



BIULETYN 2/2013

POLSKIEGO STOWARZYSZENIA SZTUCZNEJ INTELIGENCJI

Szanowni Państwo,

Oddajemy do Państwa rąk kolejny numer biuletynu PSSI.

Przygotowując kolejne numery stopniowo rozszerzamy jego formułę. Rozpoczynamy zatem publikację artykułów członków Rady Naukowej, w tym ECCAI Fellows – w aktualnym numerze prezentujemy tekst Profesora Stana Matwina. Ten numer zawiera również teksty prezentujące postaci i prace naukowców wyróżnionych w naszym konkursie na najlepszą rozprawę doktorską w roku ubiegłym. Z okazji jubileuszu Profesora Andrzeja Skowrona prezentujemy poświęcony mu tekst. W biuletynie można również znaleźć informacje o wybranych nadchodzących konferencjach, a także bieżącej działalności Stowarzyszenia i aktywności naukowej jego członków.

Ponadto uprzejmie informujemy, że Walne Zebranie PSSI odbędzie się dnia 8.11.2013 (piątek), przewidywana godzina: 17:00 (sala 4, budynek B1 AGH w Krakowie). Jednocześnie informujemy, że godzina rozpoczęcia może ulec nieznacznej zmianie ze względu na zmiany w harmonogramie konferencji KICSS.

Życzymy przyjemnej lektury i zapraszamy do współpracy nad poszerzaniem formuły biuletynu!

Zarząd PSSI

Przygotowanie biuletynu: Grzegorz J. Nalepa, Krzysztof Kluza

Redakcja: Magdalena M. Baran

CZŁONKOWIE WSPIERAJĄCY – PATRONI PSSI

SOFTTHIS - WEB DRIVEN COMPANY



UCZENIE SIĘ MASZYNOWE: CZTERY LEKCJE – I CO DALEJ?



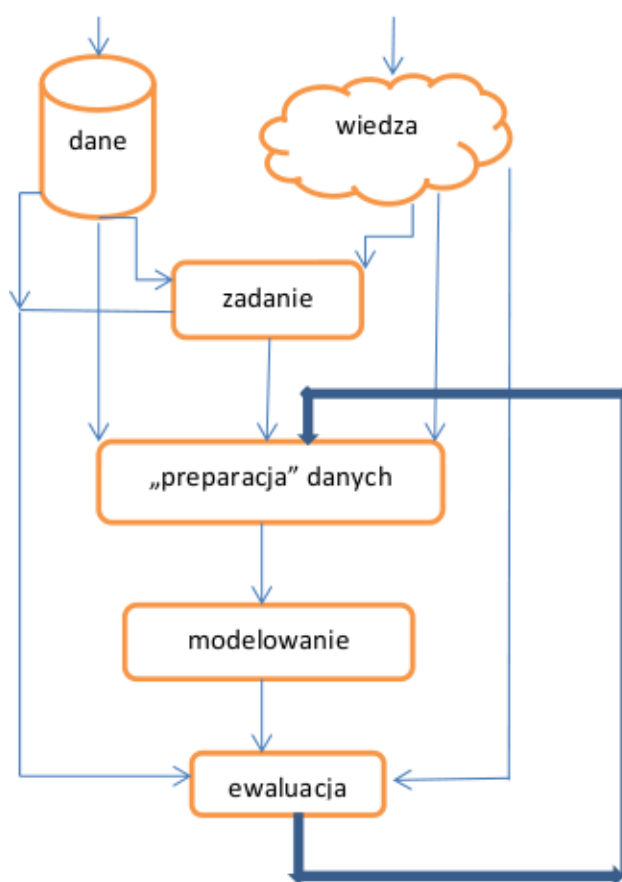
STANISŁAW MATWIN

Myślę, że czytelnicy zgodzą się ze mną co do jednego: programy uczące się, zwane też maszynami uczącymi się, stanowią zasadniczą część sztucznej inteligencji. Warto jednak przypomnieć ich historię i dokonania. Chciałbym też pokusić się o podsumowanie, ujęte w formie czterech „lekcji”, wynikających z dwudziestu pięciu lat pracy w tej dziedzinie, a zwłaszcza z tego, czego nauczyły mnie zastosowania, w których brałem udział. Spisując je zdałem sobie również sprawę, że takie spojrzenie wstecz pozwala nam zrozumieć, w którą stronę należy iść dalej. Dlatego wskazuję tu kilka tematów mogących zainteresować osoby poszukujące interesującej tematyki badań. Pod koniec spróbuję zastanowić się nad kierunkami przyszłych badań w dziedzinie programów uczących się, zwłaszcza w kontekście modnego zjawiska „danych masywnych” (ang. *big data*).

Uczenie maszynowe powstało jako część idei zbudowania systemów sztucznej inteligencji, dorównującej i przekraczającej inteligencję ludzką. Taki ambitny manifest badawczy przyświecał samej nazwie naszej dyscypliny w chwili jej powstania w połowie lat pięćdziesiątych. Nie można przecież mówić o systemie inteligentnym, który by się nie uczył. Szybko jednak zrozumiano, iż realizacja tego manifestu jest bardzo odległa, o ile w ogóle możliwa. Dlatego główny wysiłek skierowano w stronę metod uczących się, rozumianych w sposób znacznie węższy, takich jak uczenie się klasyfikacji obiektów, grupowania danych itp. Pomysł „architektur kognitywnych” został w dużym stopniu zastąpiony bardziej inżynierską koncepcją wąsko wyspecjalizowanych algorytmów, uczących się modeli, które mogą zostać użyte jako wewnętrzne części większych systemów podejmowania decyzji (np. diagnostyki medycznej lub sterowania dystrybucją energii).

Aby wytłumaczyć na czym polegają moje lekcje, muszę powiedzieć czym jest dla mnie zadanie uczenia się (patrz rys. 1.). Zastosowanie „uczące się” ma postać cyklu, na który składa się kilka etapów. Wymaga ono przede wszystkim danych, a oprócz tego zrozumienia, o co w nim chodzi. To z kolei wymaga ogólnej wiedzy i orientacji w dziedzinie, w której zadanie jest osadzone, a szczególnie opanowanie języka, w którym użytkownik opisuje swe zadanie. Bez tego nie będziemy w stanie sformułować zadania w naszym języku, w języku metod uczących się. Następnie

ma miejsce „preparacja” danych – ich uzyskanie, zapamiętanie (np. w bazie danych), czyszczenie, uzupełnianie, łączenie różnych zbiorów danych, aż wreszcie ich przedstawienie w formacie wymaganym przez program uczący się. Dopiero wówczas możemy, przy pomocy algorytmu indukcyjnego uczenia się, wreszcie zbudować model. Na koniec przechodzimy do ewaluacji modelu jako rozwiązania zadania, używając w etapie ewaluacji danych i wiedzy dziedzinowej. W tle całego tego procesu mamy oczywiście użytkownika modelu lub klienta – osobę albo organizację, która będzie używać modelu aby polepszyć jakiś aspekt swojej działalności. Najczęściej ów użytkownik będzie jednocześnie dostarczycielem danych.



Rysunek 1

Po tym nieco „szkolnym” wstępie mogę powiedzieć jakie lekcje wysnułem z realizacji opisanego powyżej cyklu w wielu zróżnicowanych zastosowaniach.

1. **Zrozum swoje dane.** Większość ekspertów zgadza się, że aby zastosowanie było udane, istotne jest nie tyle jakiego narzędzia użyjemy do zbudowania modelu, ale jak zdefiniujemy dane, z których narzędzie ów model zbuduje. Musimy zatem zrozumieć język danego zastosowania. Jest to z reguły niełatwe, wymaga bowiem

wysiłku, prawdziwego zainteresowania z naszej strony dziedziną zastosowania i jej językiem, a także pomocy ze strony użytkownika. Ktoś powiedział, że przy pomocy programu uczącego się nie można się niczego nauczyć, jeśli wcześniej się już tego prawie nie umie. Chodzi o to, jak ważne jest przedstawienie (reprezentacja) danych. Najczęściej programy uczące się używają reprezentacji tablicowej, w której wiersze odpowiadają przykładom, zaś kolumny atrybutom. Bez zrozumienia danych nie zbudujemy dobrych atrybutów, a bez dobrych atrybutów, właściwych dla zastosowania i danej dziedziny, na pewno nie uda się nam zbudować użytecznego modelu. Praktycy oceniają, że w typowym zadaniu uczącym się co najmniej 80% wysiłku i kosztów pochłania właśnie ta część wstępna, preparacja czy „obróbka” danych i budowa atrybutów. Z kolei teoretycy proponują od niedawna szalenie interesujące metody uczenia się atrybutów w procesie tzw. „głębokiej nauki” (ang. *deep learning* [Bordes et al 2011]) Propozycje te, ze względu na swoją złożoność obliczeniową dość jeszcze odległe od praktyki, mogą przynieść owoce, zwłaszcza w kontekście danych maszynowych. To właśnie ten krok całego procesu, a nie etap modelowania, decyduje najczęściej o sukcesie lub porażce całego zastosowania. Mimo to wszystkie – chyba bez wyjątku – programy nauczania, kursy i podręczniki poświęcają większość uwagi modelowaniu, a tylko znikomą jej część na wspomniany wyżej decydujący etap. Jest tak być może dlatego, że metody modelowania dają się przedstawić systematycznie, w sposób naukowy, natomiast metody przygotowania danych to wciąż mozolne rzemiosło.

2. Myśl o ewaluacji. Ewaluacja zbudowanego rozwiązania stanowi bardzo istotną część całego procesu. Istnieją oczywiście standardowe metody, które można znaleźć w każdym podręczniku, ale czy rzeczywiście pasują one do zastosowania, z jakim mamy do czynienia? Z reguły istniejące i znane już metody skupiają się na jednym tylko aspekcie ewaluacji ilościowej, np. trafności w zadaniu klasyfikacji. Istnieją jednak i inne, praktycznie niekiedy ważniejsze aspekty ewaluacji, takie jak koszt uzyskiwania danych, koszt i jakość ich etykietowania, interpretowalność wyników itp. Nawet metody standardowe są często używane bezmyślnie, jak ma to miejsce w przypadku metod walidacji krzyżowej w danych strumieniowych. W występujących coraz częściej danych tego typu, właściwa ewaluacja musi brać pod uwagę oś czasu: model będzie wyuczony na danych zebranych do pewnej chwili, a użyty będzie na danych, które pojawią się po tej chwili. Walidacja krzyżowa pomiesza te dane i – jak sam kiedyś sprawdziłem – jej wyniki będą przesadnie optymistyczne w porównaniu z walidacją na zasadzie punktu w czasie: uczymy się z danych wcześniejszych czasowo niż ten punkt, a testujemy na danych późniejszych niż ten punkt. To tylko drobny przykład – chodzi mi o to, aby o ewaluacji myśleć od początku zastosowania, a nie dopiero po zbudowaniu modelu, a także o to, by ewaluację zbudować tak, aby jej wyniki mówiły o tym na ile dany model rozwiązuje zastosowanie, jak jest przydatny i jaki jest jego koszt. Ewaluacja jest zatem wielowymiarowa, być może z użyciem metod

wielokryterialnych. W prawdzie badania tego obszaru są jeszcze na wczesnym stadium rozwoju, ale może to właśnie czyni je dobrym tematem dla ambitnych młodych naukowców.

3. **Bądź ścisły.** Możliwości obiektywnej analizy całego cyklu, od pozyskiwania danych do ewaluacji, są bardzo ważne. Ile danych musimy zebrać żeby uzyskać pożądaną jakość wyników? Pod jakim względem i dokładnie w jaki sposób wybrać metodę najlepszą w danym zastosowaniu modelowania? I w końcu jak zrozumieć daną metodę uczącą się, jak ją przedstawić geometrycznie i wizualnie? U podstaw odpowiedzi na te i podobne pytania leżą matematyka i statystyka. Logika pozwala przykładowo stwierdzić, że w danej metodzie uczącej się użyto wszystkich sensownych sposobów uogólniania modelu, a jakiegokolwiek inne sposoby mogą być otrzymane z tych, których już użyliśmy. Dlatego myślę, że warto pokusić się o ścisłość w metodach uczących się, bez zbytej przesady i mnożenia zbędnych, a nieciekawych definicji. Udaną próbą osiągnięcia eleganckiej, użytecznej precyzji analitycznej jest nowa książka Petera Flacha z Uniwersytetu w Bristolu [Flach 2012]. Może warto byłoby przetłumaczyć ją na język polski?

4. **Staraj się o interpretowalność.** Interpretowalność, albo po prostu zrozumiałość, to cecha modelu pozwalająca na jego zrozumienie przez użytkownika. Bywa i tak, że jest ona nawet ważniejsza niż jego trafność. W wielu zastosowaniach (medycznych, administracyjnych) użytkownikowi trudno będzie zaakceptować model jako narzędzie podejmowania decyzji bez zrozumienia tegoż modelu. Jeśli interpretowalność jest istotna w danym zastosowaniu, to trzeba o niej myśleć od początku całego cyklu. Uważam, że interpretowalność stanowi istotne wyzwanie dla całej dyscypliny uczenia maszynowego. Po pierwsze, zapewniają ją tylko nieliczne algorytmy: reguły i drzewa decyzyjne, sieci Bayesowskie i chyba tu kończy się lista. Sieci neuronowe, maszyny wektorów wsparcia, metody regresji nie mają z interpretowalnością wiele wspólnego. Istnieją jednak ciekawe próby „wbudowania” interpretowalności w sieci neuronowe [Maclin *et al* 07]. Po drugie, nie ma metod ewaluacji interpretowalności. Jak zatem ją mierzyć? Jak porównywać? Myślę, że szersze i dogłębne badania interpretowalności, być może interdyscyplinarne, są nam bardzo potrzebne, i że ktoś się za nie poważnie weźmie. Ciekawym nowym podejściem jest wizualizacja – być może zastąpi ona interpretowalność, albo przynajmniej nada jej nowy wymiar.

Tyle lekcji z doświadczenia. Na koniec chcę pokrótce zastanowić się, w którą stronę zmierzamy, jako dyscyplina. Które spośród gałęzi sztucznej inteligencji będą rozwijać się w najbliższym czasie? Jaki, jeśli w ogóle, będzie wpływ danych „masywnych” na uczenie się maszynowe? Niewątpliwie dane pochodzące z sieci społecznościowych stanowią nową jakość. Z jednej strony, jak wskazują liczne prace z ostatnich lat, z tego typu danych, za pomocą metod uczących się, można wywieść cenną wiedzę. Z drugiej strony, dane te w samej swej naturze przedstawiają poważne wyzwanie dla prywatności osób, których dotyczą. Czy

można użyć metod uczących się, aby choćby częściowo pomóc zachować prywatność? Myślę, że tak. Bardzo ciekawe będą też próby połączenia metod uczących się z danych z modelami teoretycznymi tzw. dynamiki sieciowej [Barabasi 03], wypracowanymi w ostatnim okresie.

Inne wyzwanie dotyczy uczenia się z danych strumieniowych (ang. *stream data*). Większość istniejących metod modelowania zakłada, często *implicite*, stacjonarność danych. Jednak pewne zastosowania, szczególnie dotyczące danych pochodzących z systemów rozproszonych sensorów, wymagają metod modelowania z danych napływających ciągłymi strumieniami. W dodatku często mamy tu do czynienia z faktem, że modelowane zjawisko niejako dryfuje – zmienia się w czasie w nieznanym sposób. Szybkość i objętość takiego strumienia danych, niemożliwość zapamiętania go w całości, wskazują na techniki uczenia się z „wyciągów” (ang. *summaries* [Cormode i Mutukrishnan 05]) – fascynującego nowego pomysłu, o solidnych podstawach matematycznych. Pionierami tych metod, niejako z konieczności, są ludzie zajmujący się analizą obrazów produkowanych przez nowoczesne urządzenia medyczne – funkcjonalny rezonans magnetyczny, magnetoencefalografia itp. To właśnie są przykłady „danych masywnych” – *big data*. Myślę, że problematyka tak rozumianych danych masywnych wywrze poważny wpływ na maszynowe uczenie się, zarówno w sensie zastosowań o kapitalnym znaczeniu społecznym, jak i zupełnie nowych metod algorytmicznych. Albowiem, jak uczono mnie w młodości, ilość przechodzi w jakość, a ta prawda jak najbardziej stosuje się do danych. Ale to już temat na osobną dyskusję.

[Barabasi 03] A. Barabási. *Linked - how everything is connected to everything else and what it means for business, science, and everyday life*. Plume 2003, s. 1-294.

[Bordes et al 11] A. Bordes, J. Weston, R. Collobert, Y. Bengio. *Learning Structured Embeddings of Knowledge Bases*. AAAI 2011.

[Flach 12] P. Flach. *Machine Learning: The Art and Science of Algorithms that Make Sense of Data*, Cambridge University Press 2012.

[Cormode i Mutukrishnan] G. Cormode, S. Muthukrishnan. *An improved data stream summary: the count-min sketch and its applications*. „J. Algorithms” 55(1) 2005, s. 58-75.

[Maclin et al. 07] R. Maclin, E. W. Wild, J. W. Shavlik, L. Torrey, T. Walker. *Refining Rules Incorporated into Knowledge-Based Support Vector Learners Via Successive Linear Programming*. AAAI 2007, s. 584-589.

* Stanisław Matwin jest profesorem i dyrektorem Institute for Big Data Analytics Dalhousie University w Halifaksie, w Kanadzie, gdzie piastuje stanowisko Canada

Research Chair, a także profesorem zwyczajnym Instytutu Podstaw Informatyki PAN. Absolwent Wydziału Matematyki, Informatyki i Mechaniki UW i dr nauk matematycznych UW. Wieloletni pracownik University of Ottawa i Distinguished Professor tej instytucji, były prezes Canadian Association for Artificial Intelligence (CAIAC), Fellow CAIAC i Fellow European Coordinating Committee for AI. Autor i współautor ponad 250 publikacji ze sztucznej inteligencji i uczenia maszynowego. Szef działu zastosowań Encyclopedia of Machine Learning Springer Verlag. Jeden z członków-założycieli PSSI, czynny uczestnik życia naukowego w naszej dziedzinie w Polsce.

PROFESOR ANDRZEJ SKOWRON – SYLWETKA JUBILATA

Andrzej Skowron urodził się 6 października 1943 roku w Wadowicach. W 1961 roku ukończył liceum im. Mikołaja Kopernika w Bielsku-Białej. W 1967 roku jednocześnie został absolwentem Wydziału Matematyki Uniwersytetu Warszawskiego oraz Wydziału Elektroniki Politechniki Warszawskiej.



Doktorat i habilitację z matematycznych podstaw informatyki obronił na Uniwersytecie Warszawskim, odpowiednio w roku 1972 i 1979. W roku 1991 otrzymał tytuł naukowy profesora. Obecnie jest profesorem zwyczajnym na Wydziale Matematyki, Informatyki i Mechaniki Uniwersytetu Warszawskiego, gdzie w Instytucie Matematyki kieruje Zakładem Logiki Matematycznej. Był promotorem ponad 20 przewodów doktorskich. Niektórzy z jego doktorantów sami posiadają już tytuły profesorskie.

W środowisku naukowym Andrzej Skowron pełnił wiele ważnych funkcji. W latach 1994-2009 był redaktorem „Fundamenta Informaticae” – czasopisma o dużym znaczeniu dla badaczy pracujących nad matematycznymi podstawami informatyki, założonego w roku 1977 przez Helenę Rasiową i Zdzisława Pawłaka. Jest on także współtwórcą i współredaktorem czasopisma „Transactions on Rough Sets” oraz członkiem komitetów redakcyjnych wielu znanych czasopism międzynarodowych, w tym: „Theoretical Computer Science”, „Information Sciences”, „Knowledge and Information Systems” oraz „Knowledge Discovery and Data Mining”. W latach 1996-2000 był prezesem Międzynarodowego Towarzystwa Zbiorów Przybliżonych. Obecnie jest wiceprzewodniczącym Rady Naukowej Instytutu Podstaw Informatyki PAN, członkiem Komitetu Informatyki PAN, a także członkiem Rady Naukowej Instytutu Badań Systemowych PAN. W latach 1988-1990 pełnił funkcję Prodziekana Wydziału Matematyki, Informatyki i Mechaniki Uniwersytetu Warszawskiego. Wspierał merytorycznie ponad 100 międzynarodowych konferencji naukowych, między innymi jako przewodniczący komitetów programowych: *International Conference on Web Intelligence / Intelligent Agent Technology* (2005), *International Conference on Rough Sets and Current Trends in Computing* (pierwszej edycji konferencji w 1998 roku), jak również *Trends in Logic III: In Memoriam of Andrzej Mostowski, Helena Rasiowa, and Cecylia Rauszer* (2005). Od

dwóch lat jest aktywnym członkiem komisji konkursów na najlepsze prace doktorskie w Polskim Stowarzyszeniu Sztucznej Inteligencji.

Profesor Andrzej Skowron wygłosił wiele zaproszonych wykładów na międzynarodowych konferencjach naukowych, w tym wykłady plenarne na *IFIP World Computer Congress* (2000), *International Conference on Information Sciences* (2005), *International Conference on Pattern Recognition and Machine Intelligence* (2005), *International Conference on Web Intelligence/Intelligent Agent Technology* (2006), *International Conference on Hybrid Information Technology* (2006), *Web Intelligence Meets Brain Informatics* (2006), *International Conference on Rough Sets, Fuzzy Sets, Data Mining and Granular Computing* (2007), *KES Symposium on Agent and Multi-Agent Systems – Technologies and Applications* (2007), *2-nd World Congress on Biologically Inspired Computing* (2010), *Int. Conference on Signal Processing, Image Processing and Pattern Recognition* (2010), *Int. Symposium on Management Engineering* (2011), *KES-IIMSS* (2012), *Int. Conference on Active Media Technology* (2013), *Joint Rough Sets Symposium* (2013), *Int. Conference on Pattern Recognition and Machine Learning* (2013).

Jubilat, którego 70-lecie urodzin honorujemy, jest autorem ponad 350 prac naukowych, z których wiele jest cytowanych przez innych badaczy. Wystarczy wspomnieć, że w tegorocznym zestawieniu *Thomson Reuters* jego nazwisko jest wymieniane wśród najczęściej cytowanych autorów prac w zakresie informatyki. Zaglądając na jego profil w *Google Scholar* można dostrzec, iż jego prace z zakresu teorii zbiorów przybliżonych oraz wnioskowania boolowskiego osiągają imponujące wskaźniki bibliometryczne, przykładowo napisana wspólnie z Cecylią Rauszer praca pt. „Discernibility Matrices and Functions in Information Systems” (rozdział w książce *Intelligent Decision Support*, 1992) posiada obecnie ponad 1700 cytowań, zaś wspólny artykuł ze Zdzisławem Pawlakiem pt. *Rudiments of Rough Sets* („Information Sciences” 177/1, 2007) w ostatnich sześciu latach był cytowany już ponad 1100 razy.

Zainteresowania naukowe profesora Andrzeja Skowrona są związane z logicznymi i algorytmicznymi aspektami sztucznej inteligencji, wnioskowaniami przy niepełnej informacji, wnioskowaniami aproksymacyjnymi, zbiorami przybliżonymi, interakcyjnymi obliczeniami granularnymi, eksploracją danych, klasyfikatorami hierarchicznymi, mereologią przybliżoną, systemami wspomaganie decyzji i zarządzania ryzykiem, systemami autonomicznymi i adaptacyjnymi, oraz metodami wykorzystania wiedzy dziedzinowej w eksploracji danych i modelowaniu złożonych zjawisk. Jubilat współpracował z wieloma legendarnymi naukowcami, spośród których należy wspomnieć przynajmniej profesora Helenę Rasiową oraz profesora Zdzisława Pawlaka. Można zaryzykować stwierdzenie, iż gdy na początku lat 90-tych ubiegłego wieku zainteresował się teorią zbiorów przybliżonych uczynił tym samym krok ku zaproponowaniu nowych metod budowy systemów sztucznej inteligencji, opartych na podstawach metodycznych innych niż

klasyczna logika. Niewątpliwie prowadzone przez niego badania są obecnie jednymi z ważniejszych w środowisku teorii i zastosowań zbiorów przybliżonych.

Mimo że wczesna kariera naukowa profesora Andrzeja Skowrona była związana z matematyką, zawsze interesował się rozwiązywaniem problemów praktycznych oraz ich relacjami z abstrakcyjnymi pojęciami matematycznymi. W ostatnich latach Profesor brał udział w licznych projektach krajowych i międzynarodowych z zakresu wykrywania oszustw w transakcjach bankowych, projektowania wyszukiwarek internetowych, wspomagania decyzji medycznych, sterowania pojazdami bezzałogowymi, czy też ostatnio zarządzania ryzykiem podczas akcji ratowniczo-gaśniczych.

Profesor Andrzej Skowron otrzymał wiele prestiżowych nagród i wyróżnień, m.in. nagrody Polskiego Stowarzyszenia Matematycznego, tj. Nagrodę im. Zygmunta Janiszewskiego (1988) oraz Nagrodę im. Stanisława Mazura (1986), Recognition of Service Award (2005) przyznaną przez Association for Computing Machinery, honorową profesurę na Chongqing University of Posts and Telecommunications w Chinach (2003) oraz tytuł honorowego redaktora „Fundamenta Informaticae”. Dla Polskiego Stowarzyszenia Sztucznej Inteligencji szczególnie istotny jest przyznany mu w maju zeszłego roku prestiżowy tytuł Fellow of European Coordinating Committee for Artificial Intelligence (ECCAI). To wyróżnienie niewątpliwie stanowi wyraz uznania dla jego badań w obszarze sztucznej inteligencji, świadczy o pozycji w międzynarodowym środowisku naukowym. Jest także świadectwem pomocy, jakiej udzielił wielu badaczom młodszego pokolenia, zarówno w kraju jak i zagranicą. Tytuł ten ma duże znaczenie nie tylko dla naszego Stowarzyszenia, ale również dla całego polskiego środowiska badaczy sztucznej inteligencji, które poza osobą profesora Stanisława Matwina nie było dotychczas dostatecznie reprezentowane w gronie ECCAI Fellows.

*Profesorowi Andrzejowi Skowronowi składamy najserdeczniejsze życzenia
jubileuszowe!*

Opracowali: Jerzy Stefanowski i Dominik Ślęzak

SYSTEMY WIELOAGENTOWE, LOGIKA I TEORIA GIER



MARCIN DZIUBIŃSKI

Wywodzące się z rozproszonej sztucznej inteligencji systemy wieloagentowe stanowią nowe podejście do analizowania, projektowania i implementowania rozproszonych aplikacji przeznaczonych do pracy w dynamicznym, nieprzewidywalnym i otwartym środowisku. Jako dziedzina badawcza podejście to wyłoniło się we wczesnych latach dziewięćdziesiątych ubiegłego wieku. Od tamtej pory dziedzina ta wyewoluowała do niezależnej dyscypliny, łączącej w sobie badania z różnych dziedzin, począwszy od filozofii i logiki formalnej aż po ekonomię i teorię gier.

Podstawową abstrakcją w systemach wieloagentowych jest *agent* – jednostka osadzona w pewnym środowisku, zdolna do elastycznego i autonomicznego działania obejmującego działanie w grupie. Ostatnia ze wspomnianych wyżej cech oznacza zdolność do uczestniczenia w interakcjach wysokiego poziomu, takich jak kooperacja czy negocjacje. Szczególnie pierwsza z tych możliwości, pozwalająca agentom na osiągnięcie celów, które wykraczają poza ich indywidualne możliwości, uważana jest za jedną z najatrakcyjniejszych cech podejścia wieloagentowego.

Formalizacja pojęć pojawiających się w kontekście systemów wieloagentowych, takich jak wiedza, przekonania, cele, intencje czy zobowiązania jest zadaniem ważnym i nietrywialnym. Najbardziej wpływowym modelem pojedynczego agenta, na którym opiera się wiele istotnych formalizmów, jest *model BDI* (ang. *Beliefs, Desires/Goals, Intentions*). W modelu tym, wywodzącym się z idei wnioskowania praktycznego [1], agent opisywany jest w terminach trzech pojęć: *przekonań* (ang. *beliefs*), reprezentujących informacje posiadane przez agenta, *celów* (ang. *desires*) reprezentujących zadania, które mogą być wybrane do realizacji oraz *intencji* (ang. *intentions*), reprezentujących zadania aktualnie realizowane przez agenta. Formalizmy mające opisywać grupowe aspekty agentowości, w tym kooperację, rozszerzają model BDI wprowadzając do niego pojęcia zbiorowe, takie jak wspólne przekonania, wzajemne intencje czy wspólne zobowiązania.

Formalizmy logiczne pozwalają na tworzenie specyfikacji systemów informatycznych oraz na tworzenie programów wnioskujących. U podstaw takich zastosowań leży problem spełnialności. W przypadku systemów wieloagentowych jest on kluczowy dla dwóch zadań. Pierwsze dotyczy projektowania i tworzenia specyfikacji. Istotne jest tu stworzenie narzędzi, które wspomagałyby pracę

projektanta, pozwalając na weryfikację tworzonych specyfikacji. Sprawdzanie spójności specyfikacji sprowadza się do rozwiązania problemu spełnialności. Drugie zadanie dotyczy implementacji pojedynczych agentów. Na ogół implementacje systemów BDI opierają się na formalizmach logicznych i wykonanie programu agenta wiąże się z przeprowadzaniem wnioskowania w tych formalizmach.

Zagadnieniem, jakim zajmowałem się w mojej rozprawie doktorskiej była złożoność obliczeniowa problemu spełnialności dla modalnych logik wieloagentowych. W badaniach tych skoncentrowałem się na formalizmie TEAMLOG [2] opracowanym przez promotorkę mojej dysertacji, profesor Barbarę Dunin-Kęplisz, we współpracy z profesorem Rineke Verbrugge z Uniwersytetu Groningen.

Wyniki odnajdowane w istniejącej wcześniej literaturze wskazywały, że problem spełnialności dla logik modalnych pozwalających na wyrażanie pojęć zbiorowych, tak istotnych w przypadku systemów wieloagentowych, musi być co najmniej EXPTIME-zupełny. Co więcej, wiadomo było, że formalizmy łączące kilka logik modalnych o „niskiej” złożoności w wyniku mogą dawać logikę, dla której problem spełnialności będzie znacznie trudniejszy. Dlatego pierwszym zadaniem było sprawdzenie złożoności problemu spełnialności dla logiki TEAMLOG. Jak się okazało, problem ten jest EXPTIME-zupełny.

Wykładnicza złożoność problemu spełnialności oznacza, że realizowanie związanych z nim zadań obliczeniowych jest praktycznie niewykonalne. Jednym ze sposobów radzenia sobie z tą kwestią jest szukanie fragmentów logik, które miałyby lepsze własności obliczeniowe i zadowalającą siłę wyrazu. Dlatego drugim zadaniem było znalezienie fragmentów logiki TEAMLOG o lepszej złożoności. W przypadku logik modalnych często rozważanym fragmentem są formuły o ograniczonej głębokości modalnej. Fragmenty tego rodzaju ograniczają stopień zagłębiania modalności. Przykładowo ograniczenie głębokości modalnej do dwóch pozwala mówić o przekonaniach agentów o środowisku oraz o przekonaniach o przekonaniach innych agentów (i własnych). Nie pozwala natomiast mówić o przekonaniach o przekonaniach o przekonaniach innych agentów. Niestety w przypadku obecności modalności grupowych problem spełnialności pozostaje EXPTIME-trudny nawet w przypadku ograniczenia głębokości modalnej formuł do dwóch. Ponieważ ograniczanie głębokości modalnej do jednego jest zbyt restrykcyjne, konieczne było zaproponowanie czegoś nowego. Taką nową klasą ograniczeń jest zaproponowane w rozprawie *ograniczenie kontekstu modalnego*. Ograniczenia tej klasy określają jakiego rodzaju modalności mogą być zagnieżdżone w innych modalnościach. W przypadku logiki TEAMLOG zaproponowałem i zbadałem dwa ograniczenia, przy pomocy których udaje się uzyskać fragment dla którego problem spełnialności jest NP-zupełny. Ogólnie rzecz biorąc, ograniczenia te zabraniają formuł mówiących o wspólnych przekonaniach

grupy agentów dotyczących przekonań agentów z tej grupy, ale pozwalają na mówienie o wspólnych przekonaniach dotyczących agentów spoza grupy (i podobnie w przypadku wzajemnych intencji).

Co prawda fragmenty logiki TEAMLOG zaproponowane w pracy nie prowadzą do rozwiązywania problemu spełnialności w czasie wielomianowym, niemniej jednak stanowią dobry punkt wyjścia do zastosowania dalszych ograniczeń (np. fragmentu hornowskiego) lub zastosowania redukcji problemu spełnialności do innych problemów NP-zupełnych, dla których istnieją dobrze działające algorytmy oparte na heurystykach (np. redukcję do problemu spełnialności dla rachunku zdań).

W swoich najnowszych badaniach zajmuję się problemami związanymi z rozważanymi ostatnio w systemach wieloagentowych grami bezpieczeństwa (ang. *security games*) [3]. W ramach projektu *Strategic Resilience of Networks*, realizowanego wspólnie z Uniwersytetem Cambridge i fundowanego z grantu Fundacji na rzecz Nauki Polskiej, *Homing Plus*, badam zagadnienia związane z obroną sieci przed atakami ze strony inteligentnych przeciwników. Interesuje mnie zastosowanie teorii gier do porównania obrony scentralizowanej i zdecentralizowanej, oraz opracowanie algorytmów do wyznaczenia obrony optymalnej oraz równowag w przypadku obrony zdecentralizowanej.

Literatura:

- [1] M. Bratman. *Intentions, Plans and Practical Reason*. Harvard University Press, Cambridge MA, USA, 1987.
- [2] B. Dunin-Kępicz, R. Verbrugge. *Teamwork in Multiagent Systems: A Formal Approach*. Wiley Series in Agent Technology. John Wiley & Sons, June 2010.
- [3] C. Kiekintveld, M. Jain, J. Tsai, J. Pita, F. Ordóez, M. Tambe. *Computing optimal randomized resource allocations for massive security games*. Proceedings of The 8th International Conference on Autonomous Agents and Multiagent Systems - Volume 1, AAMAS '09, pages 689-696, Richland, SC, 2009. IFAAMAS.

* Marcin Dziubiński jest absolwentem Instytutu Informatyki Wydziału Matematyki, Informatyki i Mechaniki. W roku 2009 uzyskał tytuł doktora ekonomii na Uniwersytecie Lancaster w Anglii, zaś w roku 2011 uzyskał doktorat z nauk informatycznych na Uniwersytecie Warszawskim. Praca doktorska z informatyki zatytułowana „Complexity Issues in Multi-Modal Logics for Multi-Agent Systems” zdobyła pierwszą nagrodę w konkursie PSSI na najlepszą rozprawę doktorską ze sztucznej inteligencji w roku 2011.

GRY FORMUŁĄ 1 SZTUCZNEJ INTELIGENCJI

WOJCIECH JAŚKOWSKI



„Gry są tym dla sztucznej inteligencji tym, czym wyścigi Formuły 1 dla przemysłu samochodowego”¹.

Abstrakcyjny charakter i precyzyjne reguły czynią gry atrakcyjnym polem testowym dla badań nad sztuczną inteligencją. Centralnym problemem każdej kompetytywnej gry jest znalezienie strategii wygrywającej. Ręczne projektowanie strategii jest żmudne i nie gwarantuje sukcesu, dlatego ostatnimi laty popularność w projektowaniu strategii zyskują algorytmy inteligencji obliczeniowej. W swych założeniach oprócz zdefiniowania reguł gry do działania nie wymagają one wkładu wiedzy dziedzinowej projektanta lub też wymagają jej w ograniczonym zakresie, np. projektant ogranicza się do podania sposobu kodowania strategii. Dla algorytmów inteligencji obliczeniowej przebieg gry oraz jej wynik (a dla niektórych tylko jej wynik) jest jedyną informacją uczącą. Automatyczne dostrajanie strategii odbywa się na podstawie wielu, nierzadko setek milionów rozgrywek. Przykładami takich algorytmów są metody uczenia się ze wzmocnieniem oraz algorytmy koewolucyjne. Prowadzą one do automatycznego, samodzielnego odkrycia strategii rozpatrywanej gry.

Od czasów pierwszych eksperymentów Arthura Samuela z uczeniem się strategii gry w warcaby [6], algorytmy te doprowadziły do stworzenia programów grających na poziomie najlepszych graczy (ludzi). Najbardziej doniosłym osiągnięciem uzyskanym za pomocą algorytmów koewolucyjnych jest wyewoluowana przez Dawida Fogela *Blondie24*, której ranking w warcabach jest szacowany na 2100 w klasyfikacji ELO (tuż poniżej klasy mistrzowskiej). Z kolei uczenie się ze wzmocnieniem jest słynne z *TD-Gammon'a*, programu grającego w Tryktraka (ang. *Backgammon*), którego sukces zapoczątkował rozwój uczenia się ze wzmocnieniem.

Wśród sukcesów brak jednak nieco bardziej skomplikowanych gier i nie dotyczy to wyłącznie gier planszowych, takich jak gra „Go”, która cechuje się ogromną liczbą

¹ Zaslyszane, być może inspirowane pracą Donkers'a i współpracowników [1].

ok. 10^{170} stanów i w jej przypadku sztuczna inteligencja musi nadal uznać wyższość inteligencji organicznej. Ale cóż to jest 10^{170} stanów w porównaniu z co najmniej 10^{1685} stanami w popularnej grze komputerowej „StarCraft”?

Problemowi uczenia się strategii gier daleko zatem do rozwiązania czy to „twardymi” metodami sztucznej inteligencji, czy też „miękkimi” metodami jej bliskiej krewnej, inteligencji obliczeniowej. Dlatego problematyka ta znajduje się w centrum moich naukowych zainteresowań [4,5,7].

Interesujący jest fakt, że problem uczenia się strategii gier można postawić jako *problem oparty na testach*. Klasę takich problemów rozważałem w swojej rozprawie doktorskiej [2]. Problemy oparte na testach należą do szerokiej klasy problemów kooptymalizacji, która stanowi uogólnienie problemów optymalizacji. Cechą charakterystyczną problemów opartych na testach jest to, że oprócz przestrzeni potencjalnych rozwiązań problemu mamy także do czynienia z przestrzenią testów. Aby ocenić jakość potencjalnego rozwiązania należy wykonać pewną liczbę elementarnych interakcji rozwiązanie-test. Trudność problemu związana jest zatem nie tylko z wielkością przestrzeni potencjalnych rozwiązań, ale również z wielkością przestrzeni testów. Zwykle ta ostatnia jest nie mniejsza niż ta pierwsza. W efekcie precyzyjna ocena potencjalnego rozwiązania nigdy nie jest w praktyce możliwa, bo elementów w przestrzeni testów jest zbyt dużo, aby wykonać wszystkie interakcje rozwiązanie-test.

Przykładowo, strategii wygrywającej dla gracza „białego” w szachach szukamy w przestrzeni potencjalnych rozwiązań. Jednocześnie ocena (jedno- lub wielokryterialna) danej strategii wymaga interakcji (rozegrania gier) z pewną liczbą testów (strategiami gracza „czarnego”). Kluczowy podczas rozwiązywania problemów opartych na testach jest odpowiedni dobór testów podczas oceny danego rozwiązania w czasie działania algorytmu. Tu właśnie doskonale odnajdują się algorytmy koewolucyjne ponieważ doboru testów dokonują automatycznie. Jest to możliwe, gdyż algorytmy koewolucyjne utrzymują i ewoluują jednocześnie populację potencjalnych rozwiązań oraz populację testów. Interakcje zachodzące pomiędzy potencjalnymi rozwiązaniami i testami prowadzą do „wyścigu zbrojeń” potencjalnych rozwiązań oraz testów i są siłą napędową tychże algorytmów [3].

Praktyczne zastosowanie bolidów Formuły 1 jest ograniczone. Są ciasne, awaryjne, a przyspieszenie i prędkość, które oferują są nieprzydatne wobec korków, jakie spotykamy podczas codziennych podróży do pracy. Jednakże wiedza płynąca z pokonywania kolejnych barier aerodynamicznych, mechanicznych i elektronicznych w warunkach ekstremalnych, prowadzi do innowacji, które powoli trafiają do samochodów, którymi się poruszamy. Podobnie jest z algorytmami sztucznej inteligencji w grach.

Literatura:

- [1] J. Donkers, J. Uiterwijk, A. de Voogt. *Mancala games-topics in mathematics and artificial intelligence*. „Board Games in Academia”, s.17-21, 2001.
- [2] W. Jaśkowski, *Algorithms for Test-Based Problems*. Instytut Informatyki, Politechnika Poznańska, Poznań, 2011.
- [3] W. Jaśkowski, K. Krawiec. *Formal analysis, hardness and algorithms for extracting internal structure of test-based problems*. „Evolutionary Computation”, 19(4) 2011, s. 639-671.
- [4] W. Jaśkowski, K. Krawiec, B. Wieloch. *Evolving strategy for a probabilistic game of imperfect information using genetic programming*. „Genetic Programming and Evolvable Machines”, 9(4) 2008, s. 281-294.
- [5] K. Krawiec, W. Jaśkowski, M. Szubert. *Evolving small-board go players using coevolutionary temporal difference learning with archive*. „International Journal of Applied Mathematics and Computer Science”, 21(4) 2011, s. 717-731.
- [6] A. L. Samuel. *Some studies in machine learning using the game of checkers*. „IBM Journal of Research and Development”, 3(3) 1959, s. 211-229.
- [7] M. Szubert, W. Jaśkowski, K. Krawiec. *On scalability, generalization, and hybridization of coevolutionary learning: a case study for othello*. „IEEE Transactions on Computational Intelligence and AI in Games”, 5(3) 2013, s. 214-226.

* Wojciech Jaśkowski (ur. 1982) jest adiunktem na Wydziale Informatyki Politechniki Poznańskiej. Obecnie zajmuje się zastosowaniem metod inteligencji sztucznej i obliczeniowej w grach. W ramach badań stosuje i bada m.in. algorytmy ewolucyjne, koewolucyjne, programowanie genetyczne i metody uczenia ze wzmocnieniem. Jest laureatem programu "START" Fundacji na rzecz Nauki Polskiej (2012) oraz konkursu na stypendia dla młodych naukowców MNiSW (2013). Jego praca doktorska pt. „Algorithms for test-based problems” została wyróżniona przez PSSI w konkursie na najlepszą rozprawę doktorską w dziedzinie sztucznej inteligencji (2012).

OTWARCIE KONKURSU NA NAJLEPSZĄ ROZPRAWĘ DOKTORSKĄ W DZIEDZINIE SZTUCZNEJ INTELIGENCJI

Z inicjatywy prof. Stana Matwina, Zarząd PSSI ogłasza kolejną edycję konkursu na najlepszą rozprawę doktorską w dziedzinie Sztucznej Inteligencji. Zgodnie z regulaminem zgłoszenia należy dokonać elektronicznie na adres: pssi@agh.edu.pl oraz drogą pocztową na adres Stowarzyszenia.

Zgłoszenia przyjmujemy w terminie **do 31 grudnia 2013 roku** dla rozpraw broniących od 1 października 2012 do 30 września 2013 r. Regulamin oraz dokumenty konkursowe można znaleźć na stronie:

<http://pssi.agh.edu.pl/pl:konkurs>

Oceny prac dokona Komisja Konkursowa Konkursu Polskiego Stowarzyszenia Sztucznej Inteligencji (PSSI).

WIADOMOŚCI PSSI

PROF. ANDRZEJ SKOWRON WŚRÓD NAJCZĘŚCIEJ CYTOWANYCH NAUKOWCÓW NA ŚWIECIE


Miło nam poinformować, że profesor Andrzej Skowron, członek Rady Naukowej PSSI oraz ECCAI Fellow, znalazł się w gronie najczęściej cytowanych naukowców na świecie w dziedzinie informatyki w 2012 roku wg *Web of Sciences/Thomson Reuters*.



PROF. RYSZARD TADEUSIEWICZ CZŁONKIEM EUROPEJSKIEJ AKADEMII NAUK I SZTUK

Jest nam niezmiernie miło poinformować, że prof. Ryszard Tadeusiewicz, wiceprezes PSSI, został wybrany na członka Europejskiej Akademii Nauki i Sztuk.

Europejska Akademia Nauk i Sztuk (European Academy of Sciences and Arts) to stowarzyszenie uczonych i przyjaciół nauk mające swoją siedzibę w Salzburgu.



Stowarzyszenie powołane zostało w 1990 r., a w swoich szeregach skupia m.in. 29 laureatów Nagrody Nobla. Inauguracja udziału nowo wybranych członków w pracach Akademii odbyła się 8 marca 2014 roku.

(opracował: Krzysztof Kluza)

TRZECIE I CZWARTE OTWARTE SEMINARIUM CZŁONKÓW ORAZ SYMPATYKÓW PSSI NA POLITECHNICIE POZNAŃSKIEJ

5 czerwca 2013 poznańscy członkowie i sympatycy PSSI zorganizowali kolejne (trzecie już) otwarte seminarium, tym razem poświęcone tematyce reprezentacji semantyki, ontologiom oraz ich popularyzacji.

Zgodnie z zamysłem grupy organizatorów seminarium kierowanej przez prof. Jerzego Stefanowskiego, główną częścią seminarium była dyskusja. Z tego powodu referaty, inspirujące tę dyskusję, miały charakter przeglądowy i stawiały także otwarte pytania dotyczące symbolicznych metod reprezentowania semantyki. Seminarium zostało oficjalnie otwarte przez prof. dr hab. inż. Joannę Józefowską, która także przypomniała dotychczasowe działania środowiska poznańskiego, w tym wspomniała pierwsze zeszłoroczne seminarium.

Pierwszy referat zatytułowany „Symboliczne metody reprezentowania semantyki” wygłoszony został przez dra inż. Adama Meissnera i dotyczył genezy, historii, ewolucji i aktualnego stanu badań nad rolą i znaczeniem metod symbolicznych w badaniach nad sztuczną inteligencją. Drugi z trzech zaprezentowanych referatów, przygotowany przez dr inż. Jolantę Cybulkę, zatytułowany „Ontologia-po-raz-drugi© P.Garbacz, R.Trypuz. O aliansie nauk humanistycznych i inżynierii informatycznej”, naświetlił znaczenie i rozumienie pojęcia ontologii w informatyce – w tym w odniesieniu do pierwotnego, tj. filozoficznego rozumienia. W ostatnim wystąpieniu („A little semantics goes a long way – jak technologie semantyczne trafiły pod strzechy”) dr inż. Agnieszka Ławrynowicz nakreśliła najnowsze trendy w badaniach nad technologiami semantycznymi, a szczególnie w pracach nad urzeczywistnieniem koncepcji Połączonych Danych (ang. *Linked Data*).

W dniu **28 czerwca 2013** odbyło się natomiast czwarte otwarte seminarium zorganizowane w ramach inicjatywy poznańskich członków i sympatyków PSSI. Podczas seminarium prof. Bettina Berendt z grupy Declarative Languages and Artificial Intelligence Group (DTAI) na Wydziale Informatyki KU Leuven wygłosiła wykład zatytułowany „Privacy in Online Social Networks: Software Assistants and Beyond”. Wykład poruszał zagadnienia definicji i znaczenia prywatności w kontekście upowszechnienia się platform społecznościowych oraz prezentował rozwiązania technologiczne wspierające zarządzanie prywatnością w systemach informacyjnych. Seminarium zostało oficjalnie otwarte przez prof. dr hab. inż. Joannę Józefowską, a po wykładzie miała miejsce ożywiona dyskusja.

Zapraszamy wszystkich do zapoznania się ze sprawozdaniem z seminarium:
[na stronie internetowej PSSI.](#)

(Sprawozdanie z seminarium opracował: Jerzy Stefanowski)



KONFERENCJE Z OBSZARU SI

Serdecznie zapraszamy na zbliżające się konferencje związane ze Sztuczną Inteligencją:

- [21st European Conference on Artificial Intelligence \(ECAI 2014\)](#), 17–22 sierpnia 2014, Praga, Czechy,
- [16th International Congress of the Catalan Association of Artificial Intelligence \(CCIA 2013\)](#), 23-25 października 2013, Vic, Katalonia, Hiszpania,
- [25th Benelux Conference on Artificial Intelligence \(BNAIC 2013\)](#), 7-8 listopada 2013, Delft, Holandia,
- [12th Scandinavian Artificial Intelligence Conference \(SCAI 2013\)](#), 20-22 listopada 2013, Aalborg, Dania,
- [XIII Conference of the Italian Association for Artificial Intelligence \(AI*IA 2013\)](#), 4-6 grudnia 2013, Turyn, Włochy,
- [33rd SGAI International Conference on Artificial Intelligence \(AI-2013\)](#), 10-12 grudnia 2013, Cambridge, Wielka Brytania.

WALNE ZEBRANIE PSSI 2013

Uprzejmie informujemy, że Walne Zebranie PSSI odbędzie się dnia 8.11.2013 (piątek), przewidywana godzina: 17:00 (sala 4, budynek B1 AGH w Krakowie).

Jednocześnie informujemy, że godzina rozpoczęcia może ulec nieznacznej zmianie ze względu na zmiany w harmonogramie konferencji KICSS.

Porządek Walnego Zebrania

1. Otwarcie Walnego Zebrania przez Prezesa Stowarzyszenia.
2. Wybór Przewodniczącego i Sekretarza Zebrania.
3. Powołanie Komisji Skrutacyjnej.
4. Zatwierdzenie porządku Walnego Zebrania.
5. Wręczenie dyplomów w Konkursie PSSI na najlepszą rozprawę doktorską.
6. Przedstawienie informacji na temat działalności PSSI w ostatnim roku.
7. Przedstawienie Sprawozdania Zarządu za okres kadencji.
8. Głosowanie nad przyjęciem Sprawozdania Zarządu za okres kadencji.
9. Głosowanie nad propozycjami nowych kandydatów do Rady Naukowej.
10. Przedstawienie ordynacji wyborczej wynikającej ze Statutu PSSI.
11. Wybory Prezesa i Członków Zarządu PSSI.
12. Wybory Komisji Rewizyjnej.
13. Dyskusja na temat dalszych działań PSSI.
14. Wolne wnioski.
15. Zamknięcie Walnego Zebrania.

Serdecznie zapraszamy Państwa do Krakowa!

SKŁADKI PSSI

Dziękujemy wszystkim, którzy opłacili składki członkowskie PSSI. Jednocześnie przypominamy, że wysokość składek członkowskich decyzją uchwały Zarządu z 2010 roku wynosi:

- składka podwyższona: 120 zł/rok (obejmuje członków Zarządu PSSI),
- składka normalna: 90 zł/rok,
- składka ulgowa: 40 zł/rok (obejmuje uczniów, studentów, emerytów i rencistów),
- wpisowe: 30 zł (jednorazowa opłata, która obejmuje nowych członków, opłacających składki pierwszy raz).

Bardzo prosimy o terminowe uiszczenie składek członkowskich za 2013 rok!

Numer konta Stowarzyszenia: **60 1160 2202 0000 0002 3265 8007**

Adres: Polskie Stowarzyszenie Sztucznej Inteligencji

al. Mickiewicza 30, 30-059 Kraków

W tytule prosimy wpisać: *składka członkowska za rok 2013*, a także imię i nazwisko, w przypadku jeśli przelew nie jest wykonywany z konta członka PSSI, za którego opłacana jest składka.

CZŁONKOWIE WSPIERAJĄCY – PATRONI PSSI

SOFTTHIS - WEB DRIVEN COMPANY



Firma [Softhis](#) od 2011 roku jest Patronem PSSI.

Softhis specjalizuje się w rozwiązaniach informatycznych dla Internetu. Firma Softhis działa na pograniczu rynku aplikacji internetowych, agencji interaktywnych oraz firm tworzących oprogramowanie dedykowane i integrujących systemy. W swoich implementacjach wykorzystuje ona najnowocześniejsze narzędzia i koncepcje z zakresu technologii inteligentnych, w tym Semantic Web.