


SYSTEMY WSPOMAGANIA DECYZJI KLINICZNYCH

Informatyka w medycynie, 2017-18

WPROWADZENIE

Schemat postępowania z pacjentem



3 główne typy decyzji klinicznych:

1. proces diagnostyczny
2. diagnoza
3. leczenie i terapia

Podjmowanie decyzji klinicznych

Podjęcie dobrej decyzji wymaga

1. dokładnych i adekwatnych danych
2. odpowiedniej i aktualnej wiedzy
3. umiejętności rozwiązywania problemów (→ doświadczenia i zdolności do stosowania wiedzy do danych)

Wspomaganie decyzji klinicznych (WDK, ang. *clinical decision support*) – proces, którego celem jest **poprawa jakości opieki zdrowotnej** poprzez udostępnienie **w odpowiednim czasie i miejscu** personelowi medycznemu **inteligentnie przetworzonej** (przefiltrowanej) **wiedzy lub informacji** [Osherooff i in., 2004]

Narzędzia WDK - wymagania

Czynniki warunkujące udane wdrożenie narzędzi WDK

1. Wspomaganie decyzji jako element przyjętego postępowania
2. Oferowanie zaleceń (terapeutycznych), a nie tylko ocen (diagnostycznych)
3. Udostępnienie w odpowiednim miejscu i czasie, w którym zachodzi konieczność podjęcia decyzji
4. Implementacja w postaci systemu komputerowego



System wspomaganie decyzji klinicznych (SWDK)

Systemy wspomagania decyzji klinicznych (SWDK)

Główne kategorie SWDK

1. Systemy do wyszukiwania wiedzy i danych istotnych dla aktualnego kontekstu klinicznego (→ pacjenta)
2. Systemy do wypracowywania różnego rodzaju sugestii, zaleceń, przypomnień, alarmów dla aktualnego kontekstu
3. Systemy do odpowiedniego organizowania i prezentowania informacji w celu łatwiejszego podjęcia decyzji

SWDK nie zastępują personelu medycznego w podejmowaniu decyzji, a jedynie wspomagają go!



Charakterystyka SWDK

Rozbudowana charakterystyka obejmująca 5 głównych kategorii oraz 26 „wymiarów” opisu

1. **kontekst** (miejsce użycia, wspierane typy decyzji, moment użycia...)
2. **źródło wiedzy i danych** (źródło modelu decyzyjnego, źródło i format wykorzystywanych danych, sposób aktualizacji modelu decyzyjnego ...)
3. **wspomaganie decyzji** (mechanizm wnioskowania, „**bezpośredniość**” i **rodzaj sugestii**, wymagana reakcja użytkownika...)
4. **dostarczanie informacji/sugestii** (**sposób dostarczania sugestii**, zdolność wyjaśniania sugestii, możliwość realizacji sugestii...)
5. **przepływ pracy** (*workflow*) (użytkownik systemu, integracja z zewnętrznymi/istniejącymi przepływami pracy, ...)

„Bezpośredniość” sugestii

- Sugestie **pośrednie**
 - System dostarcza informację lub wiedzę (w tym publikacje)
 - Ostateczna decyzja wypracowywana przez decydenta
- Sugestie **bezpośrednie**
 - System dostarcza sugestie decyzji (np. możliwe diagnozy)
 - Decydent wybiera i zatwierdza jedną z sugestii

Rodzaje sugestii bezpośrednich

- **Konsultacja** – system podaje użytkownikowi sugestie na podstawie dostępnych danych
- **Krytyka** – użytkownik podaje systemowi swoją sugestię, a system ją ocenia i proponuje zmiany (np. kontrola przypisanych leków pod kątem możliwych interakcji)



Większa *subiektywna* kontrola użytkownika/decydenta w trybie krytyki

Sposób dostarczania sugestii

- **Pasywny** – użytkownik jawnie żąda wsparcia od systemu i dostarcza niezbędne dane
- **Aktywny** – system monitoruje dostępne dane i samodzielnie oferuje wsparcie odpowiednie dla kontekstu



Problem ze zbyt dużą „czułością” aktywnego systemu – duża liczba mało ważnych ostrzeżeń obniża „czujność” użytkownika

MODELE DECYZYJNE W SWDK

Systemy punktowe (skale)

- Ocena stanu pacjenta (także ryzyka zachorowania) za pomocą prostego addytywnego systemu punktowego

Asthma symptoms	PRAM Score			
	0	1	2	3
Suprasternal indrawing	absent		present	
Scalene retractions	absent		present	
Wheezing	absent	expiratory	inspiratory and expiratory	audible without stethoscope/ absent with no air entry
Air entry	normal	decreased at bases	widespread decrease	absent/minimal
Oxygen saturation	≥ 95%	92 - 95%	<92%	

- Opracowywane na podstawie modeli regresji (logistycznej, liniowej, ...) – uproszczenie reprezentacji i obliczeń

Ducharme, F.M., Chalut, D., Plotnick, L. et al. (2006). The Pediatric Respiratory Assessment Measure: a valid clinical score for assessing acute asthma severity from toddlers to teenagers. *J Pediatr* 152(4), 476-480.

Systemy punktowe – przykład


Risk factor	Categories	Reference value (W_{ij})	β_i	$\beta_i(W_{ij} - W_{iREF})$	Points _{ij} = $\beta_i(W_{ij} - W_{iREF})/B$
Age			0.0575		
	30–39	34.5 = W_{1REF}		0	0
	40–49	44.5		0.5750	2
	50–59	54.5		1.1500	4
	60–69	64.5		1.7250	6
	70–79	74.5		2.3000	8
Sex			1.3078		
	Female	0 = W_{2REF}		0	0
	Male	1		1.3078	5
Systolic blood pressure			0.0185		
	< 120	107		–0.3330	–1
	120–129	125 = W_{3REF}		0	0
	130–139	135		0.1850	1
	140–159	150		0.4625	2
	≥ 160	170		0.8325	3
Current smoker			0.9456		
	No	0 = W_{4REF}		0	0
	Yes	1		0.9456	3

$$B = 5(0.0575) = 0.2875$$

Liczba „jednostek regresji”
na jeden punkt skali

Reguły i drzewa decyzyjne

- Symboliczna reprezentacja wiedzy → łatwa interpretacja i możliwość „ręcznego” zastosowania



Stiell, I.G., R.D. McKnight, G.H. Greenberg et collab.
Implementation of the Ottawa Ankle Rules. JAMA, no 271. 1994, p. 827-832.

© Ottawa Health Research Institute

An ankle x-ray series is only required if there is pain in the malleolar zone AND any of these findings:

- Bone tenderness at A (posterior edge or tip of lateral malleolus), OR
- Bone tenderness at B (posterior edge or tip of medial malleolus), OR
- Inability to bear weight both immediately after injury and in ED.

A foot x-ray series is only required if there is pain in the malleolar zone AND any of these findings:


- Bone tenderness at C (base of 5th metatarsal), OR
- Bone tenderness at D (navicular), OR
- Inability to bear weight both immediately after injury and in ED.

© Ottawa Health Research Institute

Reguły i drzewa decyzyjne

- Indukcja drzew decyzyjnych poprzez rekurencyjny podział zbioru obiektów
 - zachłanny wybór najlepszego warunku podziału (na 2 lub więcej podzbiorów)
 - dalszy podział każdego z uzyskanych podzbiorów
 - prycinanie (*prunning*) tworzonych drzew w celu uniknięcia przeuczenia (*overfitting*) i uzyskania bardziej ogólnych modeli
- Możliwość przekształcenia drzewa na zbiór reguł
- Las – klasyfikator złożony składający się z wielu drzew

CART → L. Breiman et al. (1984)
C4.5/C5.0 → R. Quinlan (1994)



Modele bayesowskie

- Naiwny klasyfikator Bayesa


$$P(C_i|X) \propto p(C_i)P(X|C_i) \quad \longrightarrow \quad P(C_i|X) \propto p(C_i) \prod_j p(x_j|C_i)$$

- założenie niezależności zmiennych – dobre zachowanie w praktyce pomimo braku jego spełnienia
- prawdopodobieństwa $p(x_j|C_i)$ łatwe do wyznaczenia i aktualizacji
- rozszerzenia dla atrybutów ciągłych – wykorzystanie funkcji gęstości prawdopodobieństwa (parametry rozkładu estymowane z danych)

Modele bayesowskie


$$P(X_1, X_2, \dots, X_n) = \prod_i p(X_i | \pi_i)$$

- Sieć bayesowska
 - probabilistyczny model graficzny – acykliczny graf skierowany przedstawiający **zależności** między zmiennymi + prawdopodobieństwa



- możliwość wnioskowania **predykcyjnego** (*predictive, top-down*) i **diagnostycznego** (*diagnostic, bottom-up*)
- automatyczna konstrukcja sieci z danych (np. algorytm K2) albo na podstawie wiedzy eksperckiej

Sieć bayesowska – przykład




		LOS	
		terminowy	opóźniony
<i>NutriW2</i>	<i>Jp3</i>		
płynne	brak	0.4	0.6
płynne	mały	0.3	0.7
płynne	średni	0.2	0.8
płynne	duży	0.1	0.9
stałe	brak	0.7	0.3
stały	mały	0.6	0.4
stały	średni	0.5	0.5
stały	duży	0.5	0.5

Maszyny wektorów nośnych


(*support vector machine, SVM*)

- Model dla klasyfikacji binarnej
 - oddzielenie obiektów z różnych klas za pomocą hiperpłaszczyzny – optymalizacja marginesu wokół granicy
 - w przypadku braku separowalności liniowej (zazwyczaj ☹️) – przejście do przestrzeni o większej liczbie wymiarów



- W przypadku problemów wieloklasowych konstrukcja wielu modeli – *one-versus-all* lub *one-versus-one*

Maszyny wektorów nośnych



$$\begin{aligned} \max: W(\alpha) &= -\alpha^T \mathbf{1} + \frac{1}{2} \alpha^T H \alpha \\ \text{st: } \alpha^T &= 0, 0 \leq \alpha \leq C \mathbf{1} \end{aligned}$$



$$H_{ij} = y_i y_j \left(\phi(x_i) \phi(x_j) \right)$$

$$K(x_i, x_j) = \phi(x_i) \phi(x_j)$$


$$K(x_i, x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{2\sigma^2} \right)$$

Kernel trick → zastosowanie **funkcji kernelowej** do iloczynu skalarnego wektorów w nowej **przestrzeni** (dobór funkcji do danych!)



Sieci neuronowe



ReLU = rectified linear unit



ELU = exponential linear unit





Głębokie (konwolucyjne) sieci neuronowe

<https://www.clarifai.com/demo>


- Sieci składające się z wielu warstw ukrytych

- konstrukcja i selekcja cech
 - *convolution* – splot
 - *pooling* – selekcja
 - *dropout* – wyłączanie neuronów (unikanie przeuczenia)
- klasyfikacja przy użyciu nowych cech – warstwy *fully-connected*

1+




(a) Standard Neural Net




(b) After applying dropout.

$$\begin{bmatrix} 1 & 1 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 \\ 0 & 1 & 1 & 1 & 0 \\ 0 & 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 \end{bmatrix} * \begin{bmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 1 \end{bmatrix} = \begin{bmatrix} 3 & 4 & 1 \\ 4 & 3 & 3 \\ 3 & 4 & 1 \end{bmatrix}$$



Przykładowe zastosowanie

Problem: segmentacja naczyń krwionośnych w obrazach dna oka (fundus)



Przykładowe zastosowanie

ARTICLE

OPEN

Scalable and accurate deep learning with electronic health records

Alvin Rajkomar^{1,2}, Eyal Oren¹, Kai Chen¹, Andrew M. Dai¹, Nissan Hajaj¹, Michaela Hardt¹, Peter J. Liu¹, Xiaobing Liu¹, Jake Marcus¹, Mimi Sun¹, Patrik Sundberg¹, Hector Yee¹, Kun Zhang¹, Yi Zhang¹, Gerardo Flores¹, Gavin E. Duggan¹, Jamie Irvine¹, Quoc Le¹, Kurt Litsch¹, Alexander Mossin¹, Justin Tansuwan¹, De Wang¹, James Wexler¹, Jimbo Wilson¹, Dana Ludwig², Samuel L. Volchenboum³, Katherine Chou¹, Michael Pearson¹, Srinivasan Madabushi¹, Nigam H. Shah⁴, Atul J. Butte², Michael D. Howell¹, Claire Cui¹, Greg S. Corrado¹ and Jeffrey Dean¹

Predictive modeling with electronic health record (EHR) data is anticipated to drive personalized medicine and improve healthcare quality. Constructing predictive statistical models typically requires extraction of curated predictor variables from normalized EHR data, a labor-intensive process that discards the vast majority of information in each patient's record. We propose a representation of patients' entire raw EHR records based on the Fast Healthcare Interoperability Resources (FHIR) format. We demonstrate that deep learning methods using this representation are capable of accurately predicting multiple medical events from multiple centers without site-specific data harmonization. We validated our approach using de-identified EHR data from two US academic medical centers with 216,221 adult patients hospitalized for at least 24 h. In the sequential format we propose, this volume of EHR data unrolled into a total of 46,864,534,945 data points, including clinical notes. Deep learning models achieved high accuracy for tasks such as predicting: in-hospital mortality (area under the receiver operator curve [AUROC] across sites 0.93–0.94), 30-day unplanned readmission (AUROC 0.75–0.76), prolonged length of stay (AUROC 0.85–0.86), and all of a patient's final discharge diagnoses (frequency-weighted AUROC 0.90). These models outperformed traditional, clinically-used predictive models in all cases. We believe that this approach can be used to create accurate and scalable predictions for a variety of clinical scenarios. In a case study of a particular prediction, we demonstrate that neural networks can be used to identify relevant information from the patient's chart.

npj Digital Medicine (2018)1:18; doi:10.1038/s41746-018-0029-1

Przykładowe zastosowanie



1

Health systems collect and store electronic health records in various formats in databases.




JOHN DOE



2

All available data for each patient is converted to events recorded in containers based on the Fast Healthcare Interoperability Resource (FHIR) specification.



3

The FHIR resources are placed in temporal order, depicting all events recorded in the EHR (i.e. timeline). The deep learning model uses this full history to make each prediction.

Fig. 4 Data from each health system were mapped to an appropriate FHIR (Fast Healthcare Interoperability Resources) resource and placed in temporal order. This conversion did not harmonize or standardize the data from each health system other than map them to the appropriate resource. The deep learning model could use all data available prior to the point when the prediction was made. Therefore, each prediction, regardless of the task, used the same data

Wyjaśnianie decyzji

<http://cnnlocalization.csail.mit.edu/>

- Wprowadzenie dodatkowej warstwy *pooling-u* (*global average pooling*) w celu identyfikacji istotnych elementów informacji wejściowej





Figure 2. Class Activation Mapping: the predicted class score is mapped back to the previous convolutional layer to generate the class activation maps (CAMs). The CAM highlights the class-specific discriminative regions.


Autoenkodery

- Sieci konwolucyjne odtwarzające obraz wejściowy
 - kompresja danych – transformacja obrazu wejściowego do ograniczonej liczby wartości (neuronów w warstwie ukrytej)
 - możliwość wykorzystania wartości z warstwy ukrytej do dalszego przetwarzania



Przykładowe zastosowanie

Poprawa jakości zdjęć z TK



Nishio, M., Nagashima, C., Hirabayashi, S., Ohnishi, A., Sasaki, K., Sagawa, T., ... Yamashita, T. (2017). Convolutional auto-encoders for image denoising of ultra-low-dose CT. *Heliyon*, 3(8).

Indeksowane publikacje

- Odpowiednio przetworzone i poindeksowane publikacje medyczne – wyszukiwanie publikacji (lub jej fragmentu) dopasowanej do aktualnego kontekstu


1. Introduction and epidemiology

Posterior wall fractures are the most common acetabular fractures and account for approximately 24% of acetabular fractures.

They typically involve the rim of the acetabulum, a portion of the retroacetabular surface, and a variable segment of the articular cartilage.

The fracture line leaves undisturbed the major portion of the posterior column. A posterior dislocation is usually associated.

Posterior wall fractures are partial fractures of the posterior column.




fractures	0.534
acetabulum	0.326
posterior wall	0.103
...	



Algorytmy kliniczne

- Sformalizowany zapis wytyczne postępowania klinicznego (*clinical practice guidelines, CPG*)



HISTORIA I PRZYKŁADY SWDK

Historia i architektury SWDK

Systemy samodzielne (izolowane)

AAPHelp
(1972)

MYCIN
(1975)

DXplain
(1987)

Isabel
(2003)

Watson?
(2006)

Systemy zintegrowane

HELP
(1975)

Systemy zorientowane na usługi

SEBASTIAN
(2005)

AAPHelp (1972-2004)

- System do diagnozowania bólu brzucha (wskazanie jednej z 7 przyczyn, m.in. zapalenie wyrostka)
- Bayesowski model decyzyjny zakładający niezależność atrybutów (NB)
- Prawdopodobieństwa warunkowe ustalone na podstawie analizy kilku tysięcy przypadków
- Dobre wyniki w testach klinicznych (309 przypadków)
 - Trafność diagnostyczna lepsza od trafności lekarzy (91% $\leftrightarrow$ 65-80%)
 - Duże „zyski” (mniej zbędnych operacji) w przypadku wyrostka (6 $\leftrightarrow$ 20)
- Wyników nie udało się powtórzyć w innych lokalizacjach!
- Wzrost trafności diagnostycznej związany z narzuceniem strukturalnego podejścia do zbierania danych

AAPHelp

- System przez długi czas rozwijany (do 2004) i rozbudowany o inne problemy i dziedziny (ginekologia)
- Udostępniony wybranym użytkownikom (początkujący lekarze) w formie aplikacji webowej i mobilnej

The screenshot shows the AAPHelp web application interface. At the top, there is a header bar with "YCHI. University of Leeds" on the left and "Acute Abdominal Pain System © 2001-2004" on the right. Below the header, a navigation menu includes links for "Home", "Select Patient", "New Patient", and "Logout". The version number "v1.0.1.2" is displayed in the top right corner. The main content area is divided into two columns. The left column features the "AAPHelp" logo in large blue letters, followed by the subtitle "Decision Support in Acute Abdominal Pain". Below this, a paragraph states: "Acute Abdominal Pain is a difficult clinical area which causes problems for clinicians world wide." Another paragraph explains: "The purpose of AAPHelp is to give decision support based on clinical evidence and 'best practice' from the UK and Europe." A login section indicates "Not logged in." and provides input fields for "Username" and "Password", along with a "Login" button. The right column contains a list of links: "About AAPHelp", "What is AAPHelp?", "Why is AAPHelp Needed?", "What does AAPHelp do?", "Does AAPHelp Help?", "How to use AAPHelp", and "YCHI Home Page".

YCHI. University of Leeds

Acute Abdominal Pain System © 2001-2004

v1.0.1.2

• Home • [Select Patient](#) • New Patient • Logout

AAPHelp

Decision Support in Acute Abdominal Pain

Acute Abdominal Pain is a difficult clinical area which causes problems for clinicians world wide.

The purpose of AAPHelp is to give decision support based on clinical evidence and "best practice" from the UK and Europe.

Not logged in.

Username

Password

[About AAPHelp](#)

[What is AAPHelp?](#)

[Why is AAPHelp Needed?](#)

[What does AAPHelp do?](#)

[Does AAPHelp Help?](#)

[How to use AAPHelp](#)

[YCHI Home Page](#)

MYCIN (1975)

- „Szkielet” systemu wypełniony wiedzą dotyczącą rozpoznawania i leczenia infekcji bakteryjnych
- Model decyzyjny – reguły definiowane przez ekspertów
- Zaawansowany mechanizm wnioskowania – wnioskowanie w tył (od hipotezy do przesłanek), łączenie wielu reguł
- Możliwość uzasadniania wyboru poszczególnych reguł (reguły w formie „maszynowej” oraz tekstowej)
- Uwzględnienie niepewności związanej z regułami oraz z danymi (→ *confidence factors*)
- Nigdy nie wykorzystany w praktyce klinicznej

Rule507

IF:	1) The infection that requires therapy is meningitis,
	2) Organisms were not seen on the stain of the culture,
	3) The type of infection is bacterial,
	4) The patient does not have a head injury defect, and
	5) The age of the patient is between 15 years and 55 years
THEN:	The organisms that might be causing the infection are diplococcus-pneumoniae and neisseria-meningitidis

MYCIN – przykładowa sesja

Możliwość prowadzenia interakcji z systemem

In this series, how many of the cultures were positive of the e.coli (ORGANISM-1)? *(typical system prompt)*

**** WHY** *(request from user to determine motivation for question)*

[i.e. WHY is it important to determine the number of cultures which were positive for the organism?] *(system's rephrasing of the WHY question, and answer)*

[1.0] This will help to determine whether there is significant disease associated with this occurrence of the organism.
It has already been established that
[1.1] the culture was taken from a sterile source
[1.2] the number of cultures in the series is greater than 2
Therefore, if
[1.3] the number of cultures which were positive for ORGANISM-1 is greater than 2
Then there is suggestive evidence (.5) that there is significant disease associated with this occurrence of the e.coli (ORGANISM-1).
[RULE049]

**** WHY** *(repeated WHY to determine relevance of previous explanation)*

[i.e. WHY is it important to determine if there is significant disease associated with this occurrence of the organism?]

[2.0] This will help to determine a diagnosis for which the infection should be treated.
It has already been established that
[2.1] the infection is not one of: primary bacteremia, meningitis
[2.2] for some current culture of the patient it is true that the site of the culture is blood
Therefore, if
[2.3] there is significant disease associated with this occurrence of the organism
Then
It is definite (1.0) that the diagnosis for which the infection should be treated is secondary-bacterimia
[RULE103]


MYCIN – Confidence Factors

- Zmiana przekonania o prawdziwości hipotezy H przy założeniu przesłanki E (*evidence*) – $CF(H, E) \in [-1, +1]$
- CF także dla danych wprowadzonych przez użytkownika

$$CF(H) = CF(H, E) \cdot CF(E)$$

- Konieczność wyznaczania CF dla sieci wnioskowania


$$CF(H, E1 \wedge E2) = \begin{cases} CF(H, E1) + CF(H, E2) - CF(H, E1)CF(H, E2) & CF > 0 \\ CF(H, E1) + CF(H, E2) + CF(H, E1)CF(H, E2) & CF < 0 \\ \frac{CF(H, E1) + CF(H, E2)}{1 - \min\{|CF(H, E1)|, |CF(H, E2)|\}} & otherwise \end{cases}$$



$$CF(H, E1) = CF(H, E2) \cdot \max\{0, CF(E2, E1)\}$$

Dxplain[®] DXplain (1987-teraz)

- System do wspomagania diagnozy w różnego typu problemach (2,4 tys. chorób związanych z 5 tys. objawów)
- Prezentowanie listy możliwych diagnoz dla danego pacjenta (także ich opisy oraz istotne publikacje)
- Model decyzyjny uwzględniający *istotność objawów, siłę związku objawów z chorobami oraz częstotliwość ich współwystępowania*
- Hierarchia rozważanych pojęć (np. objawów)
- Parametry modelu opracowane na podstawie studiów literaturowych i wiedzy eksperckiej (→ 13 osób)
- System dostępny dla zarejestrowanych użytkowników (lekarze, studenci medycyny) jako aplikacja webowa oraz usługa



DXplain – przykładowa sesja

The screenshot shows the DXplain Case Analysis interface. At the top, there's a header with the DXplain logo, the title "Case Analysis", and links for "Search DXplain", "Help", "Feedback", and "Exit". Below the header, there are dropdown menus for "Adult, Young (18 to 40 yrs)", "Male", and "> 4 weeks".

The main interface is divided into several sections:

- Finding Lookup:** A search bar with "weight loss" entered. Below it, a list of suggestions: "weight loss", "weight loss, severe", and "weight loss, slight".
- Case Findings:** A list of findings: "weight loss", "Mexican", and "hip pain". Each finding has a red 'X' icon and a green checkmark icon.
- Submit:** A green button labeled "Submit".
- OPTIONAL - Are these findings present?:** A section with four rows of radio buttons and text: "glycosuria", "insulin increase", "ketoacidosis, diabetic", and "polyneuropathy". Each row has radio buttons for "Y", "N", and "Unk".
- Common Diseases:** A list of diseases: "Diabetes mellitus type 2", "Diabetes mellitus type 1", "Adverse effects of medication", "Fluorine and compounds poisoning, chronic", "Non-alcoholic fatty liver disease", "Osteoporosis", "Tuberculosis, pulmonary", "Endogenous depression", "Neuropathy, diabetic", and "Emphysema, pulmonary".
- Rare Diseases:** A list of diseases: "Amebiasis", "Malaria", "Trichloroethylene poisoning", "Blastomycosis, North American", "Chagas disease", "Coccidioidomycosis", "Aseptic necrosis of hip", "Larva migrans, visceral", "Leishmaniasis, American cutaneous", and "Pinta".
- Legend:** A section at the bottom right with four levels of evidence: "++ sufficient evidence to strongly support this DX", "+ sufficient evidence to support this DX", "sufficient evidence to suggest this DX", and "-- minimal evidence to suggest this DX".

Annotations with blue arrows and text boxes explain the interface:

- A blue arrow points from the "weight loss" finding in the "Case Findings" list to the "weight loss" suggestion in the "Finding Lookup" section. A text box says: "As findings are selected, they appear in the Case Findings Window."
- A blue arrow points from the "glycosuria" finding in the "OPTIONAL - Are these findings present?" section to the "Common Diseases" list. A text box says: "DXplain displays lists of Common and Rare diseases that are associated with some or all of the case findings. These lists are dynamically refreshed each time a new case finding is entered."



ISABEL (2001-teraz)

- System do wspomagania diagnozy w różnych problemach – ok. 11 tys. diagnoz i 4 tys. leków
- Wiedza ekspercka pochodząca z publikacji i podręczników medycznych – specjalizowane indeksowanie i wyszukiwanie
- Możliwość udzielania dodatkowych informacji – fragmenty artykułów i książek związanych z daną sugestią
- W testach (200 przypadków) trafność diagnostyczna na poziomie 91-95% (poprawna diagnoza na liście)
- System udostępniony komercyjnie (aplikacja webowa i mobilna) dla wybranych użytkowników

ISABEL – przykładowa sesja

neonate (0-28d)
female

apnea episodes
cough

enter clinical features synonyms

age*

gender ☒ female ☐ male

Refine search:

travel

history:

show me:

☒ diagnoses

☐ causative drugs

☐ bioterrorist agents

Enter clinical features, no negatives, no numbers:

+ add a clinical feature

[get checklist](#)

[clear search](#)

Isabel is not meant to replace your clinical judgment.

diagnoses drugs

[show 10](#) [show all](#)

Pertussis

Why did this diagnosis come up?

We matched the terms: apnea | apneic | coughing | cough | coughs

Degree of match between query entered and Isabel database (Not clinical probability): 100%

☒ Bronchiolitis	☐ ? RESP
☐ Viral Pneumonia	☐ ? RESP
☐ Influenza Viruses	☐ ? INFE
☐ Chiari Malformation	☐ ? NEURO
☒ Aspiration Syndromes	☐ ? RESP
☒ Neonatal Pneumonia	☐ ? RESP
☐ Adenoviral Infections	☐ ? INFE
☐ Bacterial Pneumonia	☐ ? RESP
☒ Aortic Arch Anomalies	☐ ? CARDIO


[view all](#)

Click diagnosis for evidence-based content.

feedback: [submit](#)

We matched the terms: apnea | apneic | coughing | cough | coughs

Degree of match between query entered and Isabel database (Not clinical probability): 100%




IBM Watson (2006-teraz)

- Początkowo system do analizy tekstu (odpowiedzi na pytania zadawane w języku naturalnym → teleturniej Jeopardy (2011))
- Obecnie (?) analiza (i wizualizacja) danych w innych formatach (np. obrazy, dane genetyczne) za pomocą uczenia głębokiego (*deep learning*) → **cognitive computing**
- Specjalna wersja systemu dostosowana do zastosowań i problemów klinicznych (onkologia, choroby genetyczne,...)
- Entuzjastyczne przyjęcie w amerykańskim środowisku medycznym (AMIA 2011: “return of AI to medicine...”)
- Wykorzystanie otwartych projektów Apache (UIMA oraz Lucene) do analizy danych tekstowych

IBM Watson – przetwarzanie zapytań

Wstępne przygotowanie źródeł danych (ręczna selekcja + automatyczne przetwarzanie)

Łączenie podobnych odpowiedzi (różne formy, podobna treść) i ocena /porządkowanie ostatecznych odpowiedzi





IBM Watson – przykładowa sesja

Lyme disease = borelioza

The patient has Lyme disease. The treatment plan is antibiotics.
The patient is pregnant. She has a penicillin allergy.

What is the recommended antibiotic prescription for Lyme disease in a woman during pregnancy with penicillin allergy?




IBM Watson – usługi

Watson Platform Is Growing

Watson's APIs are the cognitive building blocks that harness our data.

Message Resonance	Entity Extraction
Face Detection	Tone Analyzer
Natural Language Classifier	Personality Insights
Speech to Text	Taxonomy
Text to Speech	Author Extraction
Language Translation	Concept Tagging
Language Detection	Relationship Extraction
Sentiment Analysis	Relationship Extraction
Retrieve and Rank	Feed Detection
Image Link Extraction	Keyword Extraction
Tradeoff Analytics	Visual Recognition
	Image Tagging
	Text Extraction



<https://www.ibm.com/watson/developercloud/services-catalog.html>

<https://conversation-demo.mybluemix.net/>

<https://personality-insights-livedemo.mybluemix.net/>

<https://www.ibm.com/watson/developercloud/visual-recognition.html>

<https://natural-language-understanding-demo.mybluemix.net/>



Symptomate (2013-teraz)

- System do wspomagania diagnozy, wstępnej kwalifikacji do wybranych programów leczenia oraz do wyszukiwania odpowiednich (lokalnych) specjalistów
- System wykorzystuje sieci bayesowskie (ok. 10 modeli) oraz dodatkowe reguły eksperckie (np. sterujące dobozem i kolejnością zadawanych pytań)
- Zaawansowany algorytm łączenia sieci bayesowskich w celu zapewnienia krótkiego czasu odpowiedzi (ok. 1 sekundy)
- System udostępniony za darmo użytkownikom „niemedycznym” (aplikacja webowa i mobilna)

HELP (1975-teraz)


- Wspomaganie decyzji zintegrowane z systemem typu *elektroniczny rekord pacjenta*
- Reguły „monitorujące” reprezentowane jako medyczne moduły logiczne (*medical logic modules*, *MLM*) → 1 reguła = 1 moduł
 - Reguły zdefiniowane przez ekspertów
 - Reguły wyzwalane zdarzeniami (pojawienie się nowych danych)
 - Reguły mogły ostrzegać (np. o interakcjach między lekami), generować raporty lub przypomnienia, dokonywać obliczeń i je raportować
- MLM zapisane przy wykorzystaniu *Arden Syntax* – język opisu reguł klinicznych (ale **problem z {}**)
- System nadal utrzymywany i rozwijany (HELP II)

HELP

- Przykład MLM –
ostrzeżenie o uczuleniu
na penicylinę

```
penicillin_order :=  
  
    event {medication_order  
  
        where class = penicillin};  
  
/* find allergies */  
penicillin_allergy :=  
  
    read last {allergy  
  
        where agent_class = penicillin};  
  
;;  
  
evoke: penicillin_order ;;  
  
logic:  
  
If exist (penicillin_allergy) then conclude true;  
  
endif;  
  
;;  
  
action:  
  
write  
  
"Caution, the patient has the following allergy to penicillin documented:"  
  
|| penicillin_allergy ;;
```


Arden Syntax – reguły rozmyte




- **Usual Arden Syntax**

```
fever_limit := 38;  
temperature := 37.9;
```

```
message := "patient has no fever";  
IF temperature > fever_limit THEN  
    message := "patient has fever";  
END IF
```

- Result message: "patient has no fever"
- Borderline case is not detected



- **Fuzzy Arden Syntax**

```
fever_limit := FUZZY SET (37.5,0) , (38,1);  
temperature := 37.9;
```


```
message := "patient has no fever";  
IF temperature > fever_limit THEN  
    message := "patient has fever";  
END IF
```

- Result message: "patient has fever" (with applicability 0.8)

SEBASTIAN (2005)

System for Evidence-Based Advice through Simultaneous Transaction with an Intelligent Agent across a Network

- Infrastruktura oparta na usługach sieciowych i pozwalająca na budowę różnorodnych SWDK



- Specyficzna wiedza kliniczna „zaszyta” w EKM (*executable knowledge module*)
- Wykorzystanie standardów (HL7 RIM, UMLS)

- Kontynuacja w projekcie OpenCDS – otwartej implementacji zaproponowanej infrastruktury

OpenCDS (2011-teraz)



The screenshot shows the OpenCDS website homepage. At the top is the 'OpenCDS' logo and a search bar. Below is a navigation menu with links: Home, The Solution, Featured Collaborators, Acknowledgements, Join the Community, News, and Contact Us. The main banner features the text 'OPEN CLINICAL DECISION SUPPORT (OPENCDS) TOOLS AND RESOURCES!' with a background image of interlocking puzzle pieces. Below the banner is a 'JOIN THE COMMUNITY' button. The page is divided into three columns: 'What Is OpenCDS?', 'Who Is Involved?', and 'How Can I Learn More?'. The 'What Is OpenCDS?' section describes the project as a multi-institutional effort to develop open-source CDS tools. The 'Who Is Involved?' section mentions Dr. Kensaku Kawamoto as the founder. The 'How Can I Learn More?' section provides instructions on how to register as a collaborator.

OpenCDS

Home The Solution Featured Collaborators Acknowledgements Join the Community News Contact Us

OPEN CLINICAL DECISION SUPPORT (OPENCDS) TOOLS AND RESOURCES!

A consortium effort, connecting collaborators together across the healthcare continuum to improve patient outcomes through the effective use of standards-based, open source clinical decision support.

JOIN THE COMMUNITY >

What Is OpenCDS?

OpenCDS is a multi-institutional, collaborative effort to develop open-source, standards-based clinical decision support (CDS) tools and resources that can be widely adopted to enable CDS at scale. OpenCDS is licensed under the Apache 2 license.

Now supporting **HL7's FHIR®**!

Who Is Involved?


OpenCDS was founded by Dr. Kensaku Kawamoto, MD, PhD, MHS who is a faculty member at the University of Utah Department of Biomedical Informatics and a co-chair of the HL7 CDS Work Group. Please see the [Featured Collaborators](#) page for more information on the members of the OpenCDS community.

How Can I Learn More?

Please [Register to be a Collaborator](#) (gives access to Wiki and software releases)

or

Contact Dr. Kensaku Kawamoto, MD, PhD, MHS [[Contact Us](#)]



<http://www.opencds.org>

OpenCDS


- Obsługiwane standardy

- interfejs HL7/OMG DSS
- HL7 vMR (*virtual medical record*) i FHIR

- Wbudowane narzędzia

- JBoss Drools – wnioskowanie regułowe (forward, backward)
- JBoss jBPM – obsługa modeli procesów (biznesowych)
- Appleton DTS – obsługa terminologii

Metadata discovery → odkrywanie dostępnych usług i powiązanych modułów wiedzy
Query → sprawdzanie właściwości/wymagań poszczególnych modułów wiedzy
Evaluation → zastosowanie wskazanego modułu do danych pacjenta (wypracowanie sugestii)




HL7 Virtual Medical Record (vMR)

- Model danych istotnych z punktu widzenia wspomagania decyzji klinicznych (ujednolicenie dostępu do danych)
- Dane demograficzne, kliniczne oraz zalecenia decyzyjne
- Bazuje na HL7 v3, ale wprowadza uproszczenia
 - rezygnacja z atrybutów strukturalnych (`mood code`, `negation`) → odpowiednie nazwy klas (`AppointmentRequest`, `MissedAppointment`)
 - ograniczenie zagnieżdżenia modeli – np. `problem` i podrzędne obserwacje określające czas jego występowania
 - rezygnacja z `nullFlavor` – brakujących danych nie ma


HL7 vMR – wybrane diagramy klas



vmr - (Class diagram)



extendedvMRTypes - (Class diagram)



WYTYCZNE I ALGORYTMY KLINICZNE

Wytyczne i algorytmy kliniczne

- Ustandaryzowanie opieki (taki sam sposób postępowania niezależny od „kontekstu”)
 - Upowszechnienie medycyny opartej na dowodach (*evidence-based medicine*)/wynikach aktualnych badań
 - Poprawa zgodności ze standardami, jakości opieki i ograniczenie kosztów (unikanie niepotrzebnych zabiegów)
-
- Brak ustandaryzowanej reprezentacji (zwłaszcza algorytmów)
 - Skupienie się na pojedynczych problemach

Reprezentacja wytycznych i algorytmów

Poziom sformalizowania


- Modele tekstowe (→ wytyczne)
 - Ograniczone do opublikowanego tekstu
 - Dodatkowa informacja (np. znaczniki) uzupełniająca tekst
- Modele wykorzystujące sieci zadań (→ algorytmy)
 - Interpretowane przez klinicystę
 - Przeznaczone do (semi-)automatycznej analizy i wykonania przez system komputerowy

Modele tekstowe: GEM (Guideline Elements Model)



<http://gem.med.yale.edu>

- Zestaw znaczników XML (100+) do oznaczania wybranych fragmentów dokumentu



- Narzędzia pozwalających na oznaczanie i przeglądanie dokumentów
- Oficjalny standard ASTM International
- Możliwość automatycznego przetwarzania algorytmów w formie tekstu (wykrywanie reguł)

Modele sieci zadań (task-network models)

- Algorytm w formie grafu przedstawiającego kroki postępowania i zależności kolejnościowe między nimi
- Podstawowe typy elementów/kroków
 - Zebranie danych
 - Podjęcie decyzji
 - Wykonanie działania klinicznego
 - Wywołanie innego algorytmu
- Wiele reprezentacji wykorzystujących model sieci zadań o różnym stopniu szczegółowości i złożoności
- Rosnąca popularność związana z możliwością integracji z systemami szpitalnymi (np. elektroniczną kartą pacjenta)


PROforma i OpenClinical.net

- PROforma
 - projekt naukowy (Cancer Research UK, 1992-teraz)
 - projekt komercyjny Arezzo (InferMed/Elsevier)
- OpenClinical.net
 - Internetowe repozytorium algorytmów klinicznych w PROforma
 - Wewnętrzny proces recenzji i weryfikacji przed powszechnym udostępnieniem algorytmu
 - Możliwość uruchamiania udostępnionych algorytmów bezpośrednio na stronie



"... society's growing ability to mobilise knowledge from different fields and sources is beginning to show the potential of a 'knowledge commons' in healthcare: an open system of knowledge with researchers, clinicians, patients, their families and communities all involved in capturing, refining and utilising a common body of knowledge in real time" NESTA report, 2013

Przykład – algorytm dla obrażeń brzucha




Definicja kroku decyzyjnego

Szczegółowa specyfikacja danych do zebrania

Enquiry Specific Attributes			
Sources			
Name ▼	Data Definition	Status	Default Value
cisnienie_skurczowe	integerType	Mandatory	
gcs	integerType	Mandatory	
mechanizm_urazu	mechanizm_urazu	Mandatory	
morfologia	morfologia	Mandatory	
tetno	integerType	Mandatory	

Możliwość określenia przesłanek za/przeciw poszczególnym decyzjom i ich wag (sił)



Stan pacjenta? Decision Specific Attributes

Candidates Sources Arguments Decide Properties

Candidates

stan_niestabilny

Arguments

New Argument

Condition tetno < 60 OR tetno > 120

Name stan_niestabilny_arg_01

Caption

Description

Metaprops

Support

Weight 2


Update

Argument list

- stan_niestabilny_arg_01 {tetno < 60 OR tetno > 120 } (2)
- stan_niestabilny_arg_02 {(cisnienie_skurczowe < 90) OR (cisnienie_skurczowe > 160) } (2)
- stan_niestabilny_arg_03 {gcs =< 12 } (2)
- stan_niestabilny_arg_04 {morfologia = "niska"} (1)


Edit Delete

Nadzorowane podejmowanie decyzji



A screenshot of a 'Data Entry' window. It contains several input fields: 'Morfologia' with radio buttons for 'niska', 'srednia', and 'wysoka'; 'GCS' with a text field containing '13'; 'Mechanizm urazu' with radio buttons for 'nieprzenikajacy' and 'przenikajacy'; 'Tętno' with a text field containing '125'; and 'Ciśnienie skurczowe' with a text field containing '110'. At the bottom are 'Commit' and 'Cancel' buttons.

Wprowadzone dane
pacjenta



A screenshot of a 'Confirmable Decisions' window. It has a title bar 'Confirmable Decisions'. Below it is a blue header 'Stan pacjenta?'. The main area is empty. At the bottom, there is a 'Candidates' section with two green circular icons and text: 'Stan stabilny lub niepewny' and 'Stan niestabilny'. At the very bottom are 'Commit' and 'Details...' buttons.

Brak jednoznacznego
wskazania decyzji (obie są
możliwe)

Nadzorowane podejmowanie decyzji

stan_pacjenta

decision properties description

Name: stan_pacjenta
Caption: Stan pacjenta?

state: in progress (confirmable)
cycle number: 1 (1)

Parameters

Caption/Name	Value
--------------	-------

Candidates

- Stan stabilny lub niepewny
- Stan niestabilny

candidate properties description

Name: stan_stabilny_lub_niepewny
Caption: Stan stabilny lub niepewny

Arguments

- stan_stabilny_lub_niepewny_arg_01
- stan_stabilny_lub_niepewny_arg_02**
- stan_stabilny_lub_niepewny_arg_03
- stan_stabilny_lub_niepewny_arg_04

argument properties description

Name: stan_stabilny_lub_niepewny_arg_02
Caption:

Expression: (cisnienie_skurczowe >= 90) AND (cisnienie_skurczowe <= 160)

Za stanem stabilnym lub niepewnym przemawia ciśnienie skurczowe i GCS

Za stanem niestabilnym przemawia tętno i morfologia

stan_pacjenta

decision properties description

Name: stan_pacjenta
Caption: Stan pacjenta?

state: in progress (confirmable)
cycle number: 1 (1)

Parameters

Caption/Name	Value
--------------	-------

Candidates

- Stan stabilny lub niepewny
- Stan niestabilny**

candidate properties description

Name: stan_niestabilny
Caption: Stan niestabilny

Arguments


- stan_niestabilny_arg_01**
- stan_niestabilny_arg_02
- stan_niestabilny_arg_03
- stan_niestabilny_arg_04

argument properties description

Name: stan_niestabilny_arg_01
Caption:

Expression: tetno < 60 OR tetno > 120

Nadzorowane podejmowanie decyzji



W następnym kroku system zaleci wykonanie badań obrazowych (zgodnie z algorytmem)

Możliwość wskazania dowolnej decyzji i nadpisania sugestii algorytmu/systemu

TESTOWANIE SWDK

Metody

- Testowanie takie samo, jak w przypadku nowych leków i procedur – losowe badanie kontrolowane (*randomized controlled trial*)
- Losowy podział populacji pacjentów na dwie grupy
 - Grupa badana (w której stosowana jest „interwencja”, czyli SWDK)
 - Grupa kontrolna
- Porównanie wyników dla przyjętych kryteriów w obu grupach

System MET-AP

- Mobilny system do wspomagania diagnozowania ostrego bólu brzucha u dzieci
- Model decyzyjny składający się z reguł decyzyjnych odkrytych z historycznych danych (teoria zbiorów przybliżonych)
- Testy kliniczne w Children's Hospital of Eastern Ontario (CHEO)



„Ottawa Abdominal Pain Rule”


- The diagnosis may be *appendicitis* and the management maybe *consult* when one of the following occurs:
 - A male patient experiences right lower quadrant abdominal pain and his white blood cell count is above 20000/mm³
 - A male patient experiences right lower quadrant abdominal pain lasting between 4h and 24h, combined with frequent (more than 3 times) vomiting
 - ...
- The diagnosis maybe *resolution* and the management maybe *discharge* when one of the following occurs:
 - A patient experiences abdominal pain (neither right lower quadrant nor suprapubic) lasting between 4h and 24h
 - A patient experiences abdominal pain (neither right lower quadrant nor suprapubic) of intermittent character
 - ...

Testy kliniczne MET-AP

- Cele
 - Porównanie trafności decyzji podejmowanych przez klinicystów i przez system
 - Porównanie zgodności danych zbieranych przez doświadczonych lekarzy i przez stażystów
- Ograniczenia
 - Zablokowana możliwość prezentacji decyzji sugerowanej przez system przy pacjencie (względy etyczne)
 - Z punktu widzenia lekarza ograniczenie roli systemu do mobilnej elektronicznej karty pacjenta

Model postępowania w izbie przyjęć

**Canadian Triage
Acuity Scale (CTAS)**
CTAS1 – natychmiast
CTAS2 – ≤ 15 min.
CTAS3 – ≤ 30 min.
CTAS4 – ≤ 1 godz.
CTAS5 – ≤ 2 godz.



Dostępne narzędzia decyzyjne

- Skale i systemy punktowe – MANTRELS
- Wymagają zebrania wartości wszystkich użytych atrybutów
- Nie są używane w CHEO

Table 1
MANTRELS Scoring System


Characteristic	Points
Migration of pain to right lower quadrant	1
Anorexia	1
Nausea and vomiting	1
Tenderness in right lower quadrant	2
Rebound pain	1
Elevated temperature	1
Leukocytosis	2
Shift of white blood cell count to left	1
Total	10

Recommendations:


Score < 5	<i>Appendicitis unlikely</i>
Score 5 or 6	<i>Appendicitis possible</i>
Score 7 or 8	<i>Appendicitis likely</i>
Score 9 or 10	<i>Appendicitis highly likely</i>

Source: Alvarado A. A practical score for the early diagnosis of acute appendicitis. *Ann Emerg Med.* 1986;15:557-564.

Przebieg testów



Uczestnictwo w testach



Zgodność obserwatorów

- Zgodność wartości atrybutów – współczynnik *kappa*
- Istotność atrybutów z punktu widzenia podejmowanych decyzji – *regresja logistyczna*

Atrybut	Zgodność	Istotność – lekarze	Istotność – stażyści
Czas trwania bólu	+++		
Obrona mięśniowa	+	✓	✓
Poprzednia wizyta	++		
Bolesność uciskowa	++	✓	✓
Przemieszczanie się bólu	++		
Lokalizacja bólu	++	✓	
Lokalizacja bolesności	++		✓
Temperatura	+++		
Typ bólu	++	✓	
Wymioty	+++	✓	
WBC	+++		

Przyczyny niezgodności

- Brak wystarczającego doświadczenia
- Zmiana stanu chorego między badaniami
- Niekonsekwentne odpowiedzi udzielane przez chorego lub opiekunów
- Stażyści podejmowali decyzje na podstawie danych, których nie potrafili w wiarygodny sposób zebrać

Trafność diagnostyczna

Lekarze

	Odesłanie	Obserwacja	Konsultacja
Odesłanie	248	85	15
Obserwacja	16	39	6
Konsultacja	1	13	34

MET-AP/Lekarze

	Odesłanie	Obserwacja	Konsultacja
Odesłanie	279	39	30
Obserwacja	38	18	5
Konsultacja	12	3	33

Stażyści

	Odesłanie	Obserwacja	Konsultacja
Odesłanie	166	80	17
Obserwacja	11	24	3
Konsultacja	2	13	23

MET-AP/Stażyści

	Odesłanie	Obserwacja	Konsultacja
Odesłanie	209	31	23
Obserwacja	23	7	8
Konsultacja	14	5	19

Przyczyny błędów diagnostycznych

- Niewystarczający opis przypadków (*tacit knowledge*)
- Rozdrobnienie klas decyzyjnych (zwłaszcza klasy *obserwacja*)
- Niezrównoważenie klas decyzyjnych w danych użytych do odkrywania reguł (dane niezrównoważone)
 - *Odeślanie* – 57.8%
 - *Obserwacja* – 15.1%
 - *Konsultacja* – 27.1%

PERSPEKTYWY I WYZWANIA DLA SWDK

Perspektywy i wyzwania

- Lepszy („mniej przeszkadzający”) interfejs użytkownika
- Wykorzystanie informacji tekstowej w SWDK
- Podsumowywanie dostępnej informacji o pacjencie
- Łączenie wytycznych i algorytmów klinicznych w przypadku pacjentów z wieloma chorobami (*multimorbidities*)
- Analiza baz danych w celu identyfikacji nowych zaleceń oraz algorytmów klinicznych
- Nowe architektury dla SWDK pozwalające na współdzielenie modułów i usług oraz internetowe repozytoria z modułami
- Opracowanie i rozpowszechnienie standardy reprezentacji wiedzy klinicznej (modeli decyzyjnych) oraz danych

Stosowanie wielu wytycznych klinicznych

- Wytyczne kliniczne (*clinical practice guidelines, CPG*) opracowywane są dla specyficznych problemów (schorzeń)
- 75% pacjentów 65+ cierpi na 2+ schorzenia, a koszty ich opieki są 5.5 raza wyższe niż dla pacjentów z jedną chorobą
- Leczenie takich pacjentów wymaga stosowania i uzgadniania wielu wytycznych klinicznych
 - Wykrywanie konfliktów między wytycznymi (niekorzystne interakcje)
 - Usuwanie/osłabianie konfliktów poprzez modyfikację wytycznych
- Brak mechanizmów uzgadniania jest jedną z głównych przeszkód dla stosowania algorytmów klinicznych w praktyce


Uzgadnianie wytycznych

- Podejścia manualne i pół-automatyczne
 - Ręczna lub automatyczna analiza wytycznych
 - Ręczna modyfikacja algorytmów przez ekspertów
- Podejścia automatyczne
 - Łącznie kilku (jednorodnych) algorytmów w jeden z uwzględnieniem ewentualnych niezgodności/interakcji
 - Wykrywanie niezgodności między algorytmami i ich „lokalna” modyfikacja bez łączenia




Automatyczne uzgadnianie wytycznych

- Wykorzystanie logiki do reprezentacji wytycznych oraz wiedzy dziedzinowej związanej z uzgadnianiem wytycznych
- Wykrywanie konfliktów przez sprawdzanie spójności teorii opisującej aktualną sytuację (pacjent + stosowane wytyczne)
- Naprawienie konfliktów poprzez modyfikację teorii



Potencjalne wykorzystanie w praktyce

- Centre d'Excellence Clinique en Multimorbidités de l'Hôpital Montfort (CECMM) w Ottawie



PODSUMOWANIE


Podsumowanie

- **SWDK jako asystent, a nie „komputerowy lekarz”** (ale jak testować taki system?)
- Doświadczenie i intuicja wciąż niezbędne (np. przy pozyskiwaniu danych)
- Istotny aspekt ludzki – SWDK może początkowo stanowić barierę między pacjentem a lekarzem

„A bit awkward to use at the bedside b/c I don't care to have my nose in the computer as I'm trying to interact with patients (for the same reason I don't take full notes during interaction; I write afterwards at the nursing station).

(użytkownik systemu MET-AE)

- Rosnąca popularność systemów wykorzystujących wiedzę „książkową” i tekstową oraz oferujących funkcje edukacyjne



Przyspieszony puls, poty, płytki oddech. Komputer twierdzi, że ma pan kamienie żółciowe.