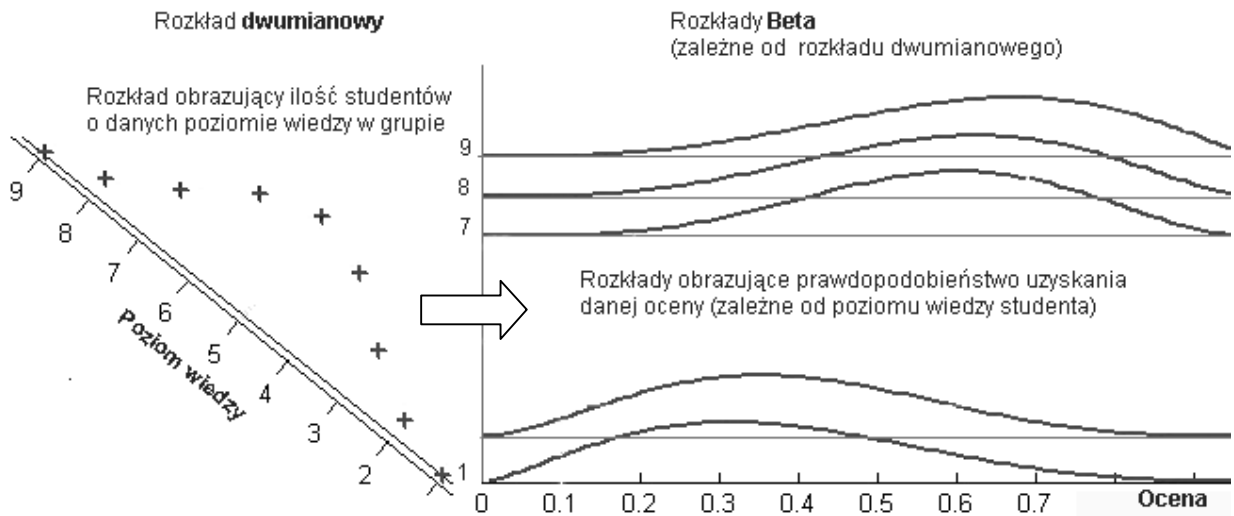


Rys. 3.9 Model rozkładu prawdopodobieństwa grupy o przewadze studentów ze średnim poziomem wiedzy

Mając wygenerowany rozkład prawdopodobieństwa poziomów wiedzy członków grupy (stworzony na podstawie rozkładu dwumianowego), przypisuje się poszczególnym studentom rozkłady prawdopodobieństwa możliwych do uzyskania ocen, wynikające z ich poziomów wiedzy.

²⁵ Przez generowanie rozumiemy tworzenie rozkładu obrazującego licznosc studentów reprezentujących poszczególne poziomy wiedzy (oś X – poziomy wiedzy, oś Y – liczba studentów)

Poniżej, na rysunku (rys. 3.10) przedstawiono transformację rozkładu studentów o danych poziomach wiedzy w krzywe rozkładu ocen.



Rys. 3.10 „Transformacja” studentekich poziomów wiedzy (rozkład dwumianowy) na krzywe rozkładu ocen (rozkład Beta)

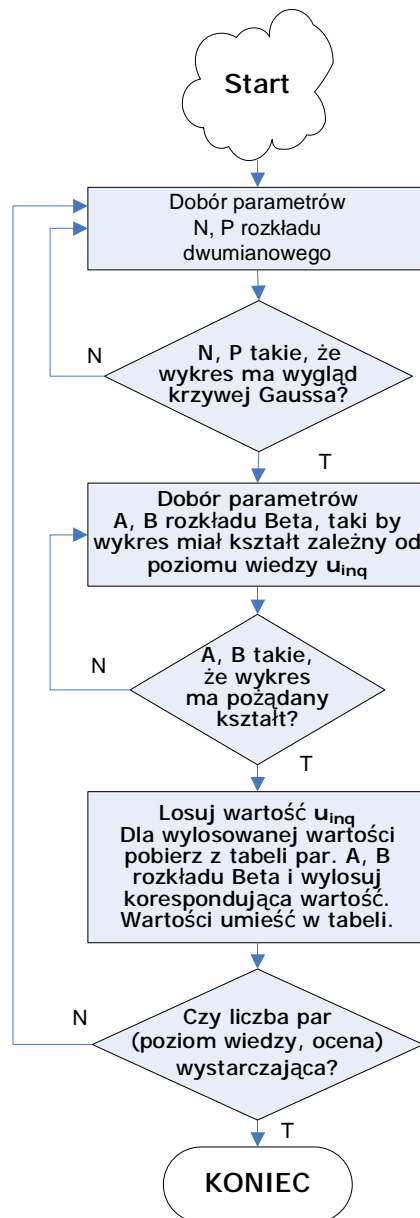
Przypisanie to jest ściśle uzależnione od rozkładu dwumianowego. Następuje transformacja (3.5) parametrów (n, p) w parametry (a, b) rozkładu Beta. Otrzymujemy rozkład prawdopodobieństw możliwych do uzyskania ocen (rozkład beta) na podstawie poziomu wiedzy danego studenta z grupy.

$$(n, p)_{dwum} \xrightarrow{\text{Transformacja}} (u_{inq}) \xrightarrow{\text{Przypisanie}} (a, b)_{beta} \quad (3.5)$$

Rysunek (rys. 3.11) przedstawia algorytm generowania par poziom wiedzy, ocena - charakteryzujący studentów tworzących grupy studentekie wykorzystywany przez generator danych wejściowych symulatora systemu e-nauczania.

Każdemu wirtualnemu studentowi o pewnym poziomie wiedzy, po ukończonej lekcji o zadanym poziomie trudności losowana jest ocena, odpowiadająca rzeczywistej ocenie uzyskanej przez studenta w teście kompetencji. Poniżej krótki opis tej procedury.

Pierwszym krokiem jest dobór parametrów (n, p) rozkładu dwumianowego, tak by wykres rozkładu obrazującego rozkład prawdopodobieństwa wystąpienia studenta o danym poziomie wiedzy, był zbliżony do wykresu krzywej rozkładu normalnego. W następnym kroku dobierane są parametry (a, b) rozkładu Beta uzależnione, od występujących poziomów wiedzy studentów, opisanych przez poprzedni rozkład. Jeśli wykres rozkładu ma pożądany kształt, to wybierana jest wartość poziomu wiedzy bieżącego studenta i do tej wartości dobierane są korespondujące parametry (a, b) wymagane do wylosowanie oceny. Następnie, na ich podstawie, losowana jest ocena, która umieszczana jest tabeli ocen. Jeśli istnieje potrzeba wygenerowanie następną parę (poziom wiedzy, ocena) algorytm rozpoczyna swoje działanie od pierwszego kroku.



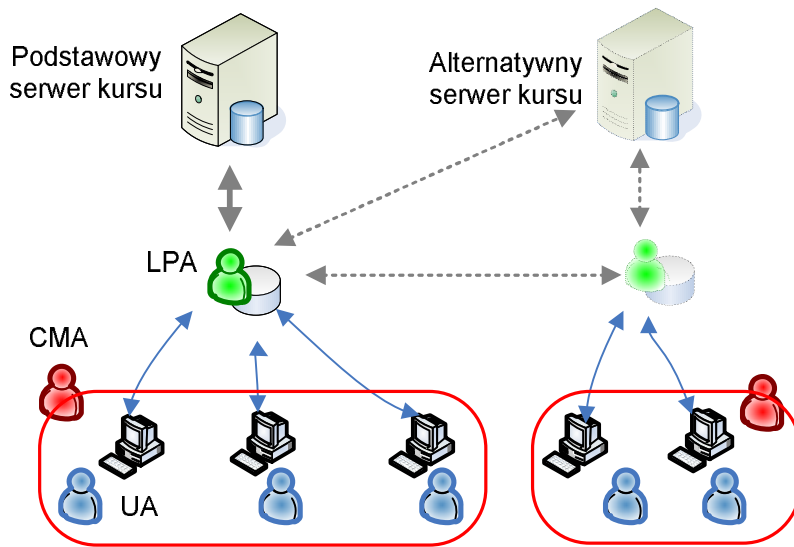
Rys. 3.11 Algorytm generowania par (poziomu wiedzy, ocena)

3.3 System e-nauczania w ujęciu agentowym

Koncepcja architektury agentowej systemu edukacji, przedstawiona poniżej, oparta jest o rozproszoną architekturę wykorzystującą agentów mobilnych. Agent mobilny, najogólniej rzecz biorąc, jest aplikacją o ściśle zdefiniowanej odpowiedzialności, która potrafi koordynować działanie innych programów, przenieść się na inny serwer, gdzie odtworzy swój stan i będzie kontynuowała działanie. Po zakończeniu działania agenta na danym serwisie, zazwyczaj nie zostaje po nim istotny ślad, najwyżej informacje w logach [12]. Takie zadanie wymaga kilku istotnych założeń technicznych. Po pierwsze, agent powinien być napisany w języku programowania, który da się przenieść na inną platformę sprzętowo-programową, (działający na innych systemach operacyjnych). Musi to być albo język interpretowany albo prekompilowany.

Zaimplementowana w architekturze agentowej (rys. 3.12) instancja systemu e-nauczania będzie zdolna do równoważenia obciążenia obliczeniowego, poprzez rozkładanie go (równomiernie) na poszczególne komputery, wykorzystując do tego celu agentów. Należy

zwrócić uwagę, że bloki funkcjonalne instancji systemu e-nauczania (rys. 3.4) znalazły odzwierciedlenie w blokach funkcjonalnych poszczególnych agentów (rys. 3.13, rys. 3.14, rys. 3.15), którzy realizują jej funkcje.

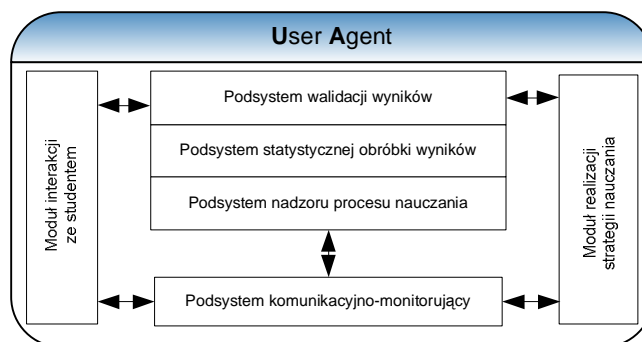


Rys. 3.12 Modelowy e-system nauczania zrealizowany w oparciu o architekturę agentową

W systemie znajdują zastosowanie trzy typy agentów:

§ UA (User's agents) - agenci studentów, realizują następujące funkcje:

- odbieranie danych od agentów ścieżki nauczania, nadzór i weryfikacja procesu nauczania studenta,
- prezentacja jednostek lekcyjnych oraz testów, interakcja z studentem.
- realizacja strategii adaptacji dla danego studenta i monitorowanie procesu nauczania,
- monitorowanie lokalnej zajętości zasobów.



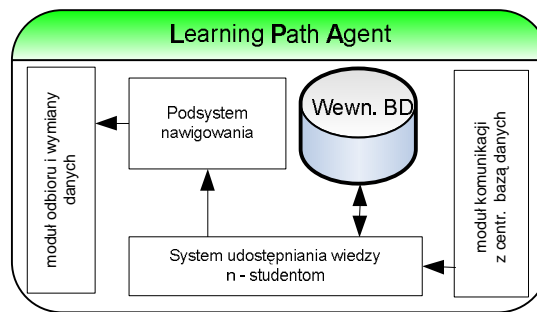
Rys. 3.13 Bloki funkcjonalne agenta studenta

Każdemu uczestnikowi kursu, na czas trwania procesu nauczania, przypisywany jest jego osobisty agent UA. Do zadań tego agenta należy bezpośrednia komunikacja ze studentem oraz pomiędzy pozostałymi agentami w systemie. Agent studenta jest, zatem pośrednikiem pomiędzy nim, a innymi agentami studentów. Warto nadmienić, że każdy agent studenta posiada z wielokrotnionym modułem systemu obliczeniowego instancji systemu e-nauczania. Do najistotniejszych bloków funkcjonalnych (rys. 3.13) tego typu agentów należą: podsystem komunikacyjno-monitorujący który wraz systemem interakcji ze studentem odpowiedzialny

jest za nadzorowanie procesu nauczania oraz moduł strategii nauczania, który odpowiada za wybieranie odpowiedniej strategii nauczania.

§ **LPA** (Learning Path Agents) - agenci ścieżki nauczania, realizują następujące funkcje:

- lokalne przechowywanie części danych kursu (Podstawa Grafu Wiedzy, wraz ze ścieżkami nauki) i przekazywanie ich do agentów profilu studenta,
- odbieranie i wymiana informacji oraz danych (jednostki lekcyjne, ścieżki nauki) pomiędzy agentami LPA i UA.



Rys. 3.14 Bloki funkcjonalne agenta ścieżki nauczania

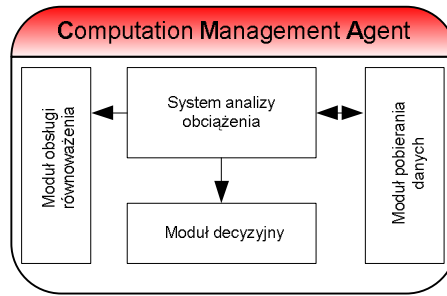
Agenci ścieżki nauczania, są agentami mobilnymi i pełnią rolę pośredników między bazą danych (ścieżek i jednostek lekcyjnych kursu), a agentami obliczeniowymi (CMA) oraz agentami profilu studenta (UP). W razie, gdy istnieje, więcej niż jedna baza wiedzy (z informacjami o kursie) agent LPA potrafi sprawdzić i skorzystać z tej, która jest mniej obciążona. Agent LPA przechowuje w lokalnej bazie niewielką liczbę lekcji (zazwyczaj <10) pobranej z globalnej kopii materiału kursu znajdującej się na serwerze. Wykorzystywany jest tu mechanizm znany z podsystemu *cache* dysków twardych. Do opisanego mechanizmu wykorzystywane jest pojęcie "*siły oddziaływania*" - czyli prawdopodobieństwa, że w najbliższym czasie wpłynie żądanie dostępu do obiektu. Jest oczywiste, że w pamięci lokalnej powinniśmy trzymać obiekty o dużej sile oddziaływania. Jednak siła oddziaływania między obiektami zazwyczaj nie jest znana i jest szacowana na bieżąco przez agenta. O niektórych typach lekcji wiemy, że ich średnia siła oddziaływania jest wyższa niż innych - np. siła lekcji szczególnie skomplikowanych (o dużym współczynniku porażek wśród studentów o różnych poziomach wiedzy) jest zazwyczaj wyższa niż lekcji „prostych”. Logiką przekazywania odpowiedniego kwantu wiedzy ze ścieżki nauczania steruje podsystem nawigowania przy pomocy systemu udostępniania wiedzy poszczególnym studentom.

§ **CMA** (*Computation Management Agents*) – agenci zarządzania obliczeniami, realizują następujące funkcje:

- przenoszenie obciążenia obliczeniowego na najmniej obciążone maszyny,
- obsługa równoważenia obciążenia
- generowanie statystyk,
- analiza zajętości pamięci, obciążenia procesora poszczególnych systemów uczestników kursu (dane pobierane od UA).

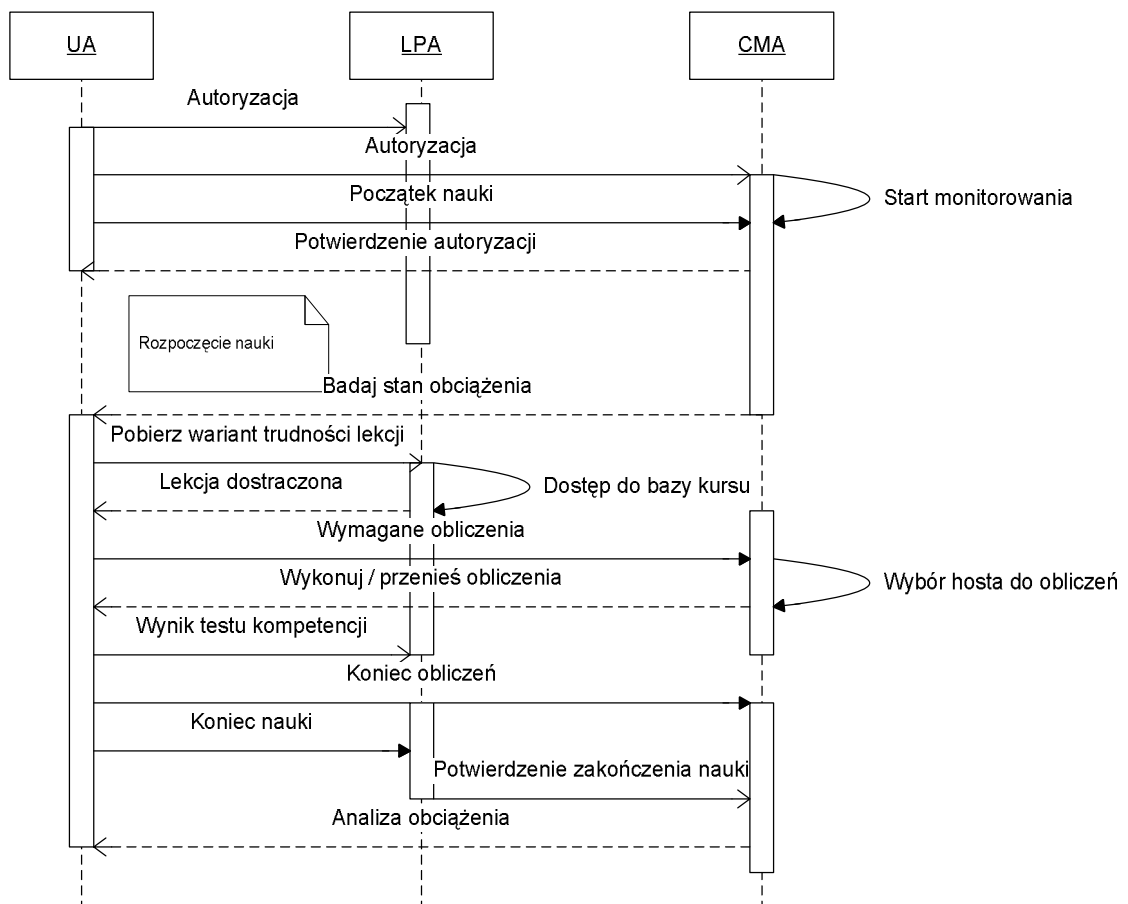
Agenci zarządzający obliczeniami, to również agenci mobilni, zarządzający realizacją strategii (obu faz) adaptacji procesu nauczania e-systemu, precyzyjniej mówiąc zarządzają obciążeniem systemu e-nauczania, poprzez przenoszenie obliczeń pomiędzy systemy obliczeniowe poszczególnych agentów studenta. Najprościej rzecz ujmując Agent CMA to agent, którego

głównym zadaniem jest przenoszenie obliczeń na poszczególne stacje robocze uczestników kursu.



Rys. 3.15 Bloki funkcjonalne agenta zarządzającego obliczeniami

Najważniejszym blokiem funkcjonalnym agenta CMA (rys. 3.15) jest system analizy obciążenia, dzięki któremu moduł decyzyjny może wyznaczać najmniej obciążone obliczeniowo stacje robocze, na których dokonywane są obliczenia. Moduł obsługi równoważenia obciążenia współpracuje z systemami obliczeniowymi poszczególnych agentów użytkownika.

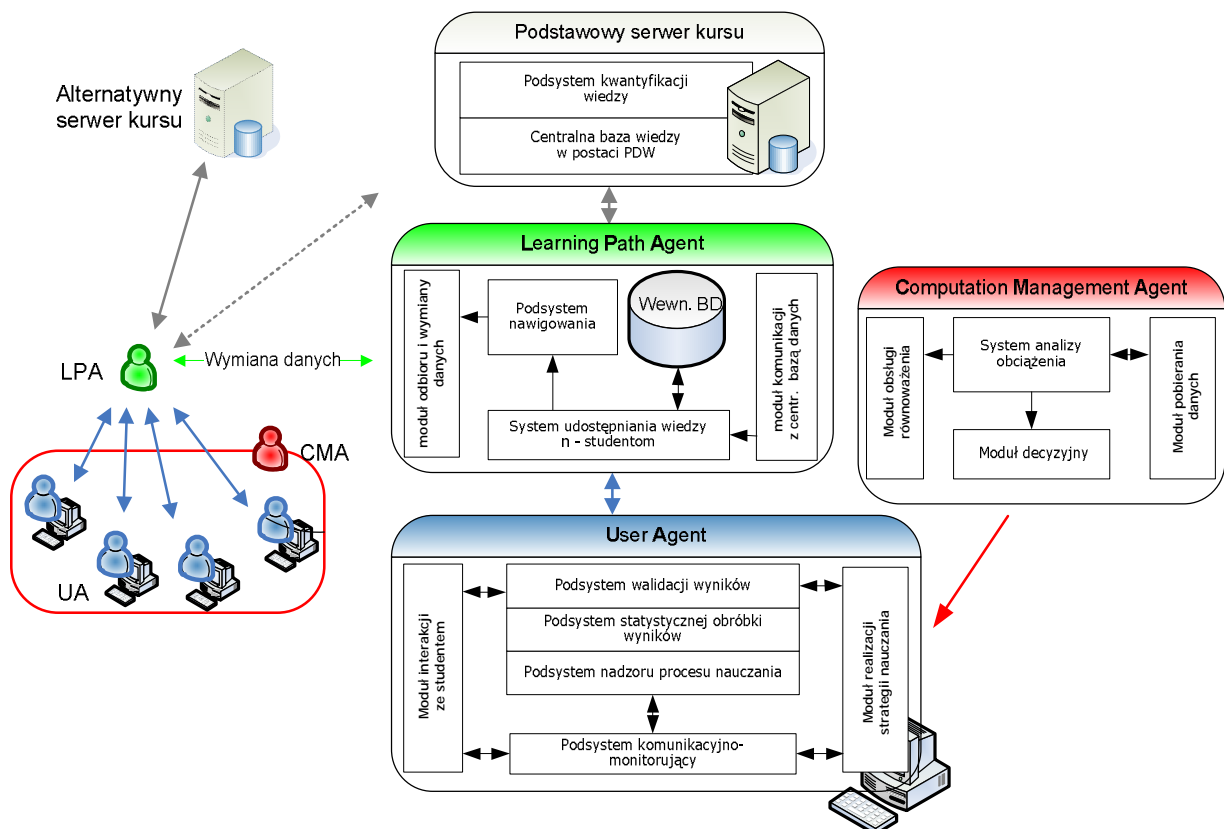


Rys. 3.16 Diagram sekwencji UML komunikacji międzyagentowej

Na rysunku (rys. 3.16) wyznaczono ogólny schemat komunikacji pomiędzy poszczególnymi typów agentów w systemie e-nauczania.

Bardzo istotną sprawą w minimalizacji odwołań do centralnej bazy kursu jest utrzymywanie wysokiego współczynnika wykorzystania lokalnej bazy, co niestety nie jest rzeczą prostą. Oszacowanie w sposób matematyczny, które jednostki lekcyjne będą potrzebne w danej chwili, nie jest możliwe. W celu polepszenia współczynnika trafień wykorzystano m.in. heurystyki opierające swe działanie o:

- § **lokalność czasową** - jeśli lekcja była ostatnio pobrana, to jest duże prawdopodobieństwo, że będzie wykorzystana ponownie w najbliższym czasie,
- § **lokalność przestrzenną** - jeśli lekcja była ostatnio pobrana, to prawdopodobnie będą też pobrane jednostki lekcyjne leżące w najbliższej okolicy danego węzła.



Rys. 3.17 Rozmieszczenie bloków systemu e-nauczania w ujęciu agentowym

W oparciu o (rys. 3.17) możemy dokonać analizy architektury e-systemu. Materiał kursu znajduje się na centralnym serwerze kursu. W razie potrzeby podsystem dostarczania Wiedzy może być rozszerzony o alternatywne serwery kursu.

W odróżnieniu od klasycznego modelu klient – serwer, przetwarzanie odbywa się nie po stronie serwerowej, a po stronie klienckiej (na komputerach uczestników kursu) i dodatkowo jest przetwarzaniem rozproszonym (ang. *distributed processing*). Za równoważenie obciążenia odpowiedzialni są agenci CMA (*Computation Management Agents*), którzy zarządzają zatrzymywaniem, wznawianiem i przenoszeniem procesów strategii adaptacji procesu nauczania na inne maszyny. Obniżenie zajętości realizowane jest przez zmniejszenie odwołań do centralnego serwera kursu, poprzez trzymanie kopii materiałów (niewielkiego wycinku) kursu przez agentów LPA w lokalnej bazie (działające jak lokalna pamięć *cache*). Agenci studentów UP odpowiedzialni za monitoring maszyn, na których uczą się uczestnicy kursu, w celu lepszego wykorzystania wspólnych zasobów przy przetwarzaniu rozproszonym.

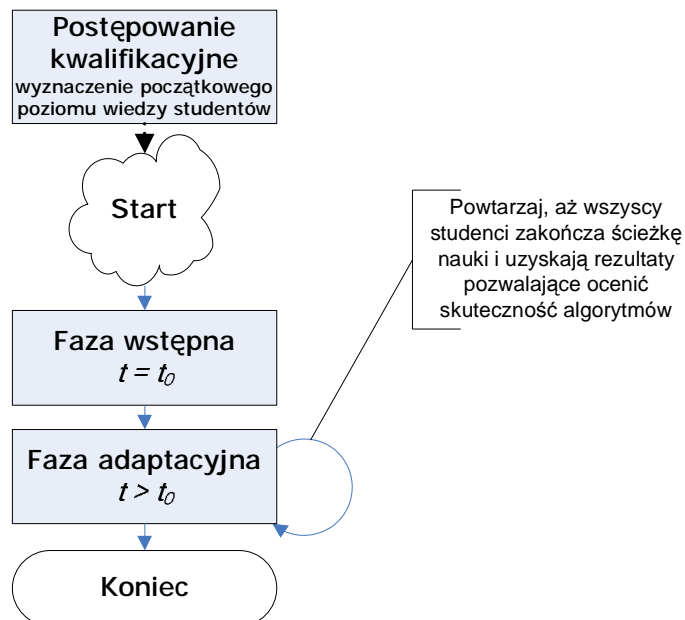
3.4 Symulacja pracy systemu e-nauczania

Można wyróżnić dwie fazy pracy systemu (rys. 3.18), w których stosowane są strategie adaptacji procesu nauczania.

1. Za *stan początkowy*, (znamienny brakiem informacji o historii ocen użytkowników, uważamy stan pracy e-systemu w chwili $t = t_0$. Stan ten zwany będzie fazą wstępną (startową). *Stan końcowy* nastąpi w momencie, gdy zostaje ukończona *faza adaptacyjna* (moment równoważny z końcem procesu nauczania).

W fazie startowej należy tak dobrać poziomy trudności pierwszej lekcji w ścieżce by była jak najlepiej dopasowana do możliwości indywidualnego studenta, czyli do jego poziomu wiedzy, a zarazem by dawała jak najlepsze wyniki testu kompetencji po jej skończeniu.

Ważnym czynnikiem jest również w miarę równomierne rozłożenia poziomów wiedzy w stosunku do stopni trudności lekcji.



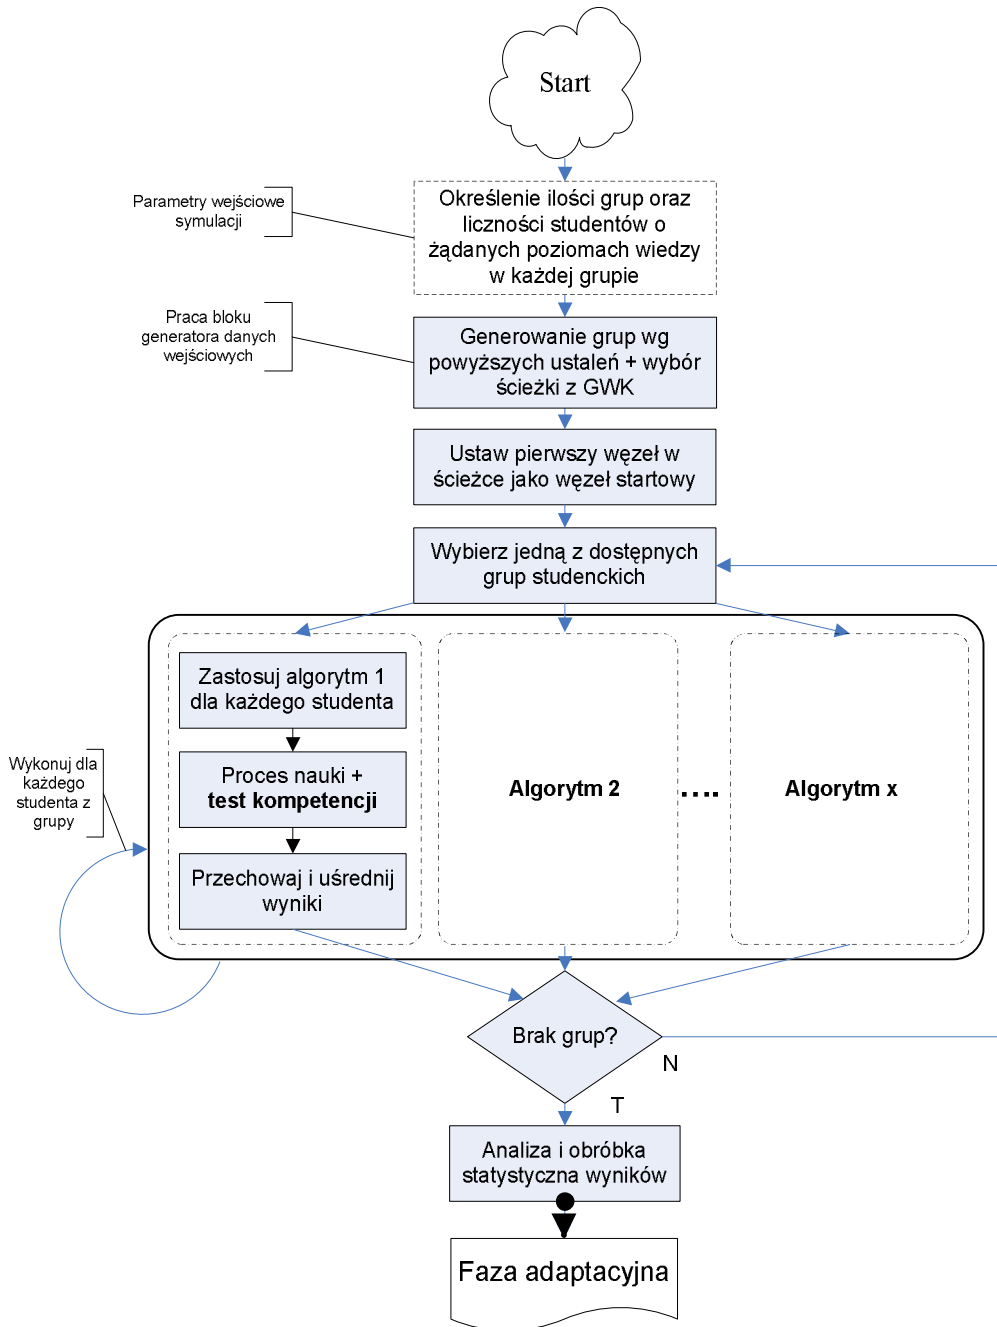
Rys. 3.18 Uproszczony diagram działania systemu e-nauczania (z podziałem na fazy)

W rzeczywistym systemie wyklucza się, zatem możliwość przypisania wszystkich studentów, bez względu na poziom ich wiedzy, na najniższy²⁶ z możliwych poziomów złożoności lekcji początkowej, ponieważ wyklucza to dopasowanie do możliwości / umiejętności studenta.

W przypadku fazy wstępnej kryterium optymalności możemy zdefiniować następująco: przypisanie takiego stopnia trudności pierwszej lekcji w ścieżce, by był jak najlepiej dopasowany²⁷ do poziomu wiedzy danego studenta, a zarazem by umożliwiał uzyskanie jak najlepsze wyniki testu kompetencji po jej skończeniu.

²⁶ Wyniki takiego przypisania zostały zamieszczone w celu odniesienia.

²⁷ Tak by stopień trudności jednostki lekcyjnej był w korelacji z umiejętnością studenta



Rys. 3.19 Schemat blokowy działania systemu w fazie wstępnej

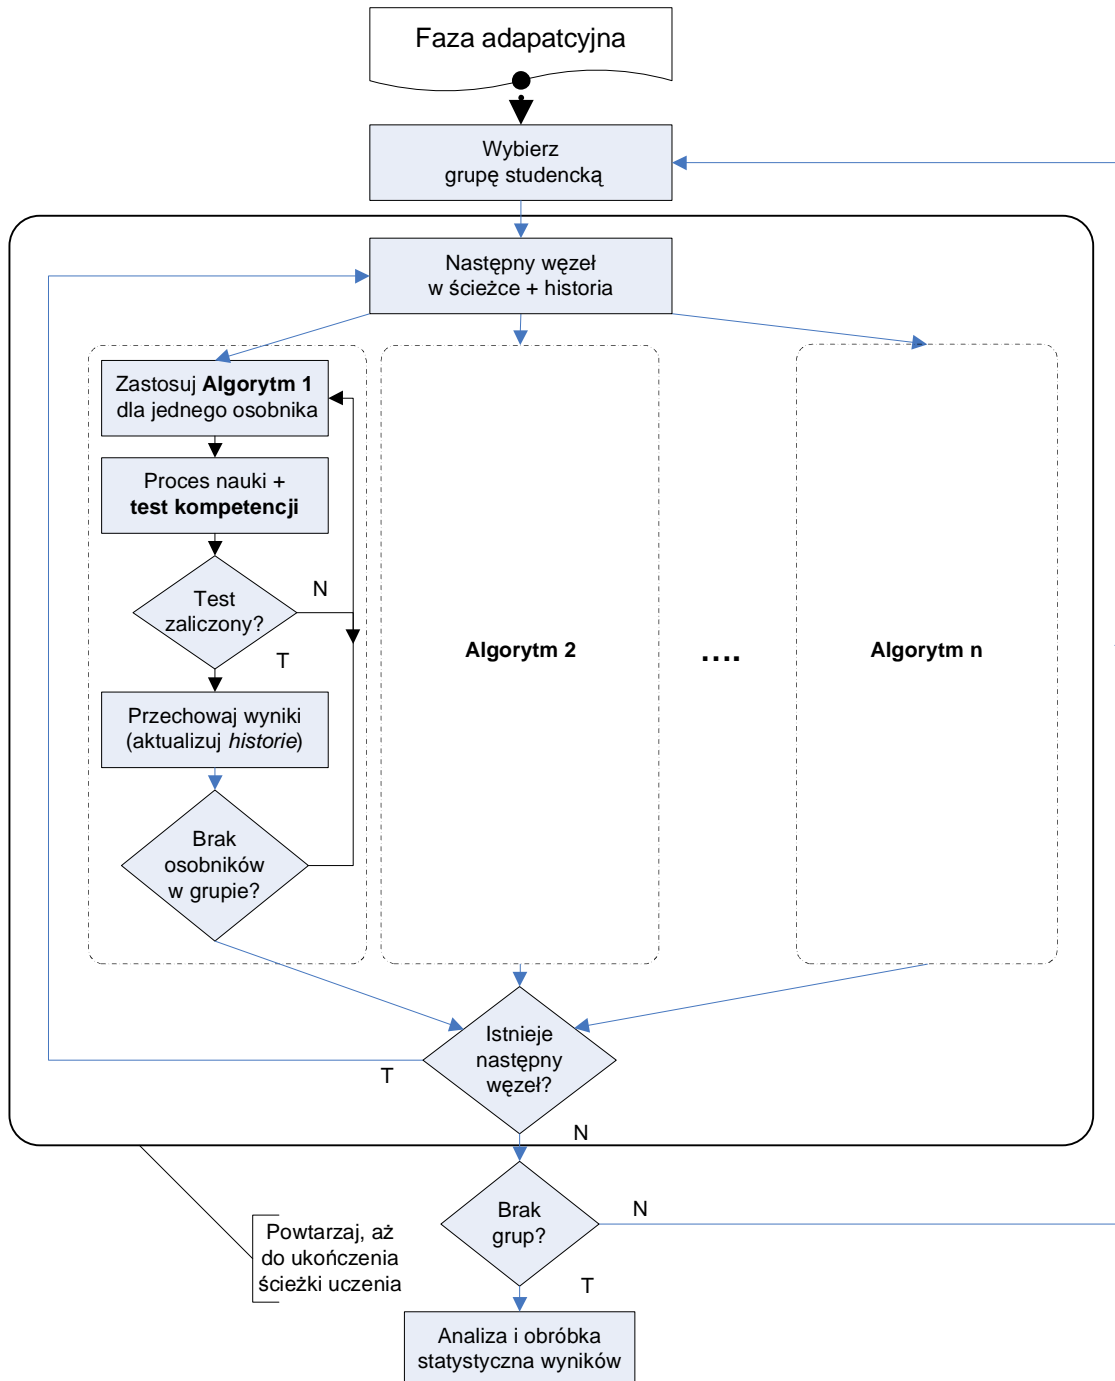
Rysunek (rys. 3.19) obrazuje schemat działania symulatora w fazie adaptacyjnej. Pierwszy blok w schemacie to pobranie parametrów wejściowych, bez których nie można zainicjować instancji symulowanego systemu e-nauczania.

2. W chwili $t > t_0$, zaczyna się faza ADAPTACYJNA, symulator systemu dysponuje już informacją o historii nauki (m.in. ocen z testów kompetencji i uzyskanych punktów kredytowych), przynajmniej z jednej lekcji wstecz.

Dla kolejnych, następujących po sobie *kroków* (lekcji) dla każdego studenta porównywana jest ocena uzyskana w teście kompetencji (z poprzedniej lekcji) ze średnią oceną grupy studenckiej o tym samym poziomie wiedzy, co użytkownik, jak również sprawdzany jest poziom trudności, na jakim student ukończył poprzednią jednostkę lekcyjną, by wyznaczyć średnią liczbę punktów kredytowych uzyskanych w procesie nauki.

Każdy krok algorytmu ma na celu wyznaczenie *optymalnego* poziomu trudności następnej lekcji dla każdego studenta z grupy.

W przypadku fazy adaptacyjnej kryterium optymalności możemy zdefiniować następująco: uzyskanie przez studenta w każdej lekcji w ścieżce nauki oceny nie mniejszej niż średnia grupy o tym samym poziomie wiedzy oraz średniej liczby punktów kredytowych większej lub równej połowie sumy wszystkich możliwych do uzyskania punktów kredytowych.



Rys. 3.20 Schemat blokowy działania systemu w fazie adaptacyjnej

Rysunek (rys. 3.20) obrazuje symulację poszczególnych strategii systemu edukacji w fazie adaptacyjnej. Wybór zastosowania poszczególnych strategii jest dokonywany przez podsystem decyzyjny symulatora.

3.5 Efektywność procesu nauczania

Jednym z kluczowych problemów spotykanych w systemach e-edukacji niższa niż zakładana skuteczność procesu nauczania. W rozprawie skupiono się również na tym problemie. Zagadnienie podnoszenia efektywności nauczania zostało sprowadza się w niniejszej pracy do dobierania najlepszego algorytmu nauczania (względem podanych poniżej kryteriów) ze zbioru możliwych strategii adaptacji.

Strategie adaptacji mają organizować proces nauczania w taki sposób, aby jak najlepiej spełniły kryteria efektywności procesu nauczania dla poszczególnych studentów, a w efekcie końcowym polepszyły efekt uczenia całej grupy.

Głównym kryterium, jakie jest brane pod uwagę przy dążeniu do zwiększenia skuteczności procesu nauczania z wykorzystaniem strategii nawigacyjnych to:

- § dążenie do uzyskiwania jak najlepszych ocen przy jednoczesnym uzyskiwaniu jak największej liczny punktów kredytowych.

Są to dwa przeciwstawne kryteria (maksymalizujące / ograniczające) – i tak odpowiednio, dążenie do uzyskania jak najlepszej oceny mogłoby być zrealizowane przez przypisywanie każdemu studentowi najprostszego wariantu trudności każdej lekcji (niemniej jednak celowość takiego działania jest, co najmniej dyskusyjna, ze względu na organizację wiedzy w kwanty o różnych trudnościach), natomiast uzyskiwanie możliwie największej sumy punktów kredytowych wiąże się z przypisywaniem na najtrudniejsze warianty trudności każdej lekcji. Wykorzystanie tego faktu, oraz jednoznacznych wyników, pozwoli uniknąć szczegółowego badania optymalności danej strategii ze względu na jej wielokryterialność.

Przyjęto, przy porównaniu efektywności strategii, że ważniejszym czynnikiem świadczącym o przydatności danej strategii, jest jak największa liczba studentów, którzy uzyskali przynajmniej połowę maksymalnej dostępnej liczby punktów kredytowych, a średnia ocena z całego procesu nauki, jest wymaganiem drugorzędym.

Podczas zarządzania procesem nauki poszczególne strategie wykorzystują też kryteria pomocnicze, zdefiniowane poniżej:

- § minimalizacja liczby studentów, którzy nie spełniają kryterium optymalności,
- § detekcja i korekcja poziomów wiedzy wyznaczonych nieprawidłowo przed / lub w fazie wstępnej,
- § „eksploatowanie” umiejętności studentów wybijających się, przez przypisywanie do trudniejszych lekcji w kolejnych krokach,
- § minimalizacja zasobów sprzętowych e-systemu.

Jako kryteria oszacowania walidacji procesu nauczania w fazie wstępnej przyjęto:

- § liczbę studentów którzy otrzymali co najmniej połowę maksymalnej liczby punktów kredytowych, na 100 studentów wyrażoną w procentach,
- § liczbę ocen powyżej średniej (dla każdego studenta z grupy), uzyskaną przez całą grupę, na 100 studentów wyrażoną w procentach,
- § średnia ocenę całej grupy dla wszystkich eksperymentów,
- § minimalną średnią ocenę ze wszystkich eksperymentów całej grupy,
- § maksymalną średnią ocenę ze wszystkich eksperymentów całej grupy.

Jako kryteria oszacowania walidacji adaptacji procesu nauczania w fazie adaptacyjnej przyjęto:

- § zmianę wykresu obrazującego poziomy wiedzy (porównanie przed i po procesie nauki),
- § rozrzut punktów na wykresie liczba suma punktów kredytowych / średnia ocena,
- § liczbę studentów, którzy zakończyli naukę z więcej niż połową max liczby punktów kredytowych.

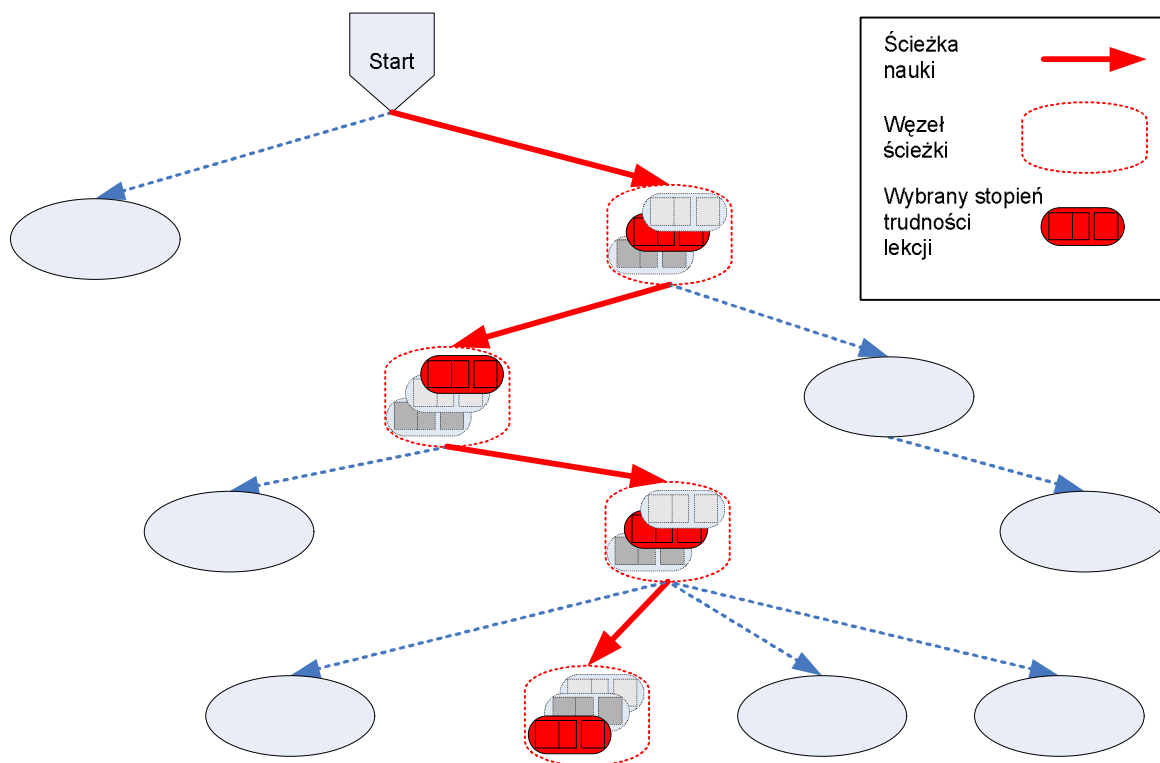
Każda ze strategii, przedstawionych szczegółowo w następnych rozdziałach, powinna spełniać przynajmniej kryterium główne. Poza tym wszystkie posiadają swoje charakterystyczne kryteria dodatkowe. I tak na przykład strategia globalnego optimum nastawiona jest na dążenie do wykrywania ponadprzeciętnych²⁸ studentów i wykorzystywania ich umiejętności poprzez przypisanie ich na trudniejsze stopnie trudności w kolejnych lekcjach. Zatem zdywersyfikuje ona swoje działanie względem poszczególnych studentów biorąc pod uwagę ich poziom wiedzy. Natomiast strategia minimalistyczna znamienna jest dążeniem do przypisywania studenta na ten sam poziom wiedzy w ciągu całego procesu nauczania. Więcej informacji na temat specyfiki działania każdej strategii zawarte jest rozdziale 4.

²⁸ Ponadprzeciętny student to taki, który uzyskuje z lekcji na lekcje, oceny wyższe niż wynikające z modelu o zadanym poziomie wiedzy.

4 Algorytmy doboru strategii wspomagających proces nauczania

4.1 Strategie nawigacyjne

Wykorzystywane w rozprawie algorytmy zwane są strategiami nawigacyjnymi (zamiennie strategiami nauczania). Algorytm nawigacyjny ma za zadanie przeprowadzić studentów przez ścieżkę nauki, i przenieść system z pewnego stanu początkowego (faza wstępna) do określonego pożądanego stanu końcowego (koniec fazy adaptacyjnej).



Rys. 4.1 Algorytm działania strategii adaptacji procesu nauczania w wybranej ścieżce nauki

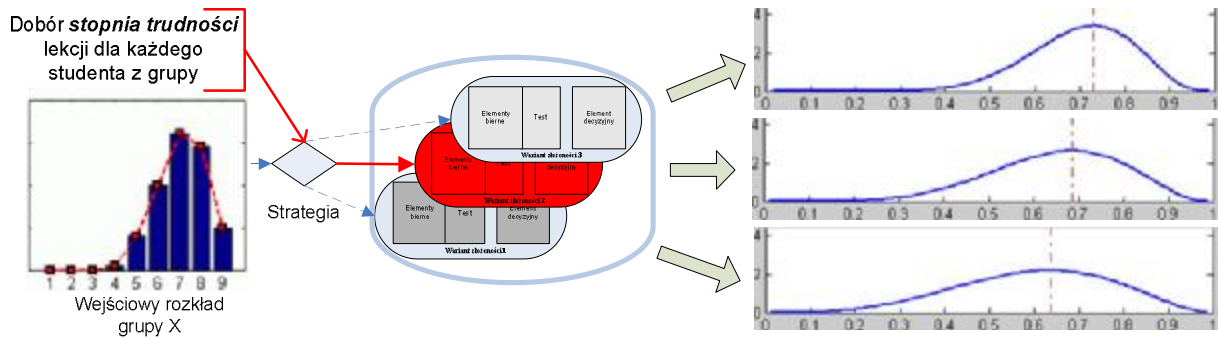
Określona uprzednio „nawigacja”, w systemie edukacji może być zrealizowana dwojako:

- § automatycznie, przez odpowiedni algorytm nawigacyjny,
- § manualnie, przez opracowanie i wytyczenie ścieżek przez grupę specjalistów posiadających wiedzę ekspercką z danej dziedziny wiedzy.

Na potrzeby niniejszej pracy przyjęto ewentualność drugą, że możliwe ścieżki nauki zostały zadane *a priori*.

Działanie algorytmu nawigacyjnego, wspomnianego powyżej, będzie opierać się na mechanizmach adaptacji nauczania²⁹, gdzie analizowane i przetwarzane są na bieżąco dane o historii ukończonych jednostek lekcyjnych, w celu przypisania przejść między następnymi lekcjami, gwarantującymi „optymalne” przyswajanie materiału.

²⁹ Przez adaptację rozumie się wnioskowanie na zebranych danych „historycznych” i dobór optymalnych „parametrów” nauczania dla każdego studenta.



Rys. 4.2 Wybór stopnia trudności jednostki lekcyjnej przez strategię nawigacyjną

Zadaniem algorytmów adaptacyjnych jest *przypisanie* każdemu użytkownikowi z grupy, odpowiedniego poziomu trudności (w bieżącej lekcji j), tak by jego ocena (*note*) uzyskana w teście kompetencji (po tej lekcji) była nie mniejsza niż średnia ocena użytkowników o takim samym poziomie wiedzy, oraz by suma punktów kredytowych była, co najmniej równa połowie, możliwych do otrzymania punktów kredytowych (4.1).

$$note_j \geq \frac{1}{n} \sum_{i=1}^n note_i \wedge \sum pts_{end} \geq \frac{1}{n} \sum_{i=1}^n pts_i \quad (4.1)$$

Ponadto, podczas działania systemu e-nauczania, powinno się zwrócić uwagę na możliwość weryfikacji wyznaczonego przed rozpoczęciem procesu nauczania poziomu wiedzy każdego z użytkowników, ze względu na możliwość złego doboru algorytmu (strategii) dostosowywania materiału kursu.

4.2 Strategie fazy wstępnej

4.2.1 Strategia proporcjonalna

Założono, że algorytm przypisania powinien dążyć do maksymalnego wykorzystania zdolności nabywania wiedzy danego studenta (ale proporcjonalnie do jego poziomu wiedzy), a co za tym idzie umieszczania go na jak najwyższych z dostępnych stopni trudności węzła.

Przypisanie stopnia trudności lekcji określanego przez parametr d_{fact} wg strategii proporcjonalnej odbywa się na podstawie odwzorowań $d_{fact} \rightarrow u_{inq}$ zapisanych w tabeli (tab. 4.1).

$$tab_i(d_{fact}) \rightarrow u_{inq} \quad (4.2)$$

gdzie:

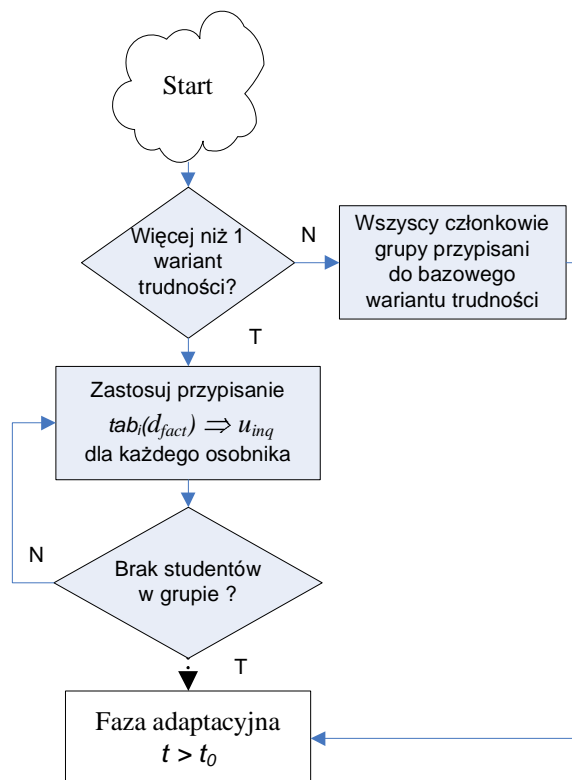
i – kolejny typ przypisania

Tabela (tab. 4.1) zawiera odwzorowania (poziom wiedzy \Rightarrow trudność lekcji). Wyznaczono trzy różniące się od siebie przypisania, wykorzystane w symulacji działania strategii proporcjonalnej, fazy startowej systemu (rozdz. 5.1.1).

Stopień trudności lekcji	Przypisanie PIERWSZE $tab_1(d_{fact})$	Przypisanie DRUGIE $tab_2(d_{fact})$	Przypisanie TRZECIE $tab_3(d_{fact})$
d_{fact}	U_{inq}	U_{inq}	U_{inq}
1	1	1, 2	1, 2, 3, 4
2	2, 3	3, 4	5, 6, 7
3	4, 5, 6	5, 6	8
4	7, 8, 9	7, 8, 9	9

Tab. 4.1 Tabela odwzorowań poziom wiedzy – trudność lekcji

Dobór poszczególnych parametrów (tab. 4.1) został wyznaczony w drodze eksperymentu w powiązaniu z heurystyką, opierającą się o założenie, że wyższy poziom wiedzy idzie w parze ze zmniejszeniem stopnia trudności jednostki lekcyjnej (tj. im wyższy jest poziom wiedzy studenta to bardziej wskazane jest umieścić go na poziomie o większym stopniu trudności, by maksymalnie wykorzystać jego możliwości).



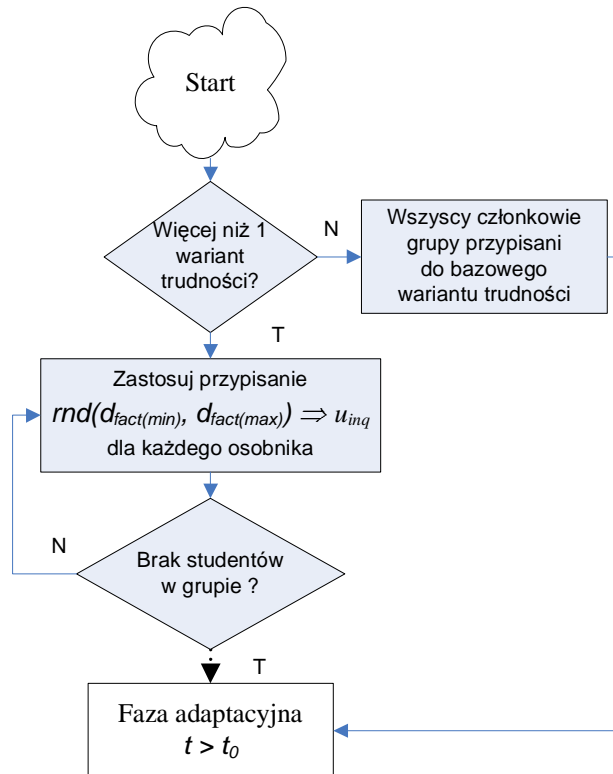
Rys. 4.3 Strategia proporcjonalna w fazie wstępnej

Powyższy rysunek (rys. 4.3) przedstawia algorytm działania strategii proporcjonalnej podczas fazy wstępnej.

4.2.2 Strategia przypadkowa

W chwili $t = t_0$, tj. rozpoczęcia fazy wstępnej, dla każdego studenta z grupy w procesie nauczaniu następuje losowe przypisanie stopnia trudności danej jednostki lekcyjnej poprzez wykorzystanie losowej permutacji wszystkich elementów wektora definiującego stopień trudności.

$$\text{rnd}(d_{\text{fact}(\min)}; d_{\text{fact}(\max)}) \Rightarrow u_{\text{inq}} \quad (4.3)$$



Rys. 4.4 Strategia przypadkowa w fazie wstępnej

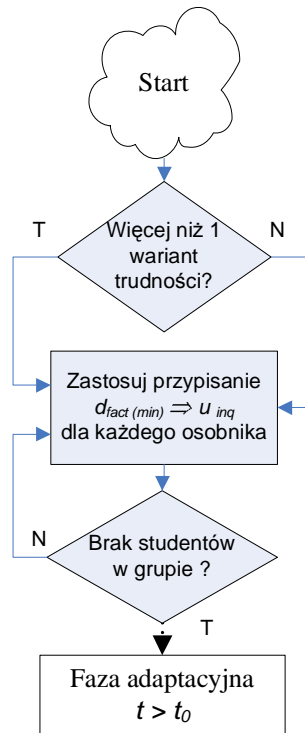
Powyższy rysunek (rys. 4.4) obrazuje kroki algorytmu przypisania przypadkowego podczas fazy wstępnej.

4.2.3 Strategia prymitywna

Strategia prymitywna bazuje na założeniu, że jeśli każdemu studentowi, bez względu na jego poziom wiedzy, zostanie przypisany najłatwiejszy z możliwych stopni trudności (4.4), to jest wysoce prawdopodobne, że większy procent studentów uzyska lepsze wyniki niż w innych przypisaniach. Podsumowując każdemu użytkownikowi z grupy, o danym poziomie wiedzy przypisuje się najniższy dostępny stopień trudności jednostki lekcyjnej węzła startowego.

Co zapisuje się następująco:

$$d_{\text{fact}(\min)} \hat{P} u_{\text{inq}} \quad (4.4)$$



Rys. 4.5 Strategia prymitywna w fazie wstępnej

Rysunek (rys. 4.5) przedstawiający algorytm działania strategii prymitywnej podczas fazy wstępnej.

Cecha	Strategia:		
	<i>przypadkowa</i>	<i>proporcjonalna</i>	<i>prymitywna</i>
Uwzględnienie cech osobowych	Nie	Tak	Nie
Różne warianty nawigacji	Nie	Tak (3)	Nie
Przypisanie stopnia trudności jednostki lekcyjnej zależne od poziomu wiedzy studenta	Nie, Losowe	Tak	Nie

Tab. 4.2 Zestawienie charakterystycznych cech strategii dla fazy wstępnej

W tabeli (tab. 4.2) zebrano cechy szczególne strategii fazy wstępnej. Jako jedyna, strategia proporcjonalna (każdy jej wariant) uwzględnia poziom wiedzy przy doborze stopnia trudności, co przekłada się znacząco na uzyskiwane wyniki nie tylko samego studenta, ale i też całej grupy. Strategia przypadkowa, w fazie wstępnej użyta, jest tylko i wyłącznie jako odniesienie do wyników działania pozostałych (dwu) strategii. W rzeczywistym systemie edukacji nie będzie wykorzystywana.

4.3 Strategie fazy adaptacyjnej

4.3.1 Strategia globalnego optimum

Przyjęto, że od studentów najlepszych, tych, którzy zostali zakwalifikowani do lekcji o maksymalnym stopniu trudności *wymaga* się najwięcej. Przypisanie, bądź „awans” na poziom najwyższy w następnej lekcji, nie jest przypadkowe, a wyznaczane jest przez algorytm w procesie adaptacji procesu nauczania.

Uzyskiwanie oceny większej bądź równej niż oczekiwana na najwyższym poziomie trudności i posiadanie średniej liczby punktów kredytowych większej lub równej od zakładanej, powoduje zwiększenie „współczynnika sukcesu” o jeden.

Zwiększenie poziomu wiedzy następuje po spełnieniu następującego warunku, student - co najmniej trzy razy z rzędu będzie uzyskiwał ocenę większą lub równą od średniej przy jednoczesnym spełnieniu warunku wymaganej liczby punktów kredytowych (współczynnik sukcesu większy równy trzy).

Każdorazowe zaliczenie lekcji i otrzymanie oceny wyższej lub równej średniej promowane jest zwiększeniem współczynnika sukcesu o jeden i zmniejszenia współczynnika porażki o jeden.

Analogicznie studentów o mniejszym poziomie wiedzy, którzy trafiają na łatwiejsze poziomy, algorytm traktuje z pewną „tolerancją”. Warto zauważyć, że algorytm nie obniża studentowi poziomu wiedzy czy nie kieruje po pierwszej porażce na niższy poziom. Każda „porażka”, czyli niezaliczenie lekcji i/lub nieuzyskanie wymaganej liczby punktów kredytowych zwiększa współczynnik porażki, który po przekroczeniu liczby 3 porażek z rzędu obniża poziom trudności jednostki lekcyjnej. Przy każdej powtarzanej lekcji założono, że student ma w niewielkim stopniu ułatwione zadanie gdyż zna już materiał i część testu przez szansa na uzyskanie oceny pozytywnej (promującej do przejścia do następnej lekcji) jest większa. Jeśli student w poprzedniej lekcji był na poziomie większym od minimalnego obniżamy kolejno poziom trudności, natomiast, gdy poziom był poprzednim kroku minimalny obniżamy poziom wiedzy studenta.

Podsumowując, algorytm ten promuje studentów wybijających się ponad średnią, stara się utrzymać ich jak najwyższym poziomie trudności każdej następnej lekcji. Występuje tu nastawienie na maksymalne eksploatowanie potencjału intelektualnego drzemiącego w każdym studentcie.

Niezapomniano także o studentach najsłabszych, bądź tych, którzy zostali niewłaściwie zaklasyfikowani w procesie rekrutacji. Algorytm daje im szansę na poprawę wyników. Zaobserwowano, że optymalna ilość powtórek każdej lekcji to liczba trzy, zwiększenie ilości powtórek nie daje wymiernych efektów, natomiast zmniejszenie powoduje drastyczną redukcję ilości zdobywanych punktów kredytowych przez „słabszych” studentów.

Do cech charakterystycznych strategii globalnego optimum należy zaliczyć:

- § Różnicowanie studentów w grupie,
- § Maksymalne wykorzystywanie potencjału umysłowego studentów „zdolnych” przy równoczesnym dążeniu do spełnienia kryterium optymalności dla fazy adaptacyjnej,
- § Zróżnicowane funkcjonowanie w zależności od poziomu wiedzy studenta,
- § Uwzględnianie możliwości zwiększenia poziomu wiedzy,
- § Korekcja poziomów wiedzy studentów „ponadprzeciętnych”,
- § Detekcja pomyłek w ocenie wiedzy studentów, (które nastąpiły przed fazą wstępną),
- § Możliwość ponawiania niezaliczonej lekcji,
- § Uwzględnienie efektu pamięci przy ponownym podchodzeniu do niezaliczonej lekcji,
- § Wykorzystanie współczynników PORAŻKI i SUKCESU.

W przypadku studenta ponadprzeciętnego:

- § Dążenie do zwiększenia poziomu trudności z lekcji na lekcje,
- § Porażka utrzymuje ten sam poziom trudności lekcji przy powtórce,
- § Zwiększenie poziomu wiedzy po trzech kolejnych sukcesach,
- § Zachowanie w „pamięci” fragmentów poprzedniej niezaliczonej lekcji – większa szansa na zaliczenie przy powtórce.

W pozostałych przypadkach:

- § Utrzymywanie takiego samego poziomu trudności,
- § Maks. trzykrotna powtórka tej samej lekcji w razie porażki,
- § Zachowanie w „pamięci” fragmentów poprzedniej niezaliczonej lekcji – większa szansa na zaliczenie przy powtórce.

4.3.2 Strategia zachowawcza

Strategia ta zakłada, że studenci otrzymujący wysokie oceny (powyżej średniej dla danego poziomu wiedzy, reprezentowanego przez studenta) z testów kompetencji w żaden sposób nie będą motywowani do dalszych wysiłków by poprawić swe „osiągnięcia”.

Wyznaczenie właściwego (tj. rzeczywistego poziomu wiedzy) musi odbyć się przed fazą wstępną. A wyniki działania tego algorytmu bazują w dużej mierze od wyników przypisania wstępnego (fazy wstępnej). Zakładając sytuację, że student o rzeczywistym poziomie wiedzy 8 został przypisany przypadkowo na poziom wiedzy 6. W kolejnych lekcjach z założenia otrzymywał będzie oceny zdecydowanie wyższe oceny od kolegów o rzeczywistym poziomie wiedzy 6, ale ten tego nie odnotuje i nie będzie dążył do maksymalnego wykorzystania potencjału intelektualnego danego studenta. *Strategia globalnego optimum* daje taką możliwość.

Każdorazowe niespełnienie *kryterium optymalności dla fazy adaptacyjnej* (równoznaczne z niezaliczeniem testu kompetencji lub nieuzyskaniem zakładanej liczby punktów kredytowych) nie obniża natychmiastowo poziomu wiedzy czy poziomu trudności lekcji, Student zawsze ma trzy szanse na poprawę wyniku. Niemniej jednak w odróżnieniu od poprzedniego *algorytmu* przyjęto, że ponowne podejście do tej samej lekcji jest dla czymś *nowym* dla studenta – brak efektu pamięciowego. Student nie utrwala wiedzy teoretycznie już nabytej, w niezaliczonej lekcji, przez co przy każdej powtórce zaczyna od początku, co namacalnie odbija się to szczególnie na średniej ocenie studentów powtarzających kolejne lekcje.

Do cech charakterystycznych strategii zachowawczej należy zaliczyć:

- § Wpływ fazy wstępnej – wyznaczonego bazowego poziomu wiedzy na wyniki studenta,
- § Wszyscy studenci traktowani jednakowo,
- § Dążeniu jedynie do spełnienia kryterium optymalności dla fazy adaptacyjnej,
- § Uwzględnianie możliwości zwiększenia poziomu wiedzy,
- § Możliwość powtarzania niezaliczonej lekcji,
- § Brak efektu pamięciowego przy ponownym podchodzeniu do niezaliczonej lekcji,
- § Wykorzystanie współczynników PORAŻKI i SUKCESU.

W przypadku studenta ponadprzeciętnego:

- § Utrzymywanie takiego samego poziomu trudności dla studentów wybijających się,

- § Porażka utrzymuje ten sam poziom trudności lekcji przy powtórce,
- § Utrzymanie poziomu wiedzy po trzech kolejnych sukcesach,
- § Brak efektu pamięci przy niezaliczonej lekcji.

W pozostałych przypadkach:

- § Utrzymywanie takiego samego stopnia trudności,
- § Maks. trzykrotna powtórka tej samej lekcji w razie porażki,
- § Brak efektu pamięci przy niezaliczonej lekcji.

4.3.3 Strategia minimalistyczna

Strategia ta nie uwzględnia możliwości poprawy poziomu wiedzy studentów, jedynie zwiększa poziom trudności jednostek lekcyjnych w przypadku uzyskania ponadprzeciętnych wyników (ocena / liczba punktów kredytowych). Nie jest brana pod uwagę ilość sukcesów z rzędu mająca na celu zwiększenie poziomu wiedzy jak to ma miejsce w strategii globalnego optimum. Studenci nie są rozróżniani (tj. dzieleni na „lepszych” – mających wysoki współczynnik sukcesu i „gorszych z niskim), przez sam algorytm tj. nie ma współczynnika sukcesu, który sugerował poziom „zdolności” danego studenta. Strategia ta wprowadza pewnego rodzaju *egalitaryzm* przy wyznaczaniu poziomu trudności następnej lekcji. Każdy student traktowany jest w ten sam sposób i ma tyle samo szans. Podobnie do strategii globalnego optimum przy porażce każdy uczeń ma trzykrotną szansę na poprawę. W tej strategii uwzględniono „pamięć” studenta materiału z niezaliczonej lekcji i praktyczną możliwość uzyskania lepszej oceny w kolejnych podejściach (maksymalnie trzech).

Do cech charakterystycznych strategii minimalistycznej należy zaliczyć:

- § Wszyscy studenci traktowani jednakowo,
- § Maksymalne wykorzystywanie potencjału studentów „zdolnych” przy równoczesnym dążeniu do spełnienia kryterium optymalności dla fazy adaptacyjnej,
- § Brak możliwości zwiększenia poziomu wiedzy,
- § Możliwość ponawiania niezaliczonej lekcji,
- § Uwzględnienie efektu pamięci przy ponownym podchodzeniu do niezaliczonej lekcji,
- § Brak współczynnika SUKCESU, współczynnik PORAŻKI wykorzystywany,
- § Utrzymywanie takiego samego stopnia trudności z lekcji na lekcję,
- § Jednokrotna „porażka” – powoduje obniżenie poziomu wiedzy,
- § Maks. trzykrotna powtórka tej samej lekcji w razie niezaliczenia.

4.3.4 Strategia odniesienia

Algorytm ten nie różnicuje swego działania w zależności od poszczególnych studentów jak w strategii globalnego optimum, ale podobnie jak on „*eksploatuje*” wybijających się studentów. Nie zostały w nim wprowadzone dodatkowe współczynniki, a obniżanie bądź zwiększanie poziomu trudności, co wiedzie do zmiany poziomu wiedzy studenta - odbywa się mniej racjonalnie. Każda porażka bądź sukces wiąże się z zmianą poziomu trudności jednostki lekcyjnej. Prowadzić to może do zatracenia orientacji, który student naprawdę, jaki poziom wiedzy reprezentuje (w wynikach można zaobserwować oscylacje³⁰ poziomów wiedzy), a w samych studentach wzbudzić poczucie braku racjonalnego kierowania poprzez ścieżkę

³⁰ Przez oscylacje rozumie, się zmiany poziomu wiedzy, z reguły nie większe niż +/-1 poziom wiedzy studenta obserwowane z lekcji na lekcję

nauki. Algorytm ten należy traktować jako poglądowy, mający raczej na celu zademonstrować celowość wprowadzenia dodatkowych współczynników (typu sukces porażka) jak i pokazać, że jedna powtórka nie zawsze pozwala na *promocje* do następnej lekcji. Strategia ta powstała jako prototyp testowy i nie będzie uwzględniana w wyborze optymalnego algorytmu doboru materiału.

Do cech charakterystycznych strategii odniesienia należy zaliczyć:

- § Wszyscy studenci traktowani jednakowo,
- § Brak zróżnicowania w funkcjonowaniu w zależności od poziomu wiedzy studenta,
- § Maksymalne wykorzystywanie potencjału umysłowego studentów „zdolnych” przy równoczesnym dążeniu do spełnienia kryterium optymalności dla fazy adaptacyjnej,
- § Po każdym sukcesie / porażce zwiększany / zmniejszany jest poziom wiedzy studenta,
- § Brak możliwości zwiększenia poziomu wiedzy,
- § Możliwość jednokrotnego ponawiania niezaliczonej lekcji,
- § Brak efektu pamięciowego przy ponownym podchodzeniu do niezaliczonej lekcji,
- § Brak współczynników SUKCESU i PORAŻKI,
- § Dążenie do zwiększenia poziomu trudności z lekcji na lekcje (studenci wybijający),
- § Każda porażka bądź sukces wiąże się z zmianą poziomu trudności jednostki lekcyjnej,
- § Brak efektu pamięci przy niezaliczonej lekcji,
- § Jednorazowa powtórka tej samej lekcji w razie porażki.

Cecha	Strategia			
	<i>Globalnego optimum</i>	<i>Zachowawcza</i>	<i>Minimalistyczna</i>	<i>Odniesienia</i>
Zróżnicowane funkcjonowanie, zależne od bieżącego poziomu wiedzy studenta	Tak	Nie	Częściowo	Nie
Maksymalizacja wykorzystania studentów wybijających	Tak	Nie	Tak	Tak
Dążenie do utrzymania stopnia trudności dla studentów słabych	Tak	Nie	Nie	Nie
Ponawianie lekcji przy porażce	Tak, trzykrotne	Tak, trzykrotne	Tak, trzykrotne	Tak, jednokrotne
Efekt pamięciowy	Tak	Nie	Tak	Nie
Korekcja różnic w poziomie wiedzy (rzeczywisty, a wyznaczony przed fazą wstępną)	Tak	Nie	Częściowo, tylko detekcja	Częściowo, tylko detekcja
Wpływ fazy wstępnej i nienależycie wyznaczonych poziomów wiedzy	Nie	Tak, duży	Częściowy, mały	Częściowy, mały
Zorientowanie na: 1. Minimalną liczbę studentów, którzy odpadną z procesu nauczania 2. Przeciętnego studenta w grupie 3. Detekcję wybijających się 4. Weryfikację poziomów wiedzy 5. Maksymalizację wyników (najlepsze spełnienie kryteriów fazy adaptacyjnej)	3, 1, 4	1, 2	1, 2	2, 4, 5

Tab. 4.3 Zestawienie cech charakterystycznych algorytmów dla fazy adaptacyjnej

W tabeli (tab. 4.3) zebrano cechy szczególne strategii fazy adaptacyjnej. Najbardziej zaawansowaną w działaniu strategią jest strategia globalnego optimum. Jako jedyna dąży do utrzymania stopnia trudności lekcji dla studentów słabych, różnicuje swoje zachowanie względem studentów o różnych poziomach wiedzy. Do najważniejszych wyróżników tej strategii, spośród pozostałych algorytmów, jest brak wpływu fazy wstępnej na końcowe rezultaty nauczania (średnia ocena, suma punktów kredytowych) oraz zorientowanie na „wyławianie” studentów wybijających się. Strategie zachowawcza i minimalistyczna, zorientowane są na studentów o średnim poziomie wiedzy i jak najmniejszy „odsiew” podczas procesu nauczania. Warto zwrócić uwagę, że strategia odniesienia, mimo iż na pozór posiadająca mniej cech szczególnych daje prawie tak dobre rezultaty jak strategia globalnego minimum (rozdział 5.2).

5 Wyniki badań eksperymentalnych

W celu potwierdzenia tezy pracy, mówiącej, że zaproponowane strategie adaptacji nauczania dadzą lepsze, a nie gorsze rezultaty, w postaci poprawionych wyników nauczania, niż w przypadku losowej, a nawet deterministycznej realizacji procesu nauczania, przeprowadzone zostały badania eksperymentalne.

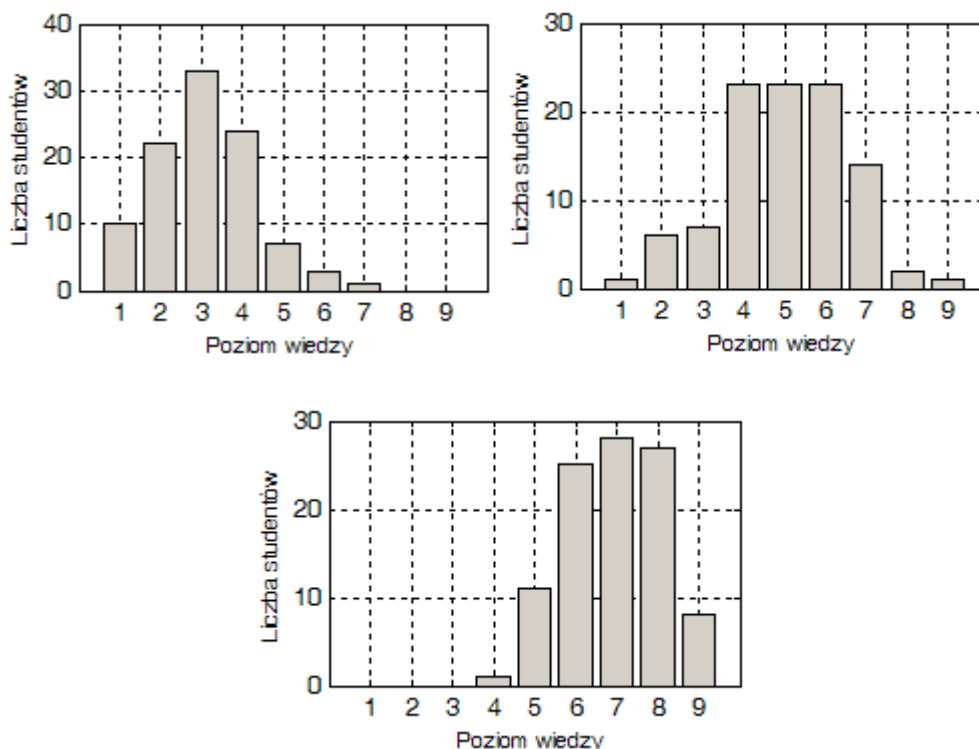
Poniżej przedstawiona została krótka charakterystyka badań eksperymentalnych:

- § wyniki uzyskane zostały poprzez symulację działania strategii adaptacji nauczania w Symulacyjnym Systemie badania możliwości Adaptacji procesu Nauczania (SSAN),
- § wyniki wygenerowane zostały w dwu fazach (wstępnej i adaptacyjnej) opisanych we wcześniejszych rozdziałach,
- § w każdej, z faz po przypisaniu stopnia trudności, student poddawany był procesowi nauki i weryfikacji wiedzy w postaci testu kompetencji,
- § procedura nauczania była powtarzana zdefiniowaną ilość razy³¹ (odpowiada to wykonaniu każdej z faz podaną ilość razy) dla każdej z utworzonych grup studenckich (każdorazowo wyniki były zapisywane),
- § na podstawie, testów otrzymano wyniki (oceny oraz sumy uzyskanych punktów kredytowych) poddane dalszej analizie,
- § po ukończeniu ścieżki nauki, wyniki były uśredniane i zapisywane w tabelach,
- § otrzymane wyniki poddane zostały statystycznej obróbce danych (w SSAN) i przedstawione w postaci przedstawionych (w tym rozdziale) wyników badań.

W celu wyboru najlepszego rozwiązania zostały przeprowadzone eksperymenty z użyciem każdej strategii. Porównanie wyników uzyskanych w eksperymencie (działania każdej z opisanych wcześniej strategii) było podstawą dyskusji i wybrania najlepszego rozwiązania. Eksperymenty wykonano oddzielnie, zarówno dla fazy wstępnej jak i fazy adaptacyjnej. Tak by wyniki faz nie oddziaływały na siebie.

Poziomy wiedzy użytkowników biorących udział w kursie, należą do przedziału $u_{inq} \in \langle 1, 9 \rangle$, każda jednostka lekcyjna posiada cztery stopnie trudności $d_{fact} \in \langle 1, 4 \rangle$.

³¹ 5, 50, 500 i 5000 razy. Liczność prób była zmieniana tak by zaobserwować ewentualne zmiany pod wpływem zwiększenia liczności próby. Zarówno dla 50 i 5000 powtórzeń wyniki nie odbiegały znacząco od siebie.



Rys. 5.1 Testowe grupy studenckie– gr. pierwsza (1) gr. druga (2), gr. trzecia (3)

Rozkłady przedstawione na rysunku (rys. 5.1) są rozkładami modelowymi, wykorzystanymi do badań strategii adaptacyjnych. Na osi x zaznaczone zostały poziomy wiedzy studentów, na osi y zaznaczono liczbę studentów z danym poziomem wiedzy w badanej grupie. Eksperyment był przeprowadzany dla trzech grup studenckich, każda o liczebności 100 studentów o różnych rozkładach poziomów wiedzy. Poszczególne grupy różniły się między sobą liczbą studentów o zadanych poziomach wiedzy. Grupy *pierwsza* (1) i *trzecia* (2) – odpowiadają rzeczywistym³² grupom studenckim ze studiów dziennych (gr. 3) i zaocznych (gr. 1). Grupa *druga* (gr. 2) jest grupą mieszaną.

5.1 Faza wstępna

Każdemu studentowi z grupy, o indywidualnym poziomie wiedzy, przyporządkowano stopień trudności lekcji, korzystając kolejno z każdej strategii. W przypadku strategii proporcjonalnej każdorazowo, wykorzystano, jedno z odwzorowań zamieszczonych w (tab. 5.2), a w przypadku strategii przypadkowej (losowej) – poziom trudności wyznaczany jest poprzez wykorzystanie losowej permutacji wszystkich elementów wektora definiującego poziom trudności. Natomiast strategia prymitywna przypisuje każdemu studentowi, bez względu na jego poziom wiedzy, najłatwiejszy stopień trudności lekcji.

Po przypisaniu stopnia trudności, każdego studenta poddawano procesowi nauczania, następnie weryfikowano nabytą wiedzę w teście kompetencji, którego wyniki były podstawą do oceny i oszacowania przydatności danej strategii w fazie wstępnej.

Jako kryteria oszacowania walidacji procesu nauczania w fazie wstępnej przyjęto:


- § liczbę ocen powyżej średniej (dla każdego studenta z grupy), uzyskaną przez całą grupę, na 100 studentów wyrażoną w procentach,

³² Obserwacja autora

- § średnia ocenę całej grupy dla wszystkich eksperymentów,
- § minimalną średnią ocenę ze wszystkich eksperymentów całej grupy,
- § maksymalną średnią ocenę ze wszystkich eksperymentów całej grupy.

5.1.1 Strategia przypadkowa

W chwili $t = t_0$, następuje losowe przyporządkowanie stopnia trudności danej jednostki lekcyjnej każdemu studentowi poprzez wykorzystanie losowej permutacji wszystkich elementów wektora definiującego poziom trudności. Wykresy i tabele, zamieszczone poniżej, obrazują działanie przypisania przypadkowego.



Rys. 5.2 Histogram stopni trudności po zastosowaniu przypisania przypadkowego

Rysunek (rys. 5.2) obrazuje rozkład poziomów wiedzy po zastosowaniu przypisania przypadkowego dla każdej z badanych grup studenckich. W tabeli (tab. 5.1) zawarto oceny uzyskane w teście kompetencji po 1 jednostce lekcyjnej (przy zastosowaniu przypisania prymitywnego).

Liczba ocen poniżej średniej na 100 studentów								
MIN	MAX	[%] ocen powyżej średniej	MIN	MAX	[%] ocen powyżej średniej	MIN	MAX	[%] ocen powyżej średniej
26	64	54,409	34	67	49,586	37	73	45,067
Średnia ocena								
MIN	MAX	dla eksperymentu	MIN	MAX	dla eksperymentu	MIN	MAX	dla eksperymentu
0,49038	0,63167	0,56508	0,33856	0,48141	0,41078	0,27426	0,41909	0,34683
Grupa TRZECIA (3)			Grupa DRUGA (2)			Grupa PIERWSZA (1)		

Tab. 5.1 Wyniki liczbowe po zastosowaniu przypisania przypadkowego dla każdej grupy

5.1.2 Strategia proporcjonalna


Przypisanie proporcjonalne to przyporządkowanie stopnia trudności lekcji określanego przez parametr d_{fact} na podstawie odwzorowań $tab_i(d_{fact}) \rightarrow U_{inq}$ znajdujących się w tabeli odwzorowań (tab. 5.2).

Podczas eksperymentu przetestowano trzy przypisania: PIERWSZE [$tab_1(d_{fact})$], DRUGIE [$tab_2(d_{fact})$] i TRZECIE [$tab_3(d_{fact})$], które to odwzorowują poziom wiedzy w stopień trudności jednostki lekcyjnej i znajdują się w poniższej tabeli.

Stopień trudności lekcji	Przypisanie PIERWSZE $tab_1(d_{fact})$	Przypisanie DRUGIE $tab_2(d_{fact})$	Przypisanie TRZECIE $tab_3(d_{fact})$
d_{fact}	U_{inq}	U_{inq}	U_{inq}
1	1	1, 2	1, 2, 3, 4
2	2, 3	3, 4	5, 6, 7
3	4, 5, 6	5, 6	8
4	7, 8, 9	7, 8, 9	9

Tab. 5.2 Tabela odwzorowań poziom wiedzy – trudność lekcji ($d_{fact} \rightarrow u_{inq}$) dla poszczególnych przypisań

Rysunki (rys. 5.3, rys. 5.4, rys. 5.5) obrazują rozkłady poziomów wiedzy po zastosowaniu wariantów przypisania proporcjonalnego dla każdej z badanych grup studenckich. Warto zwrócić uwagę, że przypisanie trzecie przypisuje najwięcej studentów na najniższe, możliwe, stopnie trudności bez względu na rodzaj grupy, natomiast przypisanie pierwsze na najtrudniejsze.

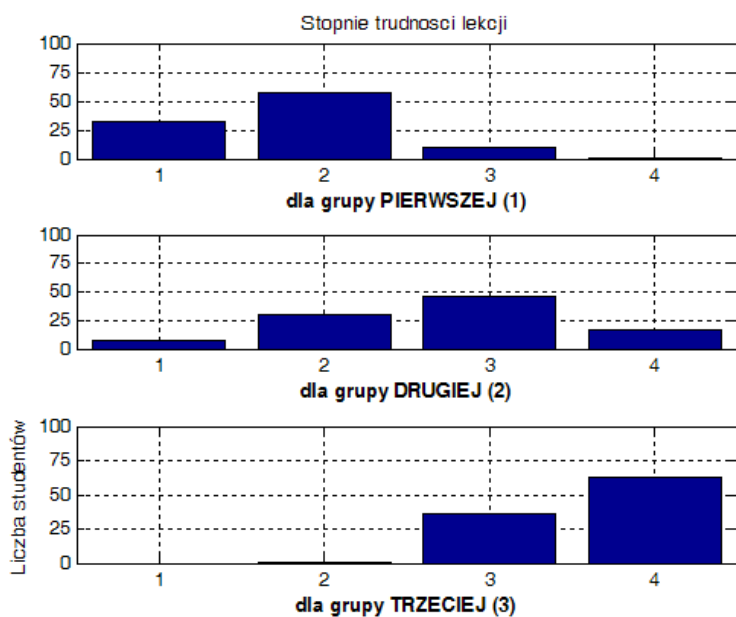


Rys. 5.3 Histogram stopni trudności po zastosowaniu przypisania Pierwszego

Liczba ocen poniżej średniej na 100 studentów								
MIN	MAX	[%] ocen powyżej średniej	MIN	MAX	[%] ocen Powyżej średniej	MIN	MAX	[%] ocen powyżej średniej
27	63	53,99	31	67	48,916	36	71	44,58
Średnia ocena								
MIN	MAX	dla eksperymentu	MIN	MAX	dla eksperymentu	MIN	MAX	dla eksperymentu
0,4678	0,61564	0,53688	0,32464	0,32464	0,39623	0,29496	0,43231	0,36181
Grupa TRZECIA (3)			Grupa DRUGA (2)			Grupa PIERWSZA (1)		

Tab. 5.3 Zestawienie wyników po zastosowaniu przypisania Pierwszego dla każdej grupy


W tabelach (tab. 5.1, tab. 5.2, tab. 5.3) zawarto oceny uzyskane w teście kompetencji po 1 jednostce lekcyjnej (przy zastosowaniu przypisania proporcjonalnego).



Rys. 5.4 Histogram stopni trudności po zastosowaniu przypisania drugiego

Liczba ocen poniżej średniej na 100 studentów								
MIN	MAX	[%] ocen powyżej średniej	MIN	MAX	[%] ocen Powyżej średniej	MIN	MAX	[%] ocen powyżej średniej
25	64	53,815	33	68	49,203	36	72	45,061
Średnia ocena								
MIN	MAX	dla eksperymentu	MIN	MAX	dla eksperymentu	MIN	MAX	dla eksperymentu
0,47401	0,61118	0,53826	0,31533	0,5104	0,41795	0,30899	0,46374	0,38375
Grupa TRZECIA (3)			Grupa DRUGA (2)			Grupa PIERWSZA (1)		

Tab. 5.3 Zestawienie wyników po zastosowaniu przypisania Drugiego dla każdej grupy




Rys. 5.5 Histogram stopni trudności po zastosowaniu przypisania Trzeciego

Liczba ocen poniżej średniej na 100 studentów								
MIN	MAX	[%] ocen powyżej średniej	MIN	MAX	[%] ocen Powyżej średniej	MIN	MAX	[%] ocen powyżej średniej
28	67	55,115	33	71	50,568	38	72	46,139
Średnia ocena								
MIN	MAX	dla eksperymentu	MIN	MAX	dla eksperymentu	MIN	MAX	dla eksperymentu
0,52056	0,65407	0,58833	0,37965	0,53879	0,45953	0,31914	0,49202	0,40363
Grupa TRZECIA (3)			Grupa DRUGA (2)			Grupa PIERWSZA (1)		

Tab. 5.4 Zestawienie wyników po zastosowaniu przypisania Trzeciego dla każdej grupy

5.1.3 Strategia prymitywna

Stworzenie takiego przypisania opierało się podejściu pragmatycznym, jeśli studentowi zostanie podany najłatwiejszy z możliwych poziomów trudności, niezależnie od jego poziomu wiedzy, istnieje szansa, że największy procent studentów z grupy uzyska lepsze rezultaty niż w innych przypisaniach. Podsumowując każdemu użytkownikowi z grupy, o danym poziomie wiedzy przypisuje się najniższy dostępny poziom trudności jednostki lekcyjnej.



Rys. 5.6 Histogram stopni trudności po zastosowaniu przypisania prymitywnego (dla wszystkich grup taki sam)

Liczba ocen poniżej średniej na 100 studentów								
MIN	MAX	[%] ocen powyżej średniej	MIN	MAX	[%] ocen Powyżej średniej	MIN	MAX	[%] powyżej średniej
28	65	55,284	34	69	51,269	36	72	46,473
Średnia ocena								
MIN	MAX	dla eksperymentu	MIN	MAX	dla eksperymentu	MIN	MAX	dla eksperymentu
0,55259	0,67699	0,61343	0,38883	0,55614	0,46572	0,32138	0,50074	0,40297
Grupa TRZECIA (3)			Grupa DRUGA (2)			Grupa PIERWSZA (1)		

Tab. 5.5 Zestawienie wyników po zastosowaniu przypisania prymitywnego

5.1.4 Wnioski i omówienie wyników fazy wstępnej

Przeanalizowane zostały wartości liczbowe uzyskane z eksperymentów z użyciem wszystkich rodzajów przypisań. Podczas wybierania najlepszego rozwiązania brano pod uwagę jedynie te przypisania, które spełniały przyjęte założenia – a mianowicie, by generować jak najlepszą średnią ocen całej grupy przy równoczesnym jak najlepszym wykorzystaniu poziomów wiedzy poszczególnych studentów.

Przypisanie prymitywne nie spełniło drugiego członu założenia, w wyniku, czego nie było brane pod uwagę jako możliwe do zastosowania w przyszłym systemie. Wyniki uzyskane w wyniku jego działania wykorzystano jako pewien punkt odniesienia do wyników pozostałych przypisań.

Przypisanie przypadkowe, mimo, iż brane było pod uwagę spełniało połowicznie postawione założenia. Połowicznie, gdyż jedynie pewnej części studentów z grup testowych były przyporządkowywane poziomom trudności lekcji odpowiadającym ich poziomom wiedzy.

Spośród przypisań proporcjonalnych - przypisanie TRZECIE daje najlepsze rezultaty, zarówno pod względem średniej oceny dla każdej grupy studenckiej (tab. 5.4) jak i procentowej liczby studentów z każdej grupy (tab. 5.5), którzy osiągnęli ocenę większą niż założona średnia.

Rozpatrując kolejno przypisania:

Prymitywne – daje umiarkowanie lepsze rezultaty niż przypisanie *proporcjonalne trzecie* zarówno, jeśli rozważyć procent studentów, którzy uzyskali lepsze od statystycznych średnie noty z lekcji w fazie wstępnej jak i ilość studentów wyrażona w procentach ogółu, którzy otrzymali lepsze noty niż oczekiwane. Mimo tego, jednak przypisanie to nie może być brane pod uwagę w końcowych rozważaniach końcowych, ze względu na niespełnienie pierwotnych założeń.

Przypadkowe – przynosi znikomo gorsze wyniki liczbowe niż *proporcjonalne trzecie*, i znacząco lepsze niż pozostałe przypisania proporcjonalne pod względem procentowej liczby studentów z każdej grupy (patrz Tab. 5.7), którzy osiągnęli ocenę większą niż założona średnia. Niemniej jednak przypisanie to nie wykorzystuje w pełni „potencjału” wiedzy studentów opisanego przez poziomy wiedzy. Trudne do rozstrzygnięcia jest uznanie jednego z przypisań (przypadkowe, proporcjonalne pierwsze czy drugie) za jednoznacznie lepsze pod

względem średniej oceny grupy wykładowej w fazie wstępnej. Gdzie dla Grupy *TRZECIEJ* (3) przypisanie przypadkowe daje niezaprzeczalnie lepsze wyniki niż przypisanie *drugie* i *pierwsze*, sytuacja zmienia się dla Grupy *DRUGIEJ* (2), gdzie to przypisanie ustępuje przypisaniu *drugiemu* i dla Grupy *PIERWSZEJ* (1) gdzie wyraźnie ustępuje obu przypisaniom proporcjonalnym. Zjawisko to można w zrozumiały sposób wytłumaczyć. Dla Grupy *PIERWSZEJ* (1) – najłabszej pod względem średniego poziomu wiedzy, przypisywanie losowych trudności powoduje, że studenci nie potrafią uzyskać odpowiednio dobrej oceny – przyporządkowywane poziomy trudności zdecydowanie nie odpowiadają poziomom wiedzy poszczególnym studentom, co owocuje najniższą średnią. Symboliczne dopasowanie, poprzez wykorzystanie przypisania *pierwszego*, powoduje widoczny wzrost średniej oceny. Podobnie rzecz się ma w przypadku przypisania *drugiego*, które jak wyraźnie widać jest jeszcze lepiej dopasowane do tej grupy.

	Liczba ocen powyżej średniej na 100 studentów								
	MIN ³³	MAX ³⁴	[%] ocen powyżej średniej ³⁵	MIN	MAX	[%] ocen powyżej średniej	MIN	MAX	[%] ocen powyżej średniej
Przypisanie PRYMITYWNE	28	65	55,284	34	69	51,269	36	72	46,473
Przypisanie PRZYPADKOWE	26	64	54,409	34	67	49,586	37	73	45,067
Przypisanie TRZECIE	28	67	55,115	33	71	50,568	38	72	46,139
Przypisanie DRUGIE	25	64	53,815	33	68	49,203	36	72	45,061
Przypisanie PIERWSZE	27	62	53,99	31	67	48,916	36	71	44,58

<p>Grupa TRZECIA (3)</p>	<p>Grupa DRUGA (2)</p>	<p>Grupa PIERWSZA (1)</p>
--------------------------	------------------------	---------------------------

Tab. 5.6 Zestawienie wyników wszystkich przypisań dla poszczególnych grup studenckich (uwzględniono min i max liczbę „porażek” dla każdej fazy wstępnej)

Proporcjonalne trzecie – jest przypisaniem dającym najlepsze rezultaty przy jednoczesnym uwzględnieniu założeń. Dla Grupy *PIERWSZEJ* (1) otrzymujemy zbliżone wyniki jak przy przypisaniu *prymitywnym*, co jest wynikiem zbieżności odwzorowania poziom wiedzy – złożoność obu przypisań. W tej grupie większość stanowią studenci o poziomach wiedzy 1 – 4,

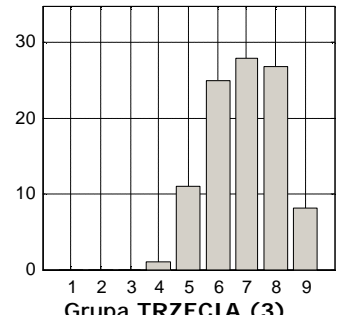
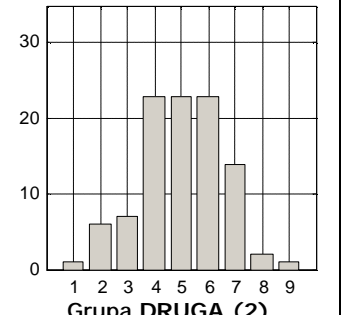
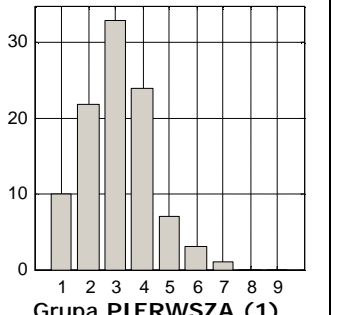
³³ **Minimalna** liczba studentów w grupie, (jaka została uzyskana po 5000 powtórzeń fazy startowej), która nie otrzymała oceny kwalifikującej do przejścia do następnej lekcji.

³⁴ **Maksymalna** liczba studentów w grupie, (jaka została uzyskana po 5000 powtórzeń fazy startowej), która nie otrzymała oceny kwalifikującej do przejścia do następnej lekcji.

³⁵ **Średnia liczba** studentów, która osiągnęła sukces (uzyskała ocenę większą lub równą zakładanej jako promująca do następnej lekcji)

którzy kierowani są na poziom najłatwiejszy trudności przez oba przypisania. Dla grupy *DRUGIEJ* (2) przypisanie *trzecie* daje niemalże dokładnie takie same rezultaty, co przypisanie *prymitywne*. Natomiast dla grupy *TRZECIEJ* (3) sytuacja widocznie się zmienia (dla średniej ocen), a wyniki przemawiają na korzyść przypisania *prymitywnego*, niemniej jednak poza tym przypadkiem, przypisanie *trzecie* daje najlepsze wyniki w stosunku do pozostałych przypisań. Jeśli priorytetem jest uzyskanie jak najwyższej średniej, nie uwzględniając pozostałych kryteriów najtrafniejszym rozwiązaniem będzie wykorzystanie przypisania *prymitywnego*.

	Średnia ocena								
	MIN ³⁶	MAX ³⁷	Całości ³⁸	MIN	MAX	Całości	MIN	MAX	Całości
Przypisanie PRYMITYWNE	0,55259	0,67699	0,61343	0,38883	0,55614	0,46572	0,32138	0,50074	0,40297
Przypisanie PRZYPADKOWE	0,49038	0,63167	0,56508	0,33856	0,48141	0,41078	0,27426	0,41909	0,34683
Przypisanie TRZECIE	0,52056	0,65407	0,58833	0,37965	0,53879	0,45953	0,31914	0,49202	0,40363
Przypisanie DRUGIE	0,47401	0,61118	0,53826	0,31533	0,5104	0,41795	0,30899	0,46374	0,38375
Przypisanie PIERWSZE	0,4678	0,61564	0,53688	0,32464	0,4609	0,39623	0,29496	0,43231	0,36181

 <p>Grupa TRZECIA (3)</p>	 <p>Grupa DRUGA (2)</p>	 <p>Grupa PIERWSZA (1)</p>
--	---	---

Tab. 5.7 Zestawienie wyników wszystkich przypisań dla poszczególnych grup studenckich (uwzględniono min i max średnią ocenę całej grupy dla każdej fazy wstępnej)

Biorąc jednak pod uwagę kryterium wykorzystania „potencjału” studentów, a w fazie adaptacyjnej dążenia do uzyskania nie tylko najlepszej średniej, ale także przynajmniej połowy maksymalnej liczby punktów kredytowych dla krótkich ścieżek nauczania to przypisanie nie jest rekomendowane.

³⁶ Minimalna zanotowana średnia jednej fazy startowej po 5000 powtórzeń

³⁷ Maksymalna zanotowana średnia jednej fazy startowej po 5000 powtórzeń

³⁸ Średnia ocena grupy przy danym przypisaniu uzyskana po 5000 powtórzeń

Faza działania systemu	Strategia	
	Sortowane wg użyteczności (od najmniejszej do największej)	
Startowa (wstępna) $t = t_0$	przypadkowa	
	prymitywna	
	proporcjonalna ³⁹	Pierwsza
		Druga
Trzecia		
Adaptacyjna $t > t_0$	minimalistyczna	
	zachowawcza	
	odniesienia	
	globalnego optimum	

Tab. 5.8 Zestawienie strategii wg faz działania systemu

W tabeli (tab. 5.8) zestawiono wszystkie strategie adaptacji procesu nauczania w uwzględnieniu ich przydatności w każdej z faz symulacji działania systemu e-edukacji. Podsumowując, rozwiązaniem w pełni spełniającym założenia i dającym jedne z najlepszych wyników liczbowych jest przypisanie *trzeciej* i ono też będzie miało najszerze zastosowanie w tworzonym systemie adaptacji procesu nauczania.

5.2 Faza adaptacyjna

Przez adaptację rozumie się wybór odpowiedniej strategii w zależności od poziomu wiedzy studenta i charakterystyki grupy, i automatyczne dobieranie stopni trudności poszczególnych lekcji w ścieżce. Proces adaptacji bazuje na wnioskowaniu na podstawie wiedzy o studencie / grupie i historii nauczania. Każda, testowa, grupa studencka (Pierwsza, Druga, Trzecia) poddana została procesowi nauczania – każdy student z grupy miał zrealizować (przejsć przez) ścieżkę nauki wydzieloną z Podstawowego Grafu Wiedzy. Ścieżka była złożona z 50 węzłów. Każda jednostka lekcyjna w ścieżce miała dostępne cztery stopnie trudności.


Strategie wykorzystywane w procesie mają dopasowywać „trudność” jednostki lekcyjnej do możliwości pojedynczego studenta, wnioskując na podstawie wiedzy zebranej w poprzednich lekcjach.

Liczba pięćdziesięciu lekcji w ścieżce została dobrana empirycznie, tak by jak najlepiej zobrazować oddziaływanie poszczególnych algorytmów i pokazać proces adaptacji procesu nauczania.

Przy dziesięciu lekcjach różnica pomiędzy algorytmami była pomijalnie mała (niemniej jednak dostrzegalna), przy dwudziestu pięciu była już wyraźna, natomiast przy pięćdziesięciu - najlepsza do przedstawienia różnic pomiędzy algorytmami, i odpowiednia do podjęcia decyzji, który algorytm jest najlepszym wyborem dla poszczególnej z grup.

Założeniem fazy adaptacji, było to by każdy z studentów ukończył każdą lekcję z jak najlepszymi wynikami oraz na jak najwyższym stopniu złożoności (z najwyższą liczbą punktów kredytowych).

³⁹ Składa się z trzech możliwych do wyboru przypisań



Rys. 5.7 Rozkład poziomów wiedzy studentów idealnych przed i po procesie nauki przy zastosowaniu idealnej strategii adaptacji procesu nauczania.

Na wykresie (rys. 5.7) przedstawione są wyniki działania idealnego algorytmu adaptacyjnego, przy spełnieniu założeń, że studenci przyswajają wiedzę perfekcyjnie tzn. wraz z czasem w toku nauki ich poziomy wiedzy zmieniają się (rosną).

5.2.1 Zasady oszacowania walidacji procesu nauczania

Jako kryteria oszacowania walidacji adaptacji procesu nauczania w fazie adaptacyjnej przyjęto:

- § zmianę wykresu obrazującego poziomy wiedzy badanej grupy studenckiej (porównanie przed i po skończonym procesie nauczania),
- § zmianę poziomu wiedzy poszczególnych studentów,
- § sumy (końcowe) punktów kredytowych poszczególnych studentów grupy,
- § średnie oceny grupy i studentów (z 95% przedziałem ufności),
- § ilość studentów którzy odpadli z grupy w procesie nauczania,
- § rozrzut punktów na wykresie liczba suma punktów kredytowych / średnia ocena,
- § liczbę studentów, którzy zakończyli naukę z więcej niż połową max liczby punktów kredytowych,
- § trend średniej oceny (przyjętej jako szereg czasowy) grupy studenckiej.

W dalszej części punktu 5, przedstawione zostaną wyniki działania strategii adaptacji procesu nauczania uzyskane podczas eksperymentów. Ze względu na rozpatrywanie trzech grup studenckich wykresy i wyniki pogrupowane są razem wg wpływu każdego z algorytmów na poszczególne grupy.

5.2.2 Strategie adaptacji grupy Pierwszej

Grupa pierwsza składa się z studentów o niedużym poziomie wiedzy. Kolorem niebieskim zaznaczono rozkład bazowy (przed rozpoczęciem procesu nauki) tychże studentów.


Badana grupa	Typ strategii			
	zachowawcza	globalnego optimum	minimalistyczna	odniesienia
Grupa PIERWSZA (1)				
Wynik [%]	19%	41%	17%	37%

Tab. 5.9 Procent studentów, którzy zakończyli naukę z więcej niż połową max liczby punktów kredytowych wg algorytmów

Kolorem czerwonym natomiast oznaczono rozkład poziomów wiedzy grupy po skończonej nauce (50 lekcji).

Jak widać z poniższych wykresów najlepsze zastosowanie dla grupy pierwszej znajduje strategia globalnego optimum, która pozwala najliczniejszej grupie studentów na podniesienie swojego poziomu wiedzy, zauważalnie dobre rezultaty daje w tym przypadku również strategia odniesienia, która to umożliwiła uzyskanie najwyższych poziomów wiedzy nieosiągalnych przy zastosowaniu pozostałych algorytmów adaptacji procesu nauczania.

Kolorem **czerwonym** zaznaczono rozkład poziomów wiedzy przed procesem nauki
Kolorem **niebieskim** zaznaczono rozkład poziomów wiedzy po procesie nauki

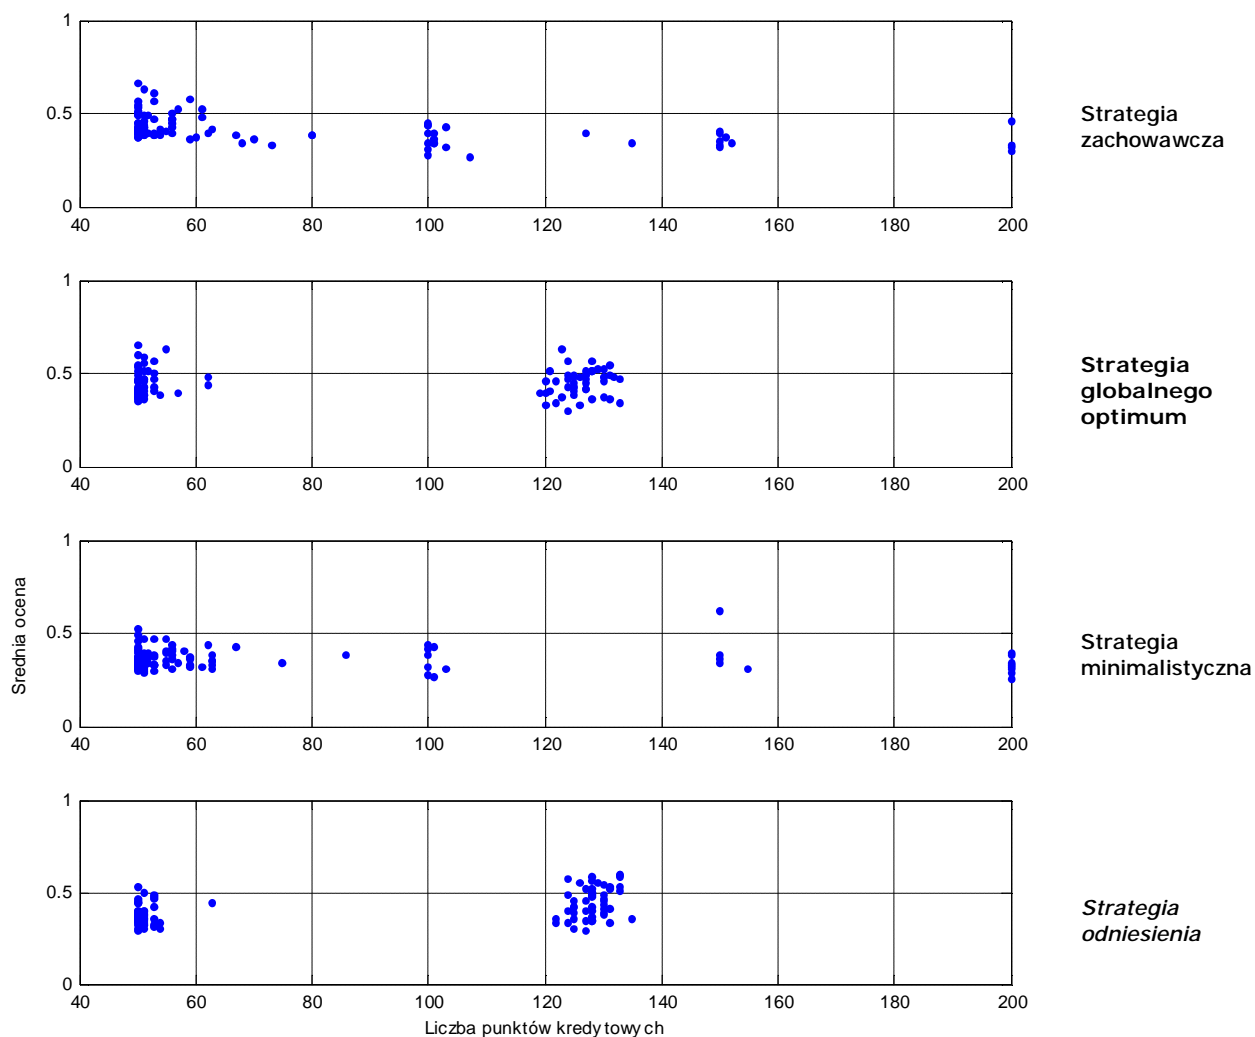


Rys. 5.8 Zestawienie poziomów wiedzy studentów po 50 lekcjach dla Grupy Pierwszej (1)

Również pod względem liczby studentów, którzy zdobyli minimalną zakładaną liczbę punktów kredytowych strategia globalnego optimum okazała się najlepsza, jako tylko nieco gorszą okazała się strategia odniesienia.

Wykres średnia ocena - liczba zdobytych punktów kredytowych najlepiej obrazuje skuteczność strategii globalnego optimum – wyraźnie widoczne jest największe zagęszczenie studentów w centralnej części wykresu (studenci, którzy przekroczyli próg minimalnej liczby punktów kredytowych) oraz ich wysokie położenie osi Y (co wskazuje na wysokie średnie uzyskiwane przez poszczególnych studentów).

Warto zwrócić uwagę na strategię minimalistyczną, która pozwoliła niewielkiemu procentowi (3,7 %) studentów uzyskać maksymalną do osiągnięcia liczbę punktów kredytowych, ale niestety kosztem wartości średniej oceny.

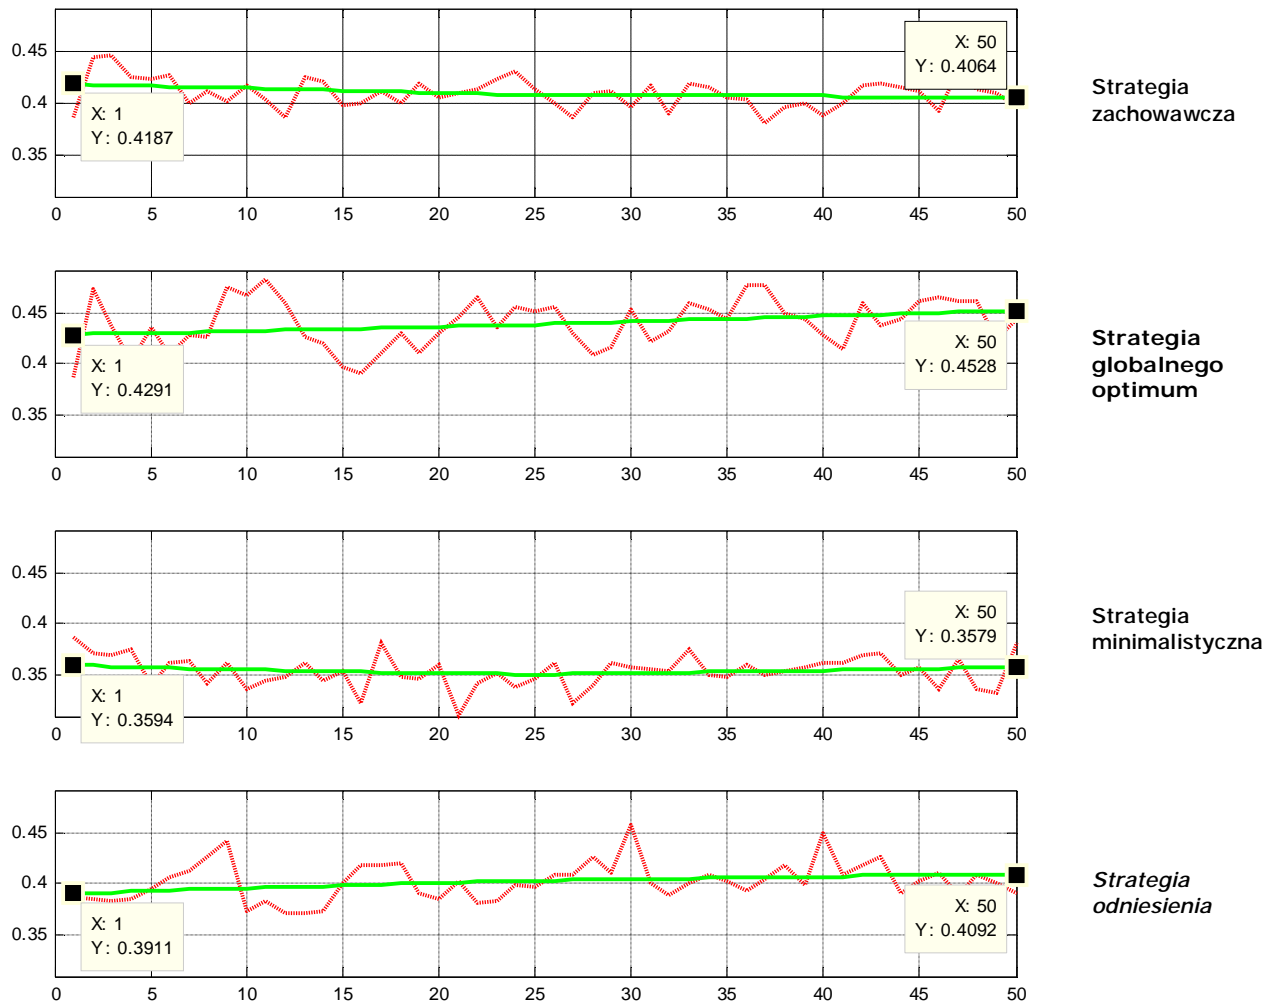


Rys. 5.9 Średnia ocena / liczba punktów kredytowych po 50 lekcjach dla Grupy Pierwszej (1)

Badana grupa	Typ strategii			
	zachowawcza	globalnego optimum	minimalistyczna	odniesienia
Grupa PIERWSZA (1)	zachowawcza	globalnego optimum	minimalistyczna	odniesienia
Średnia ocena na końcu nauki (0-1)	0,4064	<u>0,4528</u>	0,3579	0,4092

Tab. 5.10 Średnia ocena Grupy Pierwszej (1) po 50 lekcjach

Kolorem **czernym** zaznaczono średnią ocenę po każdej lekcji, kolorem **niebieskim** zaznaczono uśredniony wykres średniej, aby zaobserwować trend wykresu. Wykorzystano metodę: Locally weighted scatter plot smooth using least squares quadratic polynomial fitting.



Rys. 5.10 Zmiana średniej ocen Grupy Pierwszej (1) w ciągu 50 lekcji

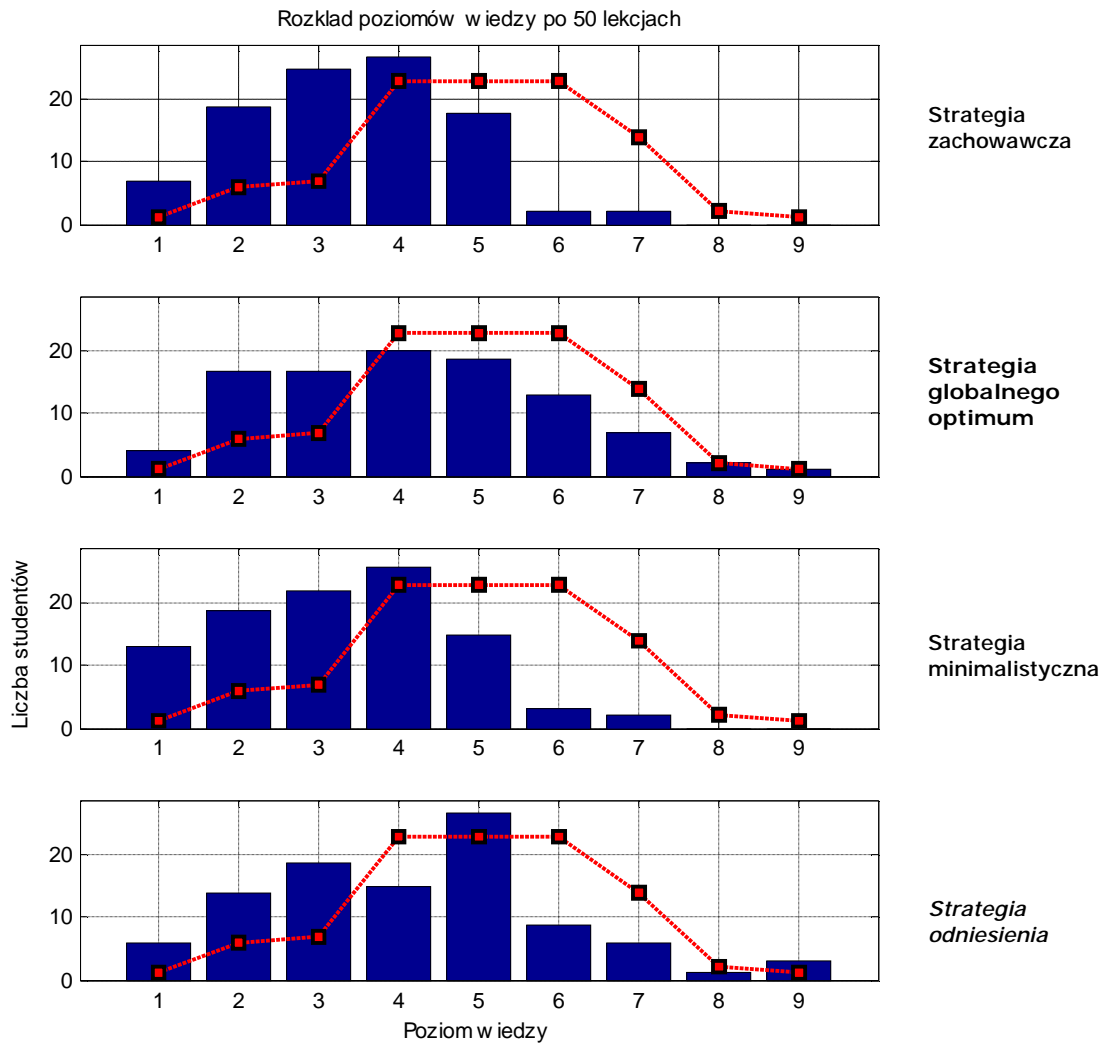
Kolejny wykres przedstawia średnie ocen w kolejnych krokach (jednostkach lekcyjnych) dla całej grupy. Kolejny raz swoją wyższość pokazała strategia globalnego optimum, nie tylko od samego początku średnia ocena grupy była najwyższa spośród pozostałych strategii to w kolejnych krokach rosła. Drugą najlepszą strategią jest strategia odniesienia – podobnie jak strategia globalnego optimum z lekcji na lekcję dają wyższą średnią.

5.2.3 Strategie adaptacji grupy Drugiej

Grupa druga składa się z studentów o średnim poziomie wiedzy i może być porównywana do mieszanych grup studentów. Kolorem niebieskim zaznaczono rozkład bazowy (przed rozpoczęciem procesu nauki) tychże studentów.

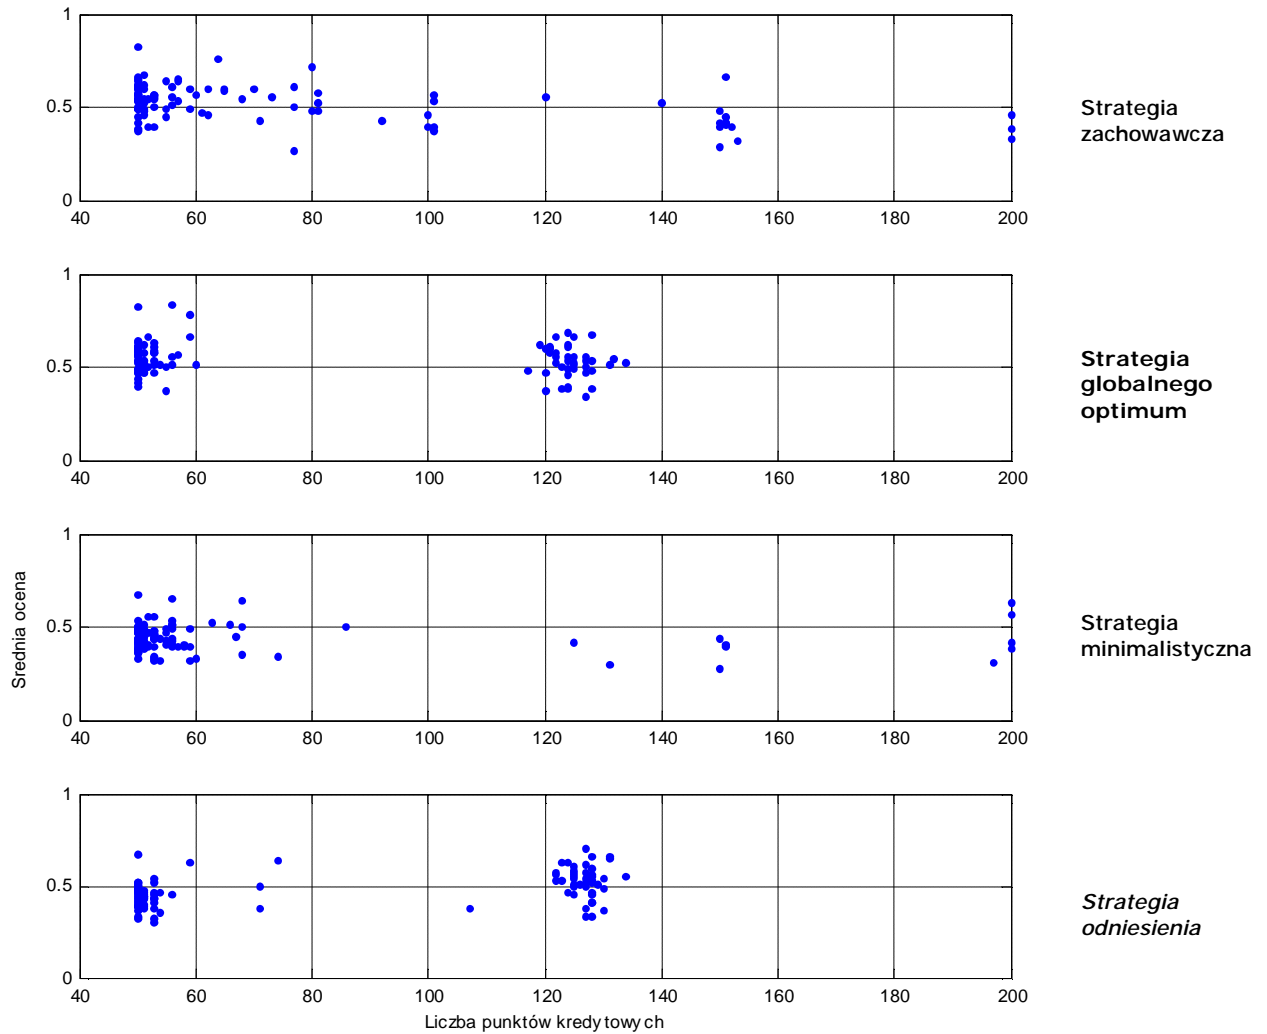
Kolorem czerwonym natomiast oznaczono rozkład poziomów wiedzy grupy po skończonej nauce (50 lekcji).

Kolorem **czzerwonym** zaznaczono rozkład poziomów wiedzy przed procesem nauki
 Kolorem **niebieskim** zaznaczono rozkład poziomów wiedzy po procesie nauki



Rys. 5.11 Zestawienie poziomów wiedzy studentów po 50 lekcjach dla Grupy Drugiej (2)

Dla tej grupy, najbardziej optymalną, okazała się strategia odniesienia, która pozwala najliczniejszej grupie studentów na podniesienie poziomu wiedzy, równie dobrą jest strategia globalnego optimum, która to umożliwia większości studentów na utrzymanie poziomu wiedzy.



Rys. 5.12 Średnia ocena / liczba punktów kredytowych po 50 lekcjach dla Grupy Drugiej (2)

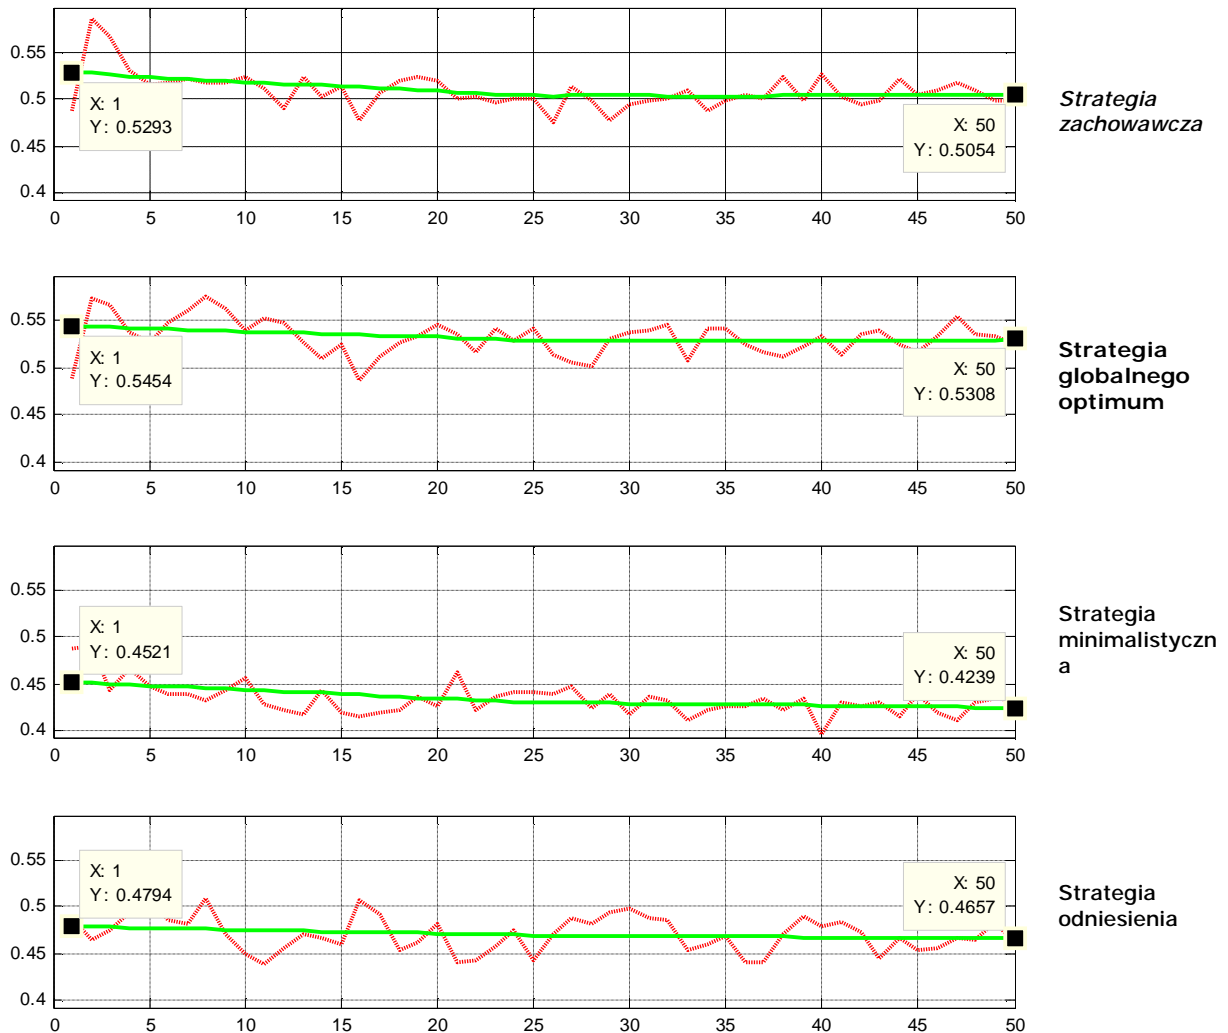
Wykres średnia ocena - liczba zdobytych punktów kredytowych tym razem ukazuje wyższość strategii globalnego optimum – wyraźnie widoczne jest największe zagęszczenie studentów w centralnej części wykresu (studenci, którzy przekroczyli próg minimalnej liczby punktów kredytowych) oraz ich wysokie położenie osi Y (co wskazuje na wysokie średnie uzyskiwane przez poszczególnych studentów) znacznie większe niż w strategii odniesienia.

Badana grupa	Typ strategii			
	zachowawcza	globalnego optimum	minimalistyczna	odniesienia
Grupa DRUGA (2)				
Wynik [%]	22%	42%	12%	44%

Tab. 5.11 Procent studentów, którzy zakończyli naukę z więcej niż połową max liczby punktów kredytowych wg algorytmów

Minimalnie lepszą (3%) pod względem liczby studentów, którzy zdobyli minimalną zakładaną liczbę punktów kredytowych okazała się strategia odniesienia w stosunku do strategii globalnego optimum.

Kolorem **czernym** zaznaczono średnią ocenę po każdej lekcji,
Kolorem **zelenym** zaznaczono wygładzony wykres średniej, aby zaobserwować trend wykresu.



Rys. 5.13 Zmiana średniej ocen Grupy Drugiej (2) w ciągu 50 lekcji

Na wykresach średniej oceny grupy w jednostkach lekcyjnych, kolejny raz swoją wyższość wykazała strategia globalnego optimum, uzyskując najwyższą średnią ocen grupy, niewiele gorszą (~4%) okazała się strategia zachowawcza.

Badana grupa	Algorytm			
	zachowawcza	globalnego optimum	minimalistyczna	odniesienia
Grupa DRUGA (2)				
Średnia ocena na końcu nauki (0-1)	0,5054	<u>0,5308</u>	0,4239	0,4657

Tab. 5.12 Średnia ocena Grupy Drugiej (2) po 50 lekcjach

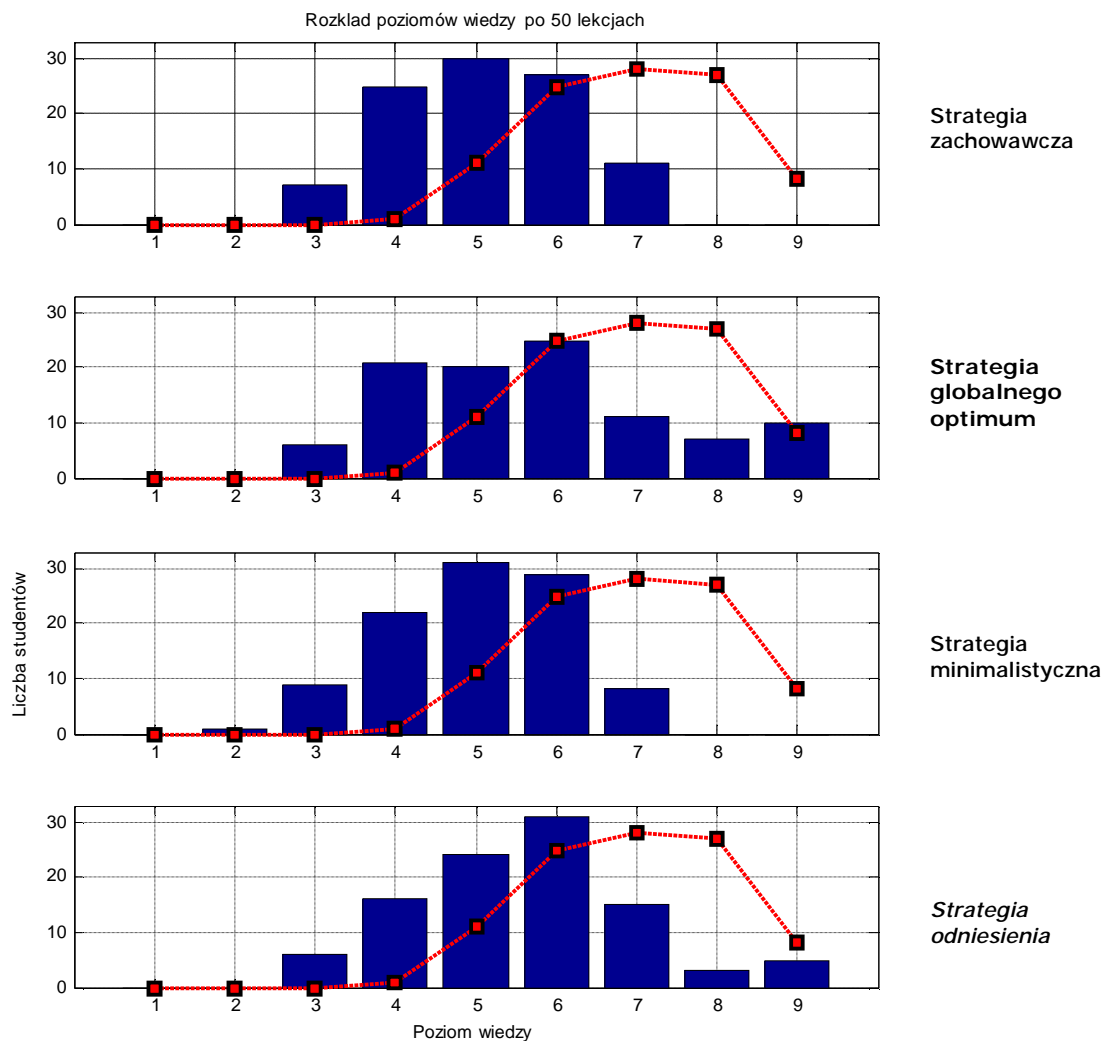
Najwyższą średnią na końcu nauki została uzyskana dzięki zastosowaniu strategii globalnego optimum, mniej dobrą dzięki strategii zachowawczej.

5.2.4 Strategie adaptacji grupy Trzeciej

Grupa trzecia składa się z studentów o najwyższych poziomach wiedzy. W tej grupie nie występują studenci o najniższych poziomach wiedzy.

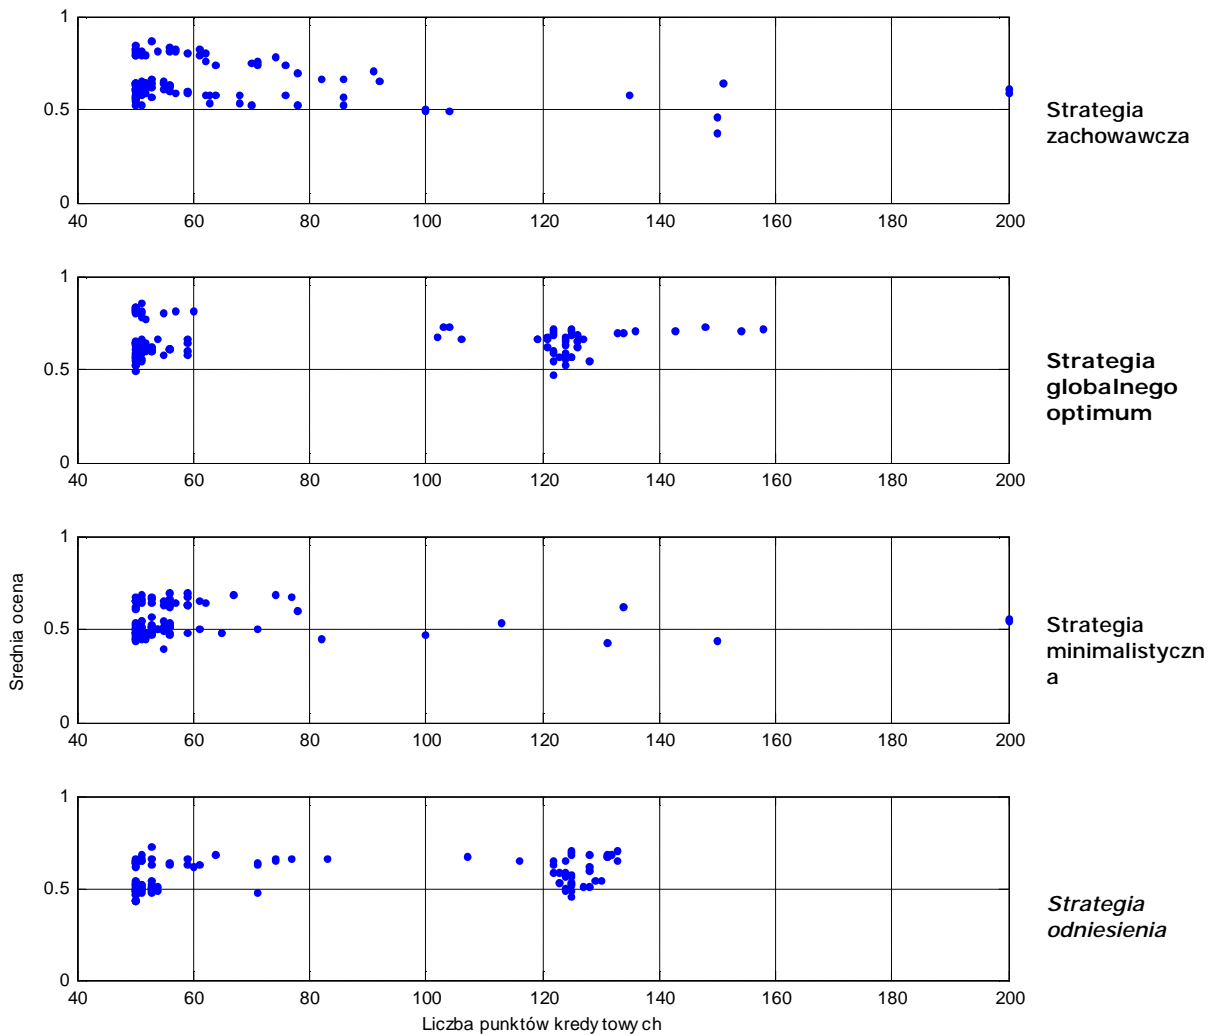
Kolorem niebieskim zaznaczono rozkład bazowy (przed rozpoczęciem procesu nauki) tychże studentów. Kolorem czerwonym natomiast oznaczono rozkład poziomów wiedzy grupy po skończonej nauce (50 lekcji).

Kolorem **czerwonym** zaznaczono rozkład poziomów wiedzy przed procesem nauki
Kolorem **niebieskim** zaznaczono rozkład poziomów wiedzy po proces nauki



Rys. 5.14 Zestawienie poziomów wiedzy studentów po 50 lekcjach dla Grupy Trzeciej (3)

Kolejny raz strategia globalnego optimum okazała się bezkonkurencyjna, większa część studentów zachowała swoje wyjściowe poziomy wiedzy, a część je zwiększyła. Zauważalnie gorsza jest strategia odniesienia. Pozostałe strategie nie są rozwiązaniami efektywnymi.



Rys. 5.15 Średnia ocena / liczba punktów kredytowych po 50 lekcjach dla Grupy Trzeciej (3)

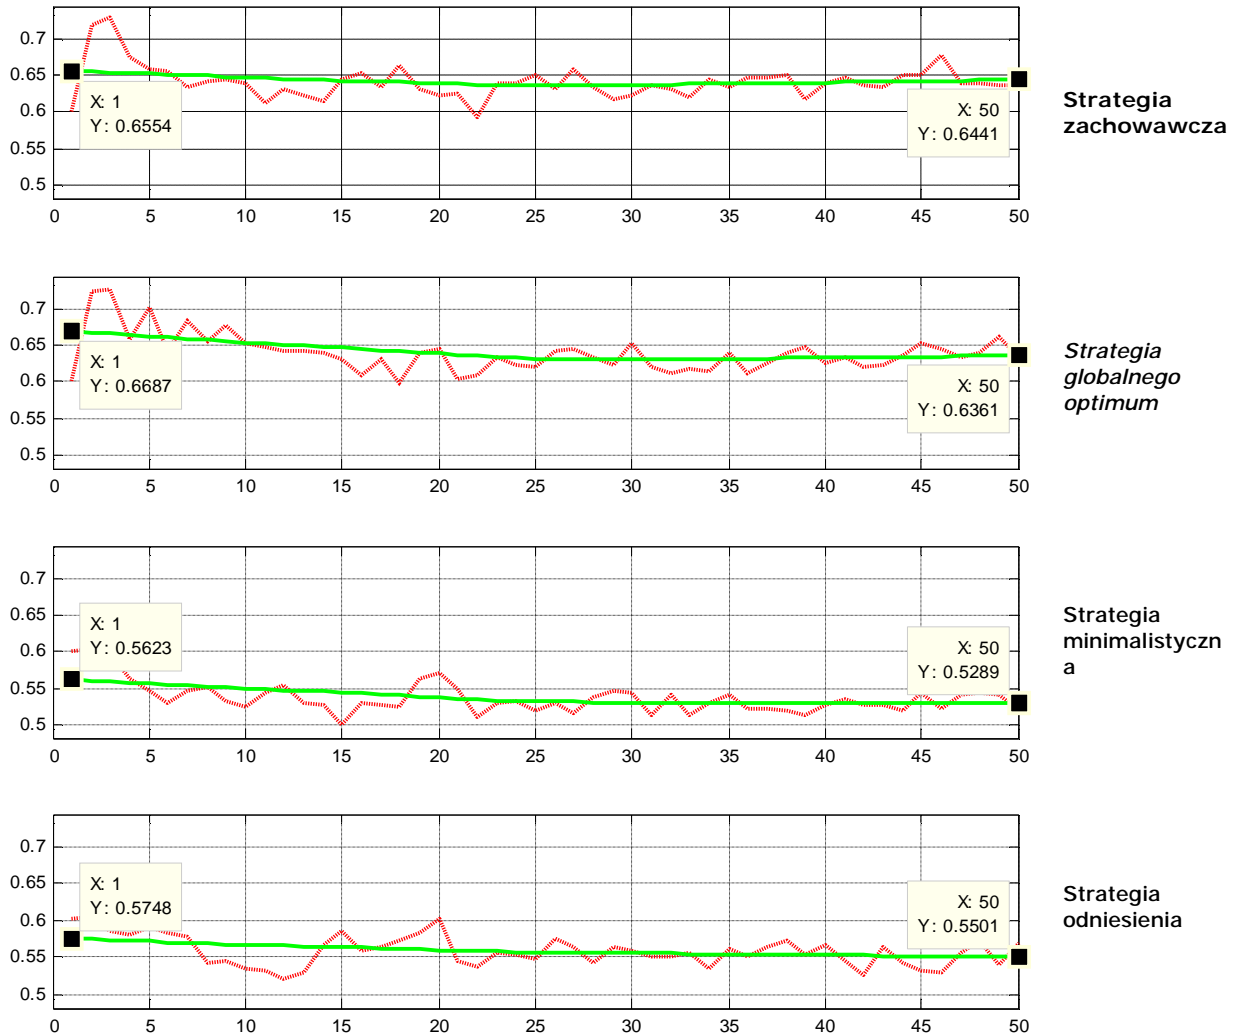
Z wykresu średniej oceny w stosunku do uzyskanej liczby punktów kredytowych łatwo można odczytać, że strategia globalnego optimum daje znaczące lepsze średnie ocen, a w dodatku niewielka część studentów uzyskuje więcej niż 60% maksymalnej liczby punktów kredytowych.

Badana grupa	Algorytm			
	zachowawcza	globalnego optimum	minimalistyczna	odniesienia
Grupa TRZECIA (3)				
Wynik [%]	27%	48%	21%	<u>49%</u>

Tab. 5.13 Procent studentów, którzy zakończyli naukę z więcej niż połową max liczby punktów kredytowych wg algorytmów

Strategia odniesienia jest tylko 1% lepsza od strategii globalnego optimum, jeśli weźmie się pod uwagę procentową liczbę studentów, którzy uzyskali minimalną kwalifikującą liczbę punktów kredytowych.

Kolorem **czernym** zaznaczono średnią ocenę po każdej lekcji,
Kolorem **niebieskim** zaznaczono wygładzony wykres średniej, aby zaobserwować trend wykresu.



Rys. 5.16 Zmiana średniej ocen Grupy Trzeciej (3) w ciągu 50 lekcji

Dla grupy Trzeciej najbardziej odpowiednią do uzyskania najwyższej średniej okazała się strategia zachowawcza, niemniej dobra (0,008% różnicy) okazała się strategia globalnego optimum.

Badana grupa	Algorytm			
	zachowawcza	globalnego optimum	minimalistyczna	odniesienia
Grupa TRZECIA (2)				
Średnia ocena na końcu nauki (0-1)	<u>0,6441</u>	0,6361	0,5289	0,5501

Tab. 5.14 Średnia ocena Grupy Trzeciej (3) po 50 lekcjach

5.2.5 Wyznaczenie linii trendu

W celu oszacowania przydatności poszczególnych strategii w procesie nauczania przeprowadzono analizę szeregów czasowych. Szeregiem czasowym nazywamy ciąg wartości zmiennej uporządkowanej (w tym przypadku oceny grupy) zgodnie z następstwem momentu lub wartości czasu, których tego dotyczą.

Wartości pomiarów ocen grupy nie pozwalają jednoznacznie odpowiedzieć na pytanie jak będzie kształtować się średnia ocena grupy (czy będzie rosła, maleć czy utrzymywać się na stałym poziomie). Średnią zależność wartości pomiarowych w od lekcji (czasu) można otrzymać wykreślając krzywą przez punkty występujące na wykresie. Jednak kształt tak otrzymanych krzywych, nie daje jednoznacznej odpowiedzi na pytanie o przydatności danej strategii.

Chcąc uzyskać możliwie gładką funkcję zmiennej lekcja (czas), można każdej wartości y_i przypisać wyrażenie


$$u_i = \frac{1}{2k+1} \sum_{j=i-k}^{i+k} y_j \quad (5.1)$$

gdzie:

y_i – wartość mierzona

Korzystając z (5.1) możemy wyznaczyć krzywą trendu interesującej nas zmiennej. Rezultaty badania krzywej trendu zamieszczono w (tab. 5.15).

Na poniższych wykresach przedstawiono linie trendu średniej oceny grupy pierwszej (1) przy zastosowaniu strategii adaptacji procesu nauczania oraz przedziały ufności (5%-95%).



Rys. 5.17 Linie trendu z zaznaczonymi przedziałami ufności (5%-95%)

Grupa	Opis linii trendu dla poszczególnych strategii			
	Globalnego optimum	Zachowawcza	Odniesienia	Minimalistyczna
Pierwsza (1)	Wyraźnie rosnąca	Nieznacznie malejąca	Ustabilizowana	Nieznacznie rosnąca
Druga (2)	Rosnąca	Nieznacznie malejąca	Ustabilizowana	Malejąca
Trzecia (3)	Wyraźnie rosnąca	Ustabilizowana	Rosnąca	Nieznacznie malejąca

Tab. 5.15 Zestawienie krzywych trendu średniej oceny grupy wg grup

Analiza trendu (tab. 5.15) z wykorzystaniem dostępnych strategii wskazuje, że strategią dającą najlepsze rezultaty dla wszystkich grup jest strategia globalnego optimum. Jak widać z tabeli, alternatywą strategii globalnego optimum jest strategia odniesienia. Średnia oceny grupy w przypadku tej strategii stabilizuje się po ~10 lekcjach i jest utrzymywana do końca procesu nauki (grupy pierwsza (1) i druga (2)). Dla grupy trzeciej (3) krzywa trendu jest rosnąca w całym okresie nauczania. Strategia minimalistyczna korzystna jest jedynie w przypadku grupy pierwszej (1). Rezultaty uzyskane z wyniku analizy trendu pokrywają się z danymi z badań doświadczalnym (symulator) – zobacz tab.5.18.

5.2.6 Wnioski i omówienie wyników fazy adaptacyjnej

Przeanalizowane zostały wykresy oraz wyniki liczbowe uzyskane z eksperymentów z użyciem wszystkich strategii. Podczas wybierania najlepszego rozwiązania dla fazy adaptacyjnej wzięto pod uwagę te przypisania, które najlepiej spełniają przyjęte kryteria – dla przypomnienia generowanie jak najlepszej średniej ocen całej grupy (średniej oceny studenta nie mniejszej niż średnia ocena dla danego poziomu jaki on reprezentuje) przy równoczesnym dążeniu do uzyskania liczby punktów kredytowych nie mniejszej niż połowa ich maksymalnej sumy do uzyskania.

Rozpatrując kolejno strategie:

Strategia zachowawcza – której jedną z cech charakterystycznych jest brak dążenia do maksymalnego wykorzystania potencjału studentów ponadprzeciętnych, dla żadnej grupy nie dała zadowalających rezultatów pod względem procentowej ilości studentów, którzy uzyskali minimalną (zalecaną) liczbę punktów kredytowych czyli spełnili drugą część kryterium optymalności dla fazy adaptacyjnej (najgorsze rezultaty spośród testowanych strategii). Natomiast uplasowała się jako druga pod względem końcowej średniej ocen grupy na końcu procesu nauki. Wynik ten zawdzięcza m.in. temu gdyż nie eksploatuje studentów wybitnych, którzy to podnoszą średnią lokalną (dla studenta) i globalną (dla całej grupy).


Strategia globalnego optimum – charakteryzująca się rozróżnianiem studentów w grupie, co objawia się zróżnicowanym funkcjonowaniem w zależności od poziomu wiedzy studenta, oraz maksymalnym wykorzystaniem potencjału umysłowego studentów „zdolnych” okazała się najbardziej pożądaną strategią zarówno pod względem średniej ocen grupy (w 2 z 3 grup dała najwyższe średnie, w 3 przypadku była gorsza tylko o 0,08%). jak i pod względem procentowej ilości studentów którzy uzyskali zalecaną lub większą liczbę punktów kredytowych (ma 3 grupy, raz dała najlepsze rezultaty, 2 razy była gorsza o 2% i 1% od strategii odniesienia).

Strategia minimalistyczna – nie wyróżniła się dla żadnej grupy ani pod względem na uzyskaną średnią końcową ocen ani też pod względem procentowej ilości studentów, którzy uzyskali nie mniejszą niż zalecaną liczbę punktów kredytowych. Wynika to między innymi z tego, że strategia ta traktuje wszystkich studentów jednakowo i nie uwzględnia możliwości zmiany poziomu wiedzy.

Strategia odniesienia – dzięki maksymalnemu wykorzystywaniu potencjału umysłowego studentów „zdolnych” przy równoczesnej możliwości jednokrotnego ponawiania niezaliczonej lekcji przez studentów „słabych” (nieradzących sobie z materiałem), pozwala na osiągnięcie najwyższej procentowej liczby studentów, którzy uzyskali nie mniejszą niż zalecaną liczbę punktów kredytowych (2 z 3 grup) oraz dla grupy najsłabszej najlepszą średnią spośród pozostałych strategii.

Podsumowując, jeśli priorytetem jest uzyskanie tylko jak największej liczby studentów, którzy uzyskali zalecaną lub większą liczbę punktów kredytowych, nie uwzględniając średniej ocen najlepszym wyborem będzie wykorzystanie strategii odniesienia dla grup (drugiej i trzeciej), natomiast dla grupy pierwszej zalecane jest użycie strategii globalnego optimum.

Natomiast biorąc pod uwagę jedynie zmaksymalizowanie średniej ocen najbardziej odpowiednia dla grup drugiej i trzeciej będzie strategia odniesienia, a dla grupy pierwszej strategia globalnego optimum. Uwzględniając możliwość wyboru tylko jednej strategii, która jest najbardziej odpowiednią dla wszystkich grup i zarazem zrównoważoną z uwagi na średnią ocen i liczbę uzyskiwanych punktów kredytowych jest strategia globalnego optimum.



Tab. 5.16 Zestawienie wyników procentowej liczby studentów, którzy uzyskali więcej niż połowę punktów kredytowych dla poszczególnych grup studenckich wg strategii

Strategia	Średnia końcowa ocen grupy		
	Zachowawcza	0,4064	0,5054
Globalnego optimum	0,4528	0,5308	0,6361
Minimalistyczna	0,3579	0,4239	0,5289
Odniesienia	0,4092	0,4657	0,5501
Badana grupa			
	Grupa PIERWSZA (1)	Grupa DRUGA (2)	Grupa TRZECIA (3)

Tab. 5.17 Zestawienie wyników średniej końcowej ocen grup wg strategii

Podczas tworzenia produkcyjnego systemu e-nauczania nic nie stoi na przeszkodzie by dla poszczególnych grup studenckich uwzględnić różne strategie, co w końcowym rezultacie podniesie wydatnie wydajność nauczania. W takim przypadku rozsądnym wydaje się połączenie wykorzystania strategii globalnego optimum ze strategią odniesienia.

Kryterium	Zalecana kolejność zastosowania strategii ze względu na kryterium i rodzaj grupy studenckiej					
	1	2	1	2	1	2
Średnia	Globalnego optimum	Odniesienia	Globalnego optimum	Odniesienia	Zachowawcza	Globalnego optimum
Liczba punktów kredyt.	Globalnego optimum	Odniesienia	Odniesienia	Globalnego optimum	Globalnego optimum	Odniesienia
Grupa	Pierwsza (1)		Druga (2)		Trzecia (3)	

Tab. 5.18 Zestawienie zalecanej kolejności zastosowania strategii ze względu na kryterium i grupę

Jak widać z powyższej tabeli strategia globalnego optimum jest najlepszym kandydatem do implementacji w rzeczywistym systemie – zatem rozróżnianie szybkości nabywania wiedzy, wykorzystanie potencjału studentów zdolnych i wybijających, wraz z dywersyfikacją wiedzy poprzez zróżnicowane doboru stopnia trudności jednostki lekcyjnej i dążeniem do utrzymania stopnia trudności dla studentów słabych w kolejnych lekcjach oraz dawanie szansy do ponawianie lekcji przy porażce sprawdza się w praktyce dla wszystkich grup. Dodatkowym atutem tej strategii jest korekcja różnic w poziomie wiedzy (rzeczywisty, a wyznaczony przed fazą wstępną) oraz zorientowanie na minimalną liczbę studentów, którzy odpadną z procesu nauczania.

5.3 Analiza wydajności technicznej systemu e-nauczania

Wraz ze wzrostem liczby grup studenckich oraz ich liczności, rośnie zapotrzebowanie na moc procesora, czas odpowiedzi bazy danych itp. do obsługi każdego żądania. Niezależnie od przyjętej strategii nauczania, już przy stuosobowej grupie, czas potrzebny na przetworzenie wyników i użycie odpowiedniej algorytmu, zaczyna być na tyle duży, że zaczyna być odczuwalny jako spowolnienie reakcji systemu na żądanie od użytkownika kursu. Czas ten rośnie proporcjonalnie do liczby uczestników kursu (rys. 5.18).

Wykorzystanie klasycznej architektury klient serwer przy rosnącej liczbie uczestników procesu nauczania zaczyna być problemem, ze względu na rosnący czas odpowiedzi systemu e-edukacji. Aby zniwelować tę przypadłość warto skorzystać z obserwacji, że nie cały czas procesor komputera studenckiego jest w 100% obciążony. Rodzi się zatem pomysł by wykorzystać moc komputerów uczestników kursu do odciążenia serwera kursu. W takim przypadku należy opracować system dystrybucji i zarządzania obciążeniem.

Skorzystano z w/w faktu, i skonstruowano trzy warianty architektury, realizujące system e-nauczania (przedstawiony w punkcie 2), przy czym jeden, oparty całkowicie na procesach zwanych agentami (opisanymi szczegółowo w rozdziale 3), realizujących postulat równoważenia obciążenia. W systemach tradycyjnych jak i wielo-agentowych jednym z podstawowych zagadnień jest zagadnienie czasu dostarczania odpowiedzi na żądania formułowane do tych systemów. Na ten czas składają się czasy aktywności agentów oraz czasy komunikacji między agentami [3].

W przypadku niniejszej pracy mierzono czas odpowiedzi $T_r^{(sys)}$ systemu na żądanie od grupy użytkowników (studentów). Czas odpowiedzi systemu (5.2) jest sumą czasów reakcji na żądania wszystkich studentów.

$$T_r^{(sys)} = \sum_1^n T_r^{(u)(i)} \quad (5.2)$$

gdzie:

$T_r^{(u)(i)}$ – czas reakcji systemu na żądanie i-tego użytkownika.

Czas odpowiedzi systemu na żądanie użytkownika (5.3) jest sumą:

- § czasu między wysłaniem żądania (od użytkownika), a odbiorem w systemie,
- § czasu przetwarzania (m.in. stosowania strategii adaptacji, obróbki danych i wizualizacji wyników etc.),
- § czasu między odesłaniem przetworzonego żądania przez system obliczeniowy, a dotarciem od użytkownika.

$$T_r^{(u)(i)} = t_{in}^{(i)} + t_{comp}^{(i)} + t_{out}^{(i)} \quad (5.3)$$

gdzie:

$t_{in}^{(i)}$ – czas wysłania żądania (do systemu),

$t_{comp}^{(i)}$ – czas przetwarzania w systemie obliczeniowym,

$t_{out}^{(i)}$ – czas powrotu odpowiedzi (do użytkownika).

Biorąc pod uwagę, że istotny wpływ na czas odpowiedzi e-systemu mają czasy wysłania i powrotu (przetworzonego) żądania, pomiary zostały przeprowadzone w wyizolowanej sieci. Jedynym ruchem jaki był generowany, był ruch wytworzony przez sam system e-nauczania.

Poniżej zostanie przedstawiona analiza wydajności (w postaci czasu odpowiedzi) systemu e-nauczania w zależności od użytej architektury. Warianty architektury podlegające badaniu, zostały opisane poniżej.


- § Wariant podstawowy – klasyczna architektura klient-serwer, brak agentów, obliczenia wykonywane na współdzielonym systemie serwerowym, wszyscy uczestnicy korzystają z jednego, centralnego serwera,
- § Wariant pierwszy (1) - przekazywanie obliczeń „wolnym” systemom klienckim - obliczenia są nadzorowane przez agentów CMA, którzy decydują, do którego systemu będą przekazane obliczenia (na podstawie informacji uzyskanych od agentów profilu UPA każdego systemu) w zależności od obciążenia w danej chwili. W tym wariantcie realizowany jest postulat lokalnego równoważenia obciążenia poprzez mechanizm automatycznego przełączania obciążenia przez agentów. Analizowana jest kolejka „zgłoszeń” poszczególnych zadań obliczeniowych i na jej podstawie podejmowana jest decyzja, do systemu i agenta (najmniej obciążonego) zadanie jest przydzielane.
- § Wariant drugi (2) – architektura rozproszona oparta o trzy serwery kursu i jeden komputer pełniący rolę serwera aplikacji sterujący obciążeniem. Jeśli jeden z serwerów osiągnie maksymalną, ustaloną z góry liczbę połączeń lub obciążenie procesora przekroczy pewien próg, następuje przekierowanie do kolejnego, najmniej obciążonego, systemu.

Jako referencyjny system testowy posłużyły komputery w poniższych konfiguracjach:

- § Serwer klasy Pentium 4, taktowany zegarem 3 GHz z technologią hiperwątkowości (ang. *Hyper Threading*) wyposażony w 1 GB pamięci operacyjnej DDR RAM, który pełnił rolę serwera kursu,
- § 25 stacji roboczych klasy AMD Athlon 1800+ z 512MB pamięci operacyjnej DDR RAM.

W analizie wpływu architektury na wydajność systemu (czasu odpowiedzi systemu na równoległe żądania obsługi przez n-studentów), skupiono się na trzech wariantach systemu e-nauczania.

Systemu w każdym przypadku realizował *strategię globalnego optimum* dla ścieżki nauczania o pięćdziesięciu węzłach. Strategia globalnego optimum została wybrana ze względu na jej złożoność oraz największą przydatność edukacyjną, co było przedstawione w poprzednim rozdziale. Liczba studentów była wartością zmienną. Dla każdego wariantu architektury systemu wykonano dziesięć pomiarów czasów odpowiedzi, dla różnych liczbowo grup studenckich. Uzyskane wyniki uśredniono. Skrypty testowe były przygotowane tak, aby wszystkie uruchamiały się w tym samym czasie, aby wymusić maksymalne obciążenie systemów poszczególnych klienckich i uzyskać porównywalne dane do analizy. Średnia wielkość porcji danych wynosiła 20kB.



Rys. 5.18 Średni czas odpowiedzi e-systemu, a wariant architektury

Dla przypomnienia czas odpowiedzi systemu to czas potrzebny na komunikację między modułami systemu, zebranie i przetworzenie danych do statystyk o grupie i studencie oraz odesłanie danych. Rzeczywisty czas nauki studenta został pominięty ze względu na techniczny aspekt pomiaru wydajności systemu.

Liczba studentów	Średni czas odpowiedzi systemu [ms]		
	Wariant podstawowy	Wariant 1	Wariant 2
10	140,5	170,6	160,6
15	260,3	280	240,9
50(*)	710,3	690	580,4
75(*)	1550,8	880	860,3
100(*)	2550,6	1320	1480,5
250(*)	3420,2	1720,5	2070,2
500(*)	4390,6	2150	3090,1
750(*)	5270	2520,2	3850,9
1000(*)	5800	2730,71	4310

Tab. 5.19 Wydajność systemu e-nauczania dla trzech wariantów architektury

Na rysunku (rys. 5.18) przedstawiono średni czas odpowiedzi symulowanego systemu e-nauczania w zależności od liczby studentów i użytej architektury. Podczas analizy działania systemu należy zwrócić uwagę, na wyniki z (*) z tabel (tab. 5.19 i tab. 5.20). Ze względu na ograniczoną liczbę stacji roboczych (15) – w przypadku, gdy liczba użytkowników w badanej grupie była większa niż fizyczna liczba komputerów, poszczególnych studentów przypisywano proporcjonalnie poszczególnym komputerom. Należy mieć świadomość, że to działanie ma istotny wpływ na otrzymane wyniki.

Dla liczby do 15 równoczesnych sesji (równolegle korzystających z systemu użytkowników) najszybciej odpowiadał system zrealizowany w architekturze klient-serwer. Natomiast architektura trójwarstwowa (wariant 2) już dla 15 studentów okazała się minimalnie wydajniejsza (+5%) od wariantu klient serwer.

Dla 50 i więcej równoległych sesji czas odpowiedzi systemu klient-serwer zaczyna znacząco się pogarszać, w stosunku do architektury trójwarstwowej i agentowej (różnica 25 - 52%).


Kosztowna w implementacji (redundancja sprzętu) architektura trójwarstwowa, najlepiej wypada w przedziale 15-70 równoległych użytkowników. W przedziale 70-200 zarówno system zrealizowany w architekturze agentowej czy trójwarstwowej daje zbliżone czasy odpowiedzi (różnica +/-6%). Natomiast dla 200 i więcej równoległych sesji, architektura agentowa zaczyna pokazywać swą wyższość nad architekturą trójwarstwową.

Łatwo zauważyć (rys. 5.18), że czas odpowiedzi systemu zrealizowanego w architekturze agentowej nie rośnie proporcjonalnie do liczby studentów, jak to ma miejsce w przypadku wariantów pierwszego i drugiego. Warto podkreślić jest również fakt, że większa liczba stacji roboczych (studentów) w rzeczywistym systemie agentowym, powinna znacząco redukować obciążanie obliczeniowe, a na czas odpowiedzi główny wpływ zaczynają mieć czasy komunikacji międzyagentowej oraz przesyłania/odbioru żądań do/z systemu obliczeniowego.

Liczba studentów	Wydajność systemu w stosunku do wariantu podstawowego [%]	
	Wariant 1	Wariant 2
10	-21,4	-14,5
15	-6,5	+5,3
50(*)	+3,2	+18,1
75(*)	+43,5	+44,6
100(*)	+48,4	+41,9
250(*)	+49,6	+39,5
500(*)	+51,1	+29,7
750(*)	+52,1	+26,8
1000(*)	+52,8	+25,7

Tab. 5.20 Wydajność systemu agentowego w stosunku do wariantu podstawowego

Z ekonomicznego punktu widzenia, implementacja systemu e-nauczania, w architekturze klient-serwer czy też architekturze agentowej, jest bardziej uzasadniona niż architektura rozproszona. Przy wariacie agentowym należy zwrócić uwagę, na czas opracowania takiej architektury.



Rys. 5.19 Procentowa różnica czasu odpowiedzi systemu, w stosunku do wariantu podstawowego architektury

Niski koszt implementacji systemu e-nauczania zrealizowanego w architekturze agentowej, nie jest jej jedynym atutem, jej zastosowanie przynosi wymierny zysk wydajnościowy w stosunku do wariantu klient serwer od ok. 20 równoległych sesji, i od ok. 200 w stosunku do architektury trójwarstwowej.

Odpowiedź systemu zrealizowanego w architekturze rozproszonej jak i klient serwer rośnie prawie proporcjonalnie do liczby studentów, w odróżnieniu od systemu agentowego, gdzie dla niewielkiej liczby (~15-20) studentów szybki czas przetwarzania jest niwelowany narzutami komunikacji międzyagentowej.

Liczność grupy	Zalecany wariant architektury systemu e-nauczania	
	Główny	Alternatywny
~10	Klient-serwer	rozproszona
15 - 70	rozproszona	-
>70-200	agentowa	rozproszona
>200	agentowa	-

Tab. 5.21 Zalecany wariant architektury systemu e-nauczania w zależności od liczby grupy

W tabeli (tab. 5.21) zamieszczono zalecane warianty implementacji architektury systemu e-nauczania w zależności od liczby uczestników.

Podsumowując należy zwrócić uwagę, że na wydajność systemu agentowego, istotny wpływ ma nie tylko komunikacja z bazą danych, ale także komunikacja między agentami. Jeśli medium transmisyjne ma ograniczoną przepustowość, bądź występują w nim zakłócenia, może to mieć znaczący wpływ na pogorszenie jego wydajności.

6 Wnioski

Gwałtowny i niestety chaotyczny rozwój e-nauczania stworzył pilną potrzebę dostosowania procesu nauczania do potrzeb studentów oraz możliwości komputerów. Wraz ze wzrostem zainteresowania zdalnym nauczaniem powstają coraz to nowe systemy, niestety bez nastawienia na indywidualne tempo nabywania wiedzy, a co gorsza, czasem nawet bez przyjętego modelu studenta. Gwałtownie również rosną też wymagania sprzętowe, niemalże liniowo w stosunku liczby nowych grup studenckich.

Niniejsza praca jest próbą odpowiedzi na brak koncepcji systemu łączącego indywidualne podejścia do studenta w procesie nauczania, czym nie mogą się poszczycić dotychczasowe rozwiązania, oraz skalowalności, nieznaney klasycznym systemom działającym w architekturze dwu lub trójwarstwowej. Praca ta stanowi propozycje systemu edukacji, samoczynnie zarządzającego wiedzą, automatyzującego proces uczenia, opartego na zdefiniowanym modelu studenta (grup studenckich) i wykorzystującego strategię nawigacji do zarządzania procesem adaptacji nauczania.

Przedstawiony w niniejszej rozprawie, model e-systemu może być użyty jako gotowy szablon systemu e-edukacji do nauki wielu dyscyplin wiedzy, szczególnie tych, które nie wymagają wiedzy praktycznej.

W pracy zaproponowano metody ewaluacji przyjętych, charakterystycznych parametrów procesu nauczania, a uzyskane wyniki mogą stanowić podstawę do automatyzacji procesu nauczania, a dokładniej do adaptacji tegoż procesu do umiejętności studentów.

Podsumowując, w pracy przedstawione zostały założenia i koncepcja systemu e-nauczania oraz narzędzia wspomagające proces nauczania. Głównym celem było stworzenie komputerowego systemu wspomagania procesu nauczania opartego o strategię nawigacyjną, to znaczy systemu umożliwiającego zdefiniowanie procesu uczenia, ewaluację parametrów tego procesu, jak również optymalizację zużycia zasobów.

Cel pracy został osiągnięty poprzez utworzenie modelu systemu e-nauczania oraz przetestowanie jego działania w Symulacyjnym Systemie badania Adaptacji Nauczania. Symulowany system e-nauczania, potrafi dobierać, przedstawione w rozprawie, strategię adaptacji procesu nauczania dla poszczególnych studentów jak i grup studenckich, zwiększając jego efektywność edukacyjną.

Przetestowane strategię adaptacji nauczania potwierdziły tezę mówiąca o poprawie efektywności e-systemu przez m.in. zobrazowanie poprawy rozkładów ocen (średniej i odchylenia standardowego wyników nauki) w postaci wyników testów kompetencji dla przebadanych grup studenckich.

Natomiast wykorzystanie architektury wielo-agentowej, pozwoliło zwiększyć wydajność techniczną systemu e-nauczania (druga część tezy pracy), poprzez skrócenie średnich (i sumarycznych) czasów przeznaczonych na analizę danych i wyników, mniejszą liczbę połączeń z centralną bazą wiedzy (redukcję obciążenia łącza danych).

Najważniejszymi nowymi elementami zrealizowanymi w tej pracy są:

1. Opracowanie metody definiowania ścieżek nauczania na podstawie istniejącego podstawowego grafu wiedzy,
2. Zdefiniowanie procesu nauczania jako grafu ze zwielokrotnionymi węzłami, wyposażonymi w elementy decyzyjne wraz z testami kontrolnymi oraz łukami, których przejście jest uwarunkowane wynikami testów kwalifikujących,
3. Wprowadzenie miar oceny (ewaluacji) realizacji procesu nauczania w poszczególnych węzłach
4. Określenie realizacji procesu nauczania i zaproponowanie metody szacowania (ewaluacji) jego parametrów,
5. Zdefiniowanie modelu studenta oraz grupy studenckiej,
6. Zdefiniowanie strategii nauczania rozumianych jako realizację procesu nauczania (wybór stopnia trudności materiału) w oparciu o indywidualne cechy studenta oraz przyjęte cele, zdefiniowane w kryteriach optymalności edukacyjnej,
7. Opracowanie Symulacyjnego Systemu badania możliwości Adaptacji procesu Nauczania (SSAN), w ramach założonego kursu nauczania danej dziedziny wiedzy, do cech osobowych studenta lub „uśrednionych” cech grupy studenckiej.
8. Opracowanie narzędzia umożliwiające ewaluację kryteriów nauczania,
9. Przeprowadzenie badań symulacyjnych wybranych strategii nauczania oraz wpływu cech osobowych studentów na wydajność systemu.

Autor zdaje sobie sprawę z **ograniczeń** i z mankamentów prezentowanej rozprawy. Stworzenie odpowiedniego podstawowego grafu wiedzy w dużej mierze wpływa na efektywność działania systemu, a jego ograniczona budowa wymaga sporej pracy grupy eksperckiej przy jego tworzeniu, podział węzłów na podwężły wiąże się z ryzykiem oceny jakości nauczania o oparciu o łatwiej kojarzony materiał lub też o bardziej abstrakcyjne rozważania. Istnieją wątpliwości, co do trafności oceny wydajności procesu nauczania w oparciu o czas przejścia danej ścieżki (zaliczenia danego kursu) lub też kosztu zaangażowania zasobów systemu. Ograniczona jest adekwatność zaproponowanego modelu symulacyjnego studenta oraz grupy studenckiej. Architektura agentowa wprowadza duży narzut przy komunikacji między-agentowej, co dyskwalifikuje to rozwiązanie w systemach pracujących na łączach nisko-przepustowych.

7 Literatura

1. Abramowicz W., Czerniejski B., Frankowski K., Goban-Klas T., Gogołek W., Goliński M., Hollender H.: Polska w drodze globalnego społeczeństwa informacyjnego, Raport, Warszawa, 2002
2. de Arriaga, F., El Alami, M., Arriaga, A.: Multi-agent architecture for intelligent E-learning. 10th IEEE International Conference on Electronics, Circuits and Systems, 2003. ICECS 2003.
3. Babczyński T., Kruczkiewicz Z., Magott J.: Performance evaluation of multiagent personalized information system, in: Proc. 7th Int. Conf. Artificial Intelligence and Soft Computing – ICAISC, Zakopane 2004, LNCS/LNAI, Springer-Verlag, vol. 307, 810-815
4. Baloian N., Motelet O., Pino J.: Collaborative Authoring, Use and Reuse of Learning Material in a Computer-integrated Classroom, Procs. of the CRIGW 2003, France, 2003.
5. Bao T.-Ch., Fu-Chien K.: The Design of Load-Balancing LMS Based on Decomposition Structure, Department of Computer Science and Information Engineering, 5th IEEE International Conference on Advanced Learning Technologies, 2005;
6. Bacopo A.: Shaping Learning Adaptive Technologies for Teachers: a Proposal for an Adaptive Learning Management System, 4th IEEE International Conference on Advanced Learning Technologies, 2004
7. Bichelmeyer, B., Misanchuk, M., & Malopinsky, L.: Adapting a Masters Course to the Web: Principles, Strategies, and Recommendations. Konferencja AECT, Denver, USA 2000.
8. Bojarski B.: Internetowe Środowisko Egzaminacyjne, Instytut Cybernetyki Technicznej Politechniki Wrocławskiej, Wrocław, 2003
9. Capusano N., Marsella M., Salerno S.: An agent based Intelligent Tutoring System for distance learning. Proc. of the International Workshop on Adaptive and Intelligent Web-Based Education Systems, ITS2000, 2000
10. Burgos, D.; Specht, M.: Adaptive e-Learning Methods and IMS Learning Design: An Integrated Approach. 6th International Conference on Advanced Learning Technologies, 2006.
11. Cetnarowicz K.: Problems of Multiagent Systems Development, Monografia, Akademia Górniczo-Hutnicza, Kraków, 2000
12. Ceyungsung P.: Design and development of a mobile learning management system adaptive to learning style of students, IEEE International Workshop on Wireless and Mobile Technologies in Education (WMTE'05), 2005
13. Chia-I Chiang F.: Intelligent assessment of distance learning, Graduate Institute of Educational Policy and Leadership, Tamkang University, Tajwan 2001
14. Colace, F., De Santo, M., Vento, M.: Evaluating on-line learning platforms: a case study, 36th conference on System Sciences, IEEE, 2003.
15. Cormen T.H., Leiserson Ch. E., Rivest R.L.: Wprowadzenie do algorytmów, WNT, Warszawa, 2003
16. Daniel B.K., Mohan P.: A model for evaluating learning objects, Advanced Learning Technologies, 2004. Proceedings. IEEE, 2004
17. Dąbrowski M.: E-edukacja w szkolnictwie wyższym. Forum Akademickie [http://forumakad.pl/archiwum/2004/10/11-za-e-edukacja_w_szkolnictwie_wyzszym.htm], 2004
18. Dinoseanu M., Salomie I.: Mobile Agent Solutions for Student Assessment in Virtual Learning Environments, IAWTIC2003, Austria

19. Duffy J.C.: Planning for Computer-Based Distance Education: A Review of Administrative Issues, 2nd Ed., 2002
20. eBip - Elektroniczny Biuletyn Informacyjny Politechniki Wrocławskiej, wydanie 120, [<http://www.pwr-old.wroc.pl/ebip/>], Wrocław, 2005
21. EduTools. CMS: Product Comparison System. June 11th, 2006 from [<http://www.edutools.info/compare.jsp?pj=8&i=263,276,299,358,366,386,387>], 2006
22. EduTools. CMS: Product List. June 2nd, 2006 from [http://www.edutools.info/item_list.jsp?pj=8], 2006
23. Evans, Hastings M., N., Peacock B.: Statistical Distributions, John Wiley and Sons, 1999
24. Fleischer A.: Analiza i metody prezentacji uzyskanych wyników, [<http://www.lo2.wroc.pl/stat.htm>]
25. García U. C., Solé R. S., Béjar J., Hall T.: Improving Learning Tools by Means of Co-operative Agents Technology - Dept. Llenguatges i Sistemes Informàtics, Universitat Politècnica de Catalunya, Hiszpania, 2002
26. Grob, H.L.; Bensberg, F.; Dewanto, B.L.: Developing, deploying, using and evaluating an open source learning management systems. Information Technology Interfaces. 26th International Conference, 2004
27. Gütl C, Mödritscher F., García-Barrios V.M.: Adaptation in E-Learning Environments through the Service-Based Framework and its Application for AdeLE, Proc. E-Learn 2004, Washington, USA, 2004.
28. Kay J., Kummerfeld B., Carmichael D., Quigley A.: The Scrutable Personalized Pervasive Computing Environment, Proc. IUI, San Diego CA, USA, 2005
29. Kay J.: Student Control, User Modeling and User-Adapted Interaction, Kluwer Academic Publishers, 2001.
30. Koper R., Tattersall C.: Learning Design: A handbook on modeling and delivering networked education and training. Springer, 2005.
31. Kobsa A.: Generic User Modeling Systems, User Modeling and User-Adapted Interaction, Kluwer Academic Publishers, 2001
32. Kavcic A.: The role of user models in adaptive hypermedia systems, Electrotechnical Conference, 2000. MELECON 2000.
33. Kaye A.: Computer Mediated Communication and Distance Education", in Mindweave: Communication, Computers and Distance Education, 2nd ed. Pergamon Press, 2003, United Kingdom.
34. Kolbusz J., Skoczylas A.: e – uniwersytet – nowoczesne metody zdobywania i testowania wiedzy, Materiały z I Krajowej Konferencji Naukowej „e – Uniwersytet: Metody i Narzędzia”, Rzeszów, 2002
35. Kuratowski K.: Wstęp do teorii mnogości i topologii, 1999
36. Leja K. M.: Efektywność i jakość w działalności szkoły wyższej na przykładzie wybranych uczelni technicznych, rozprawa doktorska Wydział Zarządzania i Ekonomii, Politechnika Gdańska 2000;
37. Limoanco, T., Sison, R.: Learner agents as student modeling: design and analysis. The 3rd IEEE International Conference on Advanced Learning Technologies, 2003. Proceedings.
38. Maia R., Netto M.: Work in Progress - A Distributed Approach to a Learning Management System using Multi-Agent Technology, Escola Politécnica, University of São Paulo, Laboratory of Integrated Systems, 2005
39. Mazur B.: Wielopłaszczyznowa Analiza Procesu Kształcenia, Zakład Narodowy im. Ossolińskich, Wrocław - Warszawa - Kraków-Gdańsk – Łódź, 1993
40. McCalla G.: The search for adaptability, flexibility, and individualization: approaches to curriculum in intelligent tutoring systems. In Jones, M., Winnie, P. (Eds.). Adaptive Learning Environments. Springer-Verlag, NATO ASI Series, 1992

41. McManus T.F.: Delivering instruction on the World Wide Web, 2001 [<http://www.csuhayward.edu/ics/htmls/Inst.html>]
42. Mielczarek R.: Jak wykorzystać potencjał e-Learningu? IX Krajowa Konferencja z cyklu „Czy Społeczeństwo Informacyjne pobudzi inicjatywy lokalne?”, Warszawa, 2003
43. Montgomery, D.C.: Design and Analysis of Experiments, 2nd Ed Wiley, Nowy Jork, 2004
44. Mortaglia T.: An automatic evaluation system for technical education at the University level, IEEE Transactions on Education, 2002
45. Mödritscher F., García-Barrios V.M., Gütl C.: The Past, the Present and the Future of adaptive E-Learning. An Approach within the Scope of the Research Project AdeLE, Proc. ICL 2004, Austria, 2004
46. Nawman I.: Observations on relationships between initial professional education for software engineering and systems engineering - a case study. 14th Conference on Software Engineering Education and Training, 2002;
47. Narsingh D.: Graph theory with applications to engineering and computer science, Prentice Hall, New Jersey, USA
48. Online assignment management - an evolutionary tale, 36th Annual International Conference on System Sciences, IEEE, 2003.
49. Osiński Z.: Możliwości, jakie stwarzają platformy e-Learning w edukacji, Materiały z V Ogólnopolskiego Forum Koordynatorów Technologii Informacyjnej, 2003, Mielec
50. Pena C.I., Marzo J.L., de la Rosa J.L.: Intelligent agents in a teaching and learning environment on the Web. Proc. of ICALT 2002, 2002.
51. Rosenberg, M.J.: E-Learning: strategies for delivering knowledge in digital age. New York, McGraw-Hill, 2001.
52. Russel, S. Norvig, P.: Artificial Intelligence: a modern approach. New York, Prentice Hall, 2004.
53. Schutte J.G.: Virtual Teaching in Higher Education: The New Intellectual Superhighway or Just another Traffic Jam? 2001, [<http://www.csun.edu/sociology/virexp.htm>]
54. Stachurski A., Wierzbicki A.: Podstawy optymalizacji, Oficyna Wydawnicza Politechniki Warszawskiej, 2000
55. Tadeusiewicz R., Kusiak J.: E-learning szansą wzbogacenia oferty edukacyjnej Uczelni, Biuletyn Informacyjny Pracowników AGH nr 138, 2005
56. Tadeusiewicz R., Chrzęszcz A., Gaś P., Kusiak J.: Współpraca między uczniem a nauczycielem w nauczaniu wspomaganym przez Internet, w "Akademia on-line", red. J. Mischke, WSHE Łódź, 2005
57. Tadeusiewicz R., Kusiak J., Zaikine O., Kushtina E., Różewski P., Malachowski B.: Polish experience in the didactical materials creation: the student involved in the learning/teaching process, Proc. Conf. EUNIS 2004, IT Innovation in a Changing World, 10th International Conference of European University Information Systems, Slovenia, 2004
58. Ubell R.: Engineers turn to e-learning, IEEE Spectrum, Vol. 37, 2001
59. Walkowiak T., Woda M.: Komunikacja w systemach e-learningowych. Internet 2005. Red. D. J. Bem i inni. Oficyna Wydaw. PWroc., Wrocław, 2005
60. Wilson R. J.: Introduction to Graph Theory, Longman Group, Londyn, 2001
61. Woda M., Walkowiak T.: Internet - a modern e-learning medium. 2nd International Conference on Soft Computing Applied in Computer and Economic Environments. ICSC 2004. Proceedings. Kunovice, Czech Republic, 2004
62. Woda M.: System zdalnego nauczania w ujęciu agentowym, Konferencja Nowe media w edukacji. Osiągnięcia pracowników Politechniki Wrocławskiej w zakresie nauczania z wykorzystaniem nowych mediów. Oficyna Wydaw. PWroc. 2005 str. 192-200, Wrocław, 2005

63. Woda M., Emilianowicz J.: Learning agents - nowe podejście usprawniające zdalne nauczanie. V Ogólnopolska Konferencja Internet - Wrocław 2003. Materiały konferencyjne. [Wrocław], 4-5 grudnia 2003. Wrocław: Oficyna Wydaw. PWroc. 2003 s. 250-256, Wrocław, 2003
64. Woda M., Michalec P.: Learning Agents - new approach for improvement e-learning solutions. 10th International Conference on Soft Computing. Mendel 2004. Brno University of Technology. Faculty of Mechanical Engineering 2004 s. 174-177, Brno, Czech Republic, 2004.
65. Woda M., Michalec P.: Distance learning system: multi-agent approach. Journal of Digital Information Management 2005 vol. 3 s. 198-201. The 2nd International Refereed Conference on Information Technology. Amman, Jordan, 2005.
66. Woda M.: Wsparcie e-edukacji poprzez wykorzystanie agentów. Uniwersytet Wirtualny: VU '2005. V Konferencja [Dokument elektroniczny]. Warszawa, 2-4 czerwca 2005.
67. Woda M., Walkowiak T.: Komunikacja w systemach e-learningowych. Internet 2005. Red. D. J. Bem [i in.]. Oficyna Wydaw. PWroc. 2005 (Biblioteka Teleinformatyki; s. 407-421, Wrocław, 2005
68. Woda M.: Conception of composing learning content into learning tree to ensure reliability of learning material. Koncepcja tworzenia drzewa wiedzy zwiększająca wiarygodność materiału uczącego. W: Proceedings of International Conference on Dependability of Computer Systems. DepCoS - RELCOMEX 2006. IEEE Computer Society [Press], cop. 2006 s. 374-381, 2006.
69. Wong K.: Density estimation for a univariate x with a Gaussian kernel. School of Economics and Finance. The University of Hong Kong, 2004
70. Wooldridge M., Jennings N.: Software Engineering with Agents: Pitfalls and Pratfalls, IEEE Internet Computing, 1999
71. Xiaofei L., El Saddik A., Georganas N.D.: An implementable architecture of an e-learning system, Electrical and Computer Engineering, 2003. IEEE CCECE 2003.
72. Zaitseva L., Boule C.: Student models in computer-based education. 3rd IEEE International Conference on Advanced Learning Technologies, 2003.
73. Zhou Y., Evens M.W.: A practical student model in an intelligent tutoring system. 11th IEEE International Conference on Tools with Artificial Intelligence, 1999.

8 Dodatki

8.1 Zapis wybranych strategii nauczania w pseudo języku

8.1.1 Strategia zachowawcza

Jest podzbiorem algorytmu „globalnego optimum”. Opis w punkcie 8.1.2

Można wyróżnić następujące przypadki, gdy obecnie analizowany jest użytkownik

A). który uzyskał ocenę *niższą* niż średnia oraz

- ü charakteryzuje się najniższym poziomem wiedzy $u_{inq} = u_{min}$,
- ü znajdował się w poprzednim kroku na *najniższym* z możliwych poziomów trudności $d_{fact(t-1)} = d_{fact min}$ to w następnym kroku,

$$u_{ing} = u_{inq(t-1)}$$

$$d_{fact} = d_{fact(t-1)}$$

B). który uzyskał ocenę *niższą* niż średnia oraz

- ü charakteryzuje się najniższym poziomem wiedzy $u_{inq} = u_{min}$,
- ü **NIE** znajdował się w poprzednim kroku najniższym z możliwych poziomów wiedzy $d_{fact(t-1)} > 1$ to w następnym kroku,

$$u_{ing} = u_{inq(t-1)}$$

$$d_{fact} = d_{fact(t-1)} - 1$$

C). który uzyskał ocenę *niższą* niż średnia oraz

- ü charakteryzuje się poziomem wiedzy różnym od najniższego $u_{inq} > u_{min}$,
- ü znajdował się w poprzednim kroku na najniższym z możliwych poziomów trudności $d_{fact(t-1)} = 1$ to w następnym kroku,

$$u_{ing} = u_{inq(t-1)} - 1$$

$$d_{fact} = d_{fact(max)}$$

D). który uzyskał ocenę *niższą* niż średnia oraz

- ü charakteryzuje się poziomem wiedzy różnym od najniższego $u_{inq} > u_{min}$,
- ü **NIE** znajdował się w poprzednim kroku najniższym z możliwych poziomów wiedzy $d_{fact(t-1)} > 1$ to w następnym kroku,

$$u_{ing} = u_{inq(t-1)}$$

$$d_{fact} = d_{fact (t-1)} - 1$$

8.1.2 Strategia globalnego optimum

Reaguj na wszystkie powyższe przypadki w analogiczny sposób, uwzględniając następujące sytuacje:

E). użytkownik, uzyskał ocenę wyższą niż średnia oraz

ü charakteryzuje się najwyższym poziomem wiedzy $u_{inq} = u_{max}$

ü znajdował się w poprzednim kroku na *najniższym* z możliwych poziomów trudności $d_{fact (t-1)} = d_{fact (min)}$

to w następnym kroku,

$$u_{ing} = u_{ing (t-1)}$$

$$d_{fact} = d_{fact (t-1)}$$

F). użytkownik, uzyskał ocenę wyższą niż średnia oraz

ü charakteryzuje się najwyższym poziomem wiedzy $u_{inq} = u_{max}$

ü **NIE** znajdował się w poprzednim kroku na *najwyższym* z możliwych poziomów trudności $d_{fact (t-1)} < d_{fact (max)}$

to w następnym kroku,

$$u_{ing} = u_{ing (t-1)}$$

$$d_{fact} = d_{fact (t-1)} + 1$$

G). użytkownik, uzyskał ocenę wyższą niż średnia oraz

ü charakteryzuje się poziomem wiedzy mniejszym niż maksymalny $u_{inq} < u_{max}$

ü znajdował się w poprzednim kroku na *najwyższym* z możliwych poziomów trudności $d_{fact (t-1)} = d_{fact (max)}$

to w następnym kroku,

$$u_{ing} = u_{ing (t-1)} + 1$$

$$d_{fact} = d_{fact (min)}$$

H). użytkownik, uzyskał ocenę wyższą niż średnia oraz

ü charakteryzuje się poziomem wiedzy mniejszym niż maksymalny $u_{inq} < u_{max}$

ü **NIE** znajdował się w poprzednim kroku na *najwyższym* z możliwych poziomów trudności $d_{fact (t-1)} < d_{fact (max)}$

to w następnym kroku,

$$u_{ing} = u_{ing (t-1)} + 1$$

$$d_{fact} = d_{fact (t-1)} + 1$$

8.2 Spis rysunków

RYS. 2.1 REPREZENTACJA WIEDZY W POSTACI GRAFU SKIEROWANEGO.....	10
RYS. 2.2 REPREZENTACJA WĘZŁA GRAFU JAKO KWANTU WIEDZY (JEDNOSTKI LEKCYJNEJ)	12
RYS. 2.3 IDEA „ZWIELOKROTNIONEGO” WĘZŁA ZŁOŻONEGO Z LEKCJI O TRZECH STOPNIACH TRUDNOŚCI .	12
RYS. 2.4 FRAGMENT PODSTAWOWEGO GRAFU WIEDZY KURSU	13
RYS. 2.5 MOŻLIWE PRZYPISANIA STOPNIA TRUDNOŚCI W WĘZŁACH W NASTĘPNYM KROKU NAUKI.....	15
RYS. 2.6 ROZKŁADÓW OCEN KOŃCOWYCH Z LABORATORIUM UC – STUDENCI ZAOCZNI (LATA 2001 - 2004)	18
.....	
RYS. 2.7 PRZYKŁAD ROZKŁADÓW OCEN KOŃCOWYCH Z LABORATORIUM UC – STUDENCI DZIENNI (LATA 2001 - 2004)	18
RYS. 2.8 IDEA POWSTAWANIA PODSTAWOWEGO GRAFU WIEDZY PGW	23
RYS. 2.9 ALGORYTM ROZMIESZCZANIA WĘZŁÓW W PŁASZCZYŹNIE Z.....	23
RYS. 2.10 TABLICA ŚCIEŻEK KURSU	23
RYS. 2.11 PRZYKŁAD TWORZENIA WĘZŁA O RÓŻNYCH <i>STOPNIACH TRUDNOŚCI</i>	24
RYS. 2.12 ALGORYTM TWORZENIA PODSTAWOWEGO GRAFU WIEDZY	25
RYS. 3.1 KONCEPCJA DZIAŁANIA SYMULACYJNEGO SYSTEMU BADANIA ADAPTACJI PROCESU NAUCZANIA	26
RYS. 3.2 ARCHITEKTURY: TRÓJWARSTWOWA I DWUWARSTWOWA	27
RYS. 3.3 OGÓLNY SCHEMAT BLOKOWY SSAN.....	30
RYS. 3.4 SCHEMAT BLOKOWY INSTANCJI SYSTEMU E-NAUCZANIA	31
RYS. 3.5 BAZOWY ROZKŁAD PRAWDOPODOBIENSTWA OCEN DLA STUDENTA O POZIOMIE WIEDZY X WRAZ ZE ZMODYFIKOWANYMI ROZKŁADAMI ODPOWIADAJĄCYMI 4 STOPNIOM TRUDNOŚCI LEKCJI.....	34
RYS. 3.6 ROZKŁADU PRAWDOPODOBIENSTWA OCEN, A STOPNIE TRUDNOŚCI JEDNOSTKI LEKCYJNEJ	35
RYS. 3.7 UPROSZCZONY ALGORYTM PRZYPORZĄDKOWYWANIA ROZKŁADÓW OCEN JEDNOSTKI LEKCYJNEJ	35
RYS. 3.8 PRACA GENERATORA DANYCH WEJŚCIOWYCH – HISTOGRAM OCEN UZYSKANY PRZEZ GRUPĘ STUDENCKĄ O LICZNOŚCI 500.	36
RYS. 3.9 MODEL ROZKŁADU PRAWDOPODOBIENSTWA GRUPY O PRZEWADZE STUDENTÓW ZE ŚREDNIM POZIOMEM WIEDZY.....	36
RYS. 3.10 „TRANSFORMACJA” STUDENCKICH POZIOMÓW WIEDZY (ROZKŁAD DWUMIANOWY) NA KRZYWE ROZKŁADU OCEN (ROZKŁAD BETA)	37
RYS. 3.11 ALGORYTM GENEROWANIA PAR (POZIOM WIEDZY, OCENA)	38
RYS. 3.12 MODELOWY E-SYSTEM NAUCZANIA ZREALIZOWANY W OPARCIU O ARCHITEKTURĘ AGENTOWĄ	39
RYS. 3.13 BLOKI FUNKCJONALNE AGENTA STUDENTA.....	39
RYS. 3.14 BLOKI FUNKCJONALNE AGENTA ŚCIEŻKI NAUCZANIA	40
RYS. 3.15 BLOKI FUNKCJONALNE AGENTA ŚCIEŻKI NAUCZANIA	41
RYS. 3.16 DIAGRAM SEKWENCJI UML KOMUNIKACJI MIĘDZY AGENTOWEJ	41
RYS. 3.17 ROZMIESZCZENIE BLOKÓW SYSTEMU E-NAUCZANIA W UJĘCIU AGENTOWYM	42
RYS. 3.18 UPROSZCZONY DIAGRAM DZIAŁANIA SYSTEMU E-NAUCZANIA (Z PODZIAŁEM NA FAZY).....	43
RYS. 3.19 SCHEMAT BLOKOWY DZIAŁANIA SYSTEMU W FAZIE WSTĘPNEJ.....	44
RYS. 3.20 SCHEMAT BLOKOWY DZIAŁANIA SYSTEMU W FAZIE ADAPTACYJNEJ	45
RYS. 4.1 ALGORYTM DZIAŁANIA STRATEGII ADAPTACJI PROCESU NAUCZANIA W WYBRANEJ ŚCIEŻCE NAUKI	48
RYS. 4.2 WYBÓR STOPNIA TRUDNOŚCI JEDNOSTKI LEKCYJNEJ PRZEZ STRATEGIĘ NAWIGACYJNĄ	49
RYS. 4.3 STRATEGIA PROPORCJONALNA W FAZIE WSTĘPNEJ	50
RYS. 4.4 STRATEGIA PRZYPADKOWA W FAZIE WSTĘPNEJ	51
RYS. 4.5 STRATEGIA PRYMITYWNA W FAZIE WSTĘPNEJ	52
RYS. 5.1 TESTOWE GRUPY STUDENCKIE– GR. PIERWSZA (1) GR. DRUGA (2), GR. TRZECIA (3)	59
RYS. 5.2 HISTOGRAM STOPNI TRUDNOŚCI PO ZASTOSOWANIU PRZYPISANIA PRZYPADKOWEGO	60
RYS. 5.3 HISTOGRAM STOPNI TRUDNOŚCI PO ZASTOSOWANIU PRZYPISANIA PIERWSZEGO.....	61
RYS. 5.4 HISTOGRAM STOPNI TRUDNOŚCI PO ZASTOSOWANIU PRZYPISANIA DRUGIEGO	62
RYS. 5.5 HISTOGRAM STOPNI TRUDNOŚCI PO ZASTOSOWANIU PRZYPISANIA TRZECIEGO	63
RYS. 5.6 HISTOGRAM STOPNI TRUDNOŚCI PO ZASTOSOWANIU PRZYPISANIA PRYMITYWNEGO (DLA WSZYSTKICH GRUP TAKI SAM)	64

RYS. 5.7 ROZKŁAD POZIOMÓW WIEDZY STUDENTÓW IDEALNYCH PRZED I PO PROCESIE NAUKI PRZY ZASTOSOWANIU IDEALNEJ STRATEGII ADAPTACJI PROCESU NAUCZANIA.	69
RYS. 5.8 ZESTAWIENIE POZIOMÓW WIEDZY STUDENTÓW PO 50 LEKCJACH DLA GRUPY PIERWSZEJ (1)	70
RYS. 5.9 ŚREDNIA OCENA / LICZBA PUNKTÓW KREDYTOWYCH PO 50 LEKCJACH DLA GRUPY PIERWSZEJ (1)	71
RYS. 5.10 ZMIANA ŚREDNIEJ OCEN GRUPY PIERWSZEJ (1) W CIĄGU 50 LEKCJI	72
RYS. 5.11 ZESTAWIENIE POZIOMÓW WIEDZY STUDENTÓW PO 50 LEKCJACH DLA GRUPY DRUGIEJ (2)	73
RYS. 5.12 ŚREDNIA OCENA / LICZBA PUNKTÓW KREDYTOWYCH PO 50 LEKCJACH DLA GRUPY DRUGIEJ (2)	74
RYS. 5.13 ZMIANA ŚREDNIEJ OCEN GRUPY DRUGIEJ (2) W CIĄGU 50 LEKCJI.....	75
RYS. 5.14 ZESTAWIENIE POZIOMÓW WIEDZY STUDENTÓW PO 50 LEKCJACH DLA GRUPY TRZECIEJ (3).....	76
RYS. 5.15 ŚREDNIA OCENA / LICZBA PUNKTÓW KREDYTOWYCH PO 50 LEKCJACH DLA GRUPY TRZECIEJ (3)	77
RYS. 5.16 ZMIANA ŚREDNIEJ OCEN GRUPY TRZECIEJ (3) W CIĄGU 50 LEKCJI.....	78
RYS. 5.17 LINIE TRENDU Z ZAZNACZONYMI PRZEDZIAŁAMI UFNOŚCI (5%-95%)	79
RYS. 5.18 ŚREDNI CZAS ODPOWIEDZI E-SYSTEMU, A WARIANT ARCHITEKTURY	85
RYS. 5.19 PROCENTOWA RÓŻNICA CZASU ODPOWIEDZI SYSTEMU, W STOSUNKU DO WARIANTU PODSTAWOWEGO ARCHITEKTURY	86

8.3 Spis tabel

TAB. 2.1 ZESTAWIENIE WZORÓW WALIDACJI (BIEŻĄCEJ, LEKCJI I TRENDU) DLA STUDENTA I GRUPY STUDENCKIEJ	20
TAB. 3.1 WYMAGANIA SPRZĘTOWO-PROGRAMOWE SYSTEMU E-NAUCZANIA.....	29
TAB. 3.2 TABELA WSPÓŁCZYNNIKÓW A, B ROZKŁADU BETA DLA UŻYTKOWNIKÓW REPREZENTUJĄCYCH RÓŻNE POZIOMY WIEDZY ORAZ DLA CZTERECH STOPNI TRUDNOŚCI KWANTU WIEDZY	33
TAB. 4.1 TABELA ODWZOROWAŃ POZIOM WIEDZY – TRUDNOŚĆ LEKCJI	50
TAB. 4.2 ZESTAWIENIE CHARAKTERYSTYCZNYCH CECH STRATEGII DLA FAZY WSTĘPNEJ.....	52
TAB. 4.3 ZESTAWIENIE CECH CHARAKTERYSTYCZNYCH ALGORYTMÓW DLA FAZY ADAPTACYJNEJ	56
TAB. 5.1 WYNIKI LICZBOWE PO ZASTOSOWANIU PRZYPISANIA PRZYPADKOWEGO DLA KAŻDEJ GRUPY	60
TAB. 5.2 TABELA ODWZOROWAŃ POZIOM WIEDZY – TRUDNOŚĆ LEKCJI ($D_{FACT} \Rightarrow U_{INQ}$) DLA POSZCZEGÓLNYCH PRZYPISAŃ	61
TAB. 5.3 ZESTAWIENIE WYNIKÓW PO ZASTOSOWANIU PRZYPISANIA DRUGIEGO DLA KAŻDEJ GRUPY	63
TAB. 5.4 ZESTAWIENIE WYNIKÓW PO ZASTOSOWANIU PRZYPISANIA TRZECIEGO DLA KAŻDEJ GRUPY	64
TAB. 5.5 ZESTAWIENIE WYNIKÓW PO ZASTOSOWANIU PRZYPISANIA PRYMITYWNEGO	65
TAB. 5.6 ZESTAWIENIE WYNIKÓW WSZYSTKICH PRZYPISAŃ DLA POSZCZEGÓLNYCH GRUP STUDENCKICH (UWZGLĘDNIONO MIN I MAX LICZBĘ „PORAŻEK” DLA KAŻDEJ FAZY WSTĘPNEJ).....	66
TAB. 5.7 ZESTAWIENIE WYNIKÓW WSZYSTKICH PRZYPISAŃ DLA POSZCZEGÓLNYCH GRUP STUDENCKICH (UWZGLĘDNIONO MIN I MAX ŚREDNIĄ OCENĘ CAŁEJ GRUPY DLA KAŻDEJ FAZY WSTĘPNEJ)	67
TAB. 5.8 ZESTAWIENIE STRATEGII WG FAZ DZIAŁANIA SYSTEMU	68
TAB. 5.9 PROCENT STUDENTÓW, KTÓRZY ZAKOŃCZYLI NAUKĘ Z WIĘCEJ NIŻ POŁOWĄ MAX LICZBY PUNKTÓW KREDYTOWYCH WG ALGORYTMÓW	69
TAB. 5.10 ŚREDNIA OCENA GRUPY PIERWSZEJ (1) PO 50 LEKCJACH.....	71
TAB. 5.11 PROCENT STUDENTÓW, KTÓRZY ZAKOŃCZYLI NAUKĘ Z WIĘCEJ NIŻ POŁOWĄ MAX LICZBY PUNKTÓW KREDYTOWYCH WG ALGORYTMÓW	74
TAB. 5.12 ŚREDNIA OCENA GRUPY DRUGIEJ (2) PO 50 LEKCJACH.....	75
TAB. 5.13 PROCENT STUDENTÓW, KTÓRZY ZAKOŃCZYLI NAUKĘ Z WIĘCEJ NIŻ POŁOWĄ MAX LICZBY PUNKTÓW KREDYTOWYCH WG ALGORYTMÓW	77
TAB. 5.14 ŚREDNIA OCENA GRUPY TRZECIEJ (3) PO 50 LEKCJACH	78
TAB. 5.15 ZESTAWIENIE KRZYWYCH TRENDU ŚREDNIEJ OCENY GRUPY WG GRUP	80
TAB. 5.16 ZESTAWIENIE WYNIKÓW PROCENTOWEJ LICZBY STUDENTÓW, KTÓRZY UZYSKALI WIĘCEJ NIŻ POŁOWĘ PUNKTÓW KREDYTOWYCH DLA POSZCZEGÓLNYCH GRUP STUDENCKICH WG STRATEGII	81
TAB. 5.17 ZESTAWIENIE WYNIKÓW ŚREDNIEJ KOŃCOWEJ OCEN GRUP WG STRATEGII.....	82

TAB. 5.18 ZESTAWIENIE ZALECANEJ KOLEJNOŚCI ZASTOSOWANIA STRATEGII ZE WZGLĘDU NA KRYTERIUM I GRUPĘ	82
TAB. 5.19 WYDAJNOŚĆ SYSTEMU E-NAUCZANIA DLA TRZECH WARIANTÓW ARCHITEKTURY	85
TAB. 5.20 WYDAJNOŚĆ SYSTEMU AGENTOWEGO W STOSUNKU DO WARIANTU PODSTAWOWEGO	86
TAB. 5.21 ZALECANY WARIANT ARCHITEKTURY SYSTEMU E-NAUCZANIA W ZALEŻNOŚCI OD LICZBY GRUPY	87

Mgr inż. Marek Woda

Instytut Informatyki, Automatyki i Robotyki
Politechniki Wrocławskiej
ul. Janiszewskiego 11/17
50-372 Wrocław

Niniejszy raport otrzymują:

1. OINT	1 egz.
2. Biblioteka Główna PWr	1 egz.
3. Z-ca Dyrektora Instytutu	1 egz.
4. Promotor	1 egz.
5. Recenzenci	2 egz.
6. Autor	1 egz.
	<hr/> <hr/>
	Razem: 7 egz.

Raport wpłynął do Redakcji I-6
w listopadzie 2006 r.