

Univerzita Karlova v Praze
Filozofická fakulta
Ústav informačních studií a knihovnictví

Studijní program: informační studia a knihovnictví

Studijní obor: informační studia a knihovnictví

Mgr. Zdeněk Rybář

Aplikace a vývojové trendy expertních systémů v medicíně

Rigorózní práce

Konzultant rigorózní práce Doc. RNDr. Jiří Ivánek, CSc.

Praha 2008

Prohlášení:

Prohlašuji, že jsem rigorózní práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje.

V Praze, 20. srpna 2008

.....

podpis rigorózanta

Identifikační záznam

RYBÁŘ, Zdeněk. *Aplikace a vývojové trendy expertních systémů v medicíně* [*Applications and development trends of expert systems in Medicine*]. Praha, 2008. 133 s. Rigorózní práce. Univerzita Karlova v Praze, Filozofická fakulta, Ústav informačních studií a knihovnictví 2008. Vedoucí rigorózní práce Doc. RNDr. Jiří Ivánek, CSc.

Abstrakt:

Předmětem této rigorózní práce je oblast expertních/znalostních systémů (ES/ZS) v oblasti medicíny. Cílem rigorózní práce je zpracovat a předložit přehled různých typů systémů v oblasti medicíny a zdravotnictví, přiblížit současnou situaci a odvodit možné trendy obecného vývoje ES/ZS včetně praktických příkladů.

Práce je členěna do čtyřech tematických celků. První se zabývá obecnou teorií na poli umělé inteligence a expertních/znalostních systémů, vymezuje základní pojmy, teoretické aspekty a nastiňuje možný budoucí vývoj v dané oblasti. Druhý celek se věnuje specifickým rysům oblasti medicíny ve vztahu k ES/ZS, které jsou ve své podstatě odlišné oproti jiným vědním oborům. Tato část současně potvrzuje rostoucí trend využívání expertních systémů v lékařské informace. Třetí část rozsáhle popisuje konkrétní aplikace expertních/znalostních systémů v lékařství a rovněž se zabývá specifickou oblastí případového usuzování. Čtvrtá část je věnována vývojovým trendům na poli ES/ZS při zohlednění změn, které lze předvídat v horizontu 5 let ve vztahu k vývoji ICT a aplikací v medicíně. Následuje výběr několika konkrétních příkladů, které demonstrují úspěšnost užívání systémů v praxi a lze na nich ukázat možné nasazení v budoucích aplikacích.

Klíčová slova: expertní systémy, znalostní systémy, EHR, CME, lékařská informatika, umělá inteligence, reprezentace znalostí, báze znalostí, inferenční mechanismus, případové usuzování

OBSAH

PŘEDMLUVA

<u>I. Úvod.....</u>	<u>11</u>
<u>II. Umělá inteligence a expertní systémy v obecném pojetí.....</u>	<u>12</u>
1.1. Umělá inteligence.....	12
1.1.1. Úvod.....	12
1.1.1.1. Turingův test.....	13
1.1.1.2. Eliza.....	13
1.1.1.3. Čínská komora.....	13
1.1.2. Vybrané definice umělé inteligence.....	14
1.1.2.1. Definice Minského.....	14
1.1.2.2. Definice Richové.....	14
1.1.2.3. Definice Kotkova.....	15
1.1.3. Historie umělé inteligence a přechod k expertním systémům.....	15
1.2. Expertní systémy (ES).....	17
1.2.1. Úvod.....	17
1.2.2. Obecná historie ES.....	17
1.2.3. Struktura ES.....	19
1.2.4. Charakteristické vlastnosti.....	20
1.2.5. Úlohy vhodné pro ES.....	22
1.2.6. Rozdělení ES s ohledem na řešené úlohy.....	22
1.2.6.1. Diagnostické systémy.....	23
1.2.6.2. Plánovací systémy.....	24
1.2.6.3. Hybridní systémy.....	25
1.2.6.4. Prázdné systémy.....	25
1.2.7. Jazyky expertních systémů.....	26
1.2.8. Teoretické aspekty ES.....	27
1.2.8.1. Reprezentace znalostí.....	27
1.2.8.2. Řídící mechanismy.....	29
1.2.8.3. Neurčitá informace.....	31
1.2.9. Úloha komunikačního modulu v průběhu konzultace.....	32
1.2.10. Budoucnost expertních systémů.....	33
1.2.10.1. ES a jejich nedostatky a teoretické problémy.....	34
1.2.10.2. Perspektiva ES.....	36
1.2.10.3. Case-Based Reasoning.....	37
1.2.10.4. Lidské zdroje v expertních systémech.....	37
1.2.10.4.1. Expertní systémy a získávání znalostí.....	38
1.2.10.4.2. Získávání znalostí od expertů a případné nástrahy.....	38
1.2.10.4.3. Postoj znalostního inženýra ke znalostem.....	39
<u>III. Specifické rysy expertních systémů v medicíně</u>	<u>41</u>
1.3. Obecné aspekty medicíny ve vztahu k ES.....	41
1.3.1. Metody podpory rozhodování v medicíně.....	41
1.3.2. ES a prostředí v medicíně.....	43
1.3.2.1. Proč budovat expertní systémy v medicíně ?.....	45
1.3.2.2. Definice ES v medicíně.....	45

1.3.2.3. Obecné otázky při tvorbě ES.....	46
1.3.2.4. Reprezentace znalostí v medicíně.....	46
1.4. Formalizace lékařského problému.....	47
1.4.1. Obecné aspekty procesu formalizace.....	47
1.4.1.1. Modely zobrazení reality.....	48
1.4.1.2. Prostředky formálního popisu.....	49
1.4.1.3. Lékařský pojem a termín.....	50
1.4.1.3.1. Odborná terminologie.....	51
1.4.1.3.2. Klasifikace lékařských pojmů.....	51
1.4.2. Aplikace formálního popisu.....	53
1.4.2.1. Datové modely.....	53
1.4.2.2. Procedurální popis.....	53
1.4.2.3. Deklarativní popis.....	54
1.4.2.4. Báze znalostí.....	54
1.4.2.5. Typy klinických situací.....	54
1.4.3. Reprezentace znalostí v medicíně.....	54
1.4.3.1. Predikátová logika.....	56
1.4.3.2. Produkční pravidla.....	57
1.4.3.3. Sémantické sítě.....	58
1.4.3.4. Rámce.....	59
1.4.4. Lékařská báze znalostí.....	60
1.4.4.1. Specifika báze znalostí.....	60
1.4.4.2. Vyjadřování nejistoty.....	61
1.4.4.3. Funkce báze znalostí v expertním systému.....	62
1.4.4.4. Báze znalostí kritizujícího systému.....	63
1.4.5. Terapeutická pravidla.....	64
1.4.6. Rozhodovací procesy v medicíně.....	64
1.4.6.1. Metoda minimaxu.....	65
1.4.6.2. Bayesovské rozhodování.....	65
1.4.7. Znalostní systémy.....	67
1.4.7.1. Databázové systémy.....	67
1.4.7.2. Algoritmické systémy.....	67
1.4.7.3. Učící se systémy.....	68
IV. Aplikace expertních systémů v medicíně	69
1.5. Příklady expertních systémů v medicíně	69
1.5.1. MYCIN.....	69
1.5.2. ONCOCIN.....	72
1.5.3. INTERNIST-1.....	73
1.5.4. QMR (Quick Medical Reference).....	75
1.5.5. ILIAD.....	78
1.5.6. Další expertní systémy.....	81
1.5.7. Systémy klinických laboratoří.....	82
1.5.7.1. Cíle expertních systémů v laboratořích.....	83
1.5.7.2. Příklady laboratorních expertních systémů.....	84
1.6. Case-Based Reasoning (CBR).....	84
1.6.1. Specifikace oblasti medicíny.....	86
1.6.2. Výhody CBR v medicíně.....	87
1.6.3. Druhy CBR systémů v medicíně.....	88
1.6.3.1. Diagnostické.....	88
1.6.3.1.1. CASEY.....	88

1.6.3.1.2. FLORENCE.....	88
1.6.3.1.3. PSIQ.....	89
1.6.3.2. Plánovací.....	92
1.6.3.3. Vzdělávací.....	93
1.6.4. Reálné aplikace CBR v medicíně.....	93
1.6.4.1. GS.52 – Systém pro diagnózu dysmorfních syndromů.....	93
1.6.4.2. COSYL.....	94
1.6.4.3. ALEXIA.....	97
1.6.5. Stručný přehled dalších CBR systémů v medicíně.....	97
1.6.6. Budoucnost CBR v medicíně.....	98
<u>V. Vývojové Trendy na poli ES/ZS.....</u>	101
1.7. Oblasti uplatnění v budoucnu.....	101
1.7.1. Proces učení ve vztahu k medicíně.....	102
1.7.2. Lékařská informatika.....	102
1.7.3. Požadavky pacienta v oblasti e-zdraví (e-health).....	103
1.7.4. Vliv znalostí a dostupných informací ve vztahu pacient-lékař.....	104
1.7.5. E-learning v rámci CME (Continuous Medical Education).....	106
1.7.6. Cestovní elektronický zdravotní záznam (EHR).....	107
1.7.7. Systémy na předepisování léků.....	108
1.7.8. Další uplatnění.....	109
1.8. Vývojové trendy úspěšných aplikací znalostních systémů v medicíně...110	
1.8.1. Implementace inteligentního vzdělávacího modelu v klinické praxi.....	110
1.8.2. Vytvoření systému kontroly indikací a kontraindikací v procesu předepisování léků.....	116
1.8.3. ICONS - systém pro navržení optimální antibiotické léčby.....	121
1.8.4. TeCoMED – systém pro plošné předvídaní epidemií.....	125
<u>VI. Závěr.....</u>	129
<u>Seznam použité literatury.....</u>	130
<u>VII. Příloha.....</u>	136

Seznam obrázků:

Obrázek 1: Struktura expertního systému.....	20
Obrázek 2: Blokové schéma diagnostického expertního systému.....	24
Obrázek 3: Blokové schéma plánovacího expertního systému.....	25
Obrázek 4: Procedurální jazyky.....	26
Obrázek 5: Neprocedurální jazyky.....	27
Obrázek 6: Úloha komunikačního modulu v expertních systémech.....	33
Obrázek 7: zobrazení objektivní reality – stupně formalizace.....	48
Obrázek 8: Formální popis pojmu.....	50
Obrázek 9: Vztahy mezi komponenty expertního systému.....	55
Obrázek 10: Algoritmus příznaků při zánětech močového systému.....	57
Obrázek 11: Obecná síť.....	58

Obrázek 12: Sémantická síť s relacemi.....	59
Obrázek 13: Jednoduchý bayesovský model metastáze rakoviny.....	67
Obrázek 14: Uspořádání systému MYCIN.....	70
Obrázek 15: Vztah MYCINu k ostatním projektům na Stanfordské univerzitě.....	71
Obrázek 16: Dialog se systémem MYCIN.....	72
Obrázek 17: Menu z prostředí ONCOCIN.....	73
Obrázek 18: INTERNIST a jeho diagnostický algoritmus.....	75
Obrázek 19: QMR – screenshot s vybranou diagnózou.....	78
Obrázek 20: Záznam pacienta v průběhu konzultace se systémem ILIAD.....	80
Obrázek 21: Rozhraní simulačního módu ILIAD.....	80
Obrázek 22: Smyčka v podání CBR.....	85
Obrázek 23: Rozhodovací proces v medicíně.....	87
Obrázek 24: Kartotéční lístek/záznam v systému PSIQ.....	90
Obrázek 25: Záznam na kartě.....	90
Obrázek 26: Vybrané aspekty v různých oblastech.....	91
Obrázek 27: Reprezentace příkladu.....	91
Obrázek 28: Systém PSIQ.....	92
Obrázek 29: Koncept báze dat COSYL.....	95
Obrázek 30: Struktura komplikací v systému COSYL.....	96
Obrázek 31: Vývojový diagram konzultace v systému COSYL.....	96
Obrázek 32: Výpis z konzultace systému ALEXIA.....	97
Obrázek 33: Změna paradigmatu v oblasti péči o zdraví.....	103
Obrázek 34: Znalosti 20. století.....	104
Obrázek 35: Znalosti v 21.století.....	105
Obrázek 36: Nástroje pro práci se daty.....	106
Obrázek 37: Příklad e-learningu v CME.....	107
Obrázek 38: EHR v praxi.....	108
Obrázek 39: Lidské vazby v systému.....	111
Obrázek 40: Interview s pacientem.....	112
Obrázek 41: Fyzické vyšetření pacienta.....	112
Obrázek 42: Laboratorní vyšetření.....	113
Obrázek 43: Architektura systému.....	115
Obrázek 44: Architektura systému.....	119
Obrázek 45: Editace nového záznamu.....	120

Obrázek 46: Registrace nových indikačních pravidel.....	121
Obrázek 47: Přehled vazeb v systému ICONS.....	123
Obrázek 48: Návrh léčby antibiotiky v systému ICONS.....	124
Obrázek 49: Výpis z antibiogramu.....	125
Obrázek 50: Vývoj chřipkové epidemie v Meklenburgu v letech 1997-2001	126
Obrázek 51: architektura systému TeCoMed. .	126
Obrázek 52: Prognostický model systému TeCoMED.....	127

Seznam tabulek:

Tabulka 1: Charakteristiky vybraných expertních systémů.....	19
Tabulka 2: Přehled inferenčních metod expertních systémů.....	31
Tabulka 3: způsoby formálního zápisu.....	50
Tabulka 4: Báze znalostí.....	61
Tabulka 5: Vyjádření nejistoty.....	62
Tabulka 6: Báze znalostí – hodnocení příznaků pomocí skóre.....	63
Tabulka 7: Základní terapeutická pravidla.....	64
Tabulka 8: Rozhodovací tabulka – řešení problémů minimaxem.....	65
Tabulka 9: Plusy/mínusy systému Iliad.....	81
Tabulka 10: Stručný přehled vybraných expertních systémů.....	82
Tabulka 11: Stručný přehled vybraných klinických expertních systémů.....	84
Tabulka 12: Výčet příznaků v systému GS.52.....	94
Tabulka 13: Stručný přehled dalších CBR systémů.....	98
Tabulka 14: Klasifikace nemocí oběhové soustavy.....	121

PŘEDMLUVA

Charakteristickým rysem dnešní doby je práce s informacemi, které v průběhu svého životního cyklu prochází etapami digitálního zpracování. Současně se mění i metody získávání, uchování a přenosu informací. Dalším významným znakem je prudký rozvoj znalostní ekonomiky a rozšiřování nástrojů ICT. Expertní/znalostní systémy tak získávají na oblibě v celé řadě vědních disciplín a oborů. Strmý růst využití těchto systémů je patrný i v oblasti medicíny a to například při stanovení diagnózy, návrhu léčby, výuky mediků aj. Práce přispívá skloubením teorie a praktického přístupu k poskytnutí uceleného přehledu o expertních/znalostních systémech na poli medicíny, rovněž nechybí výhled na příštích 5 let s cílem nastínit čtenáři možné budoucí uplatnění systémů.

Protože pracuji v oblasti farmaceutického průmyslu (výroby), rozhodl jsem se napsat rigorózní práci tematicky spjatou s oborem, ve kterém profesně několik let působím. Uvědomuji si odlišnosti oblasti medicíny a farmacie oproti ostatním vědním oborům a proto jsem se rozhodl hlouběji věnovat poznatkům v oblasti expertních systémů aplikovaných v medicíně. Význam vybraného tématu vidím v tom, že odborníkům působícím v medicíně poskytne ucelený přehled významných expertních systémů z minulosti, současnosti včetně možného pohledu na budoucí vývoj.

Cílem mé rigorózní práce je zpracovat a předložit přehled různých typů znalostních/expertních systémů v oblasti medicíny, blíže popsat stávající situaci a odvodit trendy vývoje daných systémů v budoucnu.

Společně s odborníky na rešerše z naší informační centrály v Kodani jsem vypracoval tematicky zaměřenou rešerši k mé rigorózní práci, jenž mi byla zdrojem mnoha cenných informací, se kterými jsem při psaní práce pracoval.

Práce je strukturována do 4 základních tematických celků. Nejdříve je čtenář seznámen s obecnou teorií expertních/znalostních systémů, poté definuji specifika oblasti medicíny. Plynule navazuje část s reálnými úspěšnými aplikacemi znalostních systémů v medicíně. Poslední část je věnována vývojovým trendům na poli ES/ZS při zohlednění změn, které lze předvídat v horizontu 5 let ve vztahu k vývoji ICT a aplikaci v medicíně. Následuje výběr několika konkrétních aplikací, které demonstrují úspěšnost užívání systémů v praxi.

Použité informační zdroje jsou citovány dle normy ISO 690 a ISO 690-2.

Za vstřícnou pomoc a věcné připomínky při zpracování rigorózní práce si na tomto místě dovoluji poděkovat panu docentovi RNDr. Jiřímu Ivánkovi, CSc.

I. ÚVOD

Cílem rigorózní práce je zpracovat přehled různých typů expertních/znalostních systémů v dané oblasti a blíže přiblížit stávající situaci a budoucí trendy vývoje systémů v medicíně.

Nejdříve je čtenář seznámen s obecnou teorií na poli expertních/znalostních systémů, následně přecházím do oblasti medicíny, která je odlišná svými specifickými vlastnostmi a zákonitostmi oproti jiným vědním oborům. Plynule navazuje část s reálnými úspěšnými aplikacemi znalostních systémů v medicíně. Následuje kapitola věnovaná vývojovým trendům s ohledem na vývoj ICT a ukázka úspěšných aplikací.

Cíl naplňuji následující strukturou práce, která je členěna do 4 základních tematických okruhů:

Umělá inteligence a expertní systémy v obecném pojetí

Cílem tohoto oddílu je podat základní teorii ve vztahu k umělé inteligenci a expertním/znalostním systémům. V jednotlivých kapitolách se věnuji expertním systémům z pohledu historie, struktury, teoretických aspektů, výhledu do budoucna, úlohy využití lidských zdrojů, aj.

Specifické rysy expertních/znalostních systémů v medicíně

Cílem oddílu je přiblížit specifické rysy expertních/znalostních systémů v lékařství. V jednotlivých kapitolách se zabývám obecnými aspekty medicíny ve vztahu k ES, formalizací lékařského problému, podporou rozhodování v prostředí medicíny, vymezují základní pojmy spojené s oblastí tvorby a užití ES.

Aplikace expertních/znalostních systémů v medicíně

Tento oddíl rozsáhle popisuje konkrétní aplikace ES v medicíně. Jednotlivé kapitoly se věnují historickým i současným aplikacím ES, dále jsou uvedeny konkrétní případy aplikací případového usuzování.

Vývojové trendy na poli ES/ZS

Tento oddíl se zabývá možnými vývojovými trendy při zohlednění vývoje ICT v horizontu 5 let. Druhá část oddílu se zaměřuje na ukázky konkrétních programů, na nichž lze ukázat možné nasazení v budoucích aplikacích.

II. UMĚLÁ INTELIGENCE A EXPERTNÍ SYSTÉMY V OBECNÉM POJETÍ

Tento oddíl práce je věnován teoretickému vymezení základních pojmů a terminologii související s oblastí expertních/znalostních systémů a jeho cílem je přiblížit tuto oblast čtenáři této rigorózní práce. Postupně v rámci jednotlivých kapitol vymezují pojmy umělá inteligence či expertní systémy s ohledem na jejich historii, strukturu, teoretické aspekty, výhled do budoucna či využití lidských zdrojů atd.

Při psaní tohoto oddílu jsem čerpal zejména z česky a anglicky psaných monografií jako jsou: [Mařík et al., 1993], [Minsky, 1967], [Provazník et al., 1999], [Hayes-Roth, 1983], [Giarratano et al., 1993], [Berka, 1995], [Cawsey, 1997] aj.

1.1. Umělá inteligence

Motto: Expertní systémy se poznají podle toho, že ze vstupního údaje „růže voní lépe než zelí“, vyvodí závěr, že z růží bude také lepší polévka.

Murphyho počítačové zákony

1.1.1. Úvod

Vybrané organismy žijící v přírodě jsou obdařeny vlastností nesoucí pojmenování „inteligence“, která jim umožňuje reagovat na složité projevy prostředí a aktivně je využívat ve svůj prospěch.

S rozvojem techniky si lidstvo začalo klást otázku, zda lze i u uměle vytvořených systémů dosahovat reakci a celkové chování, kterému u živých organismů přiřazujeme označení inteligentní. Již v 17. století se touto otázkou zabývalo několik velikánů filozofie jako byli Descartes či Pascal. Jelikož se jednalo o filozofický pohled, vše se točilo kolem otázek, zda stroje mohou myslet (bez návodu jak dosáhnout onoho strojového učení).

Umělá inteligence (artificial intelligence) je poměrně mladá vědní disciplína, která zahrnuje postupy a algoritmy, které ve svém důsledku vedou k určitému napodobení projevů inteligentního chování člověka [Mařík et al.,

1993]. V praxi se setkáváme se skutečností, že obsah pojmu „umělé inteligence“ nebyl nikdy přesně a jednoznačně definován, i když bylo uskutečněno nespočet pokusů. Některé definice uvedu v dalším textu.

1.1.1.1. Turingův test

V roce 1950 (6 let před oficiálním datem zahájení výzkumu umělé inteligence) vynikající britský matematik Alan Turing navrhl takzvaný Turingův test [Turing, 1950], který navrhuje jak rozhodnout, zda stroj může myslet. Tento test je založen na přirozené myšlence: „Bude-li stroj reagovat na podněty lidského partnera takovým způsobem, že člověk není schopen rozeznat, zda jedná stroj se strojem či s jinou osobou prostřednictvím terminálu, lze považovat stroj za inteligentní.“ Turingův test vychází z čistě behavioristického pojetí myšlení a nebere v potaz procesy uvnitř systému, tím méně fenomenální stránky mysli. Při hlubším zamyšlení nad tímto testem napadne čtenáře myšlenka, že se vlastně testuje něco velmi speciálního, totiž umění stroje předstírat, že není stroj. Test měří schopnost počítače simulovat myšlení, ale nevypovídá nic o vlastní inteligenci počítače.

1.1.1.2. Eliza

Člověk komunikující s tímto programem může uvěřit, že komunikuje s jiným člověkem. ELIZA imituje chování psychiatra při vyšetřování pacienta. Název programu byl zvolen podle Lízy Doolitlové, hlavní postavy ze hry G. B. Shawa Pygmalion (muzikálová verze nese název My Fair Lady), která také „neví, co říká“. Na internetu je přístupné interaktivní rozhraní, ve které si lze komunikaci s Elizou vyzkoušet¹.

1.1.1.3. Čínská komora

Třicet let po Turingovi formuloval John Searle [Searle, 1980] další myšlenkový experiment, který se zdál být variantou Turingova testu. Cílem experimentu byla argumentace proti počítačovému funkcionalismu a zdůraznění niterné povahy mysli. Předpokladem bylo, že v uzavřené komoře sedí člověk –

¹ http://www-ai.ijs.si/eliza-cgi-bin/eliza_script

nazýváme ho John. Tento John nerozumí čínštině, a za pomoci rozsáhlého manuálu (v angličtině, které rozumí) vybírá (čistě podle tvaru) jedny čínské znaky jako odpovědi na jiné čínské znaky, které mu do komory vsouvá vnější experimentátor. Dotyčný manuál byl přepisem správného programu pro dialog v čínštině, takže experimentátor (rodilý Číňan) nepoznal, že zdrojem odpovědí nebyl Číňan. Závěr byl jednoznačný: John i počítač byli stejně úspěšní, avšak John čínským textům nerozuměl – proč by jim tedy měl rozumět počítač s implementovaným stejným programem ? Další úvahy o tomto testu spadají spíše do filozofické roviny, a proto se jim zde nebudu podrobněji věnovat.

1.1.2. Vybrané definice umělé inteligence

1.1.2.1. Definice Minského

Lze konstatovat, že Minského definice [Minsky, 1967] vychází z Turingova imitačního testu: „Umělá inteligence je věda o vytváření strojů, nebo systémů, které budou při řešení určitého úkolu užívat takového postupu, který – kdyby ho používal člověk – bychom považovali za projev jeho inteligence“. V Minského pojetí jsou úlohy, které umělá inteligence řeší, natolik složité, že by jejich řešení i člověkem vyžadovalo uplatnění jeho inteligence. Složitost zde lze ohodnotit počtem všech variant, které připadají na řešení v úvahu. Znalosti mohou mít charakter exaktní (sem patří například fyzikální zákony, teorémy), nebo mohou být tvořeny *heuristickými poznatky*, které nejsou podloženy hlubší teorií, avšak velmi často přispívají k nalezení řešení [Mařík et al.,1993].

1.1.2.2. Definice Richové

Dle Richové se „umělá inteligence zabývá tím, jak počítačově řešit úkoly, které dnes zatím lidé zvládají lépe“ [Rich et al.,1991]. Toto tvrzení předpokládá, že s rozvojem počítačové techniky se bude těžiště umělé inteligence posouvat a měnit. Za nedostatek lze považovat, že nezahrnuje úkoly, které je třeba řešit, ale dosud je neumí řešit ani člověk, ani stroj. Plusem je velmi stručné vymezení toho, co tvoří skutečný obsah umělé inteligence jako vědní disciplíny [Mařík et al.,1993].

1.1.2.3. Definice Kotkova

Kotek vnímá umělou inteligenci jako vlastnost technických systémů, která je předmětem zkoumání umělé inteligence jako vědní disciplíny: „Umělá inteligence je vlastnost člověkem uměle vytvořených systémů vyznačujících se schopností rozpoznávat předměty, jevy a situace, analyzovat vztahy mezi nimi a tak vytvářet vnitřní modely světa, ve kterých tyto systémy existují, a na tomto základě pak přijímat účelná rozhodnutí, za pomoci schopností předvídat důsledky těchto rozhodnutí a objevovat nové zákonitosti mezi různými modely nebo jejich skupinami“ [Kotek, 1983]. Zavedením vnitřních modelů umožňuje definovat rozhodování a řízení k danému cíli dle postupu: Je dán počáteční a cílový stav prostředí – oba svými modely. Jsou dány přípustné akce, kterými lze stavy měnit. Úkolem je nalézt takové posloupnosti akcí, které převedou počáteční stav do cílového a přitom budou respektována předem zadaná omezení. Takto formulovaný problém v umělé inteligenci nazýváme *řešením úloh* [Mařík et al., 1993]. Samotná formalizace modelů i akcí je pak zahrnována pod problematiku *reprezentace znalostí*. Kotkova charakteristika tak umožňuje explicitně určit a vyjmenovat dílčí teoretické úkoly, které spadají do umělé inteligence.

1.1.3. Historie umělé inteligence a přechod k expertním systémům

Začátek historie umělé inteligence se datuje rokem 1956, kdy v létě zorganizoval John McCarthy z MIT relativně malou konferenci na Dartmouth College v New Hampshire, na kterou byli rovněž pozváni přední odborníci zabývající se o mentální schopnosti lidí a strojů. Cílem darmouthské konference bylo prodiskutovat domněnku, že „každé hledisko učení nebo jakýkoliv jiný příznak inteligence může být v principu tak přesně popsán, že počítače by mohly pracovat se symboly stejně dobře jako s čísly“ [Rose, 1984]. Poprvé tak došlo k dosti přesnému formulování pole společného zájmu pro umělou inteligenci.

V průběhu konference byl představen první program využívající technik heuristického prohledávání, jenž byl vyvinut A. Newellem, R. Solomonoffem a H. Simonem z Carnegie Institute of Technology a nesoucí název Logic Theorist. O rok později tato skupina prezentovala další systém nazvaný GPS (General

Problem Solver). Na konferenci byl rovněž předpovězen další rozvoj umělé inteligence. Velmi ambiciózně formulovaná předpověď přinesla později díky svému nenaplnění určité zklamání a krizi v oblasti umělé inteligence.

Období od konce 50. let až do 80. let bylo ve znamení výkyvů ve výzkumu neuronových sítí. Po prvotním nadšení, kdy byl vyvinut perceptron, došlo v 70. letech k útlumu ve výzkumu neuronových sítí (zejména díky kritické knize M. Minského a S. Paperta). Renesance nastala opět v 80. letech, kdy byly odstraněny deklarované nedostatky novými algoritmy.

Koncem 50. let navrhl J. McCarthy jazyk LISP, který byl určen pro umělou inteligenci, a je dodnes hojně využíván. Nicméně období 50. a 60. let bylo též poznamenáno vášnivými diskusemi o tom, zda a jakých pokroků lze v umělé inteligenci dosáhnout, což nakonec vyústilo v takzvanou „dobu ledovou“, jež trvala až do druhé poloviny 70. let.

V 70. letech se ukázalo, že univerzálnost systémů a schopnost odvozovat bez uvažování specifik problémů (typické pro většinu komunity umělé inteligence) je hlavní slabinou univerzálních systémů. Převládla obecná shoda, že obecné metody jsou příliš slabé pro řešení vysoce specializovaných úloh, které jsou však efektivně řešeny specialisty-experty [Freigenbaum, 1979].

Ukázalo se, že *znalosti* jsou rozhodující pro vysokou efektivitu systémů umělé inteligence, zatímco obecný formální aparát poskytuje pouze nástroj pro využívání znalostí a hraje tedy druhořadou roli. Vědci I. Goldstein a S. Papery uvádějí: „Základním problémem umělé inteligence není odhalení několika efektivních obecných technik, ale spíše otázka jak reprezentovat velké množství znalostí ve tvaru, který by dovoloval jejich efektivní využívání a interakci.“ [Goldstein, et al., 1977] Proto se v umělé inteligenci začínají projevovat tendence kladení většího důrazu na znalosti než na mechanismy jejich využívání. Vznikají tak systémy, jejichž síla tkví právě v kvalitě, rozsahu a reprezentaci znalostí: *expertní systémy*.

Z hlediska teoretického i praktického je synonymem pro termín expertní systémy (expert systems) pojem znalostní systémy (knowledge-based systems). Dále tedy nebudu ve své práci činit terminologický rozdíl mezi expertními a znalostními systémy.

1.2. *Expertní systémy (ES)*

1.2.1. Úvod

Pojem expertní systém se poprvé začal používat na přelomu sedmdesátých a osmdesátých let. Podnětem bylo poznání, že kvalita systémů s umělou inteligencí závisí daleko více na kvalitě znalostí, nežli na kvalitě mechanismu pro jejich využívání. Již od počátku byly znalostní systémy vnímány jako systémy, které se opírají o špičkové znalosti převzaté od těch nejlepších odborníků – expertů. Ovšem i zde se objevilo úskalí takzvaných popularizujících článků, které ve svém důsledku vyvolaly v odborných kruzích až nereálná očekávání od expertních systémů a svým způsobem tuto oblast částečně zdiskreditovaly.

Stejně jako v ostatních oborech i v oblasti znalostních systémů dochází ke změně vize a očekávání s tím, jak plyne čas. Zatímco v prvních letech se očekávalo vytvoření několika široce a opakovatelně využitelných, problémově nezávislých expertních systémů pro něž byl charakteristický silný stupeň všeobecně přijaté standardizace, dnes má většina expertních systémů spíše charakter speciálních, problémově orientovaných vytvořených subsystémů v rámci rozsáhlejších programových celků. V minulosti byly preferovány expertní systémy jako samostatné a samonosné (stand-alone) systémy, dnes se spíše jedná o vnořené (embedded) aplikace.

1.2.2. Obecná historie ES

V posledních letech se objevily tisíce systémů v nejrůznějších aplikačních oblastech. Nejméně polovina aplikací je zaměřena na oblast *medicíny*, což lze přisuzovat faktu, že znalosti jsou v této oblasti nejlépe strukturované. O detailní zmapování a zhodnocení expertních systémů na trhu se pokoušel Waterman [Waterman, 1986]. V praxi se ukázalo, že několik málo poměrně raných systémů zásadně ovlivnilo a ovlivňuje hlavní směry ve vývoji expertních systémů. Ve vývoji expertních systémů lze zřetelně odlišit čtyři významné etapy:

- Počáteční fáze (1965-1970): DENDRAL , MACSYMA.
- Etapa výzkumných prototypů (1970-1975): MYCIN, PROSPECTOR, HEARSAY-II.

- Etapa experimentálního nasazování (1975-1981): PUFF, SACON, ONCOCIN, HEADMED, CLOT, AL/X, HASP, INTERNIST, CADUCEUS.
- Etapa komerčně dostupných systémů (od roku 1981-současnost): XCON, XSEL, DIPMETER, ADVISOR.

Tabulka 1 reprezentuje charakteristiky několika vybraných expertních systémů.

<p>DENDRAL [Feigenbaum, 1971]</p>	<p>Úkolem tohoto systému je pomáhat identifikovat chemické sloučeniny na základě spektrografických dat. Byl vyvinut na Stanfordské univerzitě v letech 1965-1969 a dodnes se rutinně využívá.</p>
<p>MACSYMA [Bogen, 1975]</p>	<p>Poskytuje soubor nástrojů pro manipulaci s matematickými výrazy a vzorci. Stále je hojně využíván, např. nukleárními fyziky, kteří jsou často nuceni řešit soustavy velkého počtu rovnic.</p>
<p>MYCIN [Buchanan, 1984]</p>	<p>Byl vyvinut ve SRI (Stanford Research Institute). Jeho úkolem je na základě jednoduše dostupných dat rychle určovat typy bakteriální infekce, kterými by mohl být nově hospitalizovaný postižen, a navrhnout vhodnou léčbu antibiotiky tak, aby se stav pacienta stabilizoval do doby, než jsou dokončena časově náročná, podrobná laboratorní vyšetření. MYCIN je významný spíše z hlediska umělé inteligence než z hlediska medicínského. Metody zpracování neurčité informace, zavedené v tomto systému, se v modifikované verzi užívají u řady nově vyvíjených systémů dodnes.</p>
<p>PROSPECTOR [Duda, 1978]</p>	<p>V tomto systému se jedná o vyhodnocování jednoduše dostupných geologických dat s cílem rychle rozhodnout, zda v dané lokalitě provádět podstatně dražší hloubkové vrty. Typická konzultace se systémem PROSPECTOR trvá několik minut a stojí několik dolarů. Může však ušetřit několikaměsíční čekání na posouzení dat a vzorků</p>

	expertem. Při prvním formálním testu se systém ukázal velice úspěšným, neboť se mu podařilo odhalit molybdenové ložisko v hodnotě sta milionu dolarů.
HEARSAY-II [Erman, 1977]	Byl prvním systémem, který ukázal, že počítač by v brzkém budoucnu mohl spolehlivě a rychle rozumět přirozené řeči v úzce vymezené předmětné oblasti. Stimuloval tak rozvoj výzkumu v oblasti rozpoznávání a porozumění přirozené řeči.
PUFF [Aikins, 1983]	Tento systém byl realizován využitím ulity EMYCIN (prázdný expertní systém). Poskytuje konzultace týkající se možných příčin obstruktivních potíží dýchacích cest.
SACON [Benet, 1979]	Poskytuje konzultace uživatelům rozsáhlého softwarového balíku MARC pro analýzu metodou konečných prvků. Využívá přístupu i architektury systému MYCIN.
ONCOCIN	Určen k řízení léčby pacienta na jednotce onkologické péče.
INTERNIST-1 [Miller et al., 1984]	Byl vyvíjen s cílem pokrýt znalostmi celou oblast interního lékařství a který je považován za jeden z vůbec nejrozsáhlejších expertních systémů v historii. Později byl modifikován a přejmenován na systém CADUCEUS , obsahující údajně 85% veškerých znalostí z interního lékařství

Tabulka 1: Charakteristiky vybraných expertních systémů

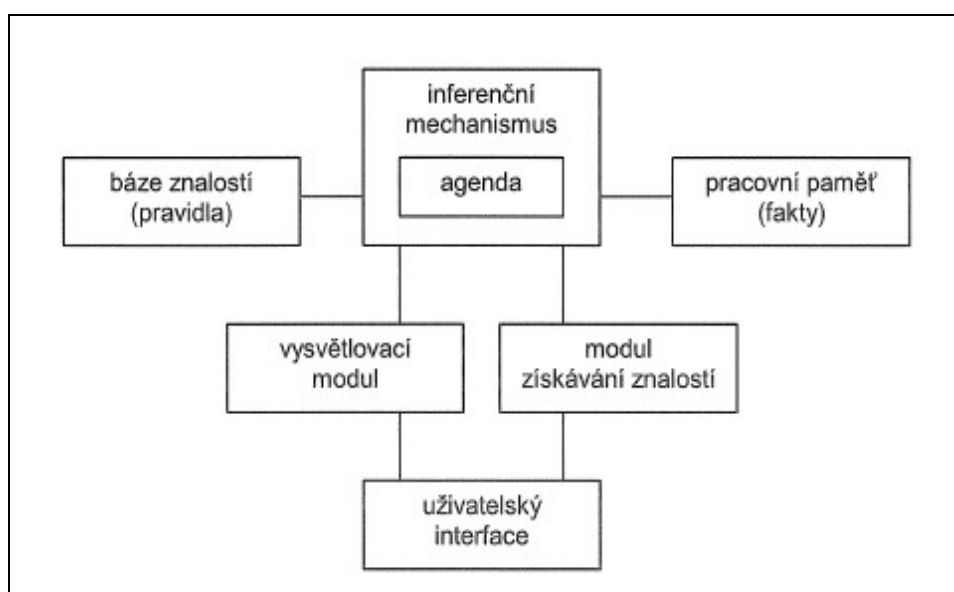
1.2.3. Struktura ES

Existuje celá řada autorů, kteří definují ve svých dílech strukturu expertních systémů. Já jsem si pro svoji práci vybral dělení Provazníka [Provazník et al., 1999]:

- **Uživatelský interface** - spojovací modul, který zabezpečuje komunikaci uživatele s ES.
- **Vysvětlovací modul** - popisuje a vysvětluje postup usuzování ES uživateli.
- **Modul získávání znalostí** - modul pro vkládání nových znalostí do ES.

- **Pracovní paměť** - databáze faktů používaných pravidly.
- **Inferenční mechanismus** - provádí inferenci (proces usuzování). Vytváří prioritní seznam pravidel, aplikuje pravidla podle seznamu a rozhoduje, která pravidla jsou splněna předloženými (existujícími) fakty.
- **Agenda** - seznam pravidel s přiřazenou prioritou vytvořený inferenčním mechanismem.
 - **Báze znalostí** - databáze pravidel.

Obrázek 1 znázorňuje grafické schéma expertního systému.



Obrázek 1: Struktura expertního systému

1.2.4. Charakteristické vlastnosti

V praxi existuje celá řada expertních systémů s různorodou architekturou, aplikacemi, vizemi. V souladu s Feigenbaumem [Feigenbaum et al., 1988] lze konstatovat, že: „*Expertní systémy jsou počítačové programy, simulující rozhodovací činnosti experta při řešení složitých úloh a využívající vhodně zakódovaných, explicitně vyjádřených speciálních znalostí, převzatých od experta, s cílem dosáhnout ve zvolené problémové oblasti kvality rozhodování na úrovni experta*“. Za cíle expertních systémů lze tedy považovat dosažení co nejlepších

odezev na reálná data, tedy co nejlepší kvality rozhodování. Mezi základní charakteristiky expertních systémů patří [Sklenák, 2001]:

- Znalosti experta jsou vyjádřeny naprosto explicitně, v takzvané podobě *báze znalostí*, a předem je dána pouze strategie využívání znalostí z této báze – *řídící mechanismus*. Pro architekturu znalostních systémů je charakteristické oddělení samostatných komponent báze znalostí a řídicího mechanismu. Tato vlastnost je základem vysokého stupně znovupoužitelnosti jednou vyvinutého a odzkoušeného řídicího mechanismu (inferenční mechanismus).
- Báze znalostí obsahuje znalosti experta, které jsou potřebné k řešení zvoleného problému. Patří mezi ně znalosti od exaktně dokázaných až po nejisté heuristiky (jedná se o exaktně nedokázané znalosti, které expert nabyl dlouholetou praxí, a o nichž ví, že mu pomáhají při řešení podobných problémů). Znalosti experta nemají statický charakter, postupně se vyvíjejí a rozrůstají. Báze znalostí musí být též transparentní, čitelná pro experta (aby ji mohl upravovat a dále rozšiřovat).
- Báze znalostí má charakter obecného rozhodovacího pravidla, popisuje tedy znalosti z dané oblasti. Pod řešením konkrétního případu se rozumí dosazení dat o daném případě do obecně formulovaných znalostí z báze znalostí. Data k danému případu poskytuje obvykle uživatel v dialogovém režimu s počítačem, který má charakter dialogu laika či méně zkušeného odborníka s expertem. Expertní systém se uživatele dotazuje na údaje, které souvisí s konzultovaným případem, a na základě odpovědí a svých obecných znalostí postupně dochází k závěru, respektive řešení. Otázky jsou expertním systémem voleny dynamicky, přičemž v úvahu se mohou brát i další kritéria, například cena získání odpovědi.
- Způsob zpracování znalostí a dat ve znalostním systému musí mít některé rysy podobné uvažování experta. Expertní systém tak musí být schopen:
 - Využívat stejně jako expert nejisté znalosti (rozuměno znalosti s přidělenou mírou důvěry v jejich platnost).
 - Využívat odpovědí, které zahrnují nejistotu uživatele (nejistota v bázi dat).

- V bázi znalostí by měli být zahrnuty *násobné* či *alternativní cesty vyvozování* – v důsledku jde o to, aby přijetí rozhodnutí bylo podporováno či vyvráceno více elementárními fakty a na ně navazujícími podpůrnými úvahami.
- Počítačový expertní systém musí být schopen nejen vést s uživatelem dialog formou otázka-odpověď, ale rovněž musí být schopen vysvětlit a zdůvodnit dílčí závěry. Velmi často je uživatelem požadováno vysvětlení odvozovacího procesu, ale i detailní informace o znalostech či faktech souvisejících s danou problematikou.

1.2.5. Úlohy vhodné pro ES

Je potřeba si uvědomit, že i expertní systémy mají své omezené možnosti při řešení zadaného úkolu. Zda je expertní systém nejvhodnějším prostředkem pro řešení dané úlohy závisí právě na charakteru úlohy. Expertní systém ve své podstatě modeluje způsob, jakým řeší danou úlohu právě expert. Opírá se o jeho znalosti dané oblasti a o heuristiky, které expert při řešení používá. Významným kritériem pro výběr způsobu řešení je složitost úlohy. Složitost úlohy se dá intuitivně odhadnout podle toho, jak narůstá počet elementárních kroků řešícího algoritmu s velikostí úlohy. Složitě úlohy jsou v podstatě neřešitelné využitím klasických sériových algoritmů.

Stejně jako expert se i expertní systémy mohou mýlit, řešení nemusí být optimální vzhledem k idealizované optimalizační formulaci problému. Pokud lze úlohu popsat tak, aby k řešení mohl být využit výpočetně jednoduchý algoritmus, bude výsledek takového algoritmu vždy lepší než výsledek který může poskytnout expertní systém.

1.2.6. Rozdělení ES s ohledem na řešené úlohy

Expertní systémy jsou dnes používány k řešení nejrůznějších úloh. Jedním ze způsobů, jakým se expertní systémy dělí v oblasti medicíny [Kasal, et al., 1998] je členění na:

- **Analytické** – klasifikace, interpretace dat, porozumění složitým signálům, identifikace systémů, lékařská diagnostika.
- **Syntetizující** – plánování, technické návrhy, návrhy terapie v medicíně.

- **Smíšené** – aplikace při výuce, monitorování.

Jiným – obecným způsobem dělení je podle charakteru řešených úloh [Mařík et al.,1997]. Dle mého názoru je toto dělení častěji používáno v praxi a je tak bližší jedincům, kteří pracují s expertními systémy. Jedná se o systémy:

- **Diagnostické,**
- **Plánovací,**
- **Hybridní.**

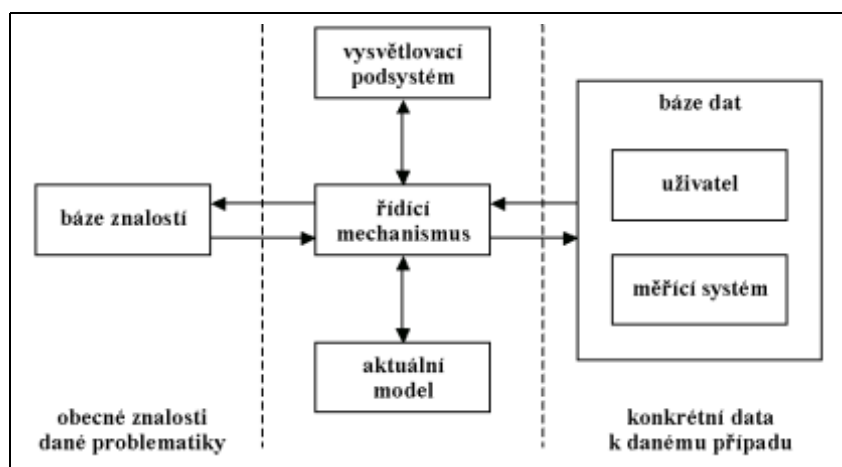
Jednotlivé systémy jsou níže rozebrány v další kapitole.

1.2.6.1. Diagnostické systémy

Diagnostické expertní systémy jsou určeny pro efektivní interpretaci dat s cílem určit, která z hypotéz (hypotézy jsou předem stanoveny) nejlépe koresponduje s aktuálními daty [Mařík et al., 1997]. Nejtypičtější příklad je stanovení diagnózy pacienta na základě jeho subjektivních potíží, tj. jsou dána možná řešení a jedno z nich systém zvolí [Kasal et al., 1998].

Báze dat může být složena jednak z uživatelem zadaných hodnot a také z hodnot měřitelných (subjektivní pocit pacienta a jeho naměřená teplota). Aktualizace modelu je provedena vstupem konkrétních dat. Model je velmi často tvořen pouze aktualizací hodnot vah (jistot, subjektivní pravděpodobnosti) poznatků, zahrnutých v bázi znalostí. Na počátku jsou hodnoty přiřazeny expertem, po zadání dat jsou v průběhu odvozování tyto hodnoty měněny. Takto je model řešen u systémů MYCIN a PROSPECTOR.

Vysvětlovací podsystém je ta část systému, jež uchovává a vysvětluje postup, jímž bylo dosaženo výsledku. Tento model tedy předpokládá využití heuristických znalostí. Tyto znalosti jsou označovány jako povrchové. Výhodou využívání heuristických znalostí je poměrně jednoduchý způsob dosažení řešení. Za určitých okolností však tato metoda selhává - příkladem může být zcela nová situace, se kterou nemá diagnostik dosud zkušenosti. Obrázek 2 znázorňuje blokové schéma diagnostického systému [Mařík et al.,1997].

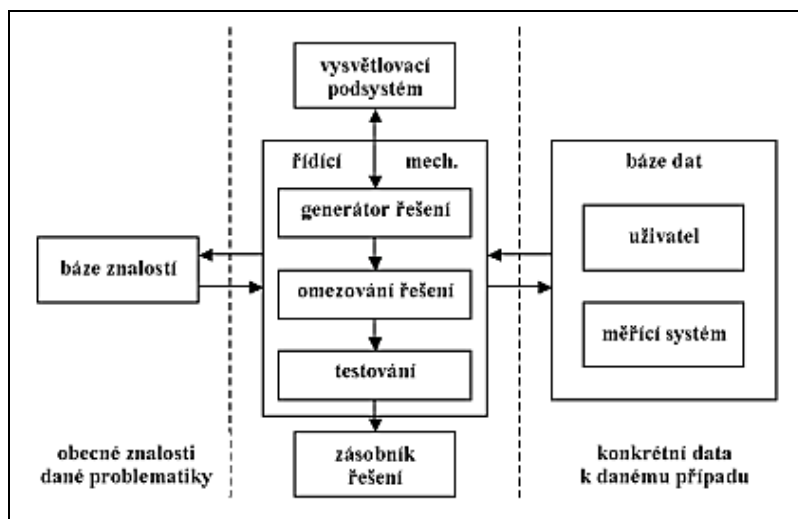


Obrázek 2: Blokové schéma diagnostického expertního systému

1.2.6.2. Plánovací systémy

Plánovací expertní systémy jsou určeny pro řešení takových úloh, kdy je znám stav počátečního objektu a cíl řešení a systém má s využitím dat a zadání nalézt posloupnost povolených kroků (operátorů), kterou lze cíle dosáhnout. Hledí se také na nalezení pokud možno (z nějakého hlediska) optimální posloupnosti. Hlavní částí plánovacího expertního systému je *generátor možných řešení*, jenž vytváří kombinace posloupností operátorů. Toto vytváření je omezoováno pravidly z báze znalostí. Dále je testována shoda řešení s daty z báze dat. Výsledkem je *seznam přípustných řešení*, z nichž každé je ohodnoceno stupněm kvality.

Typickým plánovacím expertním systémem (vyvinut 1965-1969) je DENDRAL (určen k odvozování struktur chemických látek, na základě histogramů z hmotového spektrometru a spektrometru pro jadernou magnetickou rezonanci). Lze jej považovat za první a dodnes využívaný expertní systém. Obrázek 3 znázorňuje blokové schéma plánovacího expertního systému [Mařík et al., 1997].



Obrázek 3: Blokové schéma plánovacího expertního systému

1.2.6.3. Hybridní systémy

Hybridní expertní systémy mají kombinovanou architekturu, tj. kombinují plánování a diagnostiku. Příkladem může být inteligentní expertní systém pro výuku, který diagnostikuje znalosti studenta a podle toho plánuje jeho další vzdělávání.

1.2.6.4. Prázdné systémy

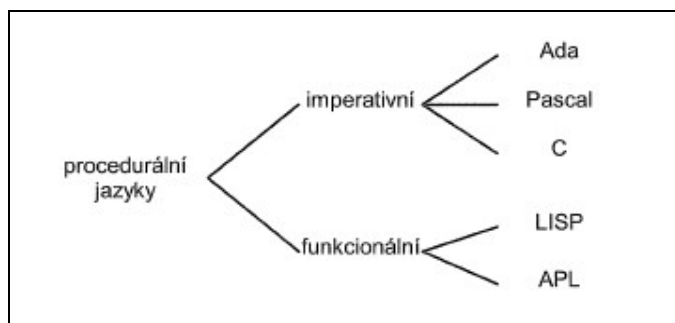
Důležitým nástrojem jsou tzv. prázdné expertní systémy [Habiballa, 2004]. Jejich idea vychází ze skutečnosti, že základní a zcela univerzální částí expertního systému je jeho inferenční mechanismus. Ten může operovat s bázemi znalostí, které mají sice společnou architekturu, ale mohou být věcně (problémově) orientovány do různých oblastí. Prázdný expertní systém je tak vybaven řídicím mechanismem a všemi ostatními komponentami, pouze báze znalostí je prázdná. Obecně jsou prázdné systémy relativně levné a dostupné, protože to skutečné *know-how* je právě ve znalostech experta. Plnění prázdných expertních systémů spadá do nové oblasti zvané znalostní inženýrství [Mařík et al.,1997].

1.2.7. Jazyky expertních systémů

V obecném programování lze najít tři principy popsané jako: proved', proved' jestliže můžeš, proved' něco smysluplného. První princip představuje klasické **procedurální** programování, druhý **deklarativní** programování, a třetí **evoluční** programování zdokonalujících se programů [Popper, 1989].

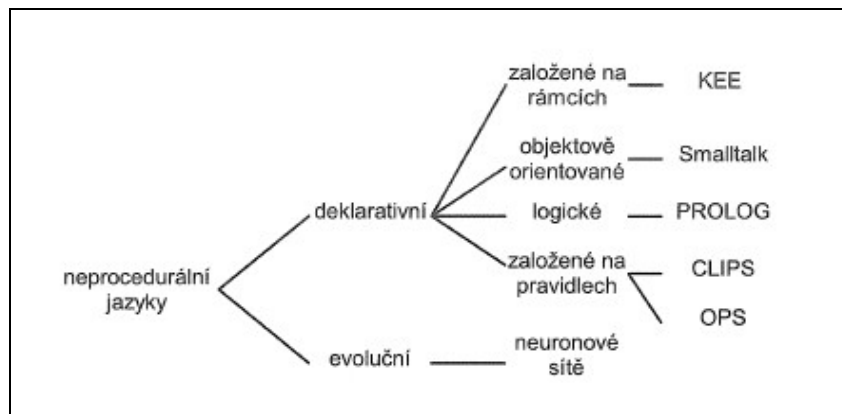
Klasický procedurální (algoritmický, konvenční, sekvenční) styl programování spočívá v jednoduchém principu, kdy je program tvořen posloupností příkazů [Provazník et al., 1999]. Charakteristickou vlastností je, že v každém kroku je definováno, co bude následovat. Procedurální jazyky lze dále dělit na imperativní a funkcionální. Hlavními představiteli imperativního programování jsou jazyky FORTRAN, Ada, Pascal, C, Modula-2, COBOL a BASIC, jejichž charakteristikou jsou imperativa (příkazy). Naproti tomu funkcionální jazyky, jako např. LISP nebo APL, jsou orientovány na funkce - pravidla, která vytvářejí spojení mezi doménami [Molnár et al.,1988].

Obrázek 4: Procedurální jazyky znázorňuje přehled procedurálních jazyků.



Obrázek 4: Procedurální jazyky

Základní představa, na které je založeno deklarativní programování, je jiná. Neorientuje se na procedurální hlediska, ale klade důraz na pravidla řešení problémů [Provazník et al., 1999]. Vyjadřuje je v některém z formalizmů a odděluje cíle od metod. Deklarativní program je pak tvořen celky, do kterých jsou seskupeny výrazy reprezentující pravidla. Hlavní deklarativní paradigmaty jsou: objektově orientované programování, programování založené na rámcích, logické programování a programování založené na pravidlech. Obrázek 5 znázorňuje základní přehled neprocedurálních jazyků [Provazník et al., 1999].



Obrázek 5: Neprocedurální jazyky

1.2.8. Teoretické aspekty ES

Již z výše zmiňovaného výkladu je patrné, že expertní systémy jako součást umělé inteligence nejsou samostatnou teoretickou partií. Patří do typické aplikační oblasti teoretických základů umělé inteligence. Z teoretického hlediska je v centru pozornosti především problematika:

- **Reprezentace znalostí,**
- **Řídících mechanismů,**
- **Zpracování neurčitě informace.**

Níže jsou jednotlivé oblasti blíže komentovány.

1.2.8.1. Reprezentace znalostí

Pro reprezentaci znalostí je v oblasti umělé inteligence (UI) používána řada technik - např. produkční pravidla, sémantické sítě, rámce, znalostní jazyky, konceptuální grafy a další [Provazník et al., 1999]. K jejich pochopení je však nutné co nejpřesněji definovat termín "znalost" a určit jeho zařazení do umělé inteligence.

Slovo "znalost" je jedním ze slov, které je všeobecně známé, ale těžko exaktně definovatelné. Podobně jako jiná slova tohoto druhu má také mnoho významů. Navíc jsou další slova, jako např. data, fakty, informace, používány mimo oblast UI jako synonyma znalostí.

Studiem znalostí se obecně zabývá epistemologie² [Provazník et al., 1999]. Znalosti mohou být podle epistemologie klasifikovány jako procedurální,

² Epistemologie, *gnoseologie, noetika, teorie poznání* - fil. obor, zabývající se podstatou a procesem poznání a skutečností, možnostmi i pravdivostí poznání

deklarativní a tacitní. Procedurální a deklarativní typ znalostí odpovídá procedurálnímu a deklarativnímu paradigmatu. Procedurální znalosti obvykle popisují postup. Jako příklad uveďme postup zapínání napájení počítačového systému. Deklarativní znalosti popisují pravdivost nějakého faktu. To je spojeno s deklarativními výroky - deklaracemi. Příkladem může být výrok [Provazník et al., 1999]: *”Nezapínej napájení procesoru před napájením periferního zařízení“*. Tacitní znalosti jsou někdy nazývány nevyslovenými znalostmi, protože nemohou být popsány jazykem. Jako příklad uveďme použití umělých neuronových sítí (UNS) v počítačovém systému. Znalosti skryté v UNS nemohou být exaktně interpretovány a popsány, přesto může být tato síť účinně použita.

Je žádoucí, aby znalosti byly reprezentovány tak, aby reprezentace:

- Byla pro danou oblast dostatečně přirozenou a přitom expresivní.
- Umožnila aplikaci efektivních deduktivních prostředků.
- Zabezpečovala rychlý přístup k položkám v bázi znalostí i bázi dat.

Důležitým požadavkem je **modularita báze znalostí**. Je třeba zajistit možnost doplňovat přírůstky do již existující báze. Tím docílíme usnadnění vytváření báze znalostí postupným zjemňováním, současně tak báze bude stále odpovídat úrovni nejnovějších poznatků v dané oblasti. Rovněž modulární reprezentace znalostí přináší výhodu v případě změn v bázi znalostí – změny jsou lokální a nepromítají se tak do ostatních částí báze. Chceme-li získat všechny údaje o daném objektu, je třeba prohledat celou bázi znalostí, protože v ní neexistuje uspořádání s ohledem na sémantiku.

Požadavek sémantického sdružování znalostí vyplývá z potřeby rychlého vybavování znalostí, ale rovněž i z potřeby vytvářet hierarchie pojmů. V souvislosti s problematikou reprezentací znalostí v systémech umělé inteligence dochází často k dělení znalostí [Mařík et al., 1997] na:

- Znalosti - reprezentované *deklarativně*, které představují, co je nebo má být poznáno, popřípadě dokázáno. Často jsou tyto znalosti nazývány *poznatky*.
- Znalosti - reprezentované *procedurálně*, které říkají, jak poznávat nebo odvozovat. V tomto případě mají znalosti často podobu *pravidel*.

Příkladem deklarativně reprezentované znalosti je tvrzení: Železo je kov. Tatož znalost reprezentována procedurálně má podobu podmíněného pravidla typu **IF-THEN**: JESTLIŽE (X je železo) PAK (X je kov). Lze vidět, že jednu a tutéž znalost lze formalizovat jak deklarativně, tak i procedurálně.

Velmi často dochází k používání kombinované reprezentace znalostí [Mařík et al., 1997]. Použití sémantických sítí jako doplňkového formalismu pro reprezentace znalostí je v expertních systémech typické, jelikož sémantická síť dokáže bez větší inferenční síly v kompaktní formě spolehlivě sdružovat podstatná fakta. Sémantické či taxonomické sítě jsou velmi často využívány jako podpůrná reprezentace znalostí, setkat se s nimi můžeme v systémech MYCIN či PROSPECTOR.

Jestliže se zabýváme řešením úlohy z reálného světa, v praxi se omezujeme jen na jeho určitou část. Některé objekty při řešení uvažujeme, jiné ignorujeme. Soubor všech objektů tvoří takzvané universum pro danou úlohu. Úloha je řešena pouze nad objekty universa. Určení universa definováním všech jeho objektů a vymezením relací a rovněž funkcionálních vztahů mezi nimi se nazývá *konceptualizace*. Explicitní popis konceptualizace se nazývá *ontologie*. Tento pojem je převzat z filozofie, kde označuje zkoumání povahy existence. Právě ontologie doplněné znalostmi vztahujícími se ke způsobu řešení pak tvoří vlastní *bázi znalostí*. Báze znalostí již není obecně problémově nezávislá, je již zaměřena na konkrétní typ úlohy a konkrétní způsob řešení.

1.2.8.2. Řídící mechanismy

Řídící (inferenční, odvozovací) mechanismus zabezpečuje v expertním systému využívání znalostí. Při návrhu těchto mechanismů se obvykle vychází z pojmů i výsledků obecné teorie řešení úloh, především z úlohy prohledávání stavového prostoru (prostoru řešení). Často jsou zahrnovány další častokrát i jen specifické, neobecné (ad-hoc) principy a techniky řízení. Ke konstrukci mechanismů se využívá i technik, které z řešení úloh bezprostředně nevycházejí, jako jsou [Mařík, et al., 1997]:

Technika agendy – v průběhu řešení se jako vedlejší produkt vytváří hierarchický zásobník úkolů, které by měly být postupně řešeny. Po vyřešení

prvního dílčího úkolu se přistupuje k řešení úkolu dalšího – ležícího na vrcholu zásobníku. Tento princip je považován za prostředek efektivního zaostřování pozornosti.

Technika démonů – démony jsou programy, jenž sledují průběh inferenčního procesu a zasáhnou v případě předem přesně specifikované situace. V každém kroku inference musí být testováno, zda situace pro spuštění některého z nich nenastala.

Technika nemonotónní inference - inferenční proces probíhá v situaci, kdy je uvažována celá řada předpokladů a podmínek. V reálné situaci nemusí být některé z nich splněny a pak je nezbytné, aby řídicí mechanismy byly vybaveny procedurami pro korektní úpravy aktuálního modelu po nesplnění původních předpokladů v průběhu řešení úlohy.

Technika tabule (black board) - znalostní báze je v tomto případě rozdělena na několik podbází, z nichž každá obsahuje znalosti z určité podoblasti řešené problematiky (znalostní zdroje). Komunikace mezi těmito dílčími bázemi je řízena speciální společně sdílenou datovou a řídicí strukturou, zvanou černá tabule. Systém využívající techniky černé tabule simuluje řešení problému panelovou diskuzí mezi odborníky několika souvisejících oborů.

Technika taxonomie - při použití této techniky je využito speciální formy odvozování tzv. děděním v taxonomické struktuře dílčích konceptů. Taxonomické struktury jsou určitou doplňkovou formou reprezentace znalostí a jsou využívány k zaostřování pozornosti v jednotlivých znalostních bázích. Úplné potvrzení některé položky v taxonomii v průběhu inference může mít za následek zamítnutí jiných položek na stejné taxonomické úrovni a následně jejich vyloučení z dalšího vyšetřování (ořezávání stavového prostoru).

Inferenční mechanismy pracují v jednotlivých krocích inference, které na sebe navazují. Posloupnost inferencí se nazývá řetězec. K dosažení cíle lze použít dvě různé strategie – dopředné řetězení (od faktů k závěru) a zpětné řetězení (od hypotéz k faktům). Dopředné řetězení se užívá v plánování, monitorování a řízení. Tabulka 2 [Provazník et al., 1999] uvádí přehled inferenčních metod (IM) v expertních systémech. Hlavní nástroje IM jsou deduktivní logika, výroková logika, predikátová logika a dopředné a zpětné řetězení. Jejich zákony umožňují efektivní prokazování platnosti tvrzení a tím i splnitelnosti cílů a podcílů. V

uvedených IM je možné použít jednoduché popisné struktury: stromů. Strom je hierarchická struktura dat, skládající se z uzlů, které obsahují informace nebo znalosti, a větví (spojení, hran), které spojují uzly. Strom je také příkladem orientovaného schématu, začínajícího od kořene (kořenového uzlu) v nejvyšší úrovni.

inferenční metoda	popis
dedukce	Metoda, při níž se z premis dospívá k novému tvrzení, závěru. Jde o postup od obecného ke zvláštnímu. Používáno již Aristotelem.
indukce	Metoda, při níž se z jedinečných výroků usuzuje na obecný závěr. Ten plyne z premis shrnujících všechny jednotlivé případy.
intuice	Schopnost postižení pravdivého výroku bez předchozího logického usuzování. V současnosti chápána jako možná heuristická cesta. Neexistuje žádná prokázaná teorie popisující tento mechanismus.
heuristika	Použití pravidel získaných zkušeností k zjednodušení tradičních způsobů řešení.
generování a přednastavení	Metoda nazývaná pokus/omyl. Při chybějící specifické znalosti se použije přednastavená (obvykle obecná či běžně známá) znalost.
nemonotónní IM	Při získání nového poznatku nebo závěru se mohou stát předešlé znalosti neplatnými.
analogie	Vyvozování závěrů na základě podobnosti s řešením jiných problémů.

Tabulka 2: Přehled inferenčních metod expertních systémů

1.2.8.3. Neurčitá informace

Neurčitost v systému má mnohé příčiny. Může jít o nepřesnost měřících přístrojů, nebo vágní jazykové formulace, subjektivní dojem - se všemi aspekty je potřeba pracovat. Právě zpracování neurčitosti je jednou z nejpodstatnějších složek expertních systémů.

Nejistota, neurčitost bývá v expertních systémech vyjadřována různými způsoby [Provazník et al., 1997]. Mohou to být přiřazené váhy, míry, stupně důvěry aj. nazývané a formulované subjektivní pravděpodobnosti. Tyto numerické parametry jsou přiřazeny jednotlivým tvrzením, pravidlům a datům. Nástrojem v těchto podmínkách je matematická teorie pravděpodobnosti.

Je-li k reprezentaci využito přirozeného jazyka, pak je neurčitost dána stupněm vágnosti použitých jazykových termů (velmi vysoký, asi ano atd.). K formalizaci vágních pojmů se využívá fuzzy množinové matematiky, inferenční mechanismy pak využívají principů fuzzy logiky.

Neurčitost lze také rozdělit na neurčitost v bázi znalostí a neurčitost v bázi dat. Je zřejmé, že oba druhy neurčitosti spolu souvisí. Jestliže pravidlo odvozuje z předpokladů závěr poznamenaný neurčitostí a ten se následně ukládá do báze dat, tak v bázi dat musí být tato neurčitost zohledněna. Důsledek pravidla totiž může být předpokladem pravidla dalšího a tak může docházet k šíření neurčitosti v posloupnosti interpretace pravidel. V tomto smyslu mluvíme o aproximativní inferenci (vyvozování).

Neurčitost vyjádřená pravděpodobnostmi využívá především podmíněnou pravděpodobnost, která vyjadřuje pravděpodobnost realizace jevu A, za předpokladu, že nastal jev B:

$$P(A | B) = \frac{P(A \cap B)}{P(B)}$$

1.2.9. Úloha komunikačního modulu v průběhu konzultace

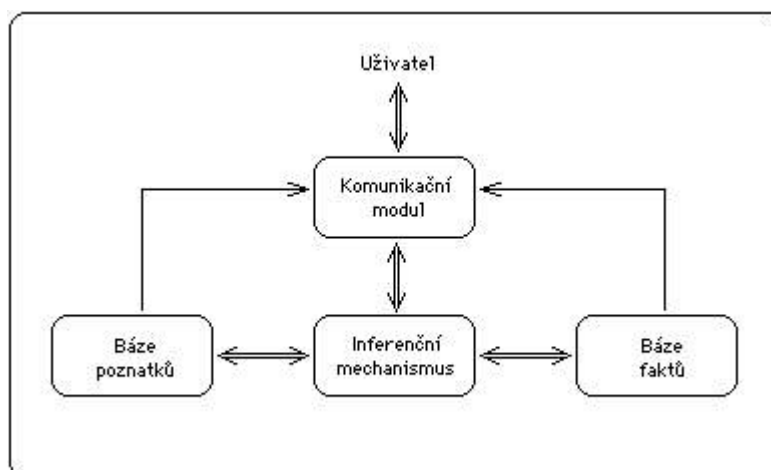
Mezi základní úkoly komunikačního modulu [Mařík et al., 1997] patří:

- Zabezpečuje plynulý dialog (kladení dotazů uživateli, zpracování odpovědí).
- Poskytuje automaticky relevantní informaci o průběhu konzultace.
- Na žádost uživatele poskytuje požadované informace o bázi znalostí a o stavu aktuálního modulu, dále poskytuje celou řadu vysvětlení a zdůvodnění, související s inferenčním procesem.

Velmi důležitou součástí každého expertního systému je vysvětlovací část komunikačního modulu. Rozlišujeme tak schopnost:

- Zodpovídat otázky typu *WHAT* (co je právě zkoumáno, která hypotéza se jeví jako nejméně pravděpodobná).
- Zpracovávat odpovědi na otázky typu *WHY* (proč je v daném okamžiku položen právě tento dotaz aj).
- Reagovat na otázky typu *WHAT-IF*.
- Zprostředkovat uživateli on-line interakci s hypertextovým systémem.
- Komunikovat v přirozeném jazyce. Je nutné odlišovat problém porozumění pokynům a žádostem uživatele od problému syntézy odpovědi. V současné době pouze hrstka expertních systémů využívá možnost přijímat informace v přirozeném jazyce.

Obrázek 6 znázorňuje úlohu komunikačního modulu.



Obrázek 6: Úloha komunikačního modulu v expertních systémech

1.2.10. Budoucnost expertních systémů

V oblasti expertních systémů [Mařík et al., 1997] hrají důležitou roli následující skutečnosti:

- Stimulujícím faktorem pro budování expertních systémů jsou jejich potenciálně široké aplikační možnosti a vysoká univerzálnost.

- Báze znalostí je stále častěji vnímána jako organizovaný soubor utříděných špičkových znalostí příslušné problémové oblasti, přičemž již samotný proces jejich tvorby přispívá k utřídění znalostí.

Expertní systémy nabízejí jako jedna z mála oblastí výzkumu v praxi aplikovatelné technologie pro inteligentní zvládnání informační exploze. Je velice obtížné si představit využití tohoto obrovského objemu dat bez užití znalostí, tj. bez aplikace metod umělé inteligence.

1.2.10.1. ES a jejich nedostatky a teoretické problémy

Mezi nejzávažnější nedostatky expertních systémů [Hayes-Roth, 1983] patří:

1. *Úzká oblast expertizy.* Soudobé expertní systémy jsou schopny fungovat pouze v úzké, bázi znalostí vymezené, problémové oblasti. Mimo tuto oblast nejsou schopny komunikovat.
2. *Nedostatek znalostí o vlastních možnostech a omezeních.* Expertní systémy nejsou schopny sdělit uživateli, co je jejich oblast expertizy, co jsou a nejsou schopny řešit.
3. *Využívání povrchových a málo strukturovaných znalostí.* Soudobé systémy se často opírají o výlučně asociativní znalosti, které experti získávají dlouhodobým sledováním vnějšího chování systémů. Nedostatečná různorodost znalostních struktur vede ve svém důsledku k malé a mnohdy nedostačující strukturalizaci znalostí.
4. *Příliš jednoduchý řídicí mechanismus.* Využívání povrchových znalostí spolu se snahou tvůrců o univerzálnost řídicích mechanismů vede k zjednodušeným představám o práci řídicího mechanismu. Řídicí mechanismy vlastně do značné míry vycházejí z lokálního, úzkého pohledu na řešený problém, přičemž se ztrácí globální nadhled.
5. *Omezené jazykové prostředky pro vyjadřování faktů a znalostí a příliš stylizované prostředky komunikace.* Komunikace s uživatelem je obecně řečeno málo přizpůsobivá, působí schematickým dojmem. Je třeba dodat této komunikaci přirozenější ráz.
6. *Omezené vysvětlovací schopnosti.* Vysvětlovací schopnosti zdaleka nedosahují vysvětlovací schopnosti experta.

7. *Neschopnost pomoci či poradit při základním návrhu struktury báze znalostí.* Současné expertní systémy většinou nejsou schopny poskytnout znalostnímu inženýrovi pomoc při výchozím návrhu struktury báze znalostí. Z toho vyplývá, že při komunikaci uživatele a expertního systému je nezbytná přítomnost znalostního inženýra.
8. *Existence znalostního cara.* Pokud se na tvorbě báze znalostí podílí větší počet expertů, je nezbytné, aby jeden z nich koordinoval znalosti získané od různých expertů a zabezpečoval tak jejich konzistenci.

I přes výše uvedené nedostatky mají expertní systémy veliký význam [Mařík et al., 1997]:

1. V praxi se již využívají k počítačovému řešení úzce vymezených úloh. Technologie jednoduchých diagnostických expertních systémů, které využívají heuristické znalosti je v podstatě zvládnuta.
2. Vývoj ES staví před pracovníky v oblasti umělé inteligence nové teoretické problémy, jejichž řešení přináší podklady pro konstrukci expertních systémů dalších generací.
3. Expertní systémy způsobily změnu v technologii programování. Představují kvalitativní skok od programování klasického k programování situačnímu (vykonávej, když můžeš). Tvorba bází znalostí má charakter programování v programovacím jazyku, který má ve srovnání s běžnými programovacími jazyky (LISP, Pascal) o stupeň vyšší obecnější vyjadřovací prostředky.
4. Existence ES přispívá k výchově budoucích uživatelů a tvůrců systémů založených na znalostech, v nichž se znalosti využívají a zpracovávají.

Vývoj ES jednoznačně vede od poměrně jednoduchých systémů první generace využívajících pouze jeden typ reprezentace znalostí a nepříliš komplikovaný řídicí mechanismus k expertním systémům druhé a vyšší generace. V souvislosti s rozpracováním problematiky expertních systémů vyšších generací lze naznačit některé velmi důležité problémy, které bude třeba v nejbližší době řešit [Mařík aj. 1997]:

- *Výrazně větší využívání hloubkových znalostí* by přineslo kvalitativní skok v možnostech řídicího mechanismu i vysvětlovacího subsystému, a tudíž i v celkové efektivnosti expertního systému.

- *Vnořování kauzálních modelů do ES.* Právě tyto děje se v praxi lépe exaktně modelují.
- *Práce s různorodými zdroji znalostí.* Udržení konzistence znalostí a zvládnutí procesu jejich řízení a vyvolávání z různých segmentů je velmi aktuálním, dnes již částečně řešeným problémem.
- *Schopnosti uvažovat v čase* by měla být vlastní všem systémům řešícím například úlohy predikce chování.
- *Učení z vlastních zkušeností.* Existuje příliš málo systémů, které jsou schopny na základě provedených konzultací měnit strukturu znalostí.
- *Bezprostřední propojování či integrace ES s vnějším prostředím* je dalším přirozeným směrem vývoje v oblasti expertních systémů.

1.2.10.2. Perspektiva ES

Navzdory výše uvedeným problémům a nástrahám expertních systémů existuje celá řada výhod, které svým uživatelům přinášejí [Giarratano at al., 1993]:

- Zvýšená dostupnost expertízy – expertní systémy lze provozovat na libovolných počítačích.
- Snížené náklady na provedení expertízy – cena práce počítače je nižší než cena práce experta.
- Trvalost expertízy – znalosti uložené v expertním systému jsou použitelné trvale, expert může odejít.
- Násobná expertíza – znalosti v expertním systému mohou pocházet od více expertů.
- Vzrůst objektivit expertízy – ve stejných situacích systém rozhoduje stejně, expertízu lze snadno dokumentovat.
- Schopnost vysvětlování.
- Rychlá odezva.
- Úplnost expertízy – expertní systém nepodléhá emocím, únavě či stresu.

Expertní systém současnosti může být dobrý sluha v rukou poučeného uživatele. Budoucnost znalostních systémů patrně nespočívá v samostatných

složitých systémech ohromujících uživatele svou inteligencí, ale v menších tzv. inteligentních modulech zabudovaných do rozsáhlejších aplikací.

1.2.10.3. Case-Based Reasoning

Podstatou systémů Case-Based Reasoning (CBR) [Berka, 1995] (usuzování na základě případů) je představa, že expert se v neznámé situaci rozhoduje na základě podobnosti s již dříve řešenými (a vyřešenými) případy a nikoliv na základě soustavy pravidel. Znalosti jsou tedy reprezentovány v podobě případů a inferenční mechanismus pak mezi nimi hledá případ, který odpovídá dané situaci nejlépe. Buď se požaduje takzvaná *plná shoda* (perfect match) se známým případem, nebo se lze spokojit s případem nejbližším. Znalosti bývají uloženy v databázi, kdy každému záznamu odpovídá jeden příklad a jednotlivé položky jsou charakteristiky případu, tedy dotazy, které systém klade během konzultace. I systém založený na pravidlech, kdy co objekt, to pravidlo, lze chápat jako CBR systém. Taková báze pravidel vznikne prostým přepsáním jednotlivých příkladů.

Mezi klíčové otázky patří volba vhodných příkladů, které dostatečně dobře pokrývají zvolenou oblast expertízy. To se dosti obtížně určuje jednorázově. Některé systémy proto mají schopnost „doučování se“. Jestliže konzultovaná situace neodpovídá žádnému případu z databáze, vyžádá si závěr od experta a vyřešený případ se zařadí do databáze jako nová znalost.

Samozřejmě existuje celá řada komerčně dostupných CBR systémů. Ve své práci o některých z oblasti medicíny pojednám podrobněji v kapitole 6.

1.2.10.4. Lidské zdroje v expertních systémech

Futurologové v oblasti umělé inteligence věří, že výpočetní technika stále větší měrou bude schopna duplikovat odbornou kvalifikaci lidí – výzkumníků [Feigenbaum et al., 1988]. Na druhou stranu skeptici tvrdí, že vzhledem k povaze znalostí jsou stroje schopny podporovat expertízy provázené lidskými zdroji, ale nemohou je kompletně nahradit. Dialog obou skupin vědců vede k různým závěrům týkajícím se manipulace se znalostmi, jejich tvorbě, interpretaci a automatizaci.

1.2.10.4.1. *Expertní systémy a získávání znalostí*

Jak již bylo uvedeno výše, cílem expertních systémů je pracovat s lidskými znalostmi, a to při využití počítačových jazyků. Záměrem každého systému je zpracovat a automatizovat rozhodovací procesy (jež jsou vstupem lidského experta) v počítačové podobě. Tvorba expertního systému zpravidla zahrnuje následující 3 kroky:

1. Sběr informací od jednoho či více lidských zdrojů, nebo z dokumentačních zdrojů.
2. Přeměna získaných informací do procedur (pravidel, omezení) s ohledem na operace, se kterými má daný systém pracovat.
3. Tvorba a adaptace počítačového programu pro uplatnění těchto pravidel a omezení v určených operacích.

Právě první dva kroky jsou charakteristické pro sběr informací a jejich přeměnu do strojem čitelné podoby – což je znakem získávání znalostí. Je na znalostních inženýrech provádět tyto kroky. Raná stádia získávání znalostí často zahrnují rozsáhlá sezení expertů a znalostních inženýrů. Tento dialog je typickou činností pro získávání dat.

1.2.10.4.2. *Získávání znalostí od expertů a případné nástrahy*

Znalostní inženýři rozlišují pojmy „znalost“ a „selský rozum“. Znalost je vnímána jako typ myšlení, které je vlastní expertům. Experti jsou velice často dobře placeni a ve svém odvětví se pohybují na řídicích postech. Právě získání ono částečného know-how od těchto expertů je úkolem znalostních inženýrů. Příprava na dialog s expertem sestává rovněž ze studia knih a jiných pramenů.

Z antropologického pohledu zahrnuje získávání znalostí komplexní sled dotazů. Znalostní inženýr musí porozumět nejen rozhodovací mechanismy experta, ale získané podklady musí být převedeny do strojem čitelné podoby. Tento krok je zpravidla rozdělen do dvou fází. Prvním krokem je konstrukce modelu, který popisuje činnosti jimiž se expert zabývá, kombinuje porozumění explicitního modelu experta v interakci s informacemi získanými z kontextu dialogu. Za druhé, následně vykonstruovaný model má být přeložen do takové podoby, aby informace mohla generovat užitečná tvrzení o externím světě. Velice často právě tento krok je označován jako „úzké místo“ (bottle neck) při tvorbě

expertních systémů – „sběr a kódování znalostí potřebné pro vytvoření inteligentního učícího systému je stále časově náročným úkolem, což v důsledku vede k alokaci zvýšených zdrojů na projekt. Samozřejmě se zde promítá nedostatek vysoce-sofistikovaných nástrojů při získávání znalostí...“[Buchanan et al.,1983].

Znalost neexistuje sama o sobě, musí být interpretována. Zprávy jsou vnímány, protože účastníci rozmluvy sdílejí znalosti o světě. Vztah mezi tím, co si lidé myslí že dělají, co říkají že dělají a tím co pozorují, je velice komplexní. Znalostní inženýři však pohlížejí na tuto oblast trochu z jiného pohledu. Problém dle jejich názoru není v podstatě samotné získávání informací od expertů, ale v tom, že lidé jsou součástí různých zájmových skupin. Nápravou je v jejich pojetí automatizace získávání znalostí, což je v rozporu se „společenským“ vnímáním.

1.2.10.4.3. *Postoj znalostního inženýra ke znalostem*

- Vnímá znalost jako tvrzení: existuje nebo chybí, je správná nebo špatná. Znalost je koncipována jako absolutní pojem dle tvrzení: jestliže ji máš, jsi expert, jestliže ji postrádáš jsi novic. Tento postoj je v rozporu s názorem vědců, kteří tvrdí, že i nováček vládne znalostmi, ale jiného charakteru než expert.
- Vnímá usuzování jako proces, který respektuje formální pravidla
- Staví se ke znalostem jako k čistě kognitivnímu fenoménu. Znalost je alokována výhradně v individuální mysli. Její zkoumání je procesem myšlení.

Výše uvedený postoj znalostního inženýra má rovněž dopad na znalosti v expertních systémech

1. Znalosti mají v expertním systémem z pohledu inženýra statickou povahu. V každodenním životě dochází k výměně názorů, postojů mezi lidmi. Ale informace obsažené ve znalostní základně nejsou modifikovány dle tohoto přístupu. Vypuštěná informace je dle nich irelevantní.
2. Znalosti obsažené v expertních systémech mají velmi často křehkou povahu. Důvodem je i fakt, že inženýři obecně podceňují vztah mezi

domněnkou a akcí. Známým příkladem takového opomenutí je případ expertního systému MYCIN. Pacient mužského pohlaví byl infikován bakteriální infekcí a MYCIN určil jako jeden z možných zdrojů nákazy předchozí amniocentézu [Buchanan et al., 1984]. Přestože se tento fakt zdá být absurdním, nikdo nevložil do systému informaci o tom, že muži nemohou být těhotní. Informace o tom, které pohlaví může být těhotné je tak jasná, že experti nepovažovali za nutné toto sdělovat znalostnímu inženýrovi.

3. Dialog s omezeným počtem expertů může způsobit problémy při globální implementaci expertního systému.

III. SPECIFICKÉ RYSY EXPERTNÍCH SYSTÉMŮ V MEDICÍNĚ

Tento oddíl je orientován na specifické rysy expertních/znalostních systémů v lékařství. Právě tato oblast lékařské informatiky prožívá v posledních letech na významu, což je způsobeno rozvojem informačních technologií a rovněž novými programovacími jazyky, které se dané problematice věnují. Práce lékaře se mění ze zcela individuálního pojetí na pojetí týmové spolupráce, která se opírá o stále se zužující specializace. Cílem znalostních systémů je pomoci lékaři řešit otázky spojené s poznáním a podílet se na určení diagnózy, terapie a prognózy.

Postupně se v jednotlivých kapitolách věnuji podpoře rozhodování v medicíně, vymezují základní pojmy spojené s oblastí tvorby a užití expertních systémů v lékařství. Při studiu jsem vycházel zejména z anglicky psané literatury [Warner et al.,1997], [Coieira, 2003], [Silbernagl,1993], [Buchanan, 2006], protože dané problematice se nevěnuje příliš mnoho českých autorů. Výjimkou je [Kasal et al, 1998], [Zvárová et al., 1992] nebo [Berger, 1993].

1.3. Obecné aspekty medicíny ve vztahu k ES

1.3.1. Metody podpory rozhodování v medicíně

Metodám podpory rozhodování v medicíně věnovalo velkou pozornost mnoho významných odborníků. Například Braude [Braude, 1987] pojímal medicínskou informatiku jako aplikaci počítačové vědy do lékařství a zdravotnictví, která zahrnuje zejména následující oblasti:

- Reprezentace znalostí, principy vytváření bází znalostí a databází v medicíně.
- Studium vlastností přirozeného jazyka v medicínském kontextu a metody zpracování textové informace.
- Metody umělé inteligence, aplikované na báze znalostí a při vytváření expertních systémů.
- Studium lidských faktorů při ukládání a využívání znalostí v počítači a při používání i konzultačních systémů.
- Metody rozhodování a řešení medicínských problémů.

- Analýza podstaty medicínských znalostí a jejich významu pro klinické aktivity.
- Studium vlivu pokročilých počítačových technologií na ustálené postupy při zjišťování, přenášení a využívání medicínských znalostí.

V medicíně je rozhodování založeno na dvou základních typech znalostí: *vědeckých znalostech* (poznání podstaty problémů a procesů biomedicínským výzkumem) a *empirických znalostech* (zkušenostech, získaných při diagnostice a léčbě pacientů). Oba typy znalostí jsou popisovány v učebnicích a dalších odborných publikacích a zejména vědecké znalosti jsou vyučovány na lékařských fakultách. Vědecké znalosti (know-how) jsou kognitivního typu, tj. poznáváme podstatu biologických procesů, vztahy mezi patofyziologickými podmínkami a příznaky nemocí. Klinická zkušenost, soustředěná v dobře vedené dokumentaci o nemocných a v počítačové formě uložená v databázi nemocných, tvoří empirické znalosti (know-how): lékař zjistí určité příznaky a na jejich základě rozpozná chorobu pacienta.

Na rozdíl od činnosti lidského mozku, musí být proces rozhodování za pomoci počítače přesně popsán. Systémy pro podporu rozhodování mohou tedy pracovat na základě různých metod. Tyto metody lze zhruba rozdělit na statistické, logické a heuristické. Ke statistickým metodám patří například známé bayesovské rozhodování, mezi logické metody rozhodovacích stromů a k heuristickým metodám řadíme takové expertní systémy, kdy odvozování závěrů o vyšetřovaném pacientovi probíhá s využitím bází medicínských dat a znalostí.

S rozvojem nových informačních technologií se zdá být přirozené, že v blízké budoucnosti se počítače stanou cenným pomocníkem lékaře v náročných rozhodovacích situacích. To předpokládali již v padesátých letech Ledley a Lusted [Ledley et al., 1960], ale jejich vize se tehdy nenaplnila. Vyvíjené systémy pro medicínskou podporu rozhodování byly příliš ambiciózní. Snažily se pokrýt problémy z celé klinické medicíny a málo se orientovaly na praktické potřeby lékařů, kde by mohly poskytnout účinnou pomoc i při poměrně málo rozvinutém technickém vybavení počítačů. Toto počáteční selhání systémů pro podporu rozhodování v 60. letech vedlo k tomu, že v 70. letech se pozornost soustředila na

vytváření systémů, zaměřených do dílčích oblastí medicíny. Typickým příkladem je systém pro diagnostiku náhlých bolestí břicha vyvinutý v Leedsu [Knikl-Jones et al., 1973] a diagnostiku žloutenky, jejichž báze dat se týkají úzké medicínské oblasti a k odvozování závěrů využívají bayesovský model rozhodování. Současně se začaly vyvíjet techniky umělé inteligence podporující lepší formalizaci medicínských znalostí. K významným systémům založeným na znalostech patří například PIP [Pauker et al., 1976], CASNET [Weiss, 1978], MYCIN a INTERNIST-1, které používaly různé techniky pro reprezentaci a ukládání znalostí.

Systémy pro podporu rozhodování jsou v současné době předmětem intenzivního interdisciplinárního výzkumu. Podpora rozhodování je často založena na údajích o nemocných, ukládaných v rozsáhlých medicínských databázích. V tomto případě je cílem výzkumu vyhledávat takové znaky, které umožňují kvalitní rozhodování pro daný medicínský problém. Pro tento účel jsou vyvíjeny různé metody pro redukci a konstituci dat a výběr relevantních znaků pro rozhodování.

Expertní systémy nacházejí využití v lékařské praxi především v následujících případech [Zvárová et al., 1992]:

- Nahrazují experta v situacích, kde není dostupný.
- Umožňují expertovi, aby si nemusel pamatovat velmi vzácné údaje.
- Nahrazují vysoce kvalifikované, ale monotónní rozhodovací činnosti, např. dávkování léků.
- Monitorují ohrožené nemocné na jednotkách intenzivní péče.
- Pomáhají v pregraduální i postgraduální výuce.

1.3.2. ES a prostředí v medicíně

Expertní program může svým nasazením v klinické praxi přispět ke zkvalitnění těch terapeutických postupů, které jsou sice poměrně časté, ale v terénu nejsou vykonávány s takovou kvalitou rozhodování, jaké je schopen živý expert. V tomto případě získá expertní program rovněž charakter vzdělávacího programu, a je tedy možné, že po určitém čase se jeho uživatelé naučí postupy v té kvalitě, kterou předtím dosahoval pouze expert.

Vzdělávací charakter expertních programů je často příčinou toho, že některé systémy nedosahují po delší době používání v praxi již tak výrazného zlepšení léčby oproti samostatným rozhodnutím zdravotnického personálu.

Vzhledem k tomu, že soudobý expertní systém může úspěšně řešit problematiku v úzké klinické praxi, jsou tyto programy zejména součástí lokálních počítačových systémů. Pokročilejší jsou dneska taková řešení, kdy expertní moduly jsou funkční součástí lokálního informačního systému a jsou schopny se aktivovat automaticky v situacích, pro které jsou určeny.

Expertní systémy jsou v oblasti medicíny předmětem zkoumání a testování po dobu cca 25 let. Navzdory všem výsledkům mají expertní systémy ve větším rozsahu minimální dopad na denní rozhodovací procesy lékařů. Mezi důvody, které v největší míře limitují větší rozšíření expertních systémů patří [Warner et al.,1997]:

- Existující expertní systémy nejsou často řádně precizní a spolehlivé.
- Vývoj expertních systémů je časově i finančně náročným procesem.
- Existuje přirozený odpor lékařů k expertním systémům. Lékaři nejsou dostatečně informováni o užitečnosti a nákladové návratnosti ES. Dalším důvodem je přirozený odpor ke změnám, negativní postoj k výpočetní technice, nedostatek času na školení příslušného software.
- Na trhu je nedostatek velikých, spolehlivých klinických databází (hlavně těch, které obsahují příznaky a symptomy), které by mohly být použity jako kvalitní podklad pro konstrukci ES.
- Medicína je komplexní oblast, už jenom díky vrozené komplexitě lidského těla a chorob.
- Častý nedostatek objektivních „zlatých standardů“, které napomáhají odhalit pravdu.
- Rozdílný přístup v praktikách lékařů při výkonu povolání.
- Naše znalosti o biologii živých organismů jsou jen malým zlomkem znalostí, které bychom potřebovali k tomu, abychom mohli funkce organismu exaktně popsat.

Je potřeba rovněž uvést kladné aspekty pro uplatnění ES v medicíně [Warner et al.,1997]:

- Rostoucí dostupnost, zvyšující se výkon a klesající náklady na hardware a software.
- Stále pokračující práce v oblasti základního vědeckého výzkumu v oblasti medicíny, počítačové vědy a medicínských informací.
- Růst počítačového zpracování dat o pacientech a dostupnost klinických databází stále ve větší míře.
- Rozvoj standardů, které usnadňují výměnu informací mezi jednotlivými systémy (HL7, Arden syntax).
- Zvyšuje se množství malých, úzce specializovaných expertních systémů, například v oblastech interpretace ECG, testování plynů v krvi, funkčnost plic atd.

1.3.2.1. Proč budovat expertní systémy v medicíně ?

Díky vlivu „informační exploze“ v minulých několika dekadách se i praktičtí a specializovaní lékaři začali potýkat s problémem optimálního stanovení diagnóz s ohledem na množství informací, které bylo potřeba zpracovat. Četné empirické studie prokázaly, že se lékaři potýkají s problémy při stanovení diagnóz. Záměrem expertních systémů je podpora lékařů a ostatních zaměstnanců v oboru, přičemž hlavním úkolem je doplňovat jejich přirozenou schopnost konání úsudků při využití počítačové paměti a procesorů. Dalším kladem expertních systémů je vzdělávání nebo inteligentní interface pro klinické databáze.

1.3.2.2. Definice ES v medicíně

Typickým vstupem při rozvoji expertních systémů v medicíně je popis pacienta (věk, pohlaví, rizikové faktory, symptomy, příznaky, laboratorní údaje). Výstupem je pak odvozená informace o daném pacientovi (diagnóza, návrhy na patřičná vyšetření).

Expertní systém v medicíně sestává nejméně ze dvou komponent:

- **Báze znalostí** – je sbírkou kódovaných znalostí, které jsou zapotřebí při řešení problémů v medicínské oblasti
- **Inferenční mechanismus** – jde o počítačový program, který zpracovává informace z báze znalostí

Jedinci, kteří v expertních systémech zadávají problémy k řešení jsou označováni jako *uživatelé*. Lékaři, kteří přispívají svými znalostmi při tvorbě báze znalostí jsou označováni jako *medicínští experti*. Ti, kteří vytváří a rozvíjejí podpůrný software jsou *znalostní inženýři*.

1.3.2.3. Obecné otázky při tvorbě ES

Při tvorbě expertních systému v medicíně se setkáváme s několika obecnými problémy, jež je potřeba řešit [Kasal et al., 1998]:

- 1) *Získávání znalostí* – jak správně interpretovat lidské myšlenky, znalosti, které již v omezené míře existují v medicínských příručkách, odborných časopisech, klinických databázích do počítačové podoby?
- 2) *Reprezentace znalostí* – jakým způsobem reprezentovat lidské znalosti v datové struktuře, která je dále zpracovávána v počítačích?
- 3) *Metoda inference* – jak pracovat s abstraktními datovými strukturami s cílem dosáhnout užitečných informací v daném případě?

Mezi další otázky patří:

- jak pracovat se znalostmi tak, aby se podalo patřičné vysvětlení na požadavek uživatele?
- jakým způsobem verifikovat a aktualizovat bázi znalostí?
- jak hodnotit a validovat expertní systémy v medicíně?

1.3.2.4. Reprezentace znalostí v medicíně

Existuje celá řada kategorií, do kterých lze expertní systémy v medicíně zařadit:

- klinické algoritmy,
- klinické databanky, (zahrnují analytickou funkčnost),
- matematické patofyziologické modely,
- systémy na rozpoznávání obrazců,

- bayesovské statistické systémy,
- rozhodovací analytické systémy,
- další expertní systémy.

Diagnostické systémy v reálném prostředí balancují mezi teorií (komplexnost modelu) a praktičností (schopnost konstrukce a uchování adekvátní báze znalostí, a schopnost vytvářet takové systémy, které reagují v krátkém časovém intervalu na potřeby uživatelů).

Znalostní inženýři by při tvorbě expertních systémů měli brát v úvahu:

- stupňovitost symptomů
- stupeň nejistoty který se při vyšetření pacienta vyskytuje v souvislosti s patofyziologickými mechanismy
- časový průběh nemocí

V oblasti stanovení diagnóz se často uplatňuje kategorické nebo pravděpodobnostní usuzování. Mezi metody, které se v současné době nejvíce uplatňují patří reprezentace znalostí pravidly, pravděpodobnostmi nebo jejich kombinace.

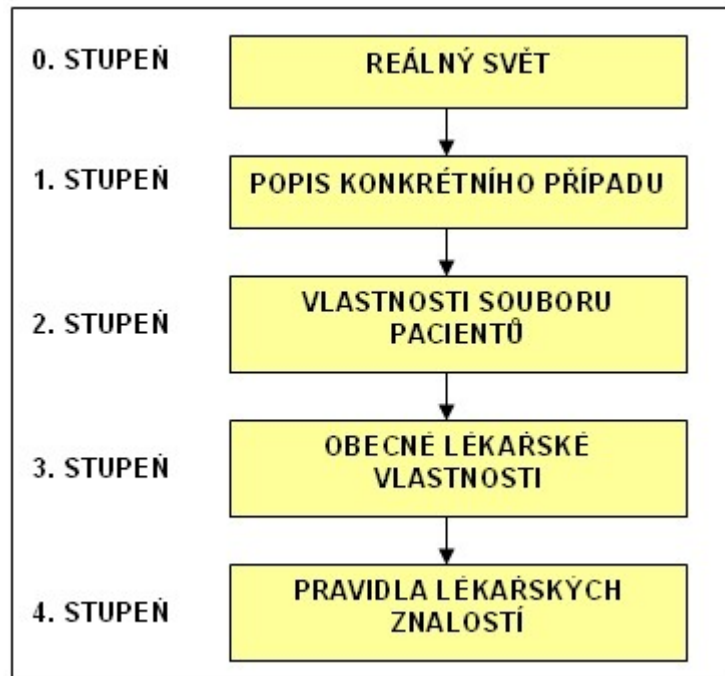
1.4. Formalizace lékařského problému

1.4.1. Obecné aspekty procesu formalizace

Formalizace lékařského problému je oblastí, která klade při využívání výpočetní techniky na lékaře vysoké nároky z hlediska jeho aktivity [Zvárová et al., 1992]. Můžeme konstatovat, že se jedná vlastně o transformaci odborných informací do podoby umožňující jejich zpracování počítačem. Jestliže přisoudíme lékaři pasivní roli, vzniká tak neúnosné riziko zkreslení výchozí informace. Nejedná se přitom o tvorbu samotných konkrétních programů, ale o přípravu podkladů pro jejich tvorbu, které vycházejí právě ze zobecnění určitého lékařského problému - jako příklad můžeme uvést klinická data, lékařské znalosti a podobně.

1.4.1.1. Modely zobrazení reality

K pochopení formalizačního procesu může posloužit model [Zvárová et al., 1993], Obrázek 7 zobrazuje objektivní realitu.



Obrázek 7: zobrazení objektivní reality – stupně formalizace

Nyní rozeberme jednotlivé stupně formalizace:

- „Nultý stupeň“ – výchozí úroveň je reálný svět, který představuje například pozorování na konkrétních nemocných osobách.
- „První stupeň“ – popis uvedených konkrétních případů, například záznamu o zdraví a nemoci. Jedná se o sběr a popis získaných informací, které autor považuje za důležité.
- „Druhý stupeň“ – zpracování skupiny jednotlivců v rámci klinického výzkumu, kde je proveden kromě výběru příznaků i pokus o zobecnění získaných pozorování.
- „Třetí stupeň“ – prezentace znalostí, které již většinou neodkazují na konkrétní zpracovaný materiál, jako příklad poslouží učebnice pro studenty lékařských fakult.
- „Čtvrtý stupeň“ – transformace lékařského problému do podoby, jenž je přípravou pro tvorbu počítačového programu. Zásadní změnou je změna symboliky. Dochází k zavedení matematicko-logického aparátu do popisu

objektů a relací, případně i k různým formám indexování těchto objektů. Z pohledu lékaře, se vymezují na tomto stupni 3 aspekty:

- o *Aspekt pragmatický* – jedná se o posouzení významu jednotlivých informací, určení jejich významnosti z hlediska začlenění do konečného stupně formalizace. Prakticky jde výhradně o odborný problém, jenž patří do kompetence lékaře.
- o *Aspekt sémantický* – posouzení smyslu transformovaných informací, aby nedošlo k jejich zkreslení. Zde je nutná kooperace lékaře a znalostního inženýra.
- o *Aspekt syntaktický* – zde je kladen požadavek, aby zápis odpovídal příslušným pravidlům formálního zápisu, například při tvorbě báze znalostí v rámci konkrétního programovacího jazyka.

1.4.1.2. Prostředky formálního popisu

Pro formální popis problému lze zvolit různé prostředky [Zvárová aj., 1992]. Volba aplikované metody v praxi je většinou závislá na odborném zaměření řešitele. Pracovní metody jako jsou matematika, statistika, logika nebo kybernetika se značně liší a navíc je i jejich pojmový aparát pro vyjádření téže podstaty zcela rozdílný. Tabulka 3 [Kasal et al., 1998] znázorňuje způsoby formálního popisu, jsou v ní uvedeny základní teorie, se kterými pracují jednotlivé uvedené obory při popisu objektivní reality – pojmy pro popis objektů, vztahy mezi nimi a rovněž vyjádření nejistoty v rámci takového popisu. Jako příklad lze uvést teorii množin. V rámci teorie množin bude onemocnění chápáno jako množina příznaků, vztahy mezi příznaky jako množinové relace a jejich diagnostický význam pro dané onemocnění jako stupeň příslušnosti k množině. Z hlediska kybernetiky bude základem systém, jeho patofyziologické mechanismy budou informacemi a neurčitost jejich manifestace entropií.

Z tabulky je patrné, že mezi prostředky formálního popisu patří:

- *Množiny* – obecný popis problému, výhodou je jednoduchost a názornost.
- *Logické notace* – má již podobu formule, kterou provází vždy její pravdivostní hodnota (nejvýhodnější prostředek pro znalostní pravidla).
- *Matematické a statistické prostředky* – použití v rámci specializovaných výpočtů.

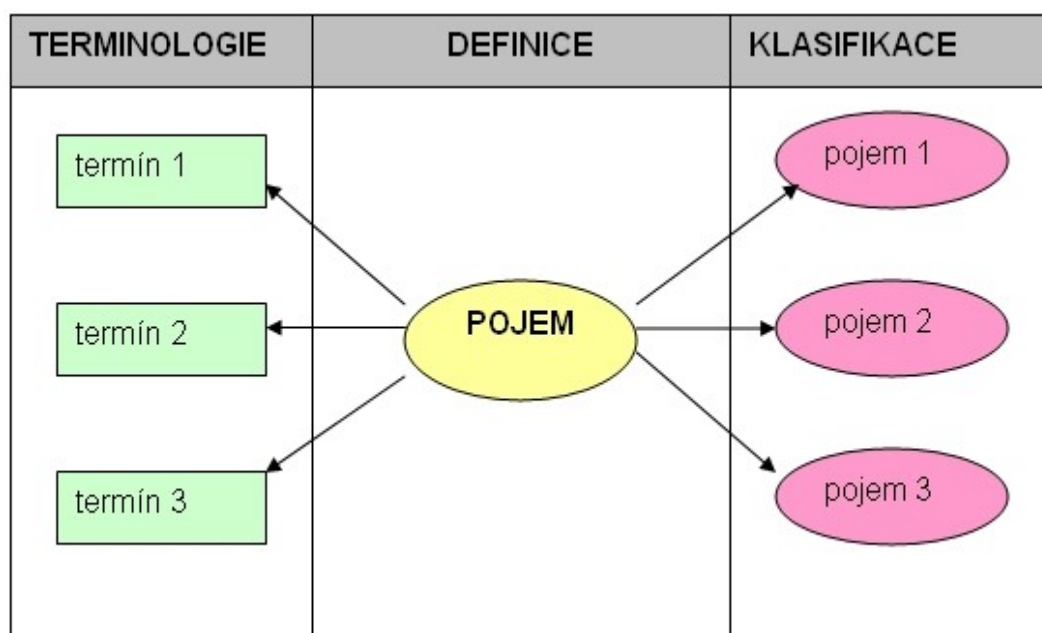
- *Kybernetický přístup* – zaveden zejména pro dynamické systémy, kde se používá pro popis fyziologických a patofyziologických dějů.

	OBJEKT	VZTAH	NEJISTOTA
LOGIKA	výrok	predikát	pravdivost
TEORIE MNOŽIN	množina	relace	příslušnost
MATEMATICKÁ ANALÝZA	proměnná	funkce	diferenciál
STATISTIKA	jev	závislost	pravděpodobnost
KYBERNETIKA	systém	informace	entropie

Tabulka 3: způsoby formálního zápisu

1.4.1.3. Lékařský pojem a termín

Zjištěním společné vlastnosti objektů získáme *pojmem*, který rovněž vypovídá o jejich významu. Přesná formulace významu pojmu je *definice*. Název (termín) potom na druhé straně tento pojem pojmenovává. Vztah mezi příbuznými pojmy řeší klasifikace. Obrázek 8. znázorňuje formální popis pojmu.



Obrázek 8: Formální popis pojmu

Vymezení, pojmenování a třídění lékařských pojmů není ve srovnání s ostatními přírodními vědami zcela optimální. V praxi pro jeden pojem existuje často více než deset synonym a chápání přesnějšího vymezení klinické jednotky (příznak, diagnóza) je v řadě oborů v rámci medicíny rozdílné. Praktickým

negativním důsledkem je pak situace, kdy efekt nového léku či hodnot nové vyšetřovací metody u dané diagnózy je popisován ve dvou publikacích. Za předpokladu, že chápání této diagnózy je v každé z publikací poněkud posunuto a jedná se tak o rozdílné množiny pacientů, často se můžeme setkat i s kontroverzními výsledky, což výsledně hodnotu finální informace snižuje. Paradoxně stále větší využívání výpočetní techniky tuto skutečnost pouze prohlubuje, protože předpokladem pro využívání počítačů je větší jednoznačnost zadání dat, vymezení pojmů nebo jejich přesné pojmenování.

Po přesném vymezení pojmu a přiřazení příslušného termínu je nutné určit jeho postavení v soustavě pojmů příbuzných. Mezi problémy patří i fakt, že existuje řada rozdílných třídění jednotlivých oblastí lékařství podle jednotlivých odborných škol.

1.4.1.3.1. *Odborná terminologie*

Lékařský jazyk [Kasal et al., 1998] – je definován na rozhraní jazyka přirozeného a formálního. Terminologie je většinou do jisté míry závazná, ale jsou zde přítomny i prvky a zvyklosti přirozeného jazyka, což se negativně projevuje při zpracování informací výpočetní technikou.

Synonyma [Kasal et al., 1998] – v odborné terminologii vede synonymie k nepřesnostem. Užití synonym má opodstatnění zejména při dvojici výrazů domácí-mezinárodní, či v odborném vs. populárním sdělení. Aspekty pro posouzení vhodnosti užití synonym lze rozdělit do dvou skupin: systémovost a přesnost (požadavky na standardní přesné a správné vymezení pojmů), do druhé skupiny patří úspornost a funkčnost (zahrnují aspekty praktické – jednoduchá, stručná a funkční komunikace).

1.4.1.3.2. *Klasifikace lékařských pojmů*

Mezi základní problémy při zpracování lékařské informace patří otázka standardního označení odborných pojmů. V praxi dochází k tomu, že tatáž klinická situace je obvykle každým lékařem popsána různě, počínaje rozdíly v chápání odborných faktů až po použití odlišných termínů pro tentýž pojem. Tato skutečnost má za následek fakt, že činnosti jako tvorba lékařských dat, jednotné ukládání dokumentace a dále pak zpětné informace jsou značně problematické.

Postupem času tak vznikaly lékařské nomenklatury, tj. tříděné (klasifikované) seznamy pojmů, které byly a jsou vhodné pro počítačové zpracování. Mezi nejznámější patří [Kasal et al., 1998]:

- *Mezinárodní klasifikace nemocí a příčin smrti (ICD)* – je přepracovávána každých 10 let, pod záštitou WHO.
- *ICD-0* – rozšíření ICD pro kódování onkologie.
- *TNM* – klinická klasifikace maligních nádorů, především pro účely srovnání terapeutických studií.
- *DSM III* – psychiatrická nomenklatura.
- *Endoskopická nomenklatura* – podrobně zpracovaná jednoúrovňová nomenklatura.

1.4.1.3.2.1. Trendy v klasifikaci lékařských pojmů

Po dlouhou dobu byla diagnóza chápána jako přesně vymezená entita a základním úkolem lékaře bylo přiřazení některé z daných diagnóz konkrétnímu pacientovi, následně byla terapie a prognóza již automaticky odvozena z uvedené diagnózy.

V současné době se objevuje celá řada pravděpodobnostních přístupů k tomuto problému. Byla navržena koncepce multifaktoriální patogeneze, respektující genetické odlišnosti a současně i rozdíly vlivem u jednotlivých osob klinického případu: patofyziologie, závažnost, orgánový systém a etiologie³. Namísto hledání přesně vymezených diagnóz jsou tak tvořeny spíše diagnostické třídy a v jejich rámci pak podtřídy pacientů s podobným průběhem. Nomenklatura se v tomto ohledu stává jen seznamem diagnostických ideálů, kde mají konkrétní případy vždy jen určitý stupeň příslušnosti k modelové představě o typickém onemocnění. Mezi nejznámější systémy tak patří [Zvářová et al., 1992]:

- *SNOP* – Systematizovaná nomenklatura patologie, 4-úrovňový systém: topografie, morfologie, etiologie a funkce.
- *SNOMED (Systemized Nomenclature of Medicine)* – dodnes jediný ucelený systém, který pokrývá oblast celého lékařství, popis jakékoliv situace v medicíně pomocí 6

³ nauka o vnitřních a zevních příčinách nemocí

úrovni-dimenzí: topografie, morfologie, etiologie, funkce, nemoc, procedura. Systém je striktně hierarchický, jde o úplný systém podmnožin, což ve své podstatě zjednodušuje práci počítače s lékařskými pojmy na vyšší úrovni.

1.4.2. Aplikace formálního popisu

Pomocí aplikací formalizace lékařského problému dochází k přípravě pro vytvoření konkrétního algoritmu, databáze nebo její zvláštní formy – báze znalostí. U většiny tzv. prázdných expertních systémů může lékař zadávat znalosti přímo interaktivním způsobem. Těžiště práce tkví poté v rozboru odborného problému s cílem vytvoření jeho jasné logické struktury. Konečným výsledkem je pak vytvoření báze znalostí.

1.4.2.1. Datové modely

Příkladem elementární formalizační úlohy je popis a uspořádání dat při tvorbě databáze. Tento postup je charakteristický danými principy včetně specifické terminologie, které se odlišují v závislosti na použitém přístupu:

- klasický model,
- relační model,
- konceptuální model.

Mezi nejběžnější praktické aplikace patří popis jako příprava pro jejich další zpracování. Pro komplexnější práci s daty typu *znalosti* je navíc zapotřebí využití dalších metodologických postupů.

1.4.2.2. Procedurální popis

Zde dochází k převodu problému do schématu. Jedná se o takzvanou *algoritmizaci*, která bývá někdy zaměňována za formalizaci, což je pojem podstatně širší. Příkladem procedurálního popisu jsou terapeutické návody, jejichž schéma může sloužit jako přímý návod pro odbornou činnost stejně tak jako východisko pro práci programátora. Problematika algoritmizace je součástí programování.

1.4.2.3. Deklarativní popis

Jako vstupní informace pro tvorbu báze znalostí lze užít jednak údaje literární, jednak výroky expertů. Ty mají velice často podobu heuristik – zkušeností intuitivního typu, které nemusí být nezbytně racionálně zdůvodnitelné. Při získávání expertních informací je vyžadován specifický přístup. Dochází k objektivizaci subjektivních informací za využití expertů. Následně je nutno expertní informaci ohodnotit, což se provádí vzhledem k jejímu specifickému charakteru nejčastěji využitím škálování. Hledání příslušného řešení (odvozování) je realizováno přímo v rámci vlastního programovacího deklarativního jazyka. V 70. a 80. letech patřily mezi nerozšířenější prostředky jazyky Prolog, LISP, Logo aj.

1.4.2.4. Báze znalostí

V expertních systémech je velmi často báze znalostí zcela oddělena od odvozovacího mechanismu. Obecně může být báze znalostí organizována v podobě produkčních pravidel, sémantické sítě, rámců nebo objektů. Důležitý je fakt, že uvedené typy organizace jsou různě vhodné pro jednotlivé typy klinických problémů.

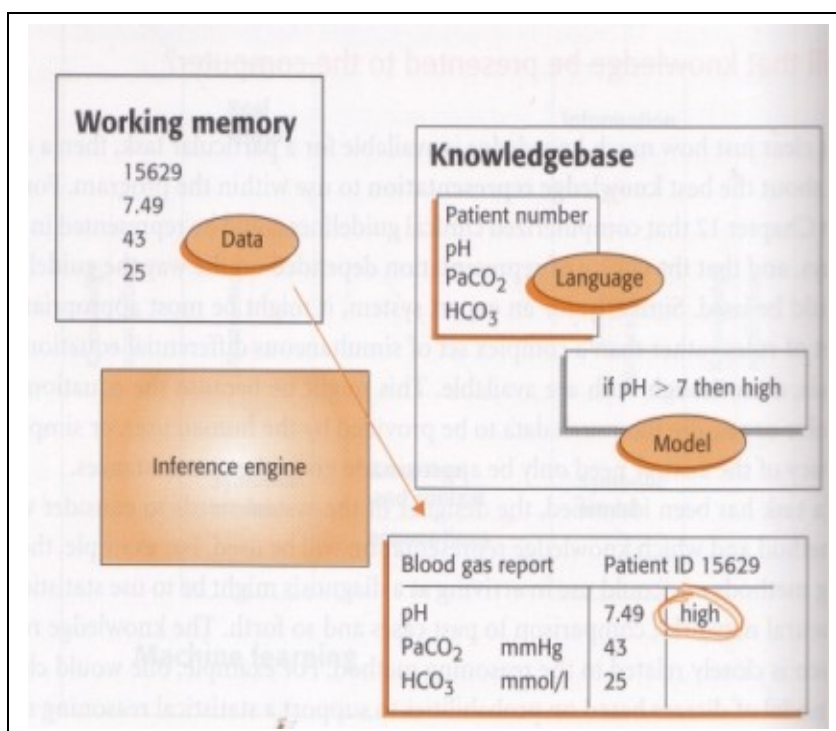
1.4.2.5. Typy klinických situací

Jestliže se rozhodneme vytvořit bázi lékařských znalostí, musíme respektovat nejen požadavky pro standardní formální popis, ale navíc je žádoucí, aby byla tato znalostní báze i standardně organizována. Existuje vysoké riziko, že rozsáhlejší databáze nebude přesně vyjadřovat informace pro danou oblast, a to díky nepřesné reprezentaci faktů a dále pak pro svou nepřehlednost.

1.4.3. Reprezentace znalostí v medicíně

Jak již bylo pojednáno dříve, expertní systémy mají na rozdíl od ostatních modelů oddělenou bázi znalostí od odvozovacího mechanismu. Báze znalostí je vytvářena formalizací lékařského problému, odvozovací mechanismy pak využívají různé formy rozhodování v podmínkách neurčitosti. Obrázek 9 [Coieira,

2003] zobrazuje vztah mezi třemi komponentami expertních systémů: bází znalostí, bází dat a inferenčním mechanismem.



Obrázek 9: Vztahy mezi komponenty expertního systému

Expertní systémy můžeme rozdělit na 2 velké skupiny [Kasal et al., 1998]:

- **Logické systémy** – typickou vlastností je možnost volného přidávání znalostí bez narušení báze znalostí. Tyto systémy se využívají zejména v oblastech, kde jsou znalosti ucelené - zejména je možno popsat i vzájemné závislosti jednotlivých pravidel. Zdrojem informací je zpravidla expert, neboť je zde nutno formulovat jako součást báze znalostí i poznatky, které jsou pouze v literatuře velmi těžko dostupné. Klasickým příkladem je systém MYCIN, jenž byl určen pro rozhodování v oblasti léčby infekcí. Podstatou těchto systémů jsou zejména:
 - **predikátová logika,**
 - **produkční pravidla.**

- **Kognitivní systémy** – tyto systémy jsou schopny přesněji modelovat úvahu lékaře (stanovení hypotézy a její ověření). Dochází zde ke sdružování znalostí týkajících se určitého faktu, což je vhodné pro usnadnění jejich vyhledávání. Používají se i v případech, kdy není možné popsat všechny konkrétní závislosti mezi příznaky a diagnózami vyčerpávajícím způsobem. Z toho plyne i použití v situacích, kdy přichází v úvahu kombinovaný výsledek = několik diagnóz současně. Nejznámějším zástupcem je systém INTERNIST, který diagnostikoval vnitřní onemocnění. Tyto systémy využívají:
 - o **sémantické sítě,**
 - o **rámce.**

1.4.3.1. Predikátová logika

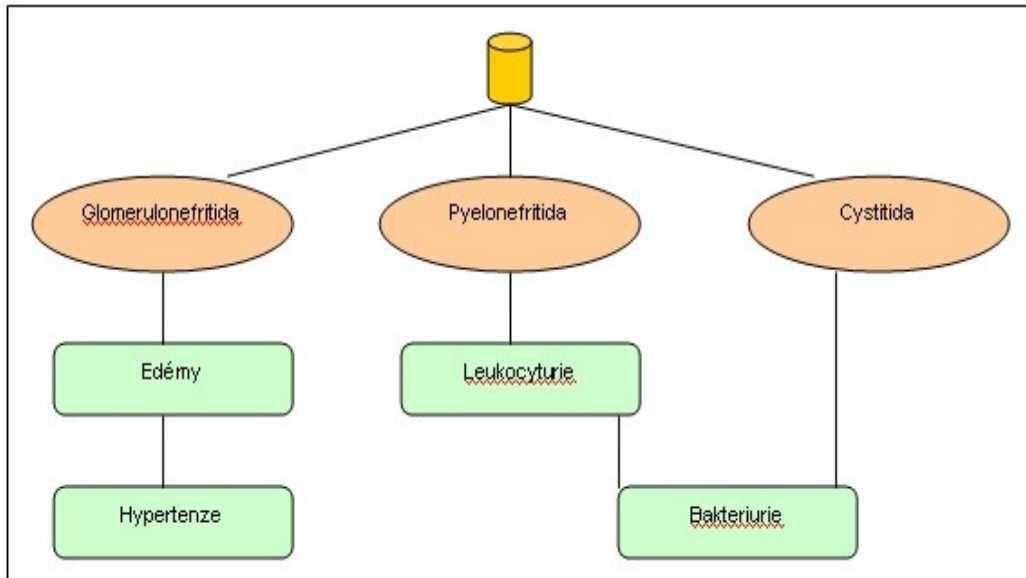
Postupem času se ukázal jedním z vhodných prostředků při tvorbě expertních systémů programovací jazyk PROLOG. V klasických programovacích jazycích je nutno počítači sdělit „co má dělat“, v programu je potřeba popsat postup, jakým způsobem má být úloha řešena. Oproti tomu v deklarativních jazycích je naproti tomu těžiště programu v zapsání – takzvané deklaraci znalostí o daném problému, jenž jsou potom v následném běhu programu již automaticky kombinovány. Tento postup silně připomíná lidskou úvahu, kdy jsou znalosti vybírány z lidské paměti a odvozovány pomocí zákonů logiky. V jazyce PROLOG je zásobou znalostí databáze, odvozovacím mechanismem je potom *predikátová logika*, jejíž pravidla jsou součástí programovacího jazyka.

Predikátová logika pracuje s vnitřní strukturou výroků, které jsou ve výrokové logice již dále nedělitelnými celky.

- Jednomístný predikát vyjadřuje *vlastnost* objektu: Výrok „Streptokok je bakterie“ vypadá ve formálním zápise takto: *bakterie (Streptokok)*.
- Dvoumístný predikát vyjadřuje *vztahy*. Formální zápis vypadá takto: *lécit (angína, Penicilin)*.

Obrázek 10 uvádí příklad databáze [Kasal et al., 1998], která vychází z algoritmů příznaků při zánětech močového systému. V jazyce PROLOG definujeme skupinu nálezů a po spuštění programu PROLOG interaktivně

komunikuje s uživatelem a ptá se ho na cíl programu. Po zadání dotazu, například „nález (pyelonefritida, bakteriurie)“ začne PROLOG prohledávat databázi a hledá tak fakta, která se ztotožní s faktem v otázce. Odpověď by byla v tomto případě kladná, protože bakteriurie je příznakem pyelonefritidy.



Obrázek 10: Algoritmus příznaků při zánětech močového systému

1.4.3.2. Produkční pravidla

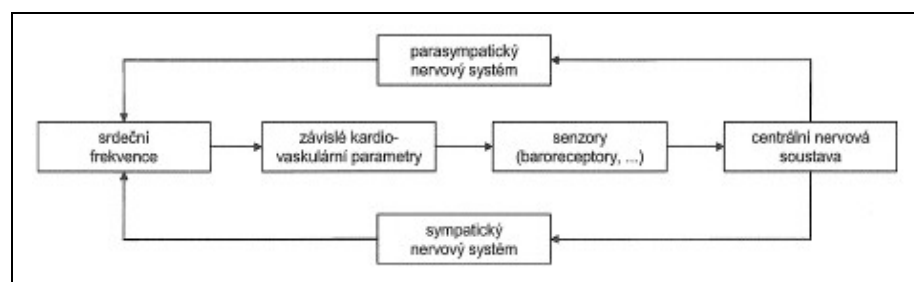
System založený na produkčních pravidlech je tvořen třemi složkami:

- **Báze dat** – Dříve nežli se přistoupí k řešení úlohy, zapíše se všechny údaje o konkrétní úloze (pacientovi) do báze dat.
- **Báze znalostí** – je souborem produkčních pravidel. Produkční pravidlo má obecný tvar: *SITUACE* => *AKCE*, (jestliže situace nastala, provede se akční část pravidla), kde *SITUACE* je popsána jednotlivými fakty, její rozpoznání spočívá ve srovnání těchto faktů se stavem báze dat.
Příklad: *SITUACE: diagnóza* => *AKCE: léčba*.
- **Řídící mechanismus** – vybírá z báze znalostí pravidla, která mají být uplatněna. Obecně se tento mechanismus uplatňuje ve 2 režimech:

- o *Režim přímého řetězení pravidel*- při aktivaci pravidla se postupuje od situace k akci. Tento způsob je charakteristický pro méně zkušeného lékaře. Nejprve je shromážděno co nejvíce informací, a teprve poté jsou z tohoto komplexu příznaků vyvozovány diagnostické závěry.
- o *Režim zpětného řetězení pravidel* – při aktivaci pravidla se prověřuje, zda jsou akce podloženy odpovídajícími situacemi. Systém stanoví pracovní diagnózu na základě omezeného množství vstupních údajů, a tu se následně pokouší potvrdit cílenými vyšetřeními. Systém se tedy snaží o zpětné ověření pravidel, které podporují předpokládanou diagnózu.

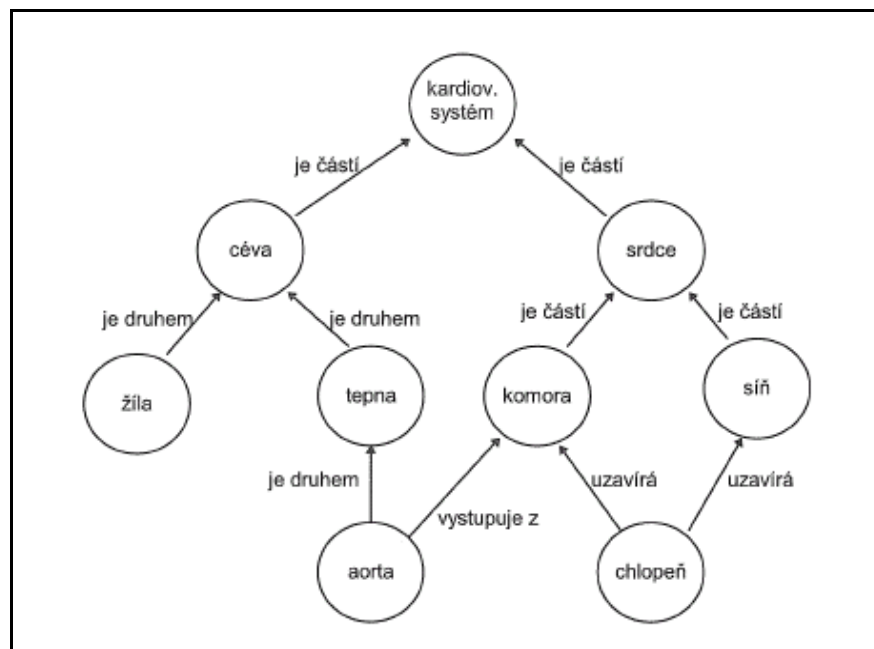
1.4.3.3. Sémantické sítě

Sémantické sítě (sítě) byly vyvinuty na začátku 60. let. Sítě jsou tvořeny orientovanými grafy s uzly představujícími koncepty (objekty). Uzly mohou být propojené **spojeními** (hranami) představujícími **relace** (závislosti). Příkladem obecné sítě je graf představující model kardiovaskulárního regulačního mechanismu člověka [Silbernagl,1993]. Obrázek 11 zobrazuje tuto obecnou síť, která obsahuje uzly představující jednotlivé části kardiovaskulárního systému nebo i jeho parametry. Relace pak ukazují, jakým směrem dochází k ovlivňování ostatních částí daným uzlem. Konkrétně, centrální nervová soustava (CNS) ovlivňuje parasymptický i sympatický nervový systém, ty pak řídí srdeční frekvenci, ta nepřímo určuje závislé kardiovaskulární parametry, a ty, snímány senzory, ovlivňují činnost CNS. Obecná síť ovšem nepopisuje míru závislostí [Provazník, 1999]. Například vliv parasymptického a sympatického systému na hodnotu srdeční frekvence je právě opačný.



Obrázek 11: Obecná síť

Nejvýznamnějšími relacemi používanými pro vyjádření znalostí v ES jsou relace typu "is a" ("je"), "a kind of" ("je druhem") a "is a part of" ("je částí") označované v anglické literatuře zkráceně ISA, AKO, resp. ISPART [Giarratano, 1998]. Jiné relace jsou samozřejmě povoleny, např. "má barvu", "má" atd. Příklad sémantické sítě používající relace "je druhem", "je částí", "vystupuje z" a "uzavírá" ukazuje Obrázek 12. Je potřeba vzít v úvahu fakt, že popis znalostí může být pracný, protože pro počítačové odvozování je nutno zavádět do báze znalostí i informace, které se zdají být při komunikaci mezi lidmi navzájem zcela samozřejmé.



Obrázek 12: Sémantická síť s relacemi

1.4.3.4. Rámce

Struktura rámců připomíná hierarchický datový model. Každý objekt je zde definován z hlediska svých vlastností a dále pak nadřazených a podřazených pojmů. Při tvorbě báze znalostí se vyplňují jednotlivé předpřipravené rubriky záznamu o daném objektu, jenž mohou mít podobu fakultativní či povinnou. Nespornou výhodou rámců je relativně jednoduchá tvorba báze znalostí a dále pak velmi efektivní dědění vlastností. Právě *dědičnost* představuje velmi důležitou

vlastnost, která dává objektu k dispozici vlastnosti všech jemu nadřazených objektů.

Pro vyjádření vztahů v hierarchii se používá termínů: rodič-dítě (parent-child). Vlastnost obsaženou v určité hierarchii stačí uvést jen jednou, na nižší stupně této hierarchie je již přenášena automaticky. Nalezené příznaky aktivují nejdříve ty diagnózy, které přicházejí v úvahu. Následně se u těchto diagnóz ověřuje přítomnost dalších příznaků, které by měly být u těchto onemocnění přítomné.

Odvozovací mechanismus diagnostických kognitivních systémů je definován vztahem: *generuj hypotézu – testuj hypotézu*.

1.4.4. Lékařská báze znalostí

Uživatel expertních systémů by měl být vždy seznámen s vlastnostmi báze dat, která obsahuje odborné informace v problematice, které se uživatel věnuje. Jedním ze základních požadavků je, aby báze znalostí popisovala příslušnou oblast co možná nejpřesněji a nejsprávněji. S ohledem na formálnost popisu se i zde vyskytují určitá specifika, které jsou uvedena v následujícím přehledu [Zvárová et al., 1992]:

1.4.4.1. Specifika báze znalostí

Tabulka 4 znázorňuje specifika báze znalostí.

<i>Úplnost báze znalostí</i>	Zde platí základní předpoklad, že systém považuje za pravdivé pouze ty údaje, které jsou obsaženy v bázi znalostí. Důsledkem je skutečnost, že jakýkoliv opomenutý údaj, který nebyl zařazen mezi pravidla, je považován expertním systémem nikoliv za neznámý, ale za nepravdivý.
<i>Nespornost báze znalostí</i>	Při tvorbě báze znalostí může dojít přidáváním dalších pravidel ke zhroucení dosavadní struktury, tato vlastnost je označována jako nemonotónnost. Původně formulovaná pravidla tak přestanou platit, vzniká spor s nově přidanými pravidly. Spornost lze odstranit formulací pravidel-výjimek, jež znemožňují uplatnění

	původního pravidla.
<i>Relativní báze znalostí</i>	S ohledem na různé zdroje informací při tvorbě báze znalostí, může dojít k nejednotnosti jejich jednotlivých částí. Přepřacování celé báze znalostí může být zpětně poměrně obtížné, protože fakta jsou často využita v různých kontextech. Sladění různých pohledů na tentýž fakt lze dosáhnout rozšířením báze znalostí o pravidlo sjednocující tyto hladiny poznání. Příkladem [Kasal et al., 1998] nejednotnosti je uvádění příznaku: hyperbilirubinémie ⁴ a dále i ikterus ⁵ (vyjádření téhož faktu jednou v podobě laboratorní hodnoty a po druhé jako klinického příznaku), nápravou může být terminologický převod: ikterus => hyperbilirubinémie, kde implikace vyjadřuje fakt, že hyperbilirubinémie nemusí být vždy provázena ikterem.

Tabulka 4: Báze znalostí

1.4.4.2. Vyjadřování nejistoty

Medicína je charakteristická existencí velkého množství znalostí, jejichž platnost je zatížena určitým stupněm nejistoty. Nejběžnějším způsobem vyjádření těchto nejistot je ohodnocení pravděpodobností nebo vícehodnotová logika. Tabulka 5 znázorňuje vyjádření nejistoty.

<i>Neurčitost</i>	U řady výroků nelze vyjádřit jejich pravdivost pouze hodnotami pravda-nepravda. Z pravidel klinických znalostí je typickým příkladem formule: $S \Rightarrow D$, kde při nálezu příznaku S je přítomna diagnóza D s vahou v . Například při váze $v=0,7$ je u daného příznaku diagnóza přítomna v 70%. Váha je zde současně diagnostickou senzitivitou příznaku. Naproti tomu formule: $\neg S \Rightarrow \neg D$ vyjadřuje specifitu příznaku, tedy podíl negativních nálezů při příznakové
-------------------	---

⁴ vrozená záležitost, kdy jaterní buňky ne zcela a korektně zachází s bilirubinem (*barvivo, které vzniká v játrech při odbourávání opotřebovaných červených krvinek a dále je vylučováno do žluče*)

⁵ žloutenka

	negativitě. Zvyšování senzitivity snižuje riziko falešné negativity a zvyšování specificity snižuje riziko falešné positivity, což má za následek <i>Odysseův syndrom</i> = „zatrhávací křeč“ některých lékařů při vyplňování žádanek na vyšetření (s ohledem na chybovost laboratorních testů) [Zvárová et al., 1992].
<i>Přesnost</i>	Kromě neurčitosti konkrétního tvrzení se popisuje i nejistota v rámci obsahu jednotlivých pojmů.
<i>Správnost</i>	Problémem je i nejistota, jestli pravidla, respektive vstupní hodnoty odpovídají skutečné realitě. Příčinou může být například chyba laboratorní metody.

Tabulka 5: Vyjádření nejistoty

1.4.4.3. Funkce báze znalostí v expertním systému

Báze znalostí je v rámci expertního systému uspořádána různým způsobem. Příkladem může být báze znalostí, kde má každý příznak přiřazeno skóre z intervalu +1 až -1, jejichž hodnoty se pro konkrétního pacienta sčítají. Tabulka 6 uvádí příklad takové báze [Kasal et al., 1998]. Báze znalostí je pak různými způsoby aktivována. Příkladem je funkce kognitivního systému, kde nalezené příznaky nejprve aktivují diagnózy, které přicházejí v úvahu. U těchto diagnóz se následně ověřuje přítomnost dalších příznaků.

DG: nefrotický syndrom (vysoké ztráty bílkovin do moči)			
<i>NUTNÝ PŘÍZNAK:</i>	proteinurie (vylučování bílkovin močí)		
<i>POSTAČUJÍCÍ PŘÍZNAK:</i>	edémy a proteinurie > 5g/24 hod		
<i>HLAVNÍ SKÓRE:</i>			
koncentrace albuminu v séru			
	nízká:	1.0	
	vysoká:	-1.0	
proteinurie	>5g/24 hod.:	1.0	
	>1g/24 hod.:	0.5	
otoky			
	symetrické a masivní:	1.0	
	symetrické, ale ne masivní:	0.3	
	asymetrické:	-0.5	
	chybí:	-1.0	
<i>POMOCNÉ SKÓRE:</i>			
koncentrace cholesterolu v séru			
	vysoká:	1.0	
	ne vysoká:	-1.0	
lipidy v moči			
	pozitivní:	1.0	
	negativní:	-0.5	

Tabulka 6: Báze znalostí – hodnocení příznaků pomocí skóre

1.4.4.4. Báze znalostí kritizujícího systému

Klasická konzultace, kdy je zadán dotaz, který není provázen hypotézou, je v praxi velmi výjimečná. Přichází v úvahu u některých genetických onemocnění a dále pak v situaci, kdy se objeví neobvyklá kombinace příznaků. Ve srovnání s těmito výjimečnými situacemi existuje zcela přirozený požadavek kontroly lékařských závěrů diagnostických i léčebných, ke kterým může dojít. Tedy nikoliv tvorba hypotéz, ale jejich ověřování.

Zásadním rozdílem oproti klasickým bázím znalostí je skutečnost, že je potřeba všechna pravidla formulovat obráceně, myšleno nikoliv od příznaku k diagnóze či od diagnózy k léčbě, ale naopak od diagnózy k příznakům (ověřování jejich přítomnosti), od léčby k diagnóze (k opodstatnění).

Do nejobecnější kategorie v této oblasti je možno zařadit stavy pacienta (příznaky, diagnózy) a dále pak akce lékaře (diagnostické a léčebné zákroky). Diagnostická a prognostická pravidla se zabývají stavy pacienta, pravidla léčebná se zabývají akcemi lékařů.

1.4.5. Terapeutická pravidla

Terapeutická pravidla jsou v širším slova smyslu pravidla pro jakoukoliv lékařskou akci. Hranice mezi vyšetřovacími a léčebnými výkony je někdy velmi plynulá, například punkce kloubního exsudátu (mokvání) může být prostředkem záměru léčebného i diagnostického. Tabulka 7 uvádí základní kategorie terapeutických pravidel [Zvárová, 1992]:

<i>Akce, procedura</i>	Ordinace určitého léku, provedení operačního zákroku, rtg vyšetření aj.
<i>Stavy pacienta</i>	Zahrnují jak příznaky tak i konkrétní diagnózy, obecně tedy všechny situace, které jsou podkladem pro léčebnou nebo diagnostickou aktivitu.
<i>Kvantifikace zákroku</i>	Nejčastěji se jedná o dávku léku, výjimečně může zahrnout o další numerické údaje typu: dávka ozáření, množství odebrané krve aj.

Tabulka 7: Základní terapeutická pravidla

1.4.6. Rozhodovací procesy v medicíně

Pro lékařskou praxi je charakteristický nepřetržitý řetěz rozhodování:

- rozhodnutí provést určité vyšetření
- dotázat se na určitý anamnestický údaj
- volba diagnózy z více možných alternativ
- rozhodnutí ordinovat konkrétní léčbu aj.

Ve všech výše uvedených případech jde o volbu optimální alternativy, přičemž kritériem správnosti rozhodnutí je minimalizace rizika, že vznikne nesprávné rozhodnutí. Pro volbu optimální strategie v podmínkách nejistoty existují 2 základní postupy:

- **metoda minimaxu**
- **Bayesovské rozhodování**

1.4.6.1. Metoda minimaxu

Tato metoda hledá takovou situaci, kdy nastává minimální pravděpodobnost vzniku maximálního rizika, jež v daném případě přichází v úvahu. V praxi se tato metoda označuje jako strategie „na jistotu“, jež má své zdůvodnění zejména při rozhodování s mimořádně závažnými důsledky. Řešení úloh metodou minimaxu je formulováno v rámci teorie her.

Příklad [Kasal et al.1998]: Do nemocnice byl převezen člověk s vnitřním zraněním, jehož zdravotní stav vyžaduje okamžitou operaci. Podle některých příznaků lze předpokládat, že má zranění X nebo Y nebo Z. Operace může být provedena 2 způsoby A a B, ale úspěšnost té či oné operace závisí na druhu zranění. Úspěšnost operace A lze podle druhu zranění (X,Y,Z) vyjádřit hodnotami 70%, 50%, 60%, úspěšnost operace B pak hodnotami 60%, 30% a 100%. Mají se lékaři rozhodnout pro operaci A, nebo B?

Tabulka 8 znázorňuje řešení dané úlohy. V matici zaznamenáme u každé strategie lékaře minimální hodnoty a označíme hvězdičkou jejich maximální hodnotu. U každé strategie „zranění“ zaznamenáme maximální hodnoty strategie lékaře a označíme hvězdičkou jejich minimální hodnotu. Z tabulky je patrné, že v obou případech vychází číslo 50, jde o hru, jejíž cena činí 50%. Úspěšnost operace A tedy v žádném případě nebude nižší než 50%.

		Příroda (zranění)			
		X	Y	Z	minima
lékaři (operace)	A	70	50	60	50*
	B	60	30	100	30
maxima		70	50*	100	

Tabulka 8: Rozhodovací tabulka – řešení problémů minimaxem

1.4.6.2. Bayesovské rozhodování

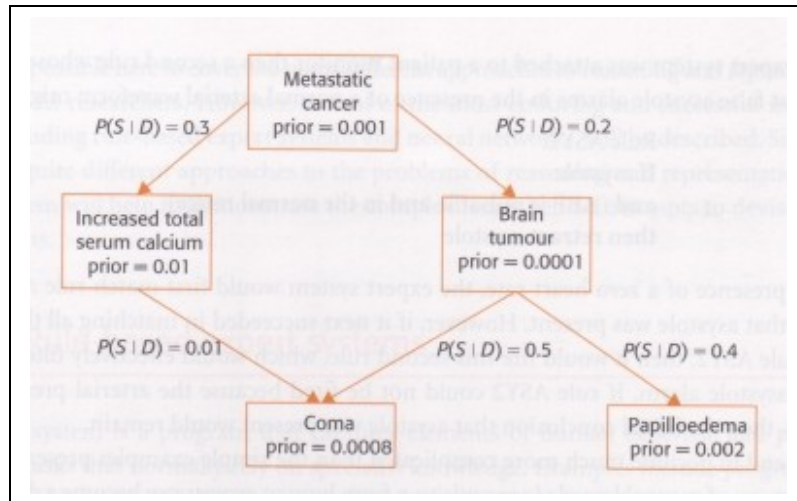
Tato metoda zahrnuje pro výběr optimální strategie ještě takzvané apriorní a podmíněné pravděpodobnosti. Tato metoda odpovídá podstatě lékařského uvažování, jenž je samo o sobě v naprosté většině pravděpodobnostního typu. Z lékařské praxe plyne, že pokud určitý příznak svědčí pro 2 onemocnění – vzácné a běžné, přiklání se diagnostik vždy k tomu běžnějšímu. Vzácnější nemoc bere v úvahu teprve tehdy, když jsou přítomny další doplňující příznaky svědčící mnohem jednoznačněji pro druhou alternativu.

- *Apriorní pravděpodobnost* – samotné vyjádření apriorní pravděpodobnosti může někdy činit potíže. Při řešení diagnostických otázek totiž např. nezávisí jen na prevalenci (demografický ukazatel, poměr počtu nemocných k počtu obyvatel) onemocnění v populaci, ale i na frekvenci daného onemocnění v materiálu konkrétního pracoviště. Na specializovaných pracovištích se totiž vzácná diagnóza může vyskytnout častěji, což je dáno jistou selekcí na nižších stupních zdravotního systému.
- *Rozhodovací strom* – je základním prostředkem k přehledné grafické reprezentaci rozhodovacího děje. Skládá se z *rozhodovacích uzlů*, míst, kde můžeme učinit rozhodnutí, jehož příkladem je provedení určitého diagnostického nebo léčebného zákroku. Dalším uzlem je *uzel možností*, kdy určitá situace vzniká bez možnosti našeho ovlivnění – jedná se o rozhodnutí přírody, kterým může být vznik určitého onemocnění apod. Při léčebných i diagnostických zákrocích se vyskytují určitá rizika, které je možno vyjádřit celkovou letalitou⁶ na základě dlouhodobých statistik. Při stanovení optimální strategie hraje svoji úlohu i znalost apriorní pravděpodobnosti diagnóz, které přicházejí v úvahu. Jako příklad je možné uvést situaci, kdy si klademe otázku: Je vhodnější provádět při chronickém zánětu jater biopsii nebo léčit přímo naslepo předpokládanou závažnější formu?
- *Stereologie* – patří do oboru aplikované matematiky. Ve své podstatě hledá metody, jak poznat strukturu trojrozměrných objektů, jestliže jsou k dispozici jenom jejich řezy, nebo průměty do roviny. Základem jsou rozhodovací procesy v oblasti geometrických pravděpodobností.
- *Markovské řetězce* – V diagnostickém procesu je pravděpodobnost využívána především když chceme vyjádřit míru nejistoty ve vztahu k přítomnosti určité nemoci. Při prognostických úvahách je potřeba využít poněkud odlišný aparát, který umožňuje posuzování pravděpodobnosti vzniku změn v časovém vývoji. A právě k tomu

⁶ úmrtnost

slouží Markovský řetězec, který lze například popsat jako posloupnost klinických stavů $S_1, S_2 \dots S_t$ v časech 1, 2...t.

Obrázek 13 znázorňuje jednoduchý příklad Bayesovského modelu na příkladu metastáze rakoviny [Coiera, 1993].



Obrázek 13: Jednoduchý bayesovský model metastáze rakoviny

1.4.7. Znalostní systémy

Jedním z dalších pohledů na znalostní systémy [Kasal et al., 1998] je dělení na:

- databázové systémy,
- algoritnické systémy,
- učící se systémy.

1.4.7.1. Databázové systémy

Ve své podstatě se jedná pouze o seznam znalostí, které lze prohledávat různými formami databázových operací určených pro vyhledávání, při použití logických či proximitních operátorů (například bibliografický systém MEDLINE).

1.4.7.2. Algoritnické systémy

Pro tyto systémy je charakterická pevná posloupnost příkazů při samotném výpočtu nebo logickém odvozování. Typickými programy tohoto typu jsou systémy pro návrh léčby – například složení infuzní terapie, určení diety,

komentování laboratorních nálezů aj. Jsou vhodné zejména pro řešení úloh, jejich obtížnost nemá těžiště v nejistotě, ale ve složitosti. Modelem je tak vlastně rozhodovací strom, přičemž větve nejsou ohodnoceny příslušnými vahami.

1.4.7.3. Učící se systémy

Tyto systémy využívají údaje o konkrétních pacientech z dřívější doby, které jsou následně využity jako parametry v rámci pravděpodobnostního výpočtu. Nedostatkem znalostních systémů umožňujících automatické logické odvozování je fakt, že vlastní báze znalostí jsou zcela závislé na svém tvůrci – myšleno člověku, který musí patřičné znalosti zobecnit a formulovat. Jedná se o zdoluhavý proces, ve kterém existuje vysoké riziko chyb a omylů (řada bází znalostí je těžko přenosná mezi více pracovišti).

Právě automatizovaná tvorba báze znalostí, která vzniká na daném pracovišti může vyústit v *učící se systém* – jde vlastně o počítačový program, který na základě vstupu údajů o pacientech postupně mění svoji rozhodovací funkci a při jeho rozhodování je tak využita komplexní do té doby získaná zkušenost.

Většina učících se systémů vycházela převážně z využití pravděpodobnostních modelů (Bayesova metoda, mnohorozměrná analýza aj.). Zcela převratným přístupem z hlediska koncepce systémů umělé inteligence jsou v současnosti takzvané *neuronové sítě*, které jsou schopny velmi přesně modelovat funkční architekturu CNS. V klasických expertních systémech jsou znalosti popisovány v podobě koncizních⁷ pravidel, zatímco v případě neuronových sítí jsou znalosti vyjádřeny v podobě řady elementárních údajů, jejichž důležitost má různou hodnotu. A zde je rozdíl oproti klasickým expertním systémům. Pokud dojde k chybě při formulaci znalostního pravidla v expertním systému, je možnost získání správného výsledku velmi snížena, naproti tomu reprezentace znalostí neuronové sítě je vůči chybám poměrně tolerantní. Vzhledem k řadě podobností s mozkem je i v oficiální terminologii neuronových sítí používána řada výrazů převzatých z oblasti neurofyziologie.

⁷ zhuštěných/stručných

IV. APLIKACE EXPERTNÍCH SYSTÉMŮ V MEDICÍNĚ

Tento oddíl je věnován konkrétním aplikacím expertních/znalostních systémů v medicíně.

První část obsahuje výčet aplikací, které významně přispěly k rozvoji ES v lékařství. Obsáhlou kapitolu věnuji systémům založeným na případovém usuzování včetně výčtu praktických aplikací. Nechybí rovněž zamyšlení nad budoucím vývojem a trendy ve využití expertních systémů.

Druhá část je věnována vývojovým trendům úspěšných aplikací znalostních aplikací. Podkladem mi byly jednotlivé příspěvky publikované na různých konferencích a ve sbornících. Cílem je demonstrovat teorii, která existuje v konkrétních aplikacích. Záměrně jsem vybral čtyři naprosto odlišné ukázky znalostních systémů, na kterých chci čtenáři demonstrovat trendy, které dané příklady nastiňují. Při studiu jsem využíval zejména anglicky psanou literaturu.

1.5. Příklady expertních systémů v medicíně

1.5.1. MYCIN

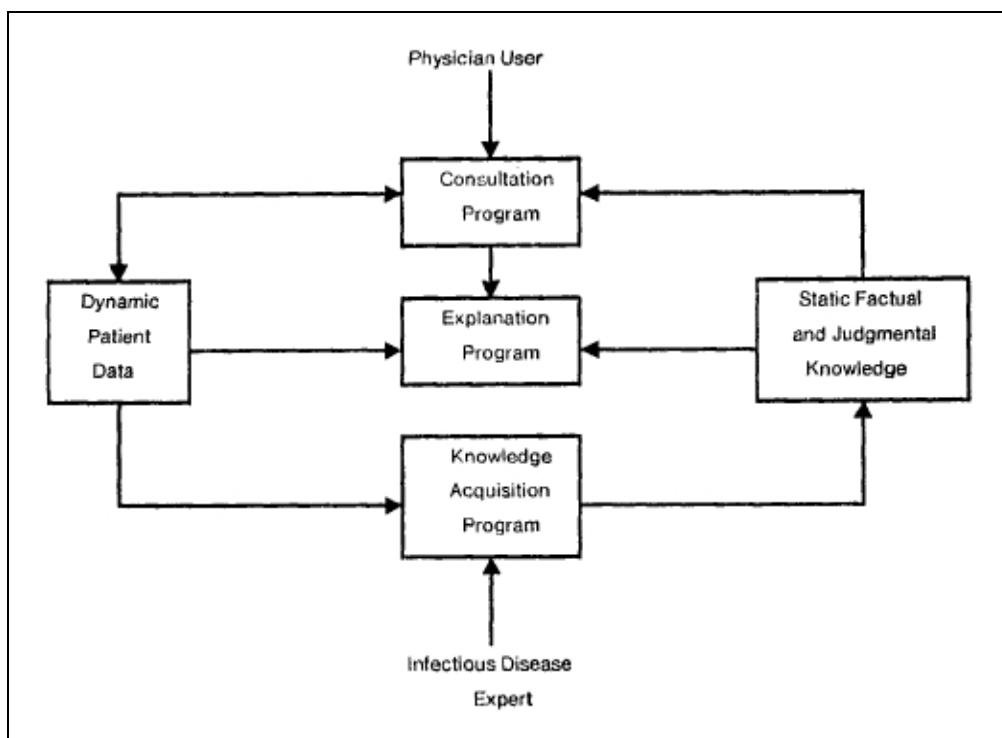
Expertní systém MYCIN byl vyvinut v 70. letech na Stanfordské univerzitě s cílem diagnostikovat a doporučit léčbu pro určité typy krevních infekcí jako jsou virové hemmorrhagické horečky provázené mohutným krvácením ze všech tkání [Buchanan, 2006]. Tato onemocnění jsou způsobena arenaviry, bunjaviry, flaviviry a filoviry, mezi něž náleží například virus Ebola. Analytická procedura sledovala rostoucí kultury a vyžadovala až 48 hodin, během nichž pacient již mohl zemřít. Program MYCIN byl napsán také kvůli tomu, aby lékařům usnadnil obtížné, avšak životně důležité rozhodnutí na základě neúplných informací.

MYCIN byl napsán v programovacím jazyku Lisp a jeho pravidla byla reprezentována jako výrazy tohoto programovacího jazyka. Je to typický představitel cílově orientovaného systému využívajícího produkčních pravidel, který používal nazpět řetězenou strategii. MYCIN obsahuje asi 500 pravidel, pracuje pomocí jednoduchých dotazů uživateli.

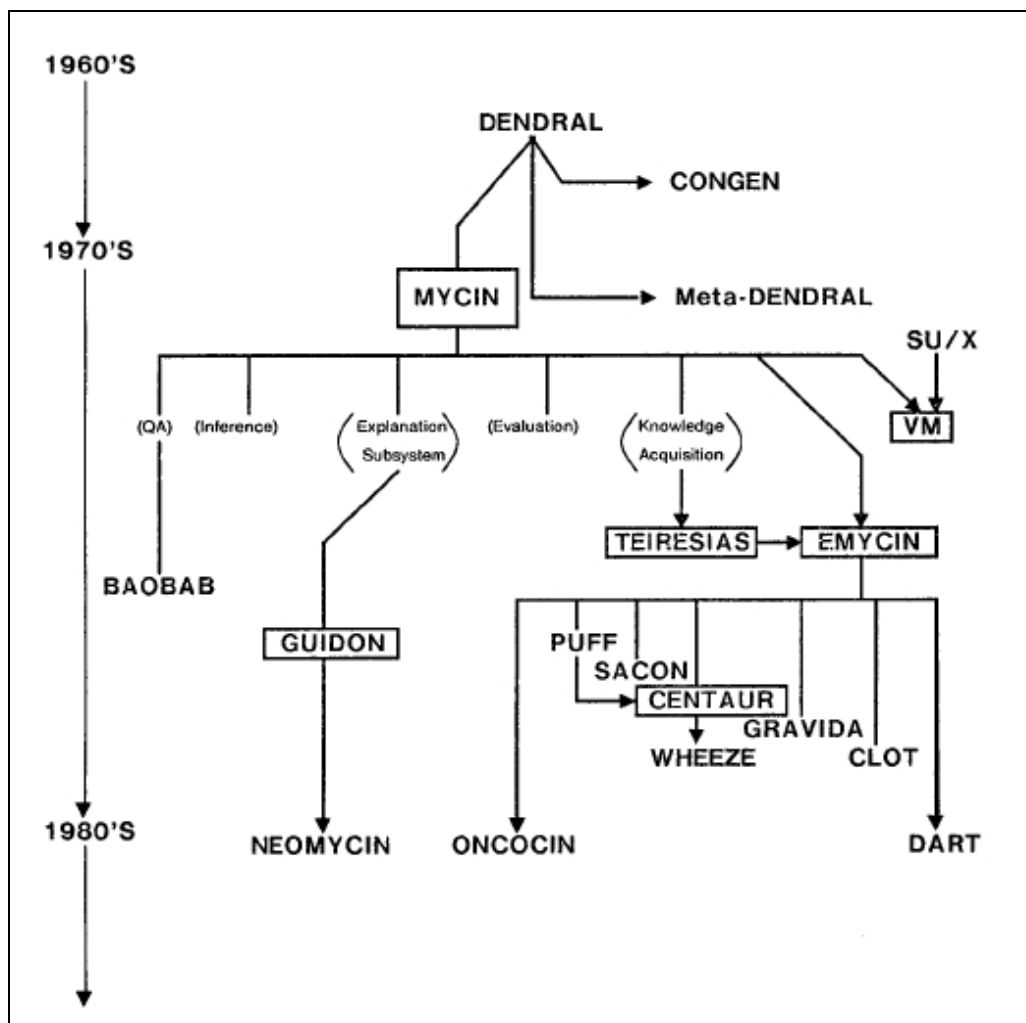
MYCIN nebyl v praxi nikdy použit. Přestože se na jeho vývoji podíleli studenti medicíny Stanfordské university, etické a právní důvody spojené s užitím počítačů v medicíně zabránily jeho nasazení.

Obrázek 14 znázorňuje uspořádání systému MYCIN – šipky znázorňují informační toky mezi moduly, bází znalostí a uživateli [Buchanan, 2006]. Obrázek 15 znázorňuje vztah MYCINU k ostatním projektům na Stanfordské univerzitě [Buchanan, 2003]. **Obrázek 16** znázorňuje příklad konzultace v systému MYCIN [Buchanan,2006].

Variantou systému MYCIN je systém EMYCIN, takzvaný „prázdný“ expertní systém, jenž umožňuje naplnění jakoukoli tematickou oblastí. Na velmi podobném principu byl vyvinut i expertní systém pro léčbu onkologických onemocnění ONCOCIN.



Obrázek 14: Uspořádání systému MYCIN



Obrázek 15: Vztah MYCINu k ostatním projektům na Stanfordské univerzitě

1) Patient's name: (first-last)
**** FRED BRAUN**

2) Sex: *(Questions 1-3 request background patient data.)*
**** M**

3) Age:
**** 55**

4) Are there any cultures for Fred Braun which may be related to the present illness, and from which organisms have been grown successfully in the microbiology laboratory?
**** Y**

-----CULTURE-1-----
5) From what site was the specimen for CULTURE-1 taken?
**** BLOOD**
= BLOOD *(System corrects typing error.)*

6) Please give the date and time when CULTURE-1 was obtained.
(mo/da/yr time)
**** JUN 20, 1977**
The first organism isolated from the blood culture of 20-JUN-77 (CULTURE-1) will be referred to as:
-----ORGANISM-1-----

7) Enter the laboratory-reported identity of ORGANISM-1:
****UNKNOWN** *(Typically identity is not yet known.)*

8) The stain (gram or Ziehl-Neelsen acid-fast) of ORGANISM-1:
**** NEG** *(Preliminary lab results give some clues.)*

9) Is ORGANISM-1 rod or coccus (etc.):
**** ROD**

10) What is the form of the individual organisms (e.g. lancet-shaped for cocol, fusiform for rods, etc.)?
**** FUSIFORM**

(. . . more questions follow in order to gather sufficient information to infer the identity and significance of the infecting organisms . . .)

23) What is the suspected portal of entry of the gramneg rod from the blood culture of 20-JUN-77 (ORGANISM-1) into this sterile site?
**** GI (6)** *(User indicates the uncertainty of his response.)*

24) Is Fred Braun a burn patient?
**** N**

25) Is Fred Braun a compromised host (e.g. alcoholic, sickle-cell-disease, immunosuppressed)?
**** N**

26) Is Fred Braun febrile?
**** Y**

(. . . after about 50-60 questions, MYCIN prints the diagnostic hypotheses on which therapy will be based . . .)

My therapy recommendations will be designed to treat for organisms that are either very likely or, although less likely, would have a significant effect on therapy selection if they were present. It is important to cover for the following probable infection(s) and associated organism(s):

INFECTION-1 is BACTEREMIA

<ITEM-1> E.COLI [ORGANISM-1]
<ITEM-2> KLEBSIELLA [ORGANISM-1]
<ITEM-3> ENTEROBACTER [ORGANISM-1]
<ITEM-4> KLEBSIELLA-PNEUMONIAE [ORGANISM-1]

(. . . questions follow to evaluate possible therapy choices, and finally MYCIN prints its therapy recommendations . . .)

[REC-1] My preferred therapy recommendation is as follows:
In order to cover for items <1 2 3 4>:
Give: GENTAMICIN *(One drug covers 4 possible identities.)*
Dose: 119 mg (6.0 ml) q8h IV for 10 days [calculated on basis of 1.7 mg/kg]
Comments: Modify dose in renal failure.

Obrázek 16: Dialog se systémem MYCIN

1.5.2. ONCOCIN

Jedním z prvních expertních systémů týkajících se terapie byl ONCOCIN. Ve své podstatě zahrnuje jak tvorbu databáze obsahující údaje o nemocných s nádory, tak podporu při rozhodování o jejich terapii [Eriksson, 1994]. Do tohoto

programu byla zařazena základní terapeutická schémata, ale i rozhodovací postupy, které umožňují přizpůsobit chemoterapii individuálním potřebám nemocného. Filozofie programu je založena na rozhodovacím typu: *jestliže* nastane situace A, *potom* je zapotřebí udělat B.

Zkušenosti, které byly docíleny ONCOCIN byly využity při tvorbě expertního systému ONYX. Proces plánování v programu ONYX je tvořen 3 kroky:

- Použití pravidel odvozených ze strategie plánování.
- Použití znalostí o struktuře a chování lidského těla s cílem simulovat důsledky, které by mělo zavedení testovaného terapeutického plánu pro nemocného.
- Použití rozhodovací teorie k rozlišení, zda jsou výsledky simulace v souladu s terapeutickým cílem.

Obrázek 17 znázorňuje jedno z menu z prostředí ONCOCINu.

The image shows a screenshot of the ONCOCIN menu, which is a complex form for managing cancer treatment. It is divided into several sections:

- Cover Sheet:** Includes fields for 'Mass / X-Ray' and 'Disease Activity'.
- Hematology:** A table with columns for 'BSA (m2)', 'Arm assignment', 'Combination Name', 'Cycle #', 'Subcycle', and 'Visit type'. The 'Combination Name' row shows a sequence of treatments: POCC, VAM, POCC, POCC, VAM, VAM, VAM, POCC, POCC.
- CHEMOTHERAPY (includes non-cytotoxic drugs):** A table listing drug dosages for various cycles. Drugs include Procarbazine, Vinorelbine, Cyclophosphamide, and CCNU.
- Radiotherapy:** A section for scheduling radiation therapy.
- Symptom Review, Toxicity, Physical Examination, Chemistry:** Fields for monitoring patient health.
- To order: Labs and Procedures, To order: Nuclear Medicine and Tomography:** Sections for ordering additional tests.
- Scheduling:** A calendar grid showing dates from February to June.

Obrázek 17: Menu z prostředí ONCOCIN

1.5.3. INTERNIST-1

Tento expertní systém byl sestaven na podobných rozhodovacích principech, jako ONCOCIN [Wolfram, 1995]. První fáze programu byla sestavena v roce 1970, v dalších letech byla odlaďována na Univerzitě v Pittsburghu. Zahnuje diagnózu více než 600 nemocí na základě rozboru údajů o 4350 pozorovaných symptomech. Každý symptom má určenou váhu mezi 0 až 5, jež

udává jeho specifiku „jak často je diagnóza u příznaku přítomna“. Váhy jsou stanoveny takto [Kasal et al., 1998]:

0 – extrémně vzácné

1 – vzácné

2 – často

3 – většinou

4 – v převaze případů

5 – prakticky vždy

Naproti tomu váha pro senzitivitu vyjadřuje otázku: „jak často se při diagnóze vyskytuje příznak“. Váhy jsou stanoveny takto:

0 – nikdy

1 – vzácně

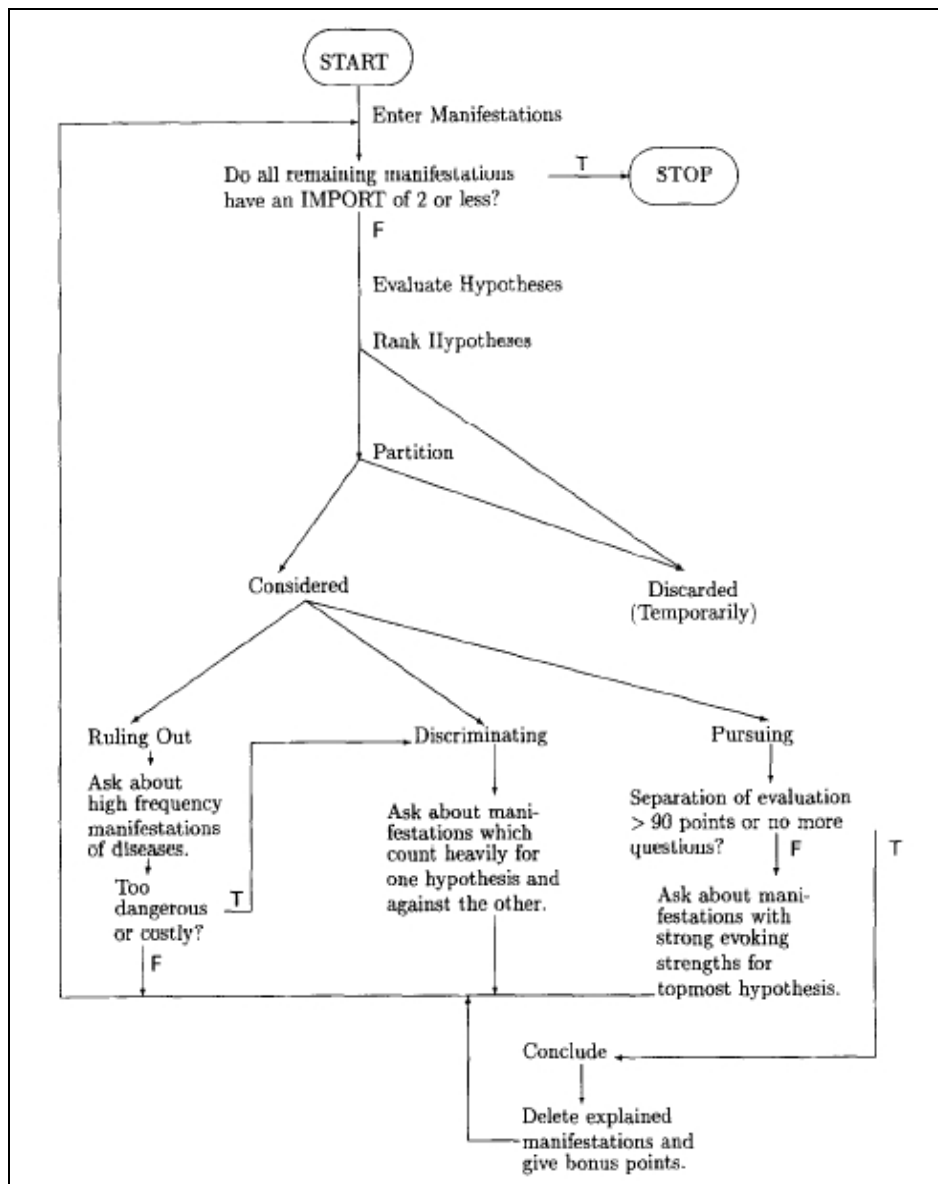
2 – v menšině případů

3 – v polovině případů

4 – ve většině případů

5 – prakticky vždy

Jako příklad můžeme uvést vztah: bolesti v *podbřišku* => *apendicitis*, kde činí hodnota z pohledu bolesti frekvence 5, specifika je však pouze 2 (bolest v *podbřišku* je přítomna u řady dalších nemocí, jedná se tedy o nutný, nikoliv však postačující příznak). Diagnostický závěr pro konkrétního pacienta je odvozován z pozitivních bodů pro všechny diagnózy, které přicházejí v úvahu, současně se odečítají hodnoty očekávaných příznaků pro danou diagnózu, které se nevyskytly. Obrázek 18 přibližuje diagnostický algoritmus systému [Wolfram, 1995]. Komerčním pokračovatelem systému je model QMR (Quick Medical Reference), který se využívá i při výuce mediků.



Obrázek 18: INTERNIST a jeho diagnostický algoritmus

1.5.4. QMR (Quick Medical Reference)

Systém byl vytvořen v roce 1985. Systém QMR byl sestaven na základě rozborů údajů získaných u 4000 nemocných s 577 nemocemi [Adam et al., 1986].

Quick Medical Reference (QMR) je diagnostickým nástrojem v oblasti interní medicíny. Databáze popisuje možné poruchy a komplikace nemocí, navrhuje kroky eliminující potíže a rovněž slouží ke vzdělávacím účelům.

V průběhu tvorby báze znalostí systému se částečně vycházelo z báze znalostí INTERNIST. Nové nemoci či příznaky byly pečlivě prostudovány v odborné literatuře, což v praxi zahrnovalo na jednu nemoc 14 dní práce na plný úvazek s odbornou literaturou, prozkoumání 50-100 relevantních příspěvků aj.

Cílem práce s odbornou literaturou bylo vytvořit seznam klinických abnormalit. Následně probíhaly konzultace s experty s cílem vytvořit profil nemoci (na jednu nemoc okolo 85 nálezů). V další fázi bylo potřeba odladit terminologii atd. [Miller, et. al, 1986]

Klíčové rysy systému

- Jedním z hlavních cílů QMR [Miller, et. al, 1986] je umožnit novému uživateli zadat informace o pacientovi v co nejpříjemnější formě. Je možné zadat pouze klíčová slova, systém si poradí i se zkrácenými tvary, přičemž nezáleží na pořadí zadávaných slov. Například uživatel, který chce zobrazit záznamy pro břišní citlivost v pravém dolním kvadrantu („abdominal tenderness, right lower quadrant“) může zadat parametry pro hledání takto: abd ten low, r l q tender, lower quadrant.
- Systém disponuje dvojím rozhraním pro vyhledávání informací: (a) k vybrané nemoci nabídne informace a odkazy, (b) zobrazí rozdílné diagnózy pro každý nález. Například pro heslo „abdominal pain, right upper quadrant“ systém nabídne 131 diagnóz, pro „chest pain, substernal, at rest“ je k dispozici 34 diagnóz.
- Systém umožňuje rovněž provádět „případové analýzy“ ve dvou módech: (a) jednoduché analýzy charakterizované několika málo nálezy, (b) pro komplexní CRC případy, kdy již byl pacient důkladně vyšetřen.
- V analytickém módu je možno zadat až 95 negativních a 95 pozitivních nálezů pro jeden případ, pozitivní jsou ty, které se vyskytují u vyšetřovaného pacienta.

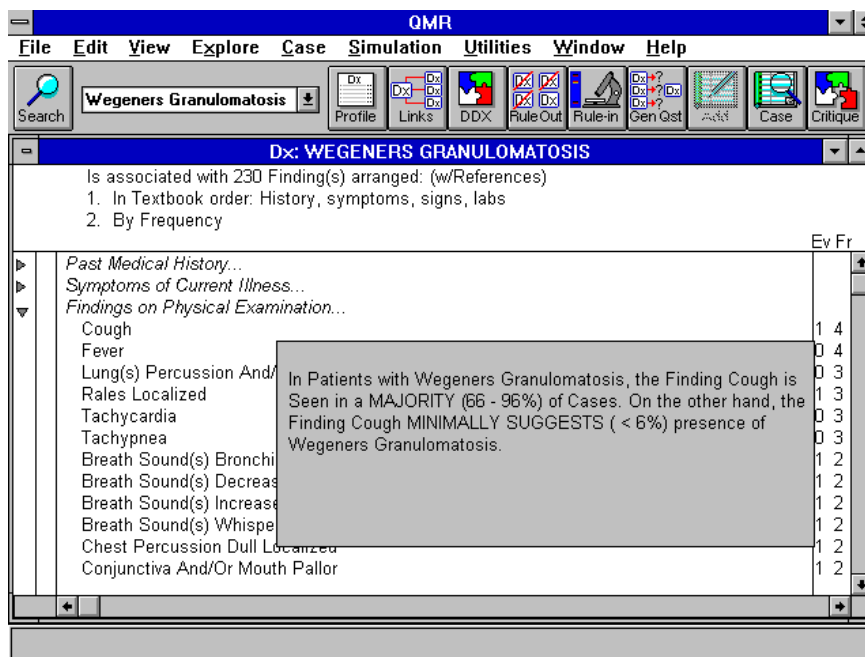
Je potřeba neustále systém aktualizovat, rozšiřovat bázi znalostí, dle odhadů se počítá s přidáním okolo 180 nových detailních profilů nemocí [Miller, et. al, 1986]. Zvažuje se implementace „přirozeného jazyka“. Samotný proces dialogu se systémem by měl zefektivnit nový systém pro tvorbu otázek. Systému chybí propracovaná dokumentace a online help. Je potřeba rozšířit i dostupné literární prameny, první vlaštvkou je předmětový heslář NLM. Je potřeba posílit i edukační rozhraní.

Studie

Otestování systému v roce 1986 prokázalo, že systém byl schopen stanovit diagnózu v 26 z celkových 36 složitých případech. Ve Velké Británii byla provedena studie, která trvala 2 roky a předmětem zkoumání byla diagnóza akutní bolesti břicha. Výzkum zahrnoval 8 nemocnic, více než 200 lékařů a 16737 pacientů, výsledky zkoumání potvrdily, že expertní systém může velice napomoci při stanovení správné diagnózy. Obrázek 19 je znázorňuje screenshot k vybrané diagnóze.

Další studie byla provedena v letech 1995/96 [Lemaire, et. al., 1999] v rámci populace na jedné univerzitě v Calgary, která si kladla za cíl zaznamenat, nakolik se shodovala navrhovaná diagnóza systému s tím, co nakonec stanovil lékař. V praxi se tak pracovalo s top 5 návrhy systému. Se systémem vedli dialog dva lékaři A a B (pracovali samostatně), kteří byli z pohledu konzultací s QMR laici. V rámci studie bylo testováno 154 případů z celkových 1144 nabízených. Průměrný věk pacienta byl 57,7 let, celkem se zúčastnilo 79 mužů a 75 žen. Lékař A docílil při konzultaci se systémem správné diagnózy v 62 případech (40%), lékař B byl úspěšný v 56 případech (36%).

Je důležité si uvědomit, že na výsledky testování má vliv kvalita báze znalostí, rozsah zadaných informací o pacientovi, zaznamenání výsledků jednotlivých vyšetření aj.



Obrázek 19: QMR – screenshot s vybranou diagnózou

1.5.5. ILIAD

Tento expertní systém vznikl na základě databanky údajů od 500 tisíc pacientů projektu HELP v Salt Lake City a je dále i v současné době rozvíjen [Chang et al., 1993]. Odvozovací část má 2000 znalostních pravidel, které jsou schopny reakce i na akutní situace, příkladem může být situace kdy: údaj o hypokalemii je podkladem k varování ošetřujícího lékaře. Integrovaný znalostní systém pak současně navrhně příslušnou léčbu, v tomto případě by to byla infúze KCl.

Systém také disponuje rozsáhlou databází diagnóz (více než 700), dále pak offline databází více jak 3000 titulů (Ročenka Medicíny) za posledních 7 let včetně abstraktů.

Případová studie

Na příkladu 33-leté pacientky (nazývejme ji Barbora) lze demonstrovat fungování systému Iliad [Warner, et. al., 1994]. Barbora se rozhodla navštívit svého ošetřujícího lékaře s tím, že si stěžovala na problémy s dechem jak v klidu, tak při zvýšené námaze. Následně lékař zadal do systému Iliad slovo „dušnost“ a systém položil upřesňující dotazy související s uvedeným klíčovým slovem.

System zobrazil lékaři 2 rozhraní. Prvním jsou hierarchicky uspořádaná data, ve druhém pak potenciální seznam diagnóz. Lékař si vybral nedostatek „Alpha-1 antitrypsin“ a systém následně pokládal dodatečné dotazy podporující danou diagnózu. V další fázi lékař provedl fyzické vyšetření a výsledky zapsal do Iliadu.

V uvedeném případě systém sdělil lékaři, že pacientka s 95% pravděpodobností trpí výše uvedenou diagnózou. Iliad na základě dosavadního dialogu navrhnul provedení specifického testu, který jednoznačně potvrdil/vyvrátil diagnózu....

Jak systém pracuje

Báze znalostí v systému Iliad je tvořena kombinací symptomů, příznaků či laboratorních výsledků při využití:

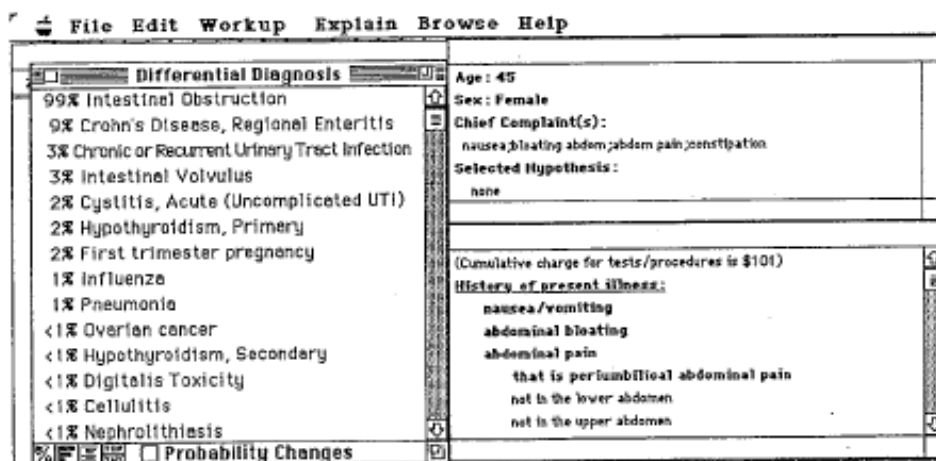
- Bayesovského rámce
- Booleovské logiky

Báze znalostí je vytvářena v procesu znalostního inženýrství. Každý týden jsou pravidelná sezení (1-2 hodiny) při účasti expertů na danou oblast, knihovníka a znalostního inženýra s cílem zpracování nových poznatků ze zdrojů odborné lékařské literatury, rozsáhlé databáze pacientů a úsudku expertů.

Iliad pracuje ve třech operačních módech [Cundick, 1999]:

- *Konzultační*

System získává od lékaře údaje o pacientově věku, pohlaví aj. Dále lékař zadává výsledky provedených vyšetření. V rámci dialogu systém po celou dobu nabízí lékaři zpřesňující kritéria a detailní slovník. Následně systém předloží seznam možných diagnóz, s tím, že lékař nabízí zpřesňující informace o postupu.



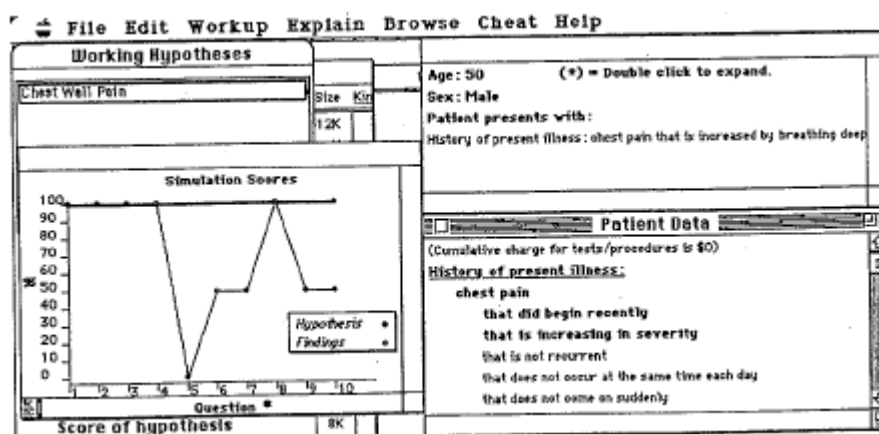
Obrázek 20: Záznam pacienta v průběhu konzultace se systémem ILIAD

- *Posudkový*

V tomto módu lékař zadává svoji pracovní hypotézu zadáním klíčového slova, či výběrem ze seznamu a systém dále pracuje pouze s daty podporujícími danou hypotézu.

- *Simulační*

Podstatou tohoto módu je poskytnout uživateli širokou škálu patientských případů a poskytnout nástroj pro učení se z konkrétních situací [CUNDICK, et al., 1989]. V průběhu dialogu, systém neustále provádí srovnání dat zadaných uživatelem vůči vlastnímu návrhu. V průběhu simulace hraje důležitou roli rozsah získaných dat o pacientovi a pracovní hypotéza, přičemž jak se mění data o pacientovi, tak systém upravuje svoji hypotézu.



Obrázek 21: Rozhraní simulačního módu ILIAD

Plusy/Mínusy

Tabulka 9 shrnuje vybrané kladné a záporné rysy systému ILIAD.

Plusy	Mínusy
deskriptivní profil nemoci	kategorizace dat uměle odvozuje implikace
citlivost při práci s nálezy	nemožnost interaktivně upozornit uživatele na mezery v dané oblasti
automatická simulace	velké mezery v dokumentaci
zadávaní dat na základě příznaků	absence databázových referencí
vysvětlení nálezů	
zpětná vazba hypotéz v průběhu simulace	
ročanka medicíny	

Tabulka 9: Plusy/mínusy systému Iliad

ILIAD v dnešní době čerpá z více než 1500 diagnóz a odvozuje pravděpodobnostní hodnoty jednotlivých nálezů pomocí Bayesovské metody. Systém obsahuje přes 14 tisíc záznamů o chorobách z oblasti interní a sportovní medicíny, pediatrie, dermatologie, gynekologie, aj.

1.5.6. Další expertní systémy

Vzhledem k existenci velkého množství expertních systémů uvádím pouze stručný přehled vybraných expertních systémů (Tabulka 10).

NÁZEV SYSTÉMU	CHARAKTERISTIKA
5GL-Expert	expertní systém pro obecnou medicínu
ABVAB	diagnostika abnormálních vaginálních krvácení
ACORN	řádce pro řešení případů bolesti na hrudníku na příjmu v nemocnicích
AIP	program na prevenci proti AIDS
CaDet	systém na podporu zachycení rakoviny v raném stádiu
Cancer Me	systém rakovinné prevence
CASPER	analýza obrazů v rámci onkologie
CMD	systém na diagnózu rakoviny žaludku
DermaDex	systém v oblasti dermatologie
DiagnosisPro	obecný systém pro interní medicínu, pediatrii, gynekologii
Dr.Gait III	systém v ortopedii (pro správné držení těla)
DXPLAIN	expertní systém pro interní medicínu
EKG	program pro automatickou interpretaci elektrokardiogramu
Epileptologist's Assistant	systém pro zvládnání epileptických záchvatů
EXSYS	diagnostika a terapie nádoru plic
GermAlert	dozor a správa mikrobiologických kultur
GIDEON	správa a diagnóza tropických nemocí, epidemiologie, mikrobiologie
MammoNet	systém pro formování diagnóz na základě mamografického vyšetření
MYOPAT	diagnostika dětských myopatií
NEOANEMIA	orientace na diagnostiku anémií
Orthoplanner	řádce zubařům v oblasti ortodoncie
PENELOPE	program pro oblast onkologie
PERFEX	interpretace kardio SPECT dat
POEMS	pooperační péče
PRODIGY	systém pro počítačové předepisování léků
RheumExpert	expertní systém v oblasti revmatologie
SETH	klinický toxikologický rádce
TUMOR-HISTO	diagnostika mozkových nádorů
VIE-PNN	JIP

Tabulka 10: Stručný přehled vybraných expertních systémů

1.5.7. Systémy klinických laboratoří

Klinické laboratoře patří mezi obory medicíny, kde se uplatňují počítačové technologie ve velikém rozsahu [Kasal et al, 2001]. Rovněž v minulosti to byly právě klinické laboratoře, kde se začaly počítače používat v rutinním provozu, což

mělo za následek skutečnost, že v této oblasti existují velice propracované expertní systémy. Tyto systémy se uplatňují nejen při chodu laboratoří, ale i v oblasti interpretace laboratorních údajů zejména v návaznosti na práci ošetřujícího lékaře.

Počítačový program v praxi posuzuje výsledky laboratorních testů z hlediska jejich vztahu k hodnotám, které se vyskytují u zdravých osob. Program tak může v rozsahu dostupných informací porovnávat laboratorní výsledky s diagnostickou hypotézou a poskytnout své stanovisko, které může obsahovat přehled možných diagnóz a návrh na další vyšetření. Z praxe jsou známy expertní systémy, které podporují klinické laboratoře v otázkách klinické farmakologie, endokrinologie, toxikologie aj.

1.5.7.1. Cíle expertních systémů v laboratořích

Od laboratorních expertních systémů se očekává přínos ve třech oblastech [Berger, 1993]:

- Racionalizace požadavků na laboratorní testy na základě doporučení, která vydá počítačový program. Uvedené doporučení je tak vydáváno na základě abnormálních hodnot, které byly naměřeny pomocí již provedených vyšetření. Toto doporučení obsahuje indikaci k dalším laboratorním testům.
- Expertní laboratorní program může zaměřit pozornost praktického lékaře na některé aspekty patologie pacienta, které by jinak mohly uniknout pozornosti.
- Expertní systém může poskytnout návrh na upřesnění diagnózy, kterou pracovníce stanovil praktický lékař v době, kdy ještě neměl k dispozici laboratorní výsledky.

Poskytovaná klinická interpretace výsledků může významně přispět ke zkvalitnění péče o nemocné. Je potřeba zejména na začátku spolupráce udržovat s ošetřujícími lékaři dialog se zaměřením na komentáře, které počítač tiskne k laboratorním testům, aby se lékař neunáhlil například s hospitalizací pacienta.

1.5.7.2. Příklady laboratorních expertních systémů

Tabulka 11 uvádí stručný výčet vybraných laboratorních systémů.

NÁZEV SYSTÉMU	CHARAKTERISTIKA
QBC Reference System	analýza v oblasti hematologie
The Sceptor, MIC	dávkování minimálního množství tlumících látek
HEPAEXPERT I,II	interpretační analýza Hepatitidy A,B
Liporap	fenotypie dyslipoproteinemie
PEIRS	interpretace výsledků v patologických zprávách
GERMWATCHER	analýza nasocomiálních infekcí
Acid-base ES	interpretace acidobazických výsledků
MICROBIOLOGY/PHARMACY	monitoring dávkování antibiotik pro léčbu ledvin
PEIRS	chemický patologický systém
PUFF	interpretace výsledků plicních testů
Pro.M.D.-CSF Diagnostics	interpretace nálezů v mozkomíšním moku
ANEMIA	interpretace hematologických laboratorních nálezů

Tabulka 11: Stručný přehled vybraných klinických expertních systémů

1.6. Case-Based Reasoning (CBR)

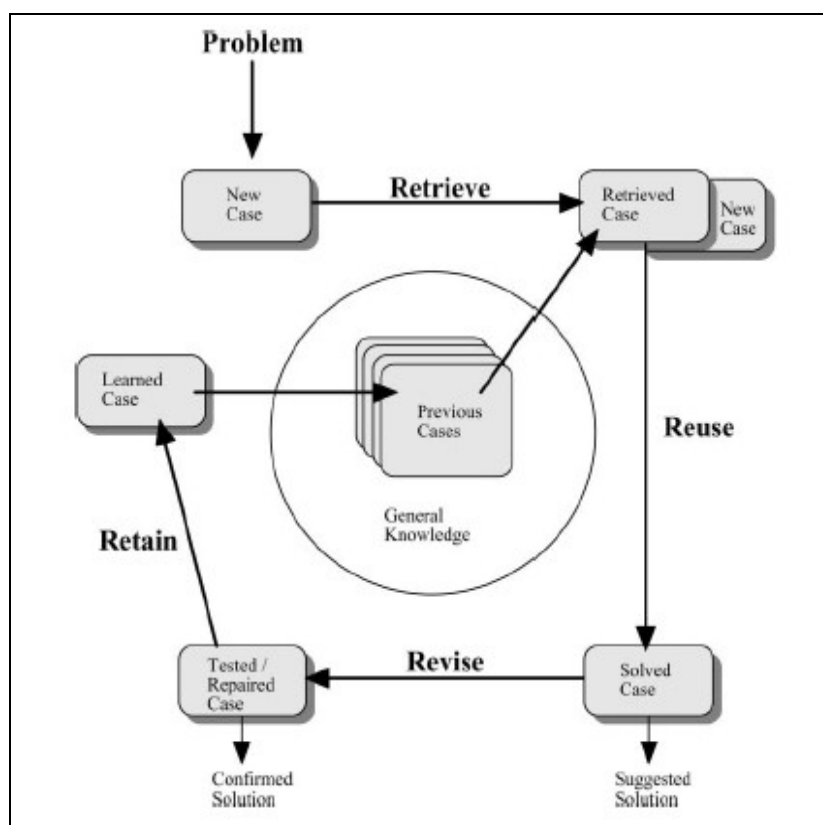
Český termín „případové usuzování“ je odvozen z anglického termínu Case-Based Reasoning, zkracováno jako CBR. V dalším textu budu zpravidla užívat anglický termín, protože je přeci jen výstižnější pro svůj obsah, oproti českému překladu.

Podstatou systémů Case-Based Reasoning je předpoklad, že expert se v neznámé situaci rozhoduje na základě podobnosti s již dříve řešenými (a vyřešenými) případy a nikoliv pouze na základě soustavy pravidel [Berka, 1995]. Dalším důležitým rozdílem oproti ostatním systémům umělé inteligence je fakt, že CBR v sobě obsahuje předpoklad pro „sebevzdělávání“, kdy vlastně veškeré nové poznatky jsou uloženy a je možno je využít při budoucím řešení problémů. Jednoduchým příkladem může být lékař, který vyšetří pacienta ve své ordinaci. Nález, který lékař udělá je velmi podobný s nálezem jiného pacienta, který jeho ordinaci navštívil před dvěma týdny. Jelikož příznaky jsou v obou případech

podobné, lékař si prohlédne předchozí diagnózu pacienta a rozhodne o dalším postupu.

V pojetí CBR se používá formule: *Případ = problém + řešení*, což pramení z tvrzení, že při existenci problému musíme najít řešení. Jde vlastně o jakousi cyklickou smyčku s efektem učení se na základě zkušeností, kdy se vyřeší daný problém, objekt se poučí z dané zkušenosti, začne se řešit nový problém, přičemž předchozí řešení patří do množiny potenciálních řešení, atd. Obrázek 22 [Aamondt, 1994] znázorňuje výše uvedený cyklus. V podstatě se jedná o tyto kroky:

- *Získat* nejběžnější případy.
- *Využít* informace a znalosti obsažené ve výše uvedeném kroku k řešení dané úlohy.
- *Přezkoumat* navrhované řešení.
- *Udržet/zachovat* získané zkušenosti pro budoucí řešení situací.



Obrázek 22: Smyčka v podání CBR

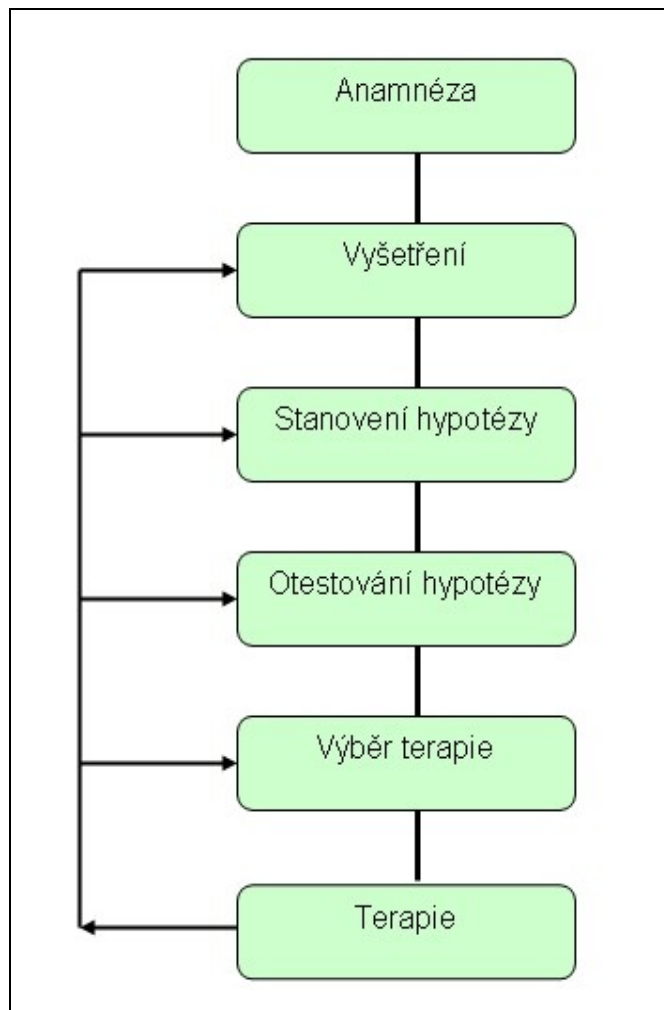
Kořeny metody CBR nalezneme v práci Rogera Schanka [Schank, 1982]. Prvním systémem, který můžeme zařadit do skupiny CBR byl CYRUS, vytvořen

Janet Kolodner [Kolodner, 1983] na Yale Univerzitě. V podstatě to byl systém postavený na otázkách a odpovědích se znalostmi z oblasti cestování a jednání dřívějšího ministra zahraničních věcí USA Cyruse Vance. Memorovací model byl z tohoto systému využit i v dalších systémech jako jsou MEDIATOR [Simpson, 1985] nebo PERSUADER [Sycara, 1988].

Další sada nástrojů byla uplatněna v modelu GREBE [Branting, 1991] – aplikace na právo USA, ve které byly zapracovány také všechny dostupné precedenty.

1.6.1. Specifikace oblasti medicíny

Jak jsem již uvedl dříve, medicína se odlišuje od ostatních oblastí interakcí výzkumu a klinického využití znalostí. Objekty jsou pacienti, přičemž znalosti o nich získané jsou mnohdy velmi povrchné. Pro získání nových znalostí je zapotřebí tradičního výzkumu, který je zpravidla založen na popisu existujících chorob, případových studiích a biostatistických záznamech. Dalším rozdílem oproti jiným odvětvím je skutečnost, že klinická praxe je charakterizována množstvím odborné dokumentace. Existují ovšem obory, kde je ono „know-how“ v rukou jedinců. Zpravidla jsou lékaři zahlceni množstvím různorodých dat, často konfrontováni řadou protichůdných informací a jsou nuceni pracovat pod vysokým stresem. Obrázek 23 ukazuje rozhodovací proces v případě lékařského postupu.



Obrázek 23: Rozhodovací proces v medicíně

1.6.2. Výhody CBR v medicíně

Případové usuzování je pro medicínu přínosné z mnoha důvodů [Gierl et al., 1998]. Patří mezi ně například:

- *Kognitivní adekvátnost*– CBR je v souladu s abstraktivním rozpoznáváním znalostí, které je pro člověka typické. Lékaři velmi často při vyšetření využívají znalosti ze své klinické praxe s cílem stanovit přesněji diagnózu pacienta.
- *Explicitní zkušenosti* - Systémy CBR využívají méně „zhuštěné“ znalosti, ale neustále rozšiřují, nahrazují či mění znalosti postupnou integrací případů do databáze.
- *Dualita objektivních a subjektivních znalostí* – v medicíně je běžné získávat nové objektivní znalosti z klinických případů. Znalosti obsažené v knihách, normách a jiných dokumentech nejsou dostatečně

specifické, jsou odlišně vnímány při odlišných diagnózách či terapiích. Naproti tomu expertní systémy jsou často postaveny na subjektivních znalostech jednotlivých lékařů. A právě zde vzniká dilema běžných systémů: míchání objektivních a subjektivních znalostí s nejasným výstupem na konci. Toto prolínání je typické pro systémy CBR, které jsou schopny oddělit subjektivní a objektivní bázi.

- *Automatické získávání subjektivních znalostí* – samotný proces integrace případů vede k neustálému doplňování poznatků. Systém je schopen seskupovat případy do skupin.

V roce 1993 bylo provedeno pozorování procesu budování báze znalostí - v případě CBR proces trval 2 měsíce, v případě běžného systému, který je řízen pravidly, trvalo budování 18 měsíců.

1.6.3. Druhy CBR systémů v medicíně

V minulosti byla v oblasti medicíny tendence uplatňovat obecné struktury CBR systémů. Podle Gierla [Gierl, 1998] lze systémy v medicíně klasifikovat například takto:

1.6.3.1. Diagnostické

1.6.3.1.1. CASEY

Casey [Koton, 1988] je expertní systém určený pro oblast selhání srdce, který kombinuje techniky pravidel i případů. Systém pracuje ve 3 krocích:

- hledání podobných případů,
- nalezení rozdílů a jejich zaznamenání,
- transfer diagnóz z obdobných případů.

V případě velkých rozdílů nebo nenalezení příkladů, je použit klasický systém pravidel. V případě systému CASEY existuje široká základna adaptačních pravidel.

1.6.3.1.2. FLORENCE

Záběr tohoto systému v poskytování lékařské péče je širší. Zahrnuje všechny základní plánovací požadavky: diagnostiku, prognózu i předpis [Gierl et al, 1998].

Diagnóza zde neslouží ke klasickým lékařským účelům, ale odpovídá na otázku „Jaký je současný zdravotní stav pacienta?“ Využívá se zde hodnotící stupnice. Prognóza hledá odpověď na otázku „ Jak se může v budoucnu změnit zdravotní stav pacienta?“. Stávající stav pacienta je porovnán se záznamy předchozích pacientů a je tak možné usoudit na budoucí vývoj.

Ve třetím kroku hledáme odpověď na otázku „Jak zlepšit zdravotní stav pacienta?“. Podkladem je samotné vyšetření a výsledky vyšetření předchozích pacientů.

Opět se zde umocňuje efekt kombinace případového usuzování a produkčních pravidel.

1.6.3.1.3. **PSIQ**

Dalším příkladem je systém PSIQ [Barcia, 1998], který se zabývá diagnostikou a terapií v oblasti duševních poruch.

Aplikace v lékařských vědách jsou zpravidla klasifikovány ve dvou rovinách:

- fyzické nemoci (kardiologie, interna, ortopedie aj.)
- duševní poruchy (psychologie, psychiatrie)

Jelikož v oblasti duševních poruch je viditelná absence měřitelných symptomů potýká se daná oblast s problémy typu:

- *Problém v ustanovení symptomů a jejich hodnot.* Vyskytuje se při projektování diagnostického systému, protože existuje problém s definováním precizních hodnot ze symptomů (téměř všechny symptomy jsou pouze pozorovatelné, neměřitelné (např., obava, úzkost, agresivita, krutost, couvne před kontaktem, atd). Toto znamená, že vnímání těchto symptomů samo naznačuje subjektivní postoj pozorovatele (v tomto případě psycholog nebo psychiatr). Profesionálové si tak v této oblasti vyberou zaznamenání pouze existence nebo nepřítomnosti jistého příznaku u pacienta.
- *Silné interakce mezi symptomy.* Tento jev je dán skutečností, že se stejný příznak může objevit v různých souvislostech vedoucích k různé diagnóze.

Případ je v systému prezentován jako formalizovaný popis epizody pacienta, následně je lékařem stanovena diagnóza a nakonec je navržen postup řešení. Současně dochází ke klasifikaci dle ICD-10 (například *schizofrenie* má alfanumerický kód F20). Interview je zahájeno s pacientem a na kartu jsou zaznamenány údaje do kategorií: hypotetická diagnóza, vyšetření, příznaky chování. Obrázek 24 znázorňuje kartu se obvyklým záznamem.

SITUATION	DIAGNOSIS	TREATMENT /BEHAVIOR	OBSERVATIONS
initial	hypothetical	initial	SELECTION
update ₁		behavior ₁	cause of the modification
update ₂		behavior ₂	
update ₃	intermediate	behavior ₃	cause of the modification

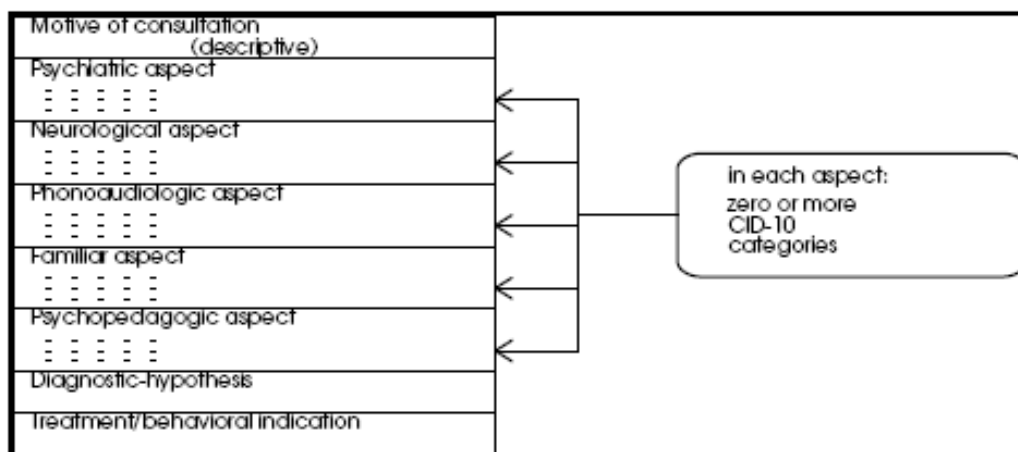
update _n	definitive	behavior _n	cause of the modification

Obrázek 24: Kartotéční lístek/záznam v systému PSIQ

S ohledem na různorodé aspekty (psychiatrické, neurologické aj.) dochází ke změně karty. Každý aspekt je popisován znamením existence nebo nepřítomnosti kategorie ICD 10 (symptomy), s eventuálními neurčitými hodnotami (málo, moc, atd). Stále je přítomna hypotetická diagnóza či konečná diagnóza.

Objevené kategorie mohou být přidány ke každému aspektu skrze pozdější rozhovory. Modifikace v diagnóze, potažmo attributech chování je ještě možná.

Obrázek 25 zachycuje novou strukturu záznamové karty.



Obrázek 25: Záznam na kartě

Z obrázku tak lze odvodit následující rysy:

- jedna nebo víc kategorií popisují aspekt
- několik aspektů definují oblast
- několik oblastí představuje diagnózu

Rys, který lze vyzorovat, je existence kategorií v různých aspektech, nebo dokonce různých oblastech, jak uvádí Obrázek 26.

cognitive area:	psychiatric aspect psychopedagogic aspect neurological aspect phonoaudiological aspect
comportamental area:	familiar aspect psychiatric aspect neurological aspect

Obrázek 26: Vybrané aspekty v různých oblastech

Každý případ v PSIQ systému je tvořen třemi druhy informací, jak ukazuje Obrázek 27. Jsou to: situace, diagnóza a ošetření/chování.

<u>situation:</u>	area _i			
	... aspect _{i,j-1}	aspect _{i,j}	aspect _{i,j+1}	
	category _{ijk-1}	category _{ijk...}}	category _{ijj}
<u>diagnosis:</u> <u>treatment/</u> <u>behavior:</u>	code	description		

Obrázek 27: Reprezentace příkladu

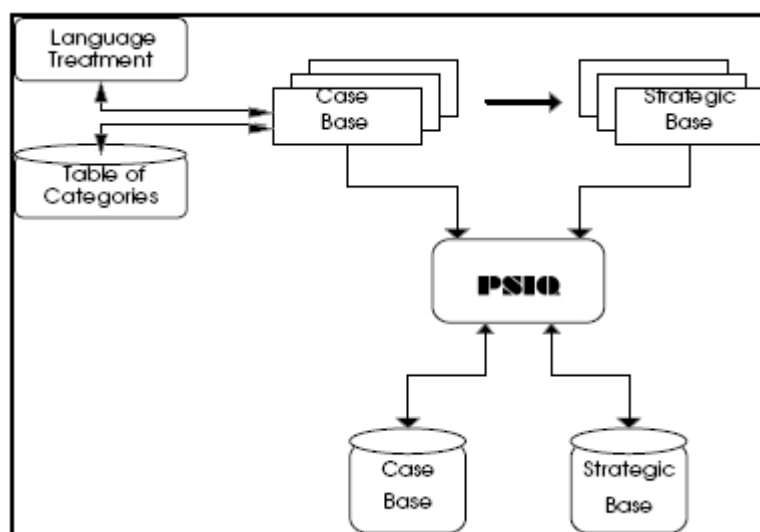
- *Situace*: je vytvořena několika oblastmi, přičemž každá oblast obsahuje aspekty, kterými je definována.
- *Diagnóza*: zpočátku je tvořena hypotetickou diagnózou.
- *Ošetření/chování*: jedná se o popisný atribut obsahující údaje, které se týkají pacienta. Tento atribut může také obsahovat popisy významných detailů z počátečního rozhovoru.

V systému je definováno několik indexů umožňující dosáhnout rozdílné alternativy:

- vybrat případy poskytující řešení pro novou epizodu
- vybrat případy pro výzkum, který může pomáhat analyzovat různé zapojené proměnné

Nad rámec těchto možností systém dokonce může pomoci ve formulaci zevšeobecnění a statistik. Obrázek 28 ukazuje architekturu systému [Barcia, 1998]:

- „*LANGUAGE TREATMENT*“ - tento modul je zodpovědný za identifikaci klíčových slov.
- „*CASE BASE*“ – tento modul uchovává případy (situace+řešení+diagnózy).
- „*STRATEGIC BASE*“ – je tvořena modifikací kategorií, diagnóz a vyšetření/chování.
- „*TABLE OF CATEGORIES*“ – zahrnuje kódy pro jednotlivé kategorie, vyjádřené diagnostickými kódy.



Obrázek 28: Systém PSIQ

1.6.3.2. Plánovací

V této kategorii se nachází systémy zaměřené zejména na podporu terapie. Specialisté vyvinuli systémy jako:

- Petersen (1994) definoval systém pro pooperační terapii v případě bolesti.
- Jurisica a Shapiro (1995) aplikovali CBR metody v terapii problémů v gynekologii.
- Systém ROENTGEN podporuje plánování radiační terapie.

1.6.3.3. Vzdělávací

Vzdělávání je v medicíně založeno na konfrontaci studentů s aktuálními případy z klinické praxe. Spojení teoretických poznatků, které jsou dostupné v řadě odborných lékařských publikací s přednostmi CBR systémů je silnou výbavou absolventů lékařských fakult.

Jedním z prvních systémů při podpoře vzdělávání byl PlanAlyzer. Tento systém byl vyvinut na Dartmouth College. Systém byl aplikován v oblasti chudokrevnosti a infarktů. Odezva na systém byla kladná, zejména díky praktickému přínosu pro vzdělávání mediků.

1.6.4. Reálné aplikace CBR v medicíně

1.6.4.1. GS.52 – Systém pro diagnózu dysmorfních syndromů

Systém GS.52 [Gierl, 1998] byl rutinně používán po mnoho let v dětské univerzitní nemocnici v Mnichově. V podstatě se jedná se o diagnostický podpůrný systém, určený pro oblast dysmorfních syndromů, které zahrnují náhodnou kombinaci různých projevů. Mezi hlavní úskalí patří vysoká variabilita syndromů (stovky mutací), vysoké číslo znaků v jednotlivých případech (40-130) a v neposlední řadě rovněž dynamický vývoj v oblasti znalostí dané problematiky.

Každý syndrom je charakterizován vzorkem, který obsahuje typické projevy. Jednotlivé vzorky jsou získávány v průběhu expertní konzultace systému. Lékař tak může stanovit nový nebo vybírat z již existujících syndromů. Podobně pak systém rozhoduje o odpovídajících znacích a jejich relativním výskytu. Tabulka 12 [Gierl, 1998] ukazuje příklad procentního výskytu příznaků pro daný příklad.

Heart murmur	30%	Depressed nasal bridge	23%
Diminished postnatal growth rate	77%	Anteverted nares	63%
Hypercalcaemia	30%	Prominent lips	17%
Prenatal onset	75%	Long philtrum	17%
Mild microcephaly	67%	Fullness of peri-orbital region	75%
Full cheeks	46%	Medial eyebrow flare	25%

Tabulka 12: Výčet příznaků v systému GS.52

Diagnostická podpora systému sestává v hledání nejpodobnějšího případu. Jednotlivé procentní výskyty v rámci vzorků jsou porovnávány a archivovány, následně se s nimi pracuje při vyhodnocovací fázi.

V minulosti byla provedena studie na pediatrické a genetické klinice v Mnichově, které se zúčastnilo 903 pacientů a bylo shromážděno 229 typů syndromů (datovaných od roku 1987). Studie prokázala, že získaná a naměřená data jsou dostatečně kvalitní pro sestavení expertního systému. U všech pacientů bylo rovněž aplikováno cytologické vyšetření chromozómů, přičemž získané poznatky měly významně přispět ke stanovení přesnosti při stanovení diagnózy pacienta.

1.6.4.2. COSYL

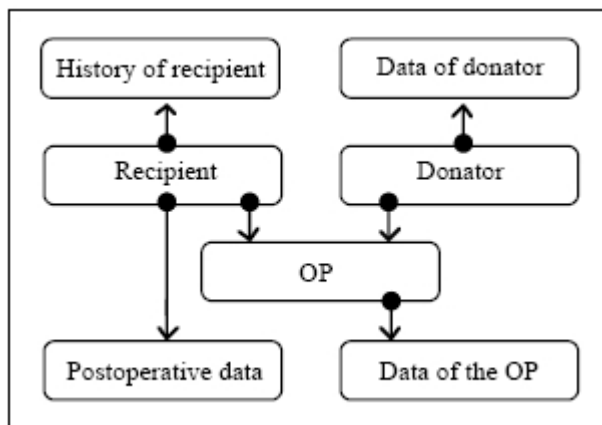
Systém se zabývá transplantací jater a hlavně následnou rehabilitací [Gierl, 1998]. Transplantace jater je léčbou, která je určena pro úzký okruh vybraných pacientů s akutním selháním jater nebo v pokročilém stádiu chronického onemocnění jater.

Samotný proces transplantace je velice náročný, provádí se pouze na vybraných lékařských pracovištích. Počet pacientů, kteří se zákroku zúčastní je rovněž relativně nízký. Veškeré zákroky jsou v maximálně možné míře zdokumentovány, což je cenný podklad pro bázi znalostí. Stejně jako u jiných systémů CBR i v této oblasti je úskalí spojené s podobností zákroků, klasifikací a adaptací.

Systém byl sestaven na základě 200 transplantací provedených v univerzitní nemocnici v Mnichově, přičemž bylo pořízeno více než 700 tisíc údajů [Swoboda, 1994]. Při transplantaci hraje důležitou roli i vazba dárce s pacientem. Je velmi důležité, jak tělo přijme cizí orgán, současně hrozí i možnost zavlečení infekce. Na druhé straně hraje důležitou úlohu i lékařský tým, který celý zákrok provádí.

Aby se zabránilo chronickému odmítnutí nové orgánu, je velice důležitá imunosupresivní terapie.

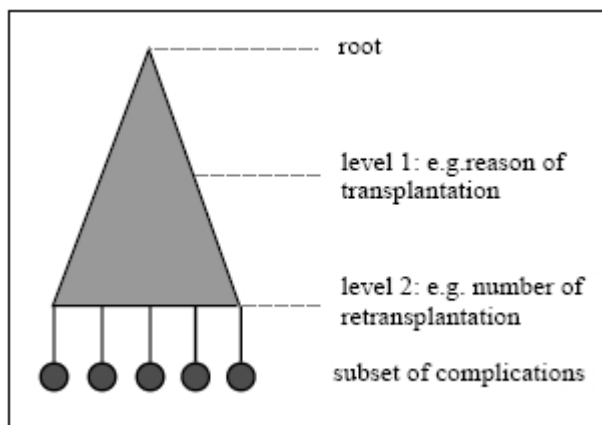
Obrázek 29 [Swoboda et. al., 1991] znázorňuje koncepci báze dat systému COSYL, která je obsahuje data o dárci, příjemci, operaci a pooperační data.



Obrázek 29: Koncept báze dat COSYL

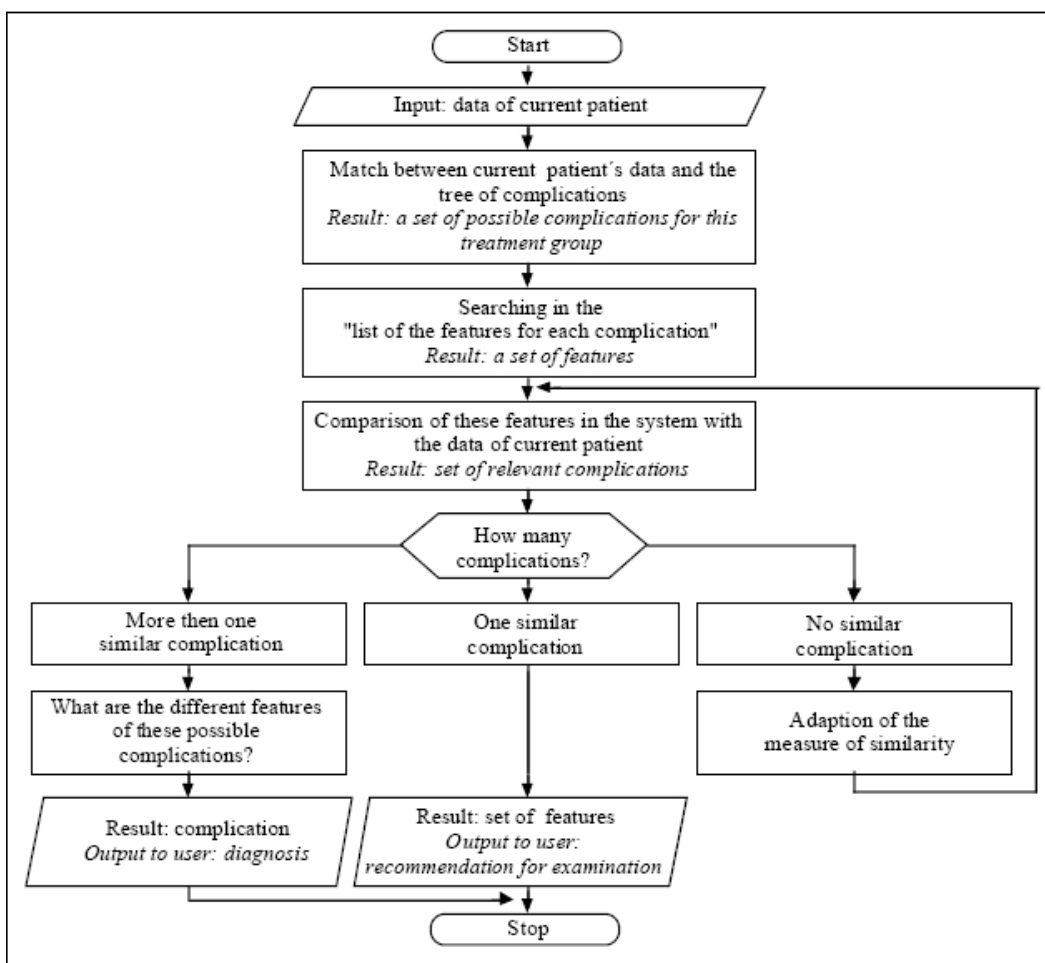
Systém COSYL pracuje s daty, která jsou k dispozici z provedených transplantací. Nejdříve jsou data importována z databáze, ohodnocena s ohledem na pooperační komplikace a následně uložena. V průběhu konzultace systému jsou aktuálně zaznamenaná data porovnána s daty uloženými.

COSYL tak pracuje s daty pacienta ve vztahu ke stromu komplikací, viz. Obrázek 30 [Swoboda et. al., 1991]. Výhodou stromu je, že systém pracuje pouze se specifickou skupinou komplikací.



Obrázek 30: Struktura komplikací v systému COSYL

Postup samotné konzultace znázorňuje Obrázek 31 [Swoboda et. al., 1991]. Systém porovnává data o aktuálně vyšetřovaném pacientovi s již uloženými záznamy. Jestliže je nalezena pouze jedna komplikace, systém znázorní diagnózu. V případě více komplikací systém navrhne potřebná vyšetření tak, aby mohl na základě předložených výsledků upřesnit diagnózu.



Obrázek 31: Vývojový diagram konzultace v systému COSYL

1.6.4.3. ALEXIA

Jako ostatní CBR systémy i ALEXIA využívá indexovanou paměť předchozích řešených úloh s tím, že navrhuje strategii řešení pro daný aktuální problém. ALEXIA se zaměřuje na oblast etiologie vysokého tlaku. Ontologie systému zahrnuje 20 uzlů, 20 znaků a symptomů, 111 pozorování, 31 doplňujících příkladů, 26 hran. Obrázek 32 demonstruje částečný výpis z konzultace systému.

```
Mr. MARTIN :  
  INTAKE      CLINICAL  
length-AHT : 6      arterial-tension : (152 118)  
gender : male      pulse : 80  
resistance-AHT : present vascular-murmur : present  
age : 50           peripheral-pulse : present  
observ-problem : absent      BIOLOGICAL  
asthenia : present      creatininemia : 99  
smoking : present      kaliemia : 2.8  
anti-AHT-treatment : present natremia : 145  
sport : absent        bicarbonatemia : 31.0
```

Obrázek 32: Výpis z konzultace systému ALEXIA

1.6.5. Stručný přehled dalších CBR systémů v medicíně

Tabulka 13 uvádí stručný výčet dalších vybraných CBR systémů.

SYSTÉM	CHARAKTERISTIKA
CARE-PARTNER	Podporuje dlouhodobou a následnou péči po transplantaci kmenových buněk.
CASEREC	Interpretace digitálních mikroskopických obrázků při identifikaci nebezpečných plísní šířených vzduchem.
ENDOCRINOLOGY AID	Podporuje stanovení a monitorování dávkování levothyroxinu při endokrinní léčbě.
FM-ULTRANET	Interpretace ultrazvukových snímků a diagnóz fetálních malformací.
GENE FINDER	Identifikuje rozmístění kódů v prvcích savčích DNA.
HR3MODUL	Klasifikuje citlivost měření při diagnóze nemocí spojených se stresem .
MÉMOIRE	Navrhuje schéma pro sémantickou součinnost CBR

	systemů v biologii a medicíně.
NUTRIGENOMICS	Poskytuje poradenství v oblasti výživy s ohledem na genetiku, zdraví a životní styl.
RHENE	Odhaduje účinnost hemodialýzy.
SISAIH	Podpora při autorizaci výkonů v nemocnicích, sleduje fakturaci za úkony dle vyšetření pacientů.
SOMNUS	Podporuje stanovení diagnózy a vyšetření v případě poruch dechu při spaní .
WHAT	Předepisuje cvičební schémata pro kardiaky a pacienty s nemocemi plic.

Tabulka 13: Stručný přehled dalších CBR systémů

1.6.6. Budoucnost CBR v medicíně

Základní překážkou v plošném šíření expertních systémů v klinickém prostředí je nedostatečná úroveň integrace [van der Lei, 1985]. Tento poznatek plyne z procesu vývoje mnoha znalostních systémů v medicíně. Integrace zahrnuje několik aspektů a úrovní, bez kterých nelze plošně implementovat systémy CBR:

- Integrace speciálního hardware a software v nemocnicích.
- Integrace v klinických zařízeních.
- Adekvátní reprezentace znalostí pomocí kombinace různých přístupů.
- Integrace problémů řešení a učení.

Expertní systémy jsou v klinické praxi přínosné v případech, kdy jsou schopny vyplnit mezeru mezi aktivitami v klinické praxi, jak je vidět například na systému DIACONS, který kombinuje dokumentaci, různé druhy monitorování a učení. Systém GS.52 zase integruje vstupní data o pacientovi, databázi, výzkum, diagnózy, zprávy a získávání znalostí. V praxi neexistuje mnoho studií, které by interpretovaly finanční dopady využívání CBR systémů v medicíně. Problémem medicíny je diferencovaný pohled na stejná data. Jestliže pacient například trpí prostatou, jinak se získanými informacemi pracují urolog, chirurg či patolog. Znalostní systémy jsou obvykle schopny poskytnout informace na jednom místě pro různé lékařské účely.

Stále více lékařů si začíná uvědomovat rostoucí význam CBR systémů v jejich každodenní klinické praxi [Gierl, 1998]. To lze ilustrovat na příkladu klinického psychiatra:

- Do databáze si ukládá záznamy o všech pacientech, které vyšetřil.
- Záznamy zahrnují: prostředí, symptomy, choroby, vyšetření a vyhodnocení.
- Může sdílet svoje záznamy s ostatními kolegy.
- V případě nových pacientů je systém schopen prohledat celou databázi záznamů a v reakci na zadané požadavky najít pacienty s co nejpodobnějšími znaky a navrhnout případnou léčbu.
- Systém je schopen provést porovnání podobných i rozdílných znaků jednotlivých pacientů.

Mezi trendy, které lze v budoucnu očekávat patří:

- *Formalizace systémů CBR v medicíně.* Mnoho systémů již bylo sestrojeno. Nyní je potřeba zkoumat společné znaky těchto systémů a následně formalizovat jazyk, případovou strukturu i zdůvodňovací mechanismy.
- *Bioinformatické aplikace.* Díky pokrokům v oblasti genetiky a genetického inženýrství se otevírá prostor pro využití těchto informací v CBR systémech.
- *Integrace se získáváním informací.* V medicíně je obrovské množství textových informací, se kterými se musí lékaři, lékařský personál i medicína potýkat. Systémy CBR by mohly ulehčit proces získávání a předkládání informací lékařské veřejnosti, rovněž stále více subjektů klade důraz na získávání údajů v elektronické podobě z vyšetření, hospitalizace či ambulantního ošetření pacientů.
- *Dolování dat.* Trend dnešní doby „dolování dat“ naráží na problémy se kterými se potýká velké množství databází obsahující záznamy – a to je kvalita uložených informací. Mnohdy jsou informace neúplné, či chybně zadané.
- *Dlouhodobé učení.* S ohledem na komplexnost medicíny a neustálé změny které v ní probíhají, budou CBR systémy hrát stále důležitější úlohu při zapracování nových poznatků do báze znalostí.

Samozřejmě se vyskytují i určité nástrahy či omezení na cestě k plošnému využívání CBR, jako jsou:

- *Legální aspekty.* Legislativa spojená s ochranou dat mnohdy komplikuje práci s daty o pacientech.
- *Budování báze znalostí v medicíně je dlouhodobou záležitostí.* V budoucnu bude potřeba sdílet báze znalostí v rámci více systémů.

V. VÝVOJOVÉ TRENDY NA POLI ES/ZS

1.7. Oblasti uplatnění v budoucnu

V horizontu 5 let lze očekávat v oblasti zdravotní péče mnoho změn, které jsou z velké části ovlivněny vývojem v ICT oblasti. Níže uvádím výčet několika oblastí a možného vývoje v nich s ohledem na uplatnění ES/ZS:

- *Infrastruktura*
 - o Miniaturizace ICT zařízení, plošné šíření technologií, konektivita z libovolného místa.
 - o Nejen zprostředkování dialogu/komunikace mezi dotčenými subjekty, ale i validita dat, tracking, práce se záznamy...
 - o Rozšíření EHR, plošná dostupnost záznamů, eliminace duplicitních záznamů.
 - o Dohled pacientů nad přístupem k jejich datům – skrze webové rozhraní budou mít pacienti možnost sledovat, kdo pracuje s jejich záznamy.
 - o Optimalizace informačního toku záznamů z dokumentace, eliminace papírových kopií a jejich rozesílání.
 - o Využívání on-line telemedicíny, videokonferencí aj.

- *Elektronický zdravotní záznam (EHR)*
 - o Zdravotní záznamy budou ukládány v definovaném formátu, změní se tak struktura dat. Dojde k rozšíření záznamu metodou rozpoznání hlasu.
 - o Využitím inteligentních nástrojů při prohledávání dat, budou záznamy lehce dostupné.
 - o Historie zdravotních záznamů se bude kombinovat s aktuálními výsledky vyšetření a bude tak docházet k lepšímu plánování eventuálních vyšetření.

- *Zdravotní diagnostika a vyšetření*

- o Rozšíření medicíny založené na důkazech.
- o Individuální přístup při vyšetření pacienta.
- o Využívání systémů na podporu rozhodování.
- o Pacienti se stále více budou zajímat o svůj zdravotní stav. ES/ZS systémy budou pracovat se stále větším počtem informací a pacientovi v rámci dialogu předkládat záznamy.

1.7.1. Proces učení ve vztahu k medicíně

“Web learning” v dnešním pojetí nesplňuje očekávání, která byla stanovena v době boomu internetu [CIRCA, 2002]. Oblast medicíny ve vztahu k učení a práci s informacemi se potýká s mnoha změnami. Stále více lidí vyžaduje osobní vizualizaci, myšlení a sofistikované nástroje pro učení. Mění se způsob prezentace médií.

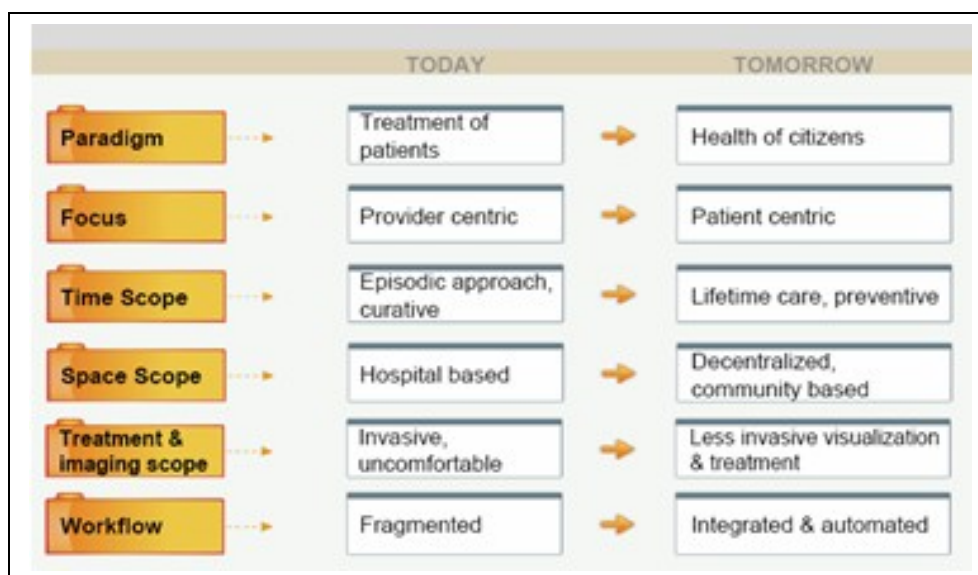
Selhává rozhraní pro práci s informacemi ve vztahu pacient-lékař. Příkladem může být následující situace: Běžná návštěva lékaře trvá 20 minut. Lékař se potýká s 20-30 ikonami na ploše svého počítače. Při vyšetření je nutno přenést mluvený text do písemné podoby. Projevuje se nedostatek standardizace při práci s daty. Objevují se komunikační problémy ve vztahu k věkové skupině pacientů aj.

Zde vidím uplatnění ES/ZS například při zprostředkování dialogu mezi pacientem a lékařem, učení lékaře v práci s ICT atd.

1.7.2. Lékařská informatika

Veřejné autority stále podporují v oblasti péče o pacienty přístup “péče o nemocného“, což je v praxi charakterizováno následujícími znaky: práce se symptomy, mnoho rozličných dat, léčení nemocí, průměrné terapie. Je potřeba změnit tento pohled a zavést do praxe přístup známý pod pojmem „péče o zdraví“, pro který platí: důraz na prevenci, detailní informace o pacientech, stanovení časné diagnózy, cílené terapie. S celým procesem souvisí i změna paradigmatu⁸, který naznačuje Obrázek 33 [Maurincomme, 2008].

⁸ MAURICE, E.: Medical Informatics save lives. Agfa HealthCare, 2008.



Obrázek 33: Změna paradigmatu v oblasti péči o zdraví

Zde vidím uplatnění ES/ZS zejména:

- v procesu identifikace rizik u pacienta
- pomoc při stanovení časných diagnóz
- pro dosažení efektivního vyšetření
- v oblastech rozhodovacích procesů
- způsobu sběru dat o pacientech
- způsobu nakládání záznamů o pacientovi aj.

1.7.3. Požadavky pacienta v oblasti e-zdraví (e-health)

Dle ISO 2220 (Identification of Subjects of Care) je pacient definován jako osoba, zákazník či obyvatel, který má nárok na obdržení zdravotní péče. V praxi platí, co člověk, to jiné priority. Někteří preferují situaci, kdy se jim řekne, co a jak mají udělat, jiní chtějí mít plnou kontrolu nad svým rozhodnutím a situací, další preferují dialog s odborníkem aj. Obecně platí zásada, že každý chce, aby se mu naslouchalo.

V praxi tak platí, že:

- ne každý pacient rozumí lékařským termínům a pokynům,

- ne každý pacient je ochoten číst příbalovou informaci,
- ne každý pacient se zeptá, když nerozumí výkladu,
- ne každý pacient chce/může navštívit odborného lékaře.


V oblasti e-health vytvořila WHO aplikaci pod jménem „Map of Medicine“⁹, jejímž cílem je fungovat jako znalostní základna v oblasti poskytování zdravotní péče. Podporuje plánování zdravotní péče, nabízí přes 390 cest, pokrývá 28 specializací, slouží jako podpora klinických lékařů, pracuje s rozšířenými standardy, slouží jako nástroj pro vzdělávání aj. I v této aplikaci se uplatňují prvky ES/ZS.

1.7.4. Vliv znalostí a dostupných informací ve vztahu pacient-lékař

Existuje tvrzení, které lze volně přeložit jako: *„Znalost je nepřítel nemoci – vhodné uplatnění toho, co známe, má větší dopad na léčbu, než-li jakákoliv technologie či lék“*.

Obecně lze v medicíně rozlišit 3 zdroje znalostí: výzkum (důkaz), měřením výkonnosti zdravotnického systému (statistika) a zkušenosti (ze strany pacienta i lékaře).

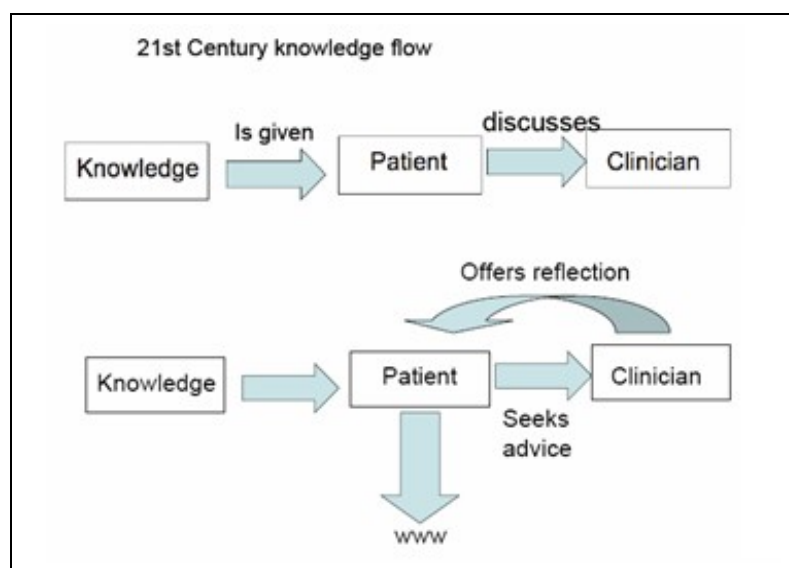
V poslední době jsem se osobně setkal s několika případy, kdy se mění tradiční tok informací a znalostí ve vztahu pacienta a lékaře. Obrázek 34 [Gray, 2008] [znázorňuje tradiční způsob předávání informací a práce se znalostmi mezi lékařem a pacientem.



Obrázek 34: Znalosti 20. století

⁹ Dostupné z „<http://www.mapofmedicine.com/>“

Ovšem díky dnešním nástrojům ICT dochází k modifikaci v tomto řetězci. Pacienti si díky internetu, vyhledávačům, databázím a jiným nástrojům mohou zjistit o svých případných příznacích detailní informace. Až poté jdou k lékaři, kde již konfrontují získané znalosti s názorem lékaře. V praxi se mi několikrát stalo (zejména ve vztahu k nemoci mé dcerky), že má laická příprava sehrála důležitou roli při dialogu s lékařem, dokonce si troufám tvrdit, že v několika případech i eliminovala zbytečná vyšetření, které by bylo nutné jinak podstoupit. Zdůrazňuji, že v žádném případě nejde o hádání se s lékařem, ale pouze o diskusi se zpětnou vazbou a práci se zdroji. Zejména praktičtí lékaři se tak stále častěji začínou dostávat do situace, kdy budou muset diskutovat s pacienty, což mnohdy může způsobit nedorozumění. Obrázek 35 [Gray, 2008] znázorňuje mnou popisovanou změnu v práci se znalostmi.



Obrázek 35: Znalosti v 21.století

Úloha ES/ZS v této oblasti může sehrát významnou roli. Při využití vhodné platformy a nástrojů lze pacientům i lékařům nabídnout silný nástroj pro práci se znalostmi.

Z výše uvedeného lze odvodit i způsob, jak by mohla vypadat situace v roce 2015. Obrázek 36 [Gray, 2008] znázorňuje jeden ze způsobů jak pacienti budou moci spravovat data o svém zdraví.

- Zdravotní péče je nyní příliš zaměřena na epizodickou akutní péči. Bude potřeba zahrnout ve větší míře prevenci a věnovat se oblasti chronických nemocí.
- Chroničtí pacienti tak budou disponovat nástroji, které jim umožní mít kontrolu nad svojí nemocí využitím vhodných IT nástrojů.
- Pacienti i jejich rodinní příslušníci budou používat nástroje ICT, které částečně nahradí pravidelné konzultace u lékaře.



Obrázek 36: Nástroje pro práci se daty

1.7.5. E-learning v rámci CME (Continuous Medical Education)

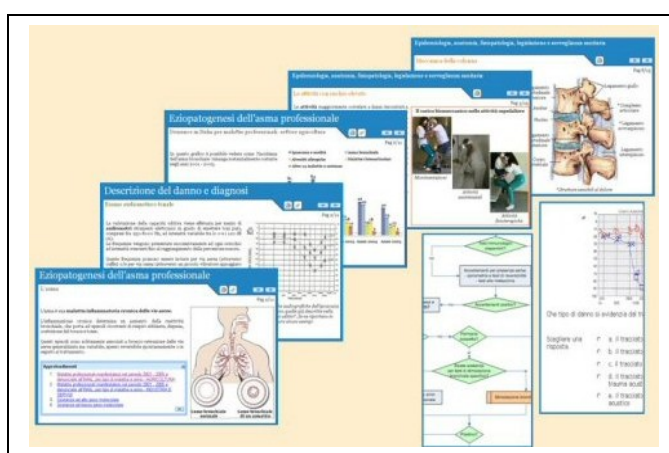
Poté co se završí implementace IS systému, nastává další fáze, kdy je potřeba proškolit různé skupiny uživatelů, kteří budou se systémem pracovat. To jak bude systém přijat uživateli je ve velké míře odvislé od přívětivosti systému.

Obrázek 37 znázorňuje jeden z programů, který byl vyvinut v Itálii.

Mezi způsoby, jak spojit dohromady uživatele a systém, je možné zařadit:

- Transfer informací skrze výukové moduly.
- Schématická prezentace skrze modelové situace při využití vývojových diagramů.
- Případové studie zaměřené na testování znalostí.
- Tradiční testy verifikující získané znalosti při práci se systémem.
- Využití tutora v procesu učení.

I zde jsou příležitosti pro využití ES/ZS.



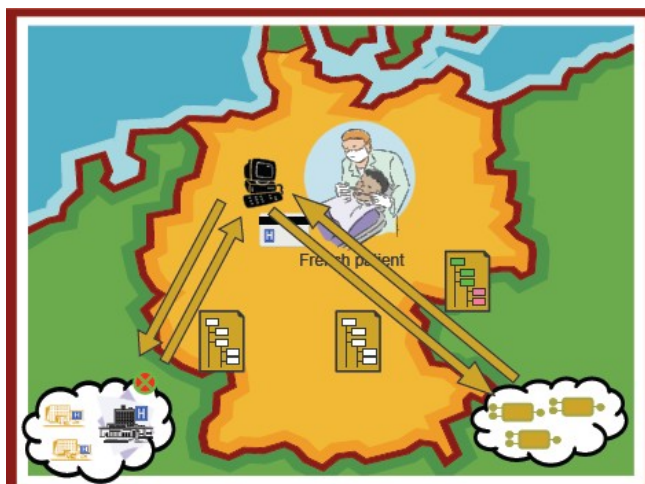
Obrázek 37: Příklad e-learningu v CME

1.7.6. Cestovní elektronický zdravotní záznam (EHR)¹⁰

Stále více lidí cestuje pracovně i soukromě po světě. Nabízí se otázka, jakým způsobem zajistit pacientům dostupnost jejich zdravotních záznamů v celém světě při zohlednění právních a regulačních pravidel jednotlivých zemí. EHR si klade za cíl:

- Dostupnost zdravotních záznamů pacienta v zemích, do kterých cestuje.
- Umožnit pacientovi mobilitu a usnadnit poskytnutí zdravotní péče v zahraničí.
- Zachovat právo pacienta na soukromí a zabránit zneužití údajů.

¹⁰ Pr. André FLORY – LIRIS – INSA de Lyon, MIE 2008



Obrázek 38: EHR v praxi

Mezi možné problémy při realizaci systému je možné zařadit:

- Heterogenita zdravotních záznamů v rámci jednotlivých států.
- Rozličná vypovídací hodnota informací v záznamu.
- Spolupráce mezi informačními providery - přístup k datům.
- Transparentnost dat, uživatelská přívětivost systému.
- Jednoduchost získání/čtení záznamu.

1.7.7. Systémy na předepisování léků

Mezi základní cíle systémů na předepisování léků patří¹¹:

- *Pomoc pacientovi při rozhodnutí, zda potřebuje lék – zahrnuje historii i současné problémy pacienta včetně lékařských záznamů a laboratorních vyšetření.*
- *Pomoc při výběru léku, který může poskytnout optimální výsledek pro pacienta s ohledem na aktuální problém – klinické pokyny pro doporučení diagnózy a léčby.*

¹¹ Karin Kajbjer SFMI, MIE 2008

- *Pomoc při tvorbě optimální nákladové struktury ve vztahu k veřejnému systému zdravotního pojištění při zohlednění nákladů pacienta – srovnání cen, doporučení lokálních autorit, úhradová politika...*
- *Předepisování léků v reálném čase – využití šablon při předepisování léků.*
- *Pomoc při transferu dat mezi lékařem a lékárnou – využitím EDI.*
- *Pomoc při komunikaci s pacientem – tisk záznamu pacienta, elektronická komunikace atd.*
- *Usnadnění komunikace objednávek léků vůči dalším subjektům – provozní podpora při administraci, sdílení historických dat.*
- *Pomoc při sledování stavu předepisování léků v dané organizaci – monitorování chování jednotlivých lékařů, podpora při vyhodnocování rizik užití léků a jejich vedlejších účinků.*

Při tvorbě systému je zapotřebí spousta informací jako je: registrace léků, základní/rozšířené farmakologické informace, doporučení lokálních autorit, klinická data, šablony pro předepisování léků, lékařské záznamy pacienta aj.

1.7.8. Další uplatnění

Mezi další oblasti, ve kterých nacházejí ES/ZS uplatnění, patří:

- Implementace inteligentního vzdělávacího modelu v praxi
- Systém pro kontrolu indikací a kontraindikací v procesu předepisování léků
- Systém pro navržení optimální antibiotické léčby
- Systém pro plošné předvídání epidemií

Tyto systémy jsou na praktických příkladech prezentovaný v další kapitole.

1.8. Vývojové trendy úspěšných aplikací znalostních systémů v medicíně

1.8.1. Implementace inteligentního vzdělávacího modelu v klinické praxi

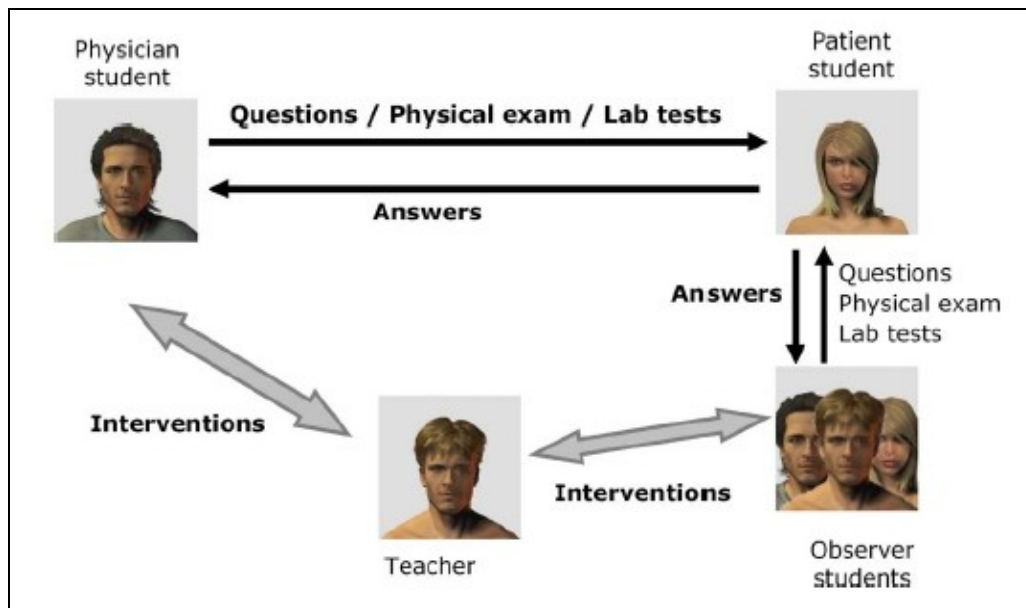
Studenti medicíny jsou při řešení problémů plynoucích z klinické praxe závislí na znalostech, které se během studia dozvěděli a rovněž na příkladech, které ve své školní praxi viděli. Vývoj posledních let má negativní vliv na přístup studentů k případovým studiím: pacienti, kteří jsou zapojeni do univerzitních programů, trpí často komplexem chorob, zkušení lékaři jsou stále více zaneprázdněni, a trend směrem k ambulantní péči snižuje počet hospitalizovaných pacientů.

Všechny tyto aspekty přispěly k vývoji systému TeachMed [Kabanza et al., 2006], který učí studenty medicíny stanovit diagnózu pro fingované pacienty, jejichž kompletní lékařské záznamy, zahrnující lékařská vyšetření včetně laboratorních testů a výsledků, jsou obsaženy v databázi systému.

Silnou stránkou systému je pedagogický modul. Systém klade důraz na poučení se z chyb, které student při stanovení diagnózy může udělat. Současně při stanovení správné hypotézy systém studentovi nastíní i možná jiná řešení za předpokladu, že se změní třeba laboratorní výsledky.

Níže uvádím základní charakteristiky systému:

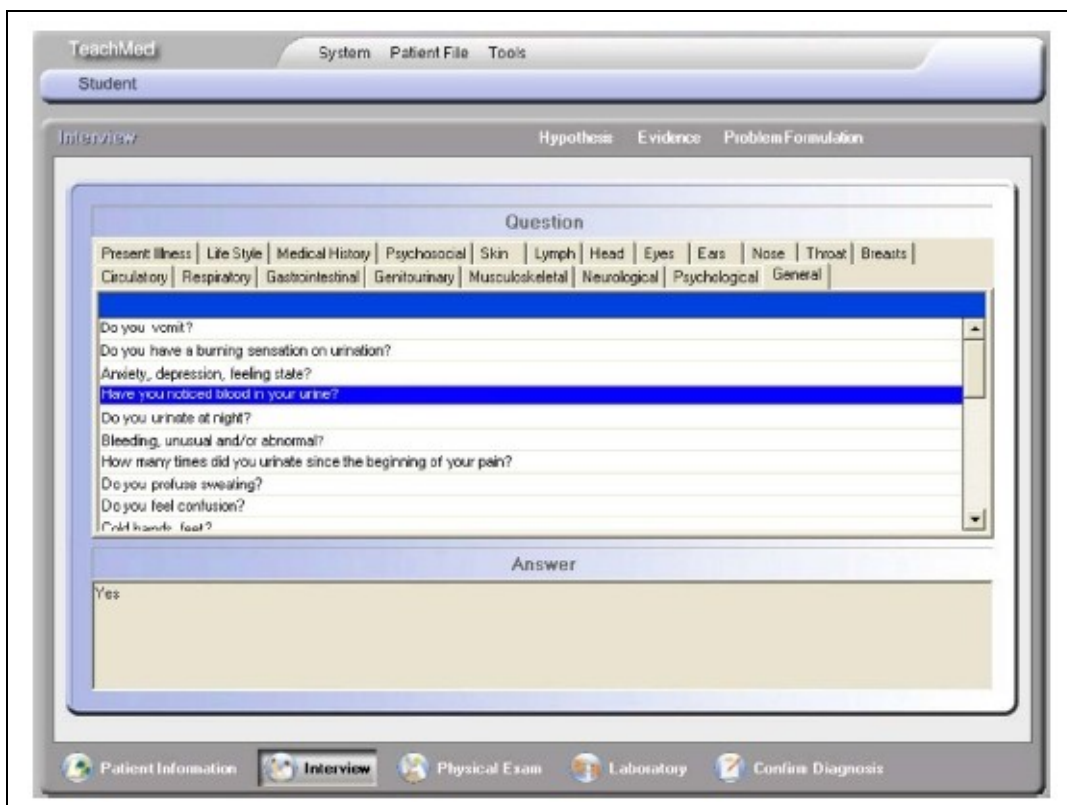
- Studenti pracují se systémem ve 4. ročníku studia (týká se studentů všech specializací), zpravidla dvakrát týdně 2 hodiny. Po čtyřech letech studia jsou již vybaveni slušným teoretickým zázemím a je vhodný čas spojit nabyté poznatky s praxí.
- Systém usuzování studenta při konzultaci se systémem je mnohem důležitější, než-li stanovení konečné diagnózy.
- Jednotlivé konzultace probíhají v malých skupinách studentů (zpravidla 6-8) pod dozorem kantora. Jeden ze studentů je vybrán aby sehrál roli pacienta. Druhý student hraje roli lékaře a ostatní studenti jsou pozorovatelé a současně se zapojují do diskuse. Obrázek 39 znázorňuje vzájemné lidské vazby v rámci systému.



Obrázek 39: Lidské vazby v systému

- Průběh konzultace lze rozdělit do 3 částí:
 - Interview s pacientem (důvod konzultace, četnost symptomů, příznaky aj).
 - Fyzické vyšetření.
 - Laboratorní/obrazová vyšetření (krevní testy, vzorky moči, rentgen, aj).

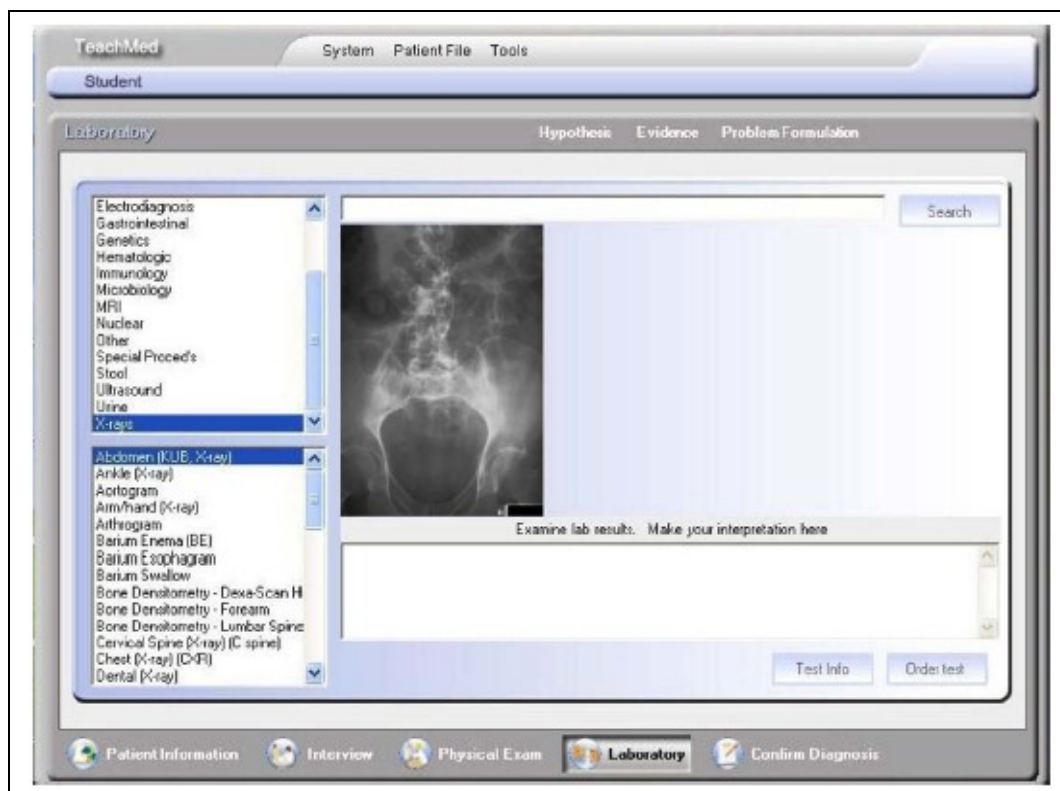
Následující obrázky znázorňují výše uvedené 3 kroky.



Obrázek 40: Interview s pacientem



Obrázek 41: Fyzické vyšetření pacienta



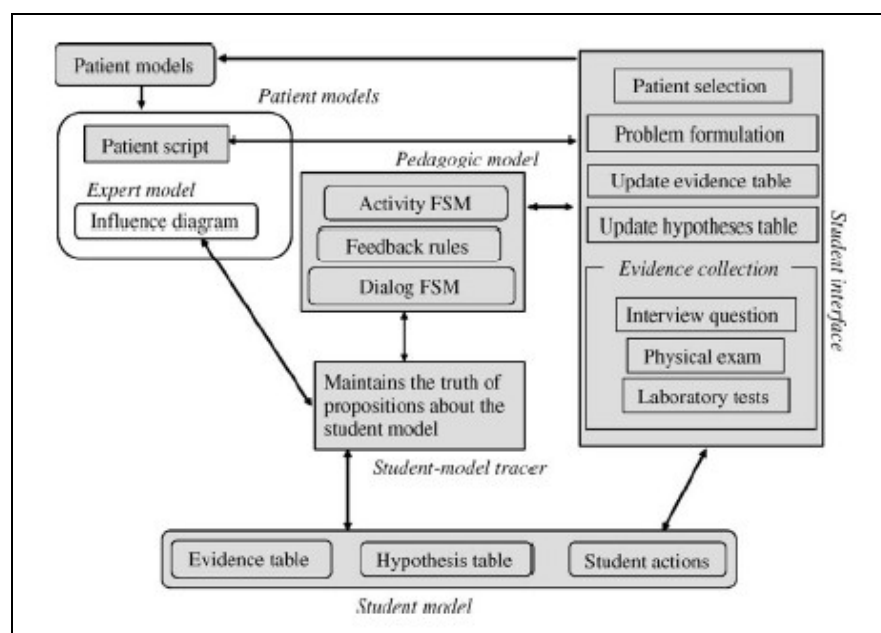
Obrázek 42: Laboratorní vyšetření

Na otázky v průběhu vyšetření odpovídá student, který je v roli pacienta. Struktura odpovědí je předem konzultována s vyučujícím kantorem. Jestliže ad hoc situace nemá předem připravené řešení, kantor vstupuje do dialogu a podá dodatečné informace.

- Podstatné body konzultace zapisuje student-lékař na tabuli, všichni přítomní tak vidí postup při vyšetření. Student je veden tak, aby stanovil jednu hypotézu, dodatečně se objeví další příznaky, které mohou již vytvořenou hypotézu zvrátit. V určitých bodech konzultace má student možnost zrekapitulovat své nálezy a zamyslet se v širším kontextu nad možnými dopady. Poté co je stanovena diagnóza, stanoví se příslušná léčba.
- V případě dotazů či nejasností může relaci kdokoliv z účastníků přerušit. Mezi typické požadavky v těchto případech patří upřesnění symptomů dané nemoci, nejistota při stanovení hypotézy, aj.
- Jestliže student nestanoví správně hypotézu – nesprávně vyhodnotí dostupné informace, je tato situace důvodem k zásahu vyučujícího. Velkým přínosem je bezprostřední konfrontace názorů.

- Jedním z kritérií pro stanovení hypotézy je úplnost vyšetření, výsledky laboratorních testů. Není vhodné, aby student v průběhu konzultace s pacientem skákal od jedné hypotézy ke druhé. Je potřeba si stanovit jasně definovanou cestu k cíli.
- Jestliže pedagog vidí, že student tápe s určením správné hypotézy, zasáhne do konzultace a vyhodnotí dosavadní průběh relace. Současně student podá vysvětlení mezi fakty, které zjistil a svým myšlenkový pochodem. Učitel rovněž vysvětlí, jak správně rozdělit kroky při stanovení nové hypotézy.
- Architekturu systému lze rozdělit následovně:
 - *Model student* – student si vybírá z databáze pacienta, dotazováním pokračuje interview, následně provádí fyzické vyšetření a laboratorní vyšetření. Otázky jsou kladeny v textové podobě. Student může v průběhu konzultace kdykoliv aktualizovat získané údaje.
 - *Model pacient* – systém TeachMed nepředkládá soustavný seznam hypotéz, které by měl student přiřadit vyšetřovanému pacientovi. Naproti tomu systém studenta neopravuje, jestliže zvolí cestu, která není zrovna tou optimální například z nákladového hlediska. Dokonce nechá studenta udělat i některé chyby, aby tak uživatel dostal prostor se z nich poučit, případně na ně přijít a opravit postup, kterým se ubírá k stanovení výsledné hypotézy.
 - Další součástí systému jsou *expertní model* a *model pedagog*

Obrázek 43 popisuje výše uvedenou architekturu systému.



Obrázek 43: Architektura systému

Příkladem dialogu se systémem je následující situace (student se snaží změnit příliš brzy stávající hypotézu za jinou):

Příznaky: akutní bolest v dolní části břicha
Pracovní hypotéza: infekce močových cest
<i>Výpis z dialogu se systémem:</i>
<i>ST lékař:</i> Můžete mi popsat svoji bolest? Je to jako sevřenost žaludku, spalující bolest?
<i>TM pacient:</i> Není to svírající bolest, ale je velmi silná.
<i>ST lékař:</i> Jak často chodíte močit od té doby, co pociťujete tu bolest?
<i>TM pacient:</i> Nevím, řekl bych že více často.
<i>ST lékař:</i> Pociťujete při močení pálení?
<i>TM pacient:</i> Ne.
<i>ST lékař:</i> Máte sexuálního partnera?
<i>Zde vstupuje do dialogu učitel:</i> je tato otázka relevantní s hypotézou, kterou sledujete? Ano/Ne, sleduji jinou hypotézu.
<i>ST lékař:</i> Ne, sleduji jinou hypotézu.
<i>Systém:</i> Přejete si pokračovat s hypotézou infekce močových cest? Ano/Ne.
<i>ST lékař:</i> Ano.
<i>Systém:</i> Jste si jist?
<i>ST lékař:</i> Ano.
<i>Systém:</i> Co si myslíte o tělesné teplotě, je důležitá při infekci močových cest?

(Je ve vztahu k zánětu močových cest/není ve vztahu k zánětu močových cest/nevím.)
<i>ST lékař:</i> Je ve vztahu k zánětu močových cest.
<i>Systém:</i> Položte tedy relevantní otázku.
<i>ST lékař:</i> Máte zvýšenou teplotu či horečku?
<i>TM pacient:</i> Nevím.
<i>ST lékař:</i> Chci změnit stávající hypotézu zánětu močových cest na novou hypotézu: STD (sexuálně přenosné nemoci).
<i>Systém:</i> Skončili jste tedy s hypotézou zánětu močových cest?
<i>ST lékař:</i> Ano.
<i>Systém:</i> Jste si jist?
<i>ST lékař:</i> Ano.
<i>Systém:</i> Co si myslíte o lateralizaci bolesti (bolest na jedné straně je větší než-li na druhé). Je ve vztahu k zánětu močových cest/není ve vztahu k zánětu močových cest/nevím.
<i>ST lékař:</i> Nevím.
<i>Systém:</i> Lateralizace bolesti ovlivňuje negativním způsobem hypotézu zánětu močových cest. Vyžádejte si od pacienta upřesnění.
<i>ST lékař:</i> Je bolest na jedné straně větší ?
<i>TM pacient:</i> Ne.

Jak je vidět z dialogu, systém v některých momentech vyžaduje od studenta potvrzení svého rozhodnutí, v některých případech si žádá upřesnění a jindy zase studenta navádí na co se ptát.

Mezi další úspěšné systémy, které se orientují na interaktivní vzdělávání mediků patří: GUIDON, SlideTutor, COMET nebo ADELE.

1.8.2. Vytvoření systému kontroly indikací a kontraindikací v procesu předepisování léků

Cílem nemocničních systémů je nejen zvýšení efektivity práce lékařů a personálu, ale hlavně zamezení chyb, které může lékař při svém výkonu udělat.

Na lékařském předpisu musí lékaři v Japonsku uvádět provedený lékařský výkon společně s uvedením nemoci pacienta. Pojišťovny, které provádějí úhradu výkonů lékařům, následně provádějí kontrolu, zda provedené lékařské výkony účinně působí na nemoc pacienta. Jestliže shledají tuto vazbu neefektivní,

neproplácí lékařům peníze. Většina zamítnutých případů je způsobena lékařskými chybami při zápisu choroby pacienta.

Snahou provozovatelů nemocnic je eliminovat případy zanedbání péče. Vyskytují se případy pacientů, kteří trpí několika nemocemi a předepsané léky mají léčivý účinek na některou z chorob, ale vůči jiným nemocem, kterými trpí, je efekt protikladný. Lékaři tyto případy leckdy z nedbalosti přehlíží. A právě těmto lékařům je určen systém, který hlídá kontraindikace předepisovaných léků.

V Japonsku je v mnoha nemocnicích využíván elektronický systém [Matsumura et al., 2004], ve kterém lékaři evidují jména chorob ve vztahu k předepisovaným lékařským předpisům. Algoritmus kontrolního programu pracuje zhruba následovně [Matsumura et al., 2004]:

- V momentě zadání názvu léku systém prohledá bázi znalostí nemocí pro které je lék účinný.
- Následně se provádí kontrola, zda pacient má stanovenou uvedenou chorobu.
- Jestliže je odpověď negativní, systém na to vizuálně upozorní.
- Systém využívá jednoduchou bázi znalostí, která je tvořena kódy léků a kódy chorob.

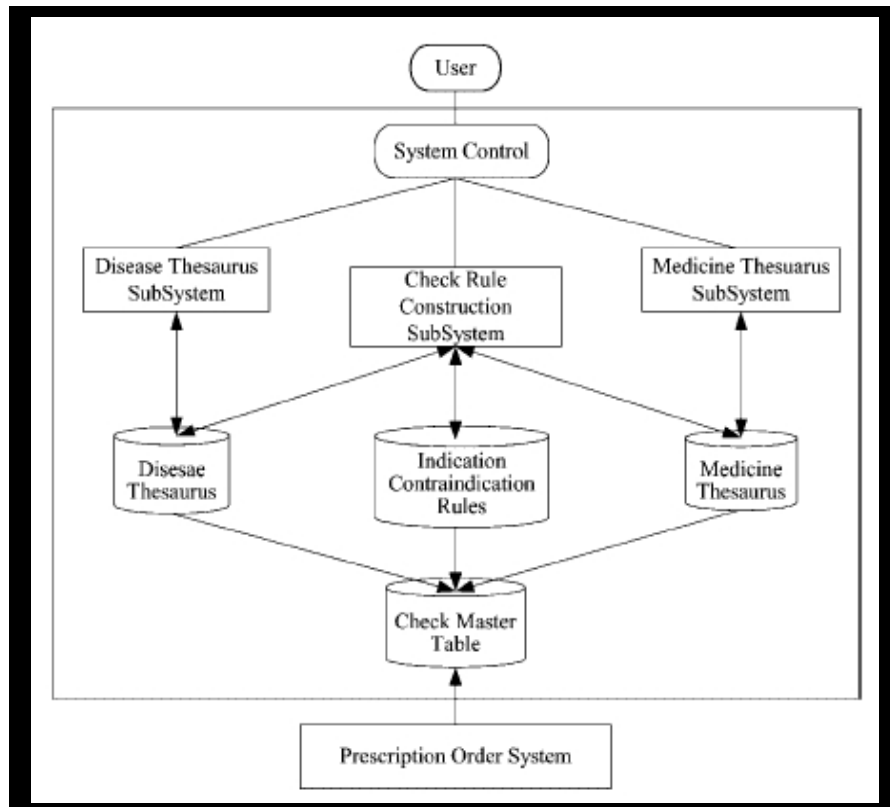
Složitostí systému je způsob, jakým vytvořit onu bázi znalostí. V jedné nemocnici se používá zhruba 3 000 druhů léků a počet chorob se vyšplhá k číslu 10 000. Každý lék má účinný efekt na některé nemoci, vůči jiným je efekt zcela opačný (související s ohrožením na životě či přímo smrtí). Z těchto čísel je patrné, že kombinatorika je vskutku náročná, nehledě na fakt, že každý rok přichází na trh nespočet nových léků a jsou klasifikovány rovněž nové nemoci.

Lékaři disponují znalostmi slovního popisu, například: „Kalcium antagonist je účinný vůči angíně pectoris“ a „bronchiální astma je kontraindikací vůči β -blokátorům“. Tento slovní popis je lehce srozumitelný pro lidi, ale mnohem hůře chápatelný stroji. Proto je potřeba usilovat o automatický překlad informací založených na slovním vyjádření do podoby kódového označení chorob a léků. Zde je nezbytná pomoc mnoha specialistů kteří vytvoří tezaurus. Například systém UMLS (Unified Medical Language System) využívá sada tezaurů k vytvoření běžného lékařského jazyka. Autoři tohoto systému [Matsumura et al., 2004] umožnili tvorbu tezauru více lidmi současně najednou. Kontrolní tabulka

může být automaticky aktualizována z údajů dostupných v tezauru a bázi znalostí, jenž jsou neustále aktualizovány. Níže uvedený popis obecného systému je v praxi aplikován v oblasti nemocí oběhové soustavy.

Obecné schéma systému

- *Diagram* – Protože diagnostické termíny a léky, které jsou používány v lékařské praxi, nejsou statické povahy, je požadována spolupráce mnoha odborníků. Byl vytvořen tezaurus, který je dostupný přes WWW rozhraní, dále byl vytvořen systém pro tvorbu báze znalostí ve vazbě na vztah léky-nemoci a vzájemné indikaci-kontraindikaci. Báze znalostí byla automaticky konvertována do kontrolní tabulky, která je využívána v systému na předpis léků. Obrázek 44 znázorňuje schéma celého systému.

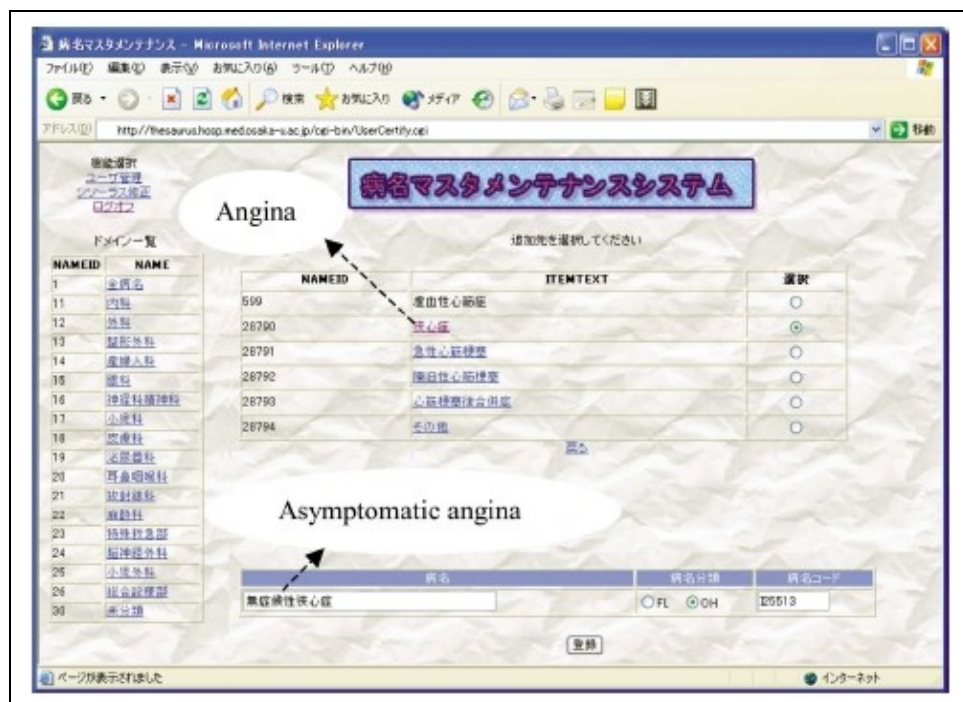


Obrázek 44: Architektura systému

- *Definování pravidel* – Struktura pravidel v systému je poměrně jednoduchá. Je tvořena klasifikací jmen nemocí a léků. Pro jednu klasifikaci léků může existovat několik klasifikací chorob. Rovněž lze vytvářet i subklasifikace léků. Uživatelé mají možnost editovat data v bázi znalostí.
- *Architektura systému* – Systém je tvořen šesti hlavními moduly: tezaurus nemocí, tezaurus léků, znalostní modul, báze znalostí, autorizační modul a databázový systém.

Fungování systému a obsluha programu

Po přihlášení uživatele do systému se objeví hlavní obrazovka programu. Uživatel tak může procházet tezaurem „rozklikáním“ vybraného uzlu ve stromové struktuře. Pro uložení nového záznamu je otevřeno nové okno pro vytvoření záznamu. Kód záznamu je automaticky vygenerován. Pro zadání jména léku či choroby, zadá uživatel požadovaný údaj do vyhledávacího okna. Obrázek 45 znázorňuje okno nového záznamu.

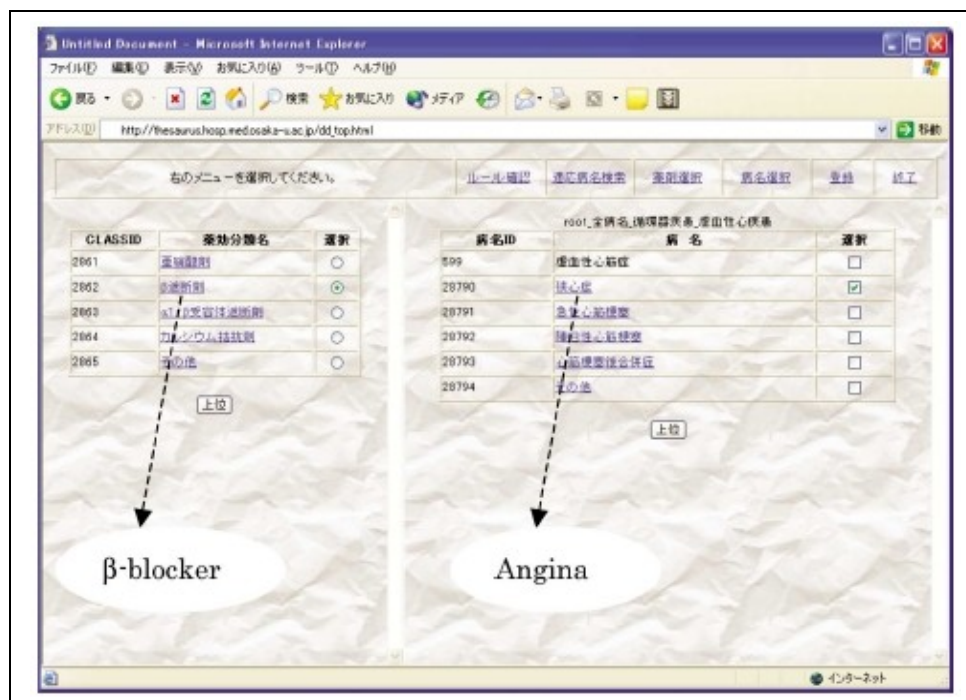


Obrázek 45: Editace nového záznamu

Pro zadání nového indikačního pravidla uživatel vybere z tezuru kód léku nebo kód nemoci. Oba typy kódů jsou vzájemně kombinovány a vytváří se tak indikační pravidla systému, což je vyjádřeno vztahem, kdy vybraný lék je účinný vůči vybrané nemoci. Stejným způsobem se registrují pravidla pro kontraindikace. Obrázek 46 ukazuje okno pro registraci nových indikačních pravidel.

Výsledky

Pro zhodnocení úspěšnosti fungování systému byl vytvořen tezaurus nemocí, tezaurus léků a báze znalostí - to vše s orientací na nemoci oběhového ústrojí. V první vrstvě tezuru nemocí bylo vytvořeno 22 klasifikačních skupin. Ve skupině nemocí oběhové soustavy bylo vytvořeno 7 klasifikačních skupin. Postupně bylo vytvořeno 49 klasifikačních skupin, které zahrnují 239 nemocí, které souvisí s oběhovou soustavou. Tabulka 14 ukazuje rozdělení do klasifikačních skupin.



Obrázek 46: Registrace nových indikačních pravidel

	Number of classification names	Number of disease names	Domain administrator
Disease of arteries	1	5	Dr Yamamoto
Abnormal blood pressure	3	10	Dr Yamamoto
Ischaemic heart disease	8	45	Dr Yamamoto
Arrhythmic	13	56	Dr Yamamoto
Heart failure	18	94	Dr Yamamoto
Abnormal object in heart	1	2	Dr Yamamoto
Cerebrovascular disease	5	32	Dr Teratani
Total	49	239	

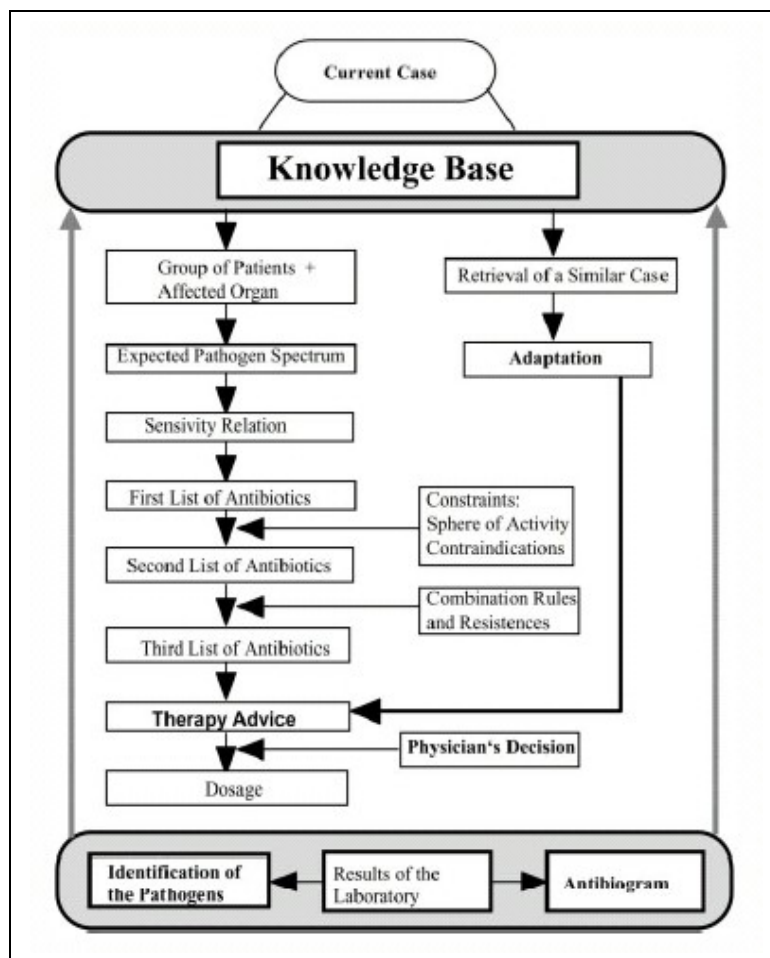
Tabulka 14: Klasifikace nemocí oběhové soustavy

1.8.3. ICONS - systém pro navržení optimální antibiotické léčby

Systém ICONS [Schmidt, 2001] je učen pro navržení optimální antibiotické léčby. Existuje celá řada bakteriálních infekcí, které komplikují léčbu a způsobují

úmrtí. Identifikace patogeneze bakterií je často náročným procesem. Obvykle je potřeba 24 hodin k identifikaci patogenu, který je zodpovědný za infekci a nejméně dalších 24 hodin spotřebuje proces výběru vhodných antibiotik k léčbě. Aby lékaři předešli k ohrožení pacienta na životě, musejí v některých případech zahájit antimikrobiální léčbu předtím, než je bakterie identifikována. Pro tyto případy, kdy je potřeba nasadit léčbu antibiotiky ještě dříve než je stanoveno patogenní spektrum bakterie, je nutné mít údaje o citlivosti, existujících kontraindikacích, a vedlejších účincích nasazovaných antibiotik.

Hlavním úkolem programu je navrhnout optimální léčbu antibiotiky pro pacienty, u kterých se vyskytla bakteriální infekce jako druhotná komplikace. Jelikož lékaři nemohou v mnoha případech čekat na výsledky laboratorních testů, využívá se ke stanovení patogenního spektra medicínských znalostí obsažených v systému ICONS. V praxi tak program prochází databází předchozích pacientů, vyhledá aplikovanou léčbu antibiotiky a po porovnání s aktuálním pacientem navrhne léčbu. Obrázek 47 zobrazuje funkčnost systému ICONS.



Obrázek 47: Přehled vazeb v systému ICONS

Projekt byl vyvinut pro jednotku intenzivní péče v Mnichově. V nedávné době byl projekt přizpůsoben a testován v nemocnici v Rostoku. Přenos programu do jiného nemocničního prostředí měl za následek mírnou modifikaci báze znalostí, současně řada informací byla modifikována s ohledem na místní prostředí.

Jelikož ICONS není diagnostický nástroj, tvůrci se nezabývali odvozováním diagnóz založených na symptomech a frekvenci výskytu, ale namísto toho usilovali o vytvoření strategie, která by se dala shrnout takto: najít všechna možná řešení a postupně tuto množinu snižovat s ohledem na kontraindikace vůči pacientovi. Jednotliví pacienti jsou rozděleni do skupin. Počáteční seznam antibiotik je dále redukován s ohledem na kontraindikace vůči pacientovi. Jestliže není nalezena žádná individuální léčba, dochází k použití kombinačních pravidel s cílem zkombinovat antibiotika. Před užitím musí být každá zvolená kombinace otestována.

V systému se vyskytují celkem 3 různé druhy přizpůsobení:

- *Přizpůsobení CBR s cílem získat navrhované postupy dávkování antibiotik* (Obrázek 48 [Schmidt, 2001] znázorňuje takový přístup). Každá kontraindikace omezuje použití navrhovaného léčebného postupu.
- *Přizpůsobení léčby s ohledem na laboratorní výsledky*. S ohledem na časovou náročnost laboratorních testů je cílem systému navržení dávkování antibiotiky před tím, než jsou výsledky testů známy. Během prvních 24 hodin je identifikován patogen, který je zodpovědný za způsobenou infekci. Za dalších 24 hodin je znám výsledek takzvaného antibiogramu, který hodnotí reakci na různá antibiotika.
- *Periodická aktualizace laboratorních informací*. Pro laboratorní výsledky byla založena zvláštní databáze, jenž je postavena na programu JAVA. Tato databáze antibiogramů (výsledky testů sensitivity jednotlivých antibiotik vůči patogenům) je měsíčně aktualizována. Obrázek 49 uvádí příklad výpisu z této databáze.

Restrictions Pathogen Spectrum Additional Therapies Own Creation		Price (DM/Day)	
ADVISABLE THERAPIES:			
LINCOSAMIDE	+ GYRASEINHEMMER :		
<input type="checkbox"/> CLINDAMYCIN	+ CI PROFLORACIN	92	to 201
PENICILLINE	+ AMINOGLYKOSIDE :		
<input type="checkbox"/> PIPERACILLIN	+ GENTAMICIN	48	to 111
<input type="checkbox"/> PIPERACILLIN	+ TOBRAMYCIN	65	to 141
<input type="checkbox"/> PIPERACILLIN	+ AMIKACIN	166	to 231
<input type="checkbox"/> AUGMENTAN	+ TOBRAMYCIN	66	to 121
<input type="checkbox"/> AUGMENTAN	+ AMIKACIN	168	to 201
<input type="checkbox"/> TAZOBAC	+ GENTAMICIN	11	to 15
<input type="checkbox"/> TAZOBAC	+ TOBRAMYCIN	28	to 42
<input type="checkbox"/> TAZOBAC	+ AMIKACIN	129	
<input type="checkbox"/> MEZLOCILLIN	+ TOBRAMYCIN	75	to 141
<input type="checkbox"/> MEZLOCILLIN	+ AMIKACIN	177	to 221

Obrázek 48: Návrh léčby antibiotiky v systému ICONS


Pseudomonas 04/96 - 03/97							
Antibiotics	Sensitive		Resistant		Not tested		
	percent	absolute	percent	absolute	percent	absolute	
Tobramycin	94,98	625	5,02	33	2,81	19	
Amikacin	91,22	613	8,78	59	0,74	5	
Ciprofloxacin	81,66	552	18,34	124	0,15	1	
Gentamicin	77,99	528	22,01	149	0,00	0	
Imipenem	71,20	482	28,80	195	0,00	0	
Ofloxacin	69,13	468	30,87	209	0,00	0	
Ceftazidim	68,89	465	31,11	210	0,30	2	

Obrázek 49: Výpis z antibiogramu

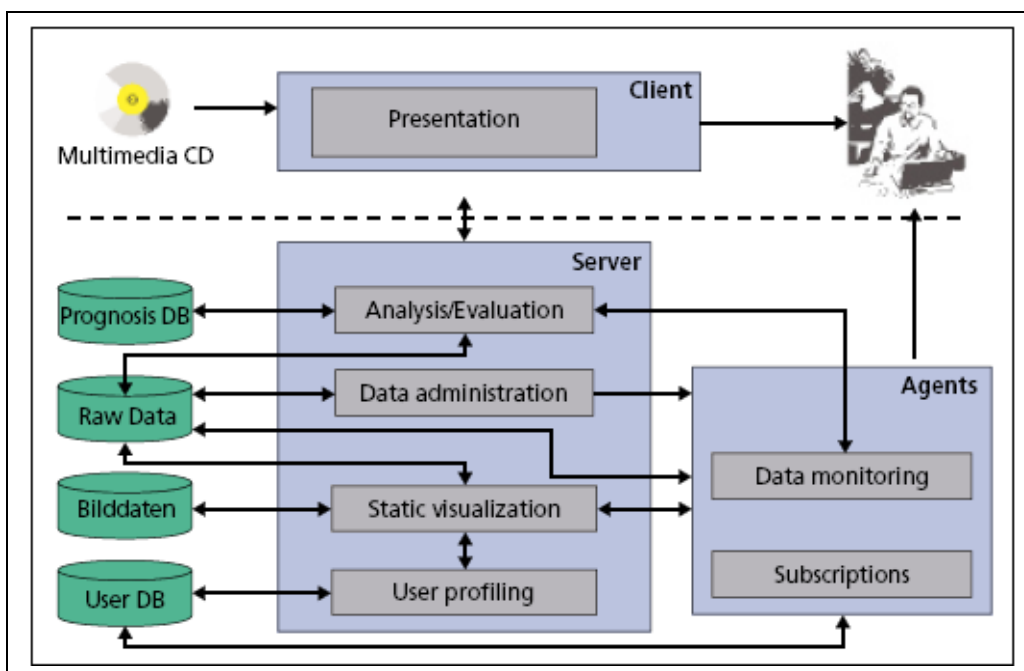
1.8.4. TeCoMED – systém pro plošné předvídání epidemií

Cílem systému TeCoMED (*Tele-Consultation to Monitor Emerging Diseases*) je předvídat plošné šíření epidemií, zejména pak chřipky a rovněž odhadovat náklady spojené s možným šířením epidemií – jak vysoké částky musí být z rozpočtu věnovány na případné utlumení epidemií [Schmidt, 2002]. Úkolem systému je poskytnout sebraná a vyhodnocená data zainteresovaným lékařům a dalším státním orgánům v německém státě Mecklenburg-Západní Pomořany.

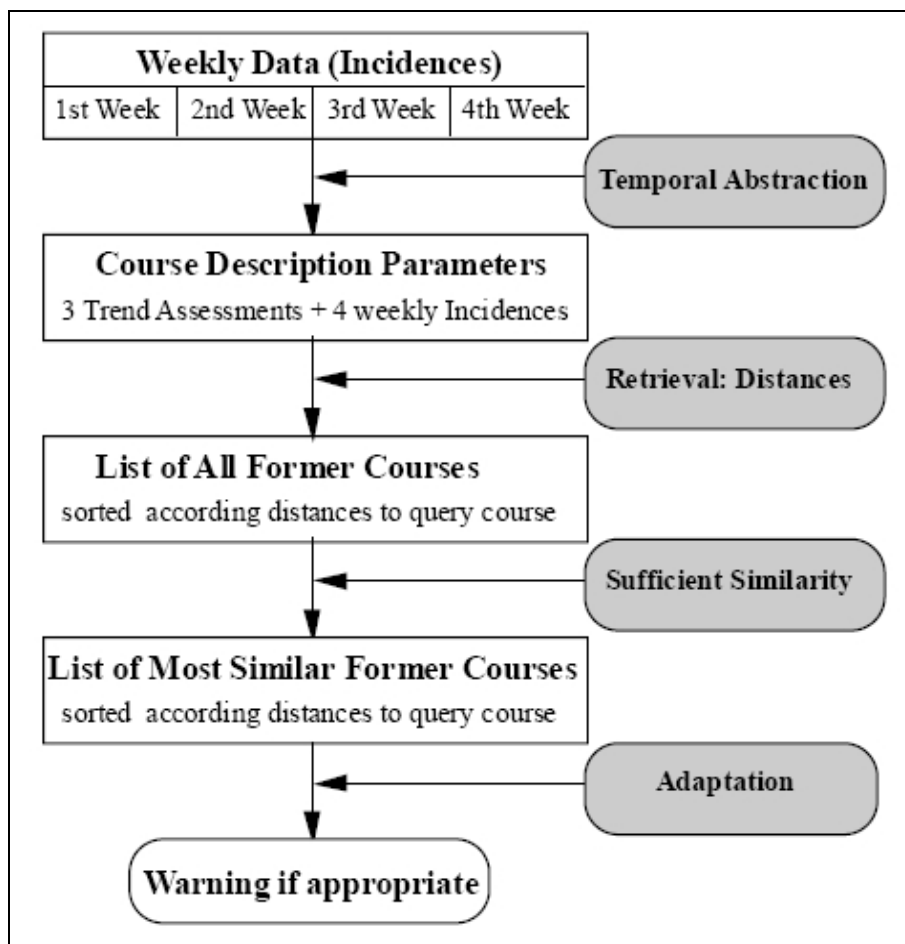
Mnoho lidí se domnívá, že chřipka je neškodné onemocnění, ale například jenom ve Spojených Státech Amerických chřipka každoročně zabije mezi 20-40 tisíci lidí. Je velice obtížné předpovědět vlny chřipkové epidemie, jedním z důvodů je cyklický vývoj, který není ovšem pravidelný. Právě díky nepravidelnému cyklickému chování není možné usuzovat budoucí predikci na základě dat z minulosti. Úkolem CBR systému je prohledat databázi dřívějších výskytů a porovnat tato data s aktuálním vývojem. Obecná zásada praví, že je možné předvídat trendy s 4 týdenním předstihem. Obrázek 50 ukazuje vývoj chřipkového onemocnění ve státě Meklenbursko-Západní Pomořany v období měsíců říjen-březen v letech 1997-2001. Obrázek 51 znázorňuje architekturu systému TeCoMed. Obrázek 52 [Schmidt, 2002] znázorňuje prognostický model systému TeCoMed.



Obrázek 50: Vývoj chřipkové epidemie v Meklenburgu v letech 1997-2001



Obrázek 51: architektura systému TeCoMed



Obrázek 52: Prognostický model systému TeCoMED

Autoři systému se rozhodli rozdělit určité specifické území Meklenburska na menší zcela samostatné územní jednotky. Tyto jednotky odpovídaly příslušným PSČ, protože ty mají vazbu na místní infrastrukturu a demografické uspořádání. V dalším kroku se ustanovila časová jednotka (v tomto případě 1 týden), za kterou se sleduje objem výdajů a úkonů spojených se zdravotní péčí. Na základě získávaných údajů je možné předpovídat budoucí vývoj nemocí a výdajů na ně v daných sledovaných oblastech. Každý výskyt epidemie je indexován dle chorob, místa vzplanutí případné epidemie a v neposlední řadě rovněž rozptylem epidemie.

Systém je tedy schopen usuzovat ze stávající situace do budoucnosti. Využívají se demografické informace, statistické modely pro šíření epidemií a definují se prahy hodnot úrovně epidemií. Nasbíraná data jsou uložena v CBR databázi a je možné je v geografické podobě reprezentovat. Systém zpětně vždy

za určité období porovnává skutečný stav s předpověďmi a dochází k doladování předpovědního mechanismu. Při příliš vysokém odlišení je potřeba v systému změnit inferenční mechanismus.

VI. ZÁVĚR

Cílem rigorózní práce bylo zpracovat přehled různých typů expertních/znalostních systémů v oblasti medicíny s důrazem na vývojové trendy a přiblížit možný budoucí vývoj uplatnění systémů s ohledem na vývoj v ICT.

Práce obsahuje obecnou teorii expertních systémů, následně je orientována na medicínu, přičemž obsahuje výčet konkrétních aplikací, které se v lékařství uplatňují.

První oddíl byl věnován teorii spojené s expertními systémy. Byly vymezeny základní pojmy, teoretické aspekty a možný budoucí vývoj.

Druhý oddíl se zabýval specifickými rysy expertních/znalostních systémů využívaných v lékařství. Uvedené systémy, kterým se věnuji, potvrzují rostoucí trend využívání expertních systémů v lékařské informace.

Třetí oddíl obsahoval konkrétní příklady úspěšných expertních systémů sestrojených pro oblast lékařství. Rovněž jsem se zabýval oblastí případového usuzování, což je specifická oblast znalostních systémů.

Čtvrtý oddíl byl věnován oblasti možného uplatnění ES/ZS v horizontu 5 let a to zejména s ohledem na vývoj ICT prostředků. V poslední kapitole jsem demonstroval ukázkou čtyř různých aplikací, na základě kterých lze demonstrovat úspěšnost nasazení expertních systémů v budoucnu.

Žijeme v informační společnosti, která je charakterizována podstatným využíváním digitálního zpracování, uchovávání a přenosu informace, přičemž ze zpracování informací se stává stále významnější ekonomická aktivita. Rovněž v dnešní době zažívá prudký rozvoj znalostní ekonomika, jejíž podstatou je, že majitel znalostí má informační výhodu před ostatními subjekty na trhu a může si tak zajistit dočasný monopol. Z výše uvedeného plyne i fakt, že expertní/znalostní systémy v dnešní době mohutného IT rozvoje zažívají renesanční období. Na trhu se vyskytuje stále větší množství sofistikovanějších systémů, které v oblasti medicíny mají pomáhat lékařům při léčbě pacientů. Rovněž vzniká stále více systémů v oblasti přípravy budoucích lékařů při výuce na fakultách.

V podmínkách českého zdravotnictví víceméně neexistuje přehled systémů z praxe a ani možný budoucí nástin uplatnění ES/ZS systémů. Práce přispívá skloubením teorie a praktického přístupu k poskytnutí uceleného přehledu o expertních/znalostních systémech na poli medicíny.

SEZNAM POUŽITÉ LITERATURY

- AAMODT, A.; PLAZA, E. Case-based reasoning: foundational issues, methodological variations, and system approaches. *AI Communications.*, 1994, vol. 7, s. 39-59.
- ADAMS, I.D.; CLIFFORD, P.C. Computer-aided diagnosis of abdominal pain: a multi-centre study. *Br. Medical Journal.* 1986, vol. 293, s. 800-804.
- AIKINS J. S. *An Expert System for Interpretation of Pulmonary Function Data. Computer. Biomedical. Research.* 16/1983, s. 199-208.
- ALEXANDRINI, F.;KRECHEL, D;MAXIMINI, K. Integrating CBR into the health care organization. *Computer-Based Medical Systems*, 2003, vol.26-27, s. 130-135.
- BALLARD, D. H.; BROWN, C. M. *Computer Vision.* New Jersey : Prentice Hall, 1982.
- BARCIA, R. M., SCHWARZ, A. B. *PSIQ – A CBR Approach to the Mental Health Area.* Dostupný z World Wide Web:<
<http://citeseer.ist.psu.edu/219040.html> >
- BENETT J. S.; ENGELMORE R. S.; SACON: A Knowledge-based Konsultant for Structural Analysis. *Proc. of IJCAI-79*, 1979, s. 47-49.
- BERGER J. *Informatika v klinické praxi pro lékaře a klinické biology.* Praha : Grada Publishing, 1993, 418 s.
- BERKA, P. *Tvorba znalostních systémů.* Praha : VŠE, 1995 , 190 s.
- BERKA, P. *Dobývání znalostí z databází.* Praha : Academia, 2003. 366 s. ISBN 80-200-1062-9.
- BOGEN R. *MACSYMA Reference Manual.* Technical Report, MIT LCS : Cambridge Mass, 1975.
- BRAUDE R.M. *Environmental and person factors in secondary career choice of graduates of medical informatics training programs.* Disertation. University of Nebraska, Lincoln Nebraska Inteligence, 1987.
- BUCHANAN B.; SHORTLIFFE E. H. *Rule-based Expert System: The MYCIN Experiments of the Stanford Heuristic Programming Project.* Addison-Wesley : Reading, Mass, 1984.
- BUCHANAN, B.G.; SHORTLIFFE, E.H. *Rule-Based Expert Sytems.* Addison-Wesley, 1984, 692 s.

BUCHANAN, B.G; BARSTOW, D.; BECHTAL, R. *Constructing an Expert System*. London : Addison-Wesley, 1983, s. 127-167.

CAWSEY, A. *The Essence of Artificial Intelligence*. Harlow (UK); New York : Prentice Hall, 1998. ix, 190 s. ISBN 0-13-571779-5.

COIERA, E. A. *Guide to Health Informatics*. London : Arnold, 2003. xxvii, 440 s.

COOPER J. B. Computer-based medical diagnosis using belief networks and bounded probabilities. *Selected Topics in Medical Artificial Intelligence*. New York : Springer Verlag, 1988, s. 85-98.

CUNDICK, R. Iliad as a Patient Case Simulator to Teach Medical Problem Solving. *Proceedings of the 13th Symposium on Computer Applications in Medical Care*. 1999.

DUDA R. O.; HART, P.E. *Development of the PROSPECTOR Consultation System for Mineral Exploration*. Artificial Intelligence Center, SRI International, 1978.

ERIKSSON H.; SHARAR Y. *Task Modeling with Reusable Problem-Solving Methods*. Knowledge Systems Laboratory, Stanford University School of Medicine, 1994.

ERMAN L. D. Functional Description of the HEARSAY II Speech Understanding System. *IEEE Conf. of Acoustic, Speech, and Signal Processing*, Hartford, Conn., 1977.

FEIGENBAUM E. A.; BUCHANAN B. G.; LEDERBERG J. On Generality and Problem Solving: A case study using the DENDRAL Program. *Machine Intelligence 6*, Edinburgh University Press, Edinburgh 1971, s. 165-190.

FEIGENBAUM E.A.; MCCORDUCK P.; NII P. *The Rise of the Expert Copany*. London : Times Book, 1988.

FEIGENBAUM, E.; MCCORDUCK, P. *The Rise of the Expert Company: How Visionary Companies are Using Artificial Intelligence to Achieve Higher Productivity and Profits*. New York : Random House, 1988.

FEIGENBAUM, E.A. *Themes and Case Studies of Knowledge Engineering*. In *Expert Systems in Microelectronic Age*. Edinburgh : Edinburgh University Press, 1979.

GIARRATANO, J.; RILEY, G. *Expert Systems. Principles and Programming*. PWS Publishing Co., 1993.

- GIERL, L.; BULL, M.; SCHMIDT, R. CBR in Medicine. *Lecture Notes in Computer Science*. 1998, vol. 1400, 273 s.
- GOLDSTEIN, I; PAPERT, S. Artificial Intelligence, Language and the Study of Knowledge. *Cognitive Science*, 1977, vol. 1, No.1.
- GRAY, M. *The Citizen 2013. International Congress of the European Federation for Medical Informatics (MIE-08)*. Goteborg, 2008. European Notes in Medical Informatics, vol. 4 No 1.
- HAYES-ROTH F.; WATERMAN, D.A. *Building Expert System*. Reading : Addison-Wesley, 1983.
- CHANG P.; LI, Y.; WU, Ch. Using ILIAD system shell to create an expert system for differential diagnosis of renal masses. *Journal of Medical Systems*. 1993, vol. 17, No. 5.
- JACKSON, P. *Introduction to Expert Systems*. Reading : Addison-Wesley. 1990.
- KABANZA F.; BISSON, G.; CHARNEAU, A.; JANG, T. Implementing tutoring strategie into a patient simulator for clinical reasoning learning. *Artificial Intelligence in Medicine*. 2006, vol. 38. 79-96 s.
- KARL BRANTING: Exploiting the complementarity of rules and precedents with reciprocity and fairness. *Proceedings from the Case-Based Reasoning Workshop 1991*, Washington DC, s. 39-50.
- KASAL, P.; SVAČINA, Š. *Lékařská informatika*, Praha : Karolinum, 1998, 543 s.
- KNILL-JONES J.R.; STERN R.B.; GIRMES D.H.; MAXWELL R.P.; THOMPSON P.H.; WILLIAMS R. Use of sequential Bayesian model in diagnosis of jaundice by computer. *British Medical Journal*. 1973, vol. 1, s. 530-553.
- KOLODNER, J. L.. Maintaining Organization in a Dynamic Long- Term Memory. *Cognitive Science* , 1983, vol. 7, s. 243–280.
- KOTEK, Z a kol. Metody rozpoznávání a umělá intelligence. *Kybernetika ve výzkumu a výuce*. Plzeň : ČSVTS FE VŠSE. 1983, s. 16-30.
- LEDLEY R.S.; LUSTED L.B. The use of electronic computers in medical data processing aids in diagnosis, current information retrieval and medical record, *IRE Trans. Med. Electron*. 1960, vol.7, s. 31-47.
- LEMAIRE, J.B.; SCHAEFER, P.; MARTIN, L.A.; FARIS, P. Effectiveness of the Quick Medical Reference as a diagnostic tool. *Canadian Medical Association Journal*, 1999, vol.21, s. 725-728.
- LUCAS, P; Gaag L. *Principles of Expert Systems*. Wokingham : Addison-Wesley, 1991.

MAŘÍK Vladimír; ŠTĚPÁNKOVÁ Olga; LAŽANSKÝ J. *Umělá inteligence (1)*. Praha : Academia, 1993.

MAŘÍK Vladimír; ŠTĚPÁNKOVÁ Olga; LAŽANSKÝ J. *Umělá inteligence (2)*. Praha : Academia, 1997.

MATSUMURA, Y.; KURATA, S.; NAKANO, H.; CHEN, Y.; TERATANI, T. Creation of a Master Table for Checking Indication and Contraindication of Medicine. From a Knowledge Base Linked With Thesaurus. *Journal of Medical Systems*, 2004, vol. 28, No. 6.

MILLER, R.A.; McNEIL, M.; CHALLINOR, S.M. The Internist/Quick Medical Reference Project. *The Western Journal of Medicine*, 1986, vol. 145, s. 816-822.

MILLER R. A.; POPLE, H. E.; MYERS, J. D. INTERNIST-1- An Experimental Computer-based Diagnostic Consultant for General Internal Medicine. New England, *Journal of Medicine*, 1984.

MINSKY, M. *Computation: Finite and Infinite Machines*. Prentice Hall, 1967.

MOLNÁR, L.; NÁVRAT, P. Programovanie v jazyku LISP. Bratislava : Alfa, vydavateľstvo technickej a ekonomickej literatúry, 1988, 264 s.

PAUKER S.G.; GORRY G.A.; KASSIRER J.P.; SHWARTZ W.B. Towards the simulation of clinical cognition: Taking a present illness by computer. *The American Journal of Medicine* 1976. vol. 60, s. 981-995.

POPPER, M.; KELEMEN, J. *Expertné systémy*. Bratislava : Alfa, vydavateľstvo technickej a ekonomickej literatúry, 1989, 360 s.

PROVAZNÍK, I.; KOZUMPLÍK, J. *Expertní systémy*. VUT v Brně. Fakulta elektrotechniky a informatiky. 1999.

RICH, E.; KNIGHT, K. *Artificial Intelligence*. New York : McGraw Hill. 1991.

SIMPSON R. L. *A computer model of case-based reasoning in problem solving: An investigation in the domain of dispute mediation*. 1985. Technical Report GIT-ICS-85/18, Georgia Institute of Technology.

ROSE, F. *Into the heart of the Mind*. New York : Happer & Row, 1984.

RUSSEL S.; NORWIG, P. *Artificial Intelligence: A Modern Approach*. New Jersey : Prentice Hall, 1995.

SEARLE, John R. Minds, Brains and Programs. *The Behavioral and Brain Science*. 1980, vol. 3, s. 417-457.

SCHANK, R. C. *Dynamic Memory: A Theory of Learning in Computers and People*. New York : Cambridge University Press, 1982.

- SCHMIDT R.; GIERL, L. Case-based reasoning for antibiotics therapy advice. *Artificial Intelligence in Medicine*. 2001, vol. 23, s. 171-186.
- SCHMIDT R.; GIERL, L. Case-Based Reasoning for Prognosis of Threatening Influenza Waves. *Advances in Data Mining, Lecture Notes in Computer Science*. 2002, vol. 2394, s.99-107.
- SILBERNAGL, S.; DESPOPOULOS, A. *Atlas fyziologie člověka*. Grada Avicenum, 1993, 268 s.
- SIMPSON, ROBERT L. *A computer model of case-based reasoning in problem solving: An investigation in the domain of dispute mediation*. 1985. Technical Report GIT-ICS-85/18, Georgia Institute of Technology.
- SKLENÁK, V. *Data, informace, znalosti a Internet*. Praha : C.H. Beck, 2001. 507 s. ISBN 80-7179-409-0.
- SWOBODA, W.; ZWIEBEL, F.M.; SPITZ, R. A case-based consultation system for postoperative management of liver-transplanted patients. *Imaging and computing in gastroenterology*, 1991, s 153-158.
- SWOBODA, W.; ZWIEBEL, F. M.; SPITZ, R.; GIERL, L. *A case-based consultation system for postoperative management of liver transplanted patients*. Medical Informatics Europe, Proceedings of the 12th International Congress of the European Federation for Medical Informatics , 1994, s. 191–195.
- SYCARA, K. *Using case-based reasoning for plan adaptation and repair*. Proceedings Case-Based Reasoning Workshop, DARPA. Clearwater Beach, Florida. Morgan Kaufmann, 1988, s. 425-434.
- TURING, A.M. Computing machinery and intelligence. *Mind*, 1950, vol. 59, No.236, s. 433-460. Dostupný z World Wide Web: <http://www.loebner.net/Prizef/TuringArticle.html>
- VAN DER LEI, J.; KWA, H. Y.; HASMAN, A.; WAAGE, M. Integrating Expert Systems with Applications. *Proceedings of Medical Informatics Europe* , 1985, s. 158–162.
- WARNER, H.R.; BOUHADDOU, O. Iliad – A medical diagnostic support program. *Top Health Inform Manager*, 1994, vol. 14, s. 51-58.
- WARNER, Homer R.; SORENSON Dean K.; BOUHADDOU O. *Knowledge Engineering in Health Informatics*. New York : Springer, 2003. 262 s. ISBN 0-38-794901-1.
- WATERMAN D. E. *A Guide to Expert Systems*. Reading : Addison-Wesley, 1986.
- WEISS M.C.; KULIKOWSKY C.A. Glaucoma consultation by computers. *Computers in Biology and Medicine*, 1978, vol. 1, s. 25-40.

WOLFRAM, D.A. An Appraisal of INTERNIST-I. *Artificial Intelligence in Medicine*, 1995, vol. 7, s. 93-116.

ZVÁROVÁ, J.a kol. *Lékařská informatika. Díl 4, Expertní a konzultační systémy v medicíně*, Praha : Karolinum, UK, 1992, 123 s.

VII. PŘÍLOHA

Tématicky zaměřená rešerše k rigorózní práci při využití databází v rámci licence pro Ferring International a internetu. Celkem jsem provedl vyhledávání ve čtyřech oblastech expertních systémů v oblasti medicíny a dotazy jsem definoval následovně:

1. SEARCH: (QMR OR QUICK ADJ MEDICAL ADJ REFERENCE) AND EXPERT ADJ SYSTEMS.DE.

Uveden výběr 13 záznamů z celkem 63 nalezených.

2. SEARCH: Iliad AND EXPERT ADJ SYSTEMS.DE.

Uveden výběr 17 záznamů z celkem 53 nalezených.

3. SEARCH: PSIQ and cased based reasoning

Uveden výběr 4 záznamů z celkem 4 nalezených.

4. SEARCH: Tecomed\$1 AND EXPERT ADJ SYSTEMS.DE.

Uveden výběr 5 záznamů z celkem 5 nalezených.

