




VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA INFORMAČNÍCH TECHNOLOGIÍ
ÚSTAV INFORMAČNÍCH SYSTÉMŮ

FACULTY OF INFORMATION TECHNOLOGY
DEPARTMENT OF INFORMATION SYSTEMS

ZÍSKÁVÁNÍ ZNALOSTÍ Z MULTIMEDIÁLNÍCH DATABÁZÍ

KNOWLEDGE DISCOVERY IN MULTIMEDIA DATABASES

SEMESTRÁLNÍ PRÁCE

SEMESTR PROJECT

AUTOR PRÁCE

AUTHOR

Bc. Petr Jurčák

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Petr Chmelař

BRNO

2008

Abstrakt

Tato práce se zabývá v dnešní době hodně rozšířenou a zajímavou částí, tedy Multimediálními databázemi a jejich dolováním. Získávání takových informací z databází, které nejsou přímo viditelné, ale které lze pomocí speciálních algoritmů z databází vydolovat.

Klíčová slova

Získávání znalostí z databází, dolování dat, multimediální databáze, klasifikace, predikce, shlukování, MPEG-7.

Abstrakt

Multimedia technologies and data mining are attracting more and more interest every day. Data mining is about obtaining some data from databases, where these data or information's are not directly visible, but they are accessible by using special algorithms.

Keywords

Knowledge Discovery in Multimedia Databases, Data Mining, Multimedia Database Technologies, classification, prediction, clustering, MPEG-7.

Citace

Jurčák Petr: Získávání znalostí z multimediálních databází. Brno, 2008, semestrální práce, FIT VUT v Brně.

Získávání znalostí z multimediálních databází

Prohlášení

Prohlašuji, že jsem tuto semestrální práci vypracoval samostatně pod vedením Ing. Petra Chmelaře.
Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

.....
Petr Jurčák
3. 1. 2008

Poděkování

Touto cestou bych rád poděkovat svému vedoucímu Ing. Petru Chmelaři za konzultace a připomínky k semestrálnímu projektu.

© Petr Jurčák, 2008.

Tato práce vznikla jako školní dílo na Vysokém učení technickém v Brně, Fakultě informačních technologií. Práce je chráněna autorským zákonem a její užití bez udělení oprávnění autorem je nezákonné, s výjimkou zákonem definovaných případů.

Obsah

Obsah	1
1 Úvod	2
1.1 Členění dokumentu	3
2 Historie	4
3 Typy databázových systémů	5
3.1 Relační databáze	5
3.1.1 Relace	5
3.1.2 Relační model dat	5
3.1.3 Jazyk SQL	6
3.2 Postrelační databáze	6
3.2.1 Objektové databáze	6
3.2.2 Objektově – relační databáze	8
3.2.3 Multimediální databáze	8
4 Multimediální databázové systémy	9
4.1 Multimediální databáze	9
4.2 SŘMMBD	10
4.3 MPEG-7	10
5 Extrakce rysů z obrazových dat	12
5.1 Extrakce rysů z obrázků	12
5.2 Tvar	12
5.3 Pohyb a umístění	13
6 Získávání znalostí z databází	14
6.1 Proces získávání znalostí z databází	15
7 Získávání znalostí z Multimédií	18
7.1 Klasifikace	18
7.2 Asociační pravidla	19
7.3 Shluková analýza	21
8 Závěr	22
Literatura	23

1 Úvod

Více, než jsme schopni si představit, je život nás všech provázán s databázemi. Jsou v nich naše peníze, naše studijní výsledky, geny DNA nebo také fotografie, video. Slouží k ukládání perzistentních dat a zpětném vyhledání podle obsahu. Vývoj databází si prošel mnoha stádií vývoje od původního pojetí databází jako kartotéky až po schopnost uchovávat v databázích složité strukturované i nestrukturované data. Dnes je jejich výskyt rozšířil do všech odvětví lidské činnosti.

Univerzální databázové systémy (database management systems – DBMS) v současné době představují nejrozšířenější prostředek pro uchovávání a manipulaci s daty komerčních aplikací. Zajišťují relativně jednoduchou správu rozsáhlých databází, integritu, efektivní vyhledávání a zpracovávání informací, odolnost proti poruchám a výpadkům a další výhody. Tohoto úspěchu bylo docíleno za cenu maximálního zjednodušení základního datového modelu a operací.

Nejběžnějším modelem používaným v dnešních databázových systémech je relační datový model. Hlavní výhodou tohoto modelu je jednoduchost a tím pádem i snadná standardizovatelnost a přenositelnost. V relačním modelu dat se struktura a vztahy dat uchovávají pouze jako množina tabulek. Tím dochází ke ztrátě přehlednosti, databáze se stává hůře spravovatelnou a budoucí změny v datovém modelu aplikace nutí programátory k citelným zásahům do jejich tabulkové reprezentace. Relační databáze jsou a i nadále zůstanou hlavním prostředkem pro správu dat komerčních aplikací, které jsou charakteristické velkým objemem údajů s jednoduchou strukturou. Řada aplikací, například z oblasti designu, multimédií, geografických systémů apod., však potřebuje takový datový model, který umožní lepší korespondenci mezi složitými reálnými daty a jejich reprezentací v databázovém systému. Tímto modelem je objektový model dat. Objektový model dat v databázových systémech vychází ze známých principů objektově orientovaného modelování a programování. Je však dále obohacen o techniky perzistence, reprezentace vztahu, dotazování, transakčního přístupu apod.

1.1 Členění dokumentu

Semestrální práce je rozdělena do následujících 8 kapitol, které na sebe tématicky navazují. První kapitola obsahuje obecný úvod do databází.

Druhá kapitola se zabývá stručným vývojem databází, které jsou rozděleny do jednotlivých etap. Vývoj začíná od počátků, kdy databáze v pravém slova smyslu jak je známe dnes, ještě neexistovala, ale pod jejich názvem se skrývaly spíše papírové kartotéky. Historie vývoje databází je zakončen dnešními postrelační databáze mezi něž patří i databáze multimediální.

Třetí kapitole je věnováno rozdělení databází do základních skupin složených z hierarchických, síťových, relačních a postrelačních databází. Po obecném rozdělení jsou v jednotlivých podkapitolách podrobně zmíněny dnes používané modely dat a to relační a postrelační. U relačního modelu dat je popsán princip, na kterém tato databáze pracuje. Vysvětlují základní prvky, jako jsou relace, relační algebra a popisuje relační jazyk SQL. U postrelačních je pozornost věnována objektovému modelu a jsou vysvětleny základní pojmy objektově orientovaného přístupu jako je objekt, třída, metoda, polymorfismus, dědičnost.

Čtvrtá kapitola pojednává o databázích multimediálních a systému řízení báze dat. Součástí kapitoly je i popis základních typů vyhledávání. Na závěr je popsán způsob popisu metadat pomocí MPEG-7, s jejichž pomocí lze vyhledávat požadované informace ve velkém množství multimediálních dat.

Pátá kapitola je věnována extrakci rysů z multimediálních dat zaměřené na obrazová data. S využitím popisu obsahu založený na primitivních vlastnostech multimédií, např. barvy, textury, tvaru, pohybu.

Kapitola šestá a sedmá pojednává o získávání znalostí z databází. Úvodem jsou popsány a vysvětleny jednotlivé kroky procesu získávání znalostí. Po té jsou popsány základní typu úloh patřící do této oblasti a jejich metod, která jsou na řešení úlohy vhodná. Hlavními částmi jsou asociační analýza, získávání asociačních pravidel z dat, klasifikační a shluková analýza.

Závěr práce je věnován celkovému zhodnocení a je popsáno, kam se bude práce ubírat, jejíž pokračování bude v rámci diplomové práce. Základním požadavkem bude zaměření se na konkrétní problémy při zjišťování rysů z audiovizuálních dat za pomoci klasifikace a implementace na vhodném demonstračního příkladu využívající datovou sadu TRECVID.

2 Historie

Předchůdcem databází byly papírové kartotéky. Umožňovaly uspořádávání dat podle různých kritérií a zařídování nových položek. Veškeré operace s nimi prováděl přímo člověk. Správa takových kartoték byla v mnohém podobná správě dnešních databází. Velkým zájemcem o databáze byly a jsou státní úřady. Již v roce 1890 vytvořil Herman Hollerith první automat na bázi děrných štítků. V roce 1911 se jeho firma spojila s další firmou a vznikla firma International Business Machines. Dnes známá pod zkratkou IBM. Již v období první světové války úřady používaly systémy děrných štítků.

Lze říci, že databáze založené na počítačích neexistovaly dříve, než byly vytvořeny první systémy pro ovládání souborů a řízení báze dat v 60 letech [2]. Historie vývoje zpracování dat spadá do období 50. let, kdy se vše nacházelo v aplikaci jak algoritmy tak samotná data. Vytvořením systémů pro ovládání souborů v 60. letech umožnila oddělit data od programu. Data byla uchováována v jednotlivých souborech. O spolupráci mezi aplikací a daty sloužila již dříve zmiňovaná vrstva systém pro ovládání souborů. Výhodou tohoto způsobu bylo hromadné zpracování dat. Ovšem mezi základní nevýhody patřily redundance dat, nebezpečí nekonzistence, problémy s přístupem k datům, bezpečnosti dat a problémy integrity dat. Tyto problémy byly vyřešeny nástupem databázových technologií v 2. polovině 60. let využívající systém řízení báze dat. Jednalo se o programovou vrstvu řešící operace nad databází. Základním přínosem databázové technologie bylo dosažením jisté nezávislosti dat na uživatelských programech a naopak. Zrozením databázového systému vznikly modelovací techniky umožňující provádět abstraktní pohled nad data. Mezi základní úrovně abstrakce nad daty patří: fyzický, konceptuální a externí pohled. V 70 letech byl představen relační databázový systém skládající se z kolekcí tabulek. Později vznikl pro ukládání perzistentních dat jako objektů OSŘBD, který musí splňovat kritéria SŘBD a musí být OOP systémem. Jelikož jak relační databázový tak i objektový systém má své výhody tak i nevýhody spojením výhod obou systémů vznikl relačně-objektový databázový systém popisující objektově-relační rysy ve standartu SQL-1999. Na sblížení relačního a objektového přístupu měla začátkem 90. let multimediální data spolu s prostorovými. Ukládání perzistentních objektů požadovalo mnoho výrobních odvětví.

Vznik první multimediální databáze se datuje od konce 80. let, jejichž vývoj se výrazně urychlil v 90. letech.

3 Typy databázových systémů

Z hlediska způsobu ukládání dat a vazeb mezi nimi můžeme databáze do následujících základních skupin hierarchická, síťová, relační a postrelační. Postrelační databáze vycházejí z relačního modelu dat a patří mezi ně objektově orientované, deduktivní, prostorové, časové, multimediální a spousta dalších vzniklých např. kombinací předchozích i všechny nově přichozí. V této práci se zmíním o posledních dvou modelech tedy relačním a postrelačním, které se dnes v praxi používají.

3.1 Relační databáze

Nejběžnějším modelem pro ukládání dat je databáze relační, která vznikla z dokumentu nazvaného „A Relation Model of Data for Large Shared Data Banks“ (Relační model data pro rozsáhlé sdílené banky dat) podle E.F. Codd v roce 1970. Codd definoval pro relační model 13 pravidel, o kterých se však díky jejich nešťastnému počtu hovoří jako o 12 pravidlech dr. Codd. Standard je popsán ANSI a ISO normou. Je to databázový systém, který je založen na relačním modelu dat a relační algebře.

3.1.1 Relační algebra

Relační algebrou je rozuměna dvojice $RA = (R, O)$ skládající se z množiny relací R a O množiny operací, které zahrnují tradiční množinové operace (sjednocení, průnik, rozdíl a součin) a speciální relační operace, mezi které patří projekce, selekce, spojení a dělení.

3.1.2 Relace

Pojem relace v relačních databázích se poněkud liší od pohledu matematické má zavedený pomocný aparát nazvaný schéma relace. Schéma relace definuje, jaký je název relace, kolik má sloupců a jaké jsou jejich názvy a domény. Domény určují přístupné hodnoty v daném sloupci. V databázích je schématem relace definice struktury tabulka. Ovšem relací není jen tabulka, ale cokoliv strukturovaného do řádku a sloupců, což znamená, že relací je i výsledek dotazu.

3.1.3 Relační model dat

Relační databázový model sdružuje jednotlivá data do tabulek (relací), které obsahují n -tice (řádky). Nad těmito daty jsou definovány přístupné operace. Tabulka (relace) tvoří základ relační databáze je

tvořen strukturou záznamů s pevně stanovenými položkami. Každý sloupe má definován jednoznačný název, typ a rozsah nebo-li doménu. Sloupce stejného typu mohou vytvářet vazby mezi jednotlivými tabulkami. Relační model klade velký důraz na zachování integrity dat. Zavádí pojmy referenční integrita, cizí klíč, primární klíč, normální tvar apod. Vztahy mezi řádky tabulek se vyjadřují pomocí cizích a kandidátních klíčů. V případě vzniklého vztahu M:M u entit, kterou není možné v relačním modelu dat uchovávat je řešením, zavedení nutné vazební tabulky.

3.1.4 Jazyk SQL

S relačními databázemi je úzce spojen pojem SQL (Structured Query Language), neboli strukturovaný dotazovací jazyk. Jeho základní model je obecně použitelný pro většinu relačních databází. Jazyk SQL byl vytvořen jakožto standard ANSI v roce 1986. Mezi nejznámější implementace jazyk SQL patří MySQL, Oracle, Microsoft Query. Poslední zmiňovaný dotazovací nástroj vyvíjený společností Microsoft používá pro komunikaci s databází rozhraní ODBC (Open Databases Connectivity). Toto rozhraní představuje funkční knihovnu sloužící jako společné aplikační programové rozhraní (API, Application Programming Interface) pro zdrojové databázové systémy. Jedinečnou vlastností rozhraní ODBC je to, že žádná z jeho funkcí není omezena pouze pro produkty jednoho výrobce.

3.2 Postrelační databáze

Navazují na relační model. Představují systémy, které si již nevystačí se základním relačním schématem a bez přímé podpory na implementační úrovni je zpracování „jiných“ dat velmi neefektivní. Mezi postrelační databáze patří systémy, které z uživatelského hlediska umožňují zpracovávat specializované údaje a podpora je nejen na aplikační úrovni.

3.2.1 Objektové databáze

Objektový model dat v databázových systémech vychází ze známých principů objektově orientovaného modelování a programování. Je dále obohacen o techniky perzistence, reprezentace vztahů, transakčních přístupů, apod. Objektově orientovaný model je založen na dekompozici informací z reálného světa na objekty.

3.2.1.1 Objekt

Pod pojmem objekt se rozumí každá strukturovaná i nestrukturovaná entita, která je jednoznačně a nezávisle identifikovatelná v rámci určitého okolního světa.

Objekt tak má jednoznačnou identitu. Každé dva i jinak datově shodné objekty jsou vzájemně odlišné. Identita objektu je určena identifikátorem tzv. OID (object identifier), který je generován systémem.

Základními vlastnostmi OID jsou: unikátnost, neměnnost po dobu existence objektu a určité zapouzdření pro koncového uživatele a programátora.

3.2.1.2 Třída

Objekt je vytvořená konkrétní instancí třídy. Třída je abstraktní popis objektu obsahující data a metody, které vykonávají nějakou činnost nad vnitřní pamětí objektu. Dále rozlišujeme rozhraní třídy (popis atributů a operací) od implementace (kódu popisující činnost operací).

3.2.1.3 Metody

Každý objekt má alespoň jeden konstruktor, jehož pomocí mohou být inicializována data v rámci objektu v okamžiku jeho vytváření. Podobně v okamžiku rušení objektu je volána metoda definována jak destruktorem a jeho cílem je provést úklid objektu před jeho rušením.

Součástí většiny tříd jsou metody umožňující získávání, editování hodnot atributů, metody provádějící výpočty a manipulace s atributy objektu, metody produkující uživatelský výstup atd.

3.2.1.4 Zapouzdření

Jak již bylo dříve řečeno, součástí třídy jsou i metody, které lze nad objektem provádět. Metody jsou okolnímu světu skryty a jsou přístupné pouze rozhraním metod. Jedná se o typickou vlastnost objektově orientovaného přístupu, která zvyšuje míru abstrakce a nezávislosti objektů.

Metody a atributy mohou mít veřejné nastavení jako public nebo soukromé nastavení private. U některých systému se zavádí ještě jedna úroveň tzv. protected (chráněná). Takto nastavené atributy a metody jsou viditelné v objektech dané třídy a v objektech z této třídy zděděné.

3.2.1.5 Dědičnost

Je další typickou vlastností objektového modelu. Myšlenkou dědičnosti je, že některé třídy mohou být zobecněním jedné či více jiných tříd. Třída zděděná z jiné třídy, dědí všechny její atributy a metody. Dědičnost umožňuje obecně rozšiřovat třídy o nové atributy a metody případně předefinovat zděděné metody.

Dědičnost existuje ve formě *jednoduché* a *vícenásobné*. Při jednoduché dědičnosti je umožněno třídě dědit pouze z jedné nadtřídy. Ve druhém případě vícenásobná dědičnost umožňuje třídě dědit vlastnosti a metody od většího počtu tříd.

3.2.1.6 Polymorfismus

Polymorfními operacemi rozumíme takové operace, které lze provádět nad objekty různých tříd. Přitom činnost operace se může lišit podle třídy objektu, nad kterým je prováděna. S polymorfními operacemi souvisí pozdní vazba.

Pozdní vazbou se označuje způsob volání polymorfních operací, kdy aplikace při volání operace dynamicky za chodu programu zvolí kód metody na základě třídy objektu, nad kterým je metoda volána. V objektově orientovaných jazycích se polymorfismus metod omezuje na třídy, které jsou ve vztahu generalizace/specializace.

3.2.2 Objektově – relační databáze

Cílem objektově relační databáze je spojit výhody relačního a objektového modelu. Snahou bylo tedy obohacení tabulek o objektovou orientaci. Z hlediska datové struktury jde o obecnější relace tzv. vnořené. Samotná perzistentní data jsou uchovány stále v tabulkách, ale data mohou mít obecně bohatší strukturu definovanou jako ADT. Abstraktní datový typ zapouzdřuje data a operace. Na vytváření nových typů vazeb mezi tabulkami je zavedena obdoba OID, který je použit k jednoznačné identifikaci objektu v objektovém modelu dat.

3.2.3 Multimediální databáze

Tématu zaměřené na multimediální databáze je věnována celá následující kapitula.

4 Multimediální databázové systémy

S rostoucí výkonností a paměťové kapacity počítačů roste i trend po multimediálních aplikacích. Prudký rozvoj v oblasti multimediálních databázových systémů nastává od poloviny 90. let. Tyto systémy slouží pro převod formátu ve formě obrazu, zvuku, videa do digitalizované podoby. Pro uchování perzistentních multimediálních dat je potřeba zavést odpovídající nové typy dat a operace pracující nad novými datovými typy.

4.1 Multimediální databáze

Multimediálními daty zpravidla rozumíme nestrukturovaná data, která podle způsobu vnímání dělíme na vizuální (textové a smíšené dokumenty, statické obrázky, video) a audio data. Samotná multimediální databáze musí zajišťovat fyzické uložení, dotazování, indexaci, extrakci obsahu a prezentaci dat.

Na první pohled nám multimediální databáze slouží jako dobrý pomocník pro uchovávání multimediálních dat. Ovšem jedním z hlavních problémů multimediálních dat je samotné vyhledávání.

Vyhledání hodnoty atributu v relačních databázích je jednoduše představitelné a realizovatelné, než nalezení požadovaného objektu na obrázku, akci na videu, melodii nebo slova ve zvukových datech. Vyhledávání v multimediálních datech se děje za pomoci metadat. Metadata jsou data o datech, jejich popis.

Na základě způsobu popisu rozlišujeme dva základní typy vyhledávání: [2]

- Vyhledávání na základě **textového popisu**: metoda postavená na vyhledávání slovního popisu obsahu obrazu tedy sémantiky dat, který byl uživatelem přidán při jejich tvorbě. Mezi hlavní nevýhody patří pracnost tvorby takového popisu a v neposlední řadě vliv subjektivního pohledu tvůrce popisu.
- Vyhledávání podle **podobnosti**: dotaz má typicky podobu vzorového obrazu nebo náčrtku a z databáze jsou vybírány obrázky, které jsou mu nejvíce podobné. Jsou porovnávány hodnoty vlastností, které se odvozují z obrazu dotazu i obrazů v databázi automaticky. Obecně neexistuje použitelná metoda, která by odvodila reprezentaci vyjadřující sémantiku obrazu, pracuje se pouze s vizuálními vlastnostmi. Mezi základní přístupy patří metrický a transformační. Metrický přístup je založený na metrice, kdy porovnání dvou obrazů se provádí vyhodnocením podobnostní funkce pro reprezentace těchto obrazů typicky vektorů rysů. Na druhou stranu transformační přístup vyjadřuje

podobnost dvou obrazů jako cenu transformace prvního obrazu na druhý nebo naopak. Podobnost je matematicky vyjádřena pomocí vzdálenostní funkce, která představuje vzdálenost vektorů rysů v n-rozměrném prostoru. Podmínkou vzdálenostní funkce pro libovolné tři reprezentace obrazů je splnění omezení metriky a to symetrie, nezápornost a trojúhelníková nerovnost.

4.2 SŘMMBD

Systém řízení multimediální báze dat (SŘMMBD) je prostředí nebo také programová vrstva spravující různé typy dat odpovídající různým mediím potenciálně reprezentované v různých formátech.

Systém řízení multimediální báze dat by měl poskytovat tyto možnosti v závislosti na úspěchu činnosti:

- Jednotný způsob dotazování nad daty různých typů, v různých formátech a z různých datových zdrojů a typů médií.
- Získání a spojitá prezentace mediálních objektů z paměťových zařízení.
- Definování struktury a požadovaný obsah výsledku dotazu uživateli, kdy výsledkem dotazu je opět multimediální objekt.
- Klientovi, který zadal dotaz doručení korektní výsledků způsobem, který zajišťuje dostatečně kvalitní prezentaci.

4.3 MPEG-7

Založen skupinou MPEG (Motion Picture Expert Group) tedy skupina expertů zabývající se pohyblivými obrázky. Konsorcium MPEG mimo jiné stojí za úspěšnými standardy MPEG-1 (1992), MPEG-2 (1994), a MPEG-4 (1998 a 1999) [6]. Standardy kódování videa MPEG-1 a MPEG-2 jsou základem celého segmentu produktů a technologií, jako Video CD, MP3, DVD, digitální televize DVB aj. MPEG-4 je první standard pro reprezentaci multimédií, umožňující interaktivitu a kombinaci přirozeného a syntetického obrazu ve formě objektů (jeho základem je model audiovizuálních dat jako kompozice těchto objektů).

Standard MPEG-7 nebo-li „Multimedia Content Description Interface“ představuje rozhraní pro popis obsahu multimediálních dat, není formátem pro kódování audiovizuálních dat. V MPEG-7 tedy jde o textový popis nějakého videa, např. jaký je jeho název, autor a co se v něm děje. Textový v tomto případě znamená, že je lidsky i strojově čitelný. Je popsán normou ISO/IEC 15938.

Pro popis různých druhů médií poskytuje MPEG-7 množinu standardizovaných deskriptorů, které slouží k rychlému vyhledání informací ve velkém množství multimediálních dat. Popis neobsahuje žádné informace o fyzickém uložení dat. Vytváření popisu za pomoci deskriptorů v MPEG-7 lze u obrazových, textových, zvukových dat.

Norma definuje následující prvky:

- *Deskriptory (Description D)* – obsahují vlastnosti, rysy atributy multimediálního obsahu založených na katalogích (název, autor, popis), sémantice (informace o událostech jednotlivých objektů), syntaxi (barva obrazu, tón zvuku) a technologii (formát, velikost, vzorkovací frekvence)
- *Popisová schémata (Description schema DS)* – obsahují popis struktury a sémantiky mezi komponentami deskriptorů nebo popisovým schématem (typ média, původ, strukturální vlastnosti nebo libovolný text)
- *Jazyk pro definici deskriptorů (Description Definition Language DDL)* – definuje D, DS, DT, jejich sémantiku, syntax, možnosti změny a rozšíření založené na XML.
- *Systémové nástroje (Systems tools)* – podpora binární kódové reprezentace pro efektivní ukládání a přenos

Norma MPEG-7 se dělí do následujících částí [2]:

- *Systémová část* – zahrnuje potřebné nástroje pro přípravu popisů MPEG-7 pro efektivní přenos a uložení.
- *DDL* – specifikuje potřebný jazyk pro definici syntaxe MPEG-7 nástrojů a nových Description schema (DS), založeno na XML.
- *Vizuální* – představuje nástroje na popis vizuálních jevů.
- *Audio* – definuje nástroje pro popis zvukových jevů.
- *Multimedia Description Schéma* – zahrnuje nástroje pro popis obecných vlastností a multimediálních popisu.
- *Referenční software* – softwarová implementace důležitých částí standardu MPEG-7.
- *Testování shody* – průvodci a procedury pro testování shody implementací MPEG-7.
- *Původ a užití popisů* – materiál informující o extrakci a užití některých nástrojů pro popis.

5 Extrakce rysů z obrazových dat

Popis obsahu multimedií můžeme rozdělit na manuální a automatický. Při manuálním popisu jsou vytvářeny smysluplné, objektivní názvy a popisy objektů, hovoru, scén a podobně, případně ruční přiřazení média do jisté kategorie. U automatického popisu se vytváří vektor rysů (deskriptor) pomocí procesu známého jako extrakce rysů. Za rysy jsou považovány určité charakteristické vlastnosti obsahu média. Mezi rysy u pohyblivých obrázků můžeme zařadit např. pohyb objektu (člověk, vozidlo,...). U zvukových dat mohou mezi rysy patřit např. frekvenční vlastnosti, tón, hlas, rozpoznání řeči a podobné vlastnosti.

5.1 Extrakce rysů z obrázků

Rozdělení vizuálních rysů je na nízké úrovni popisu, střední úrovni a vysoké úrovni popisu. Nízkoúrovňové rysy obrazových dat patří mezi relativně jednoduché extrakce obrazových rysů. Do této kategorie spadají **barevné** vlastnosti obrázku, které vyjadřují pomocí histogramu dominantnost barev. Dalším nízkoúrovňovým popisem je textura.

Textura je vizuální vzor tvořený opakujícími se primitivy, která mohou být charakterizována např. barevnými vlastnostmi, tvarem a velikostí, nebo hmatový charakter, jako hrubost, drsnost. Obecně textura nese informace o struktuře nějakého povrchu. Jedním z nejefektivnějších způsobů popisu texturních informací je extrakce rysů z frekvenčních oblastí, získané např. DCT nebo FFT, protože odpovídají lidskému chápání.

5.2 Tvar

Objekty vnímané člověkem se odlišují od způsobu jejich rozpoznání počítačem. Mohou mít různou velikost, orientaci nebo barvu a přitom mají stejný význam. Objekty v obrázku jsou složeny z jednoho nebo více regionů, k tomu počítáme i díry či další přerušování oblastí. Oblasti je možné popsat jako plochu, nebo její hranici:

- U popisu oblasti plochou bývá tato oblast reprezentována nějakou bitmapou, ve které hodnoty, jasu jsou 1, značí příslušnost do odpovídající oblasti, zatímco 0 k bílému pozadí.
- Na druhé straně hraniční reprezentace je náročnější, ale jeho výhodou je lepší vnímání, které se nejvíce přibližuje k lidskému vnímání a je lépe odolná k afinním transformacím. Kdy je možné měnit tvar objektu ve videu např. běh fotbalového hráče.

5.3 Pohyb a umístění

Pohybem je myšlena změna umístění objektu v rámci snímku následujících i další transformace objektu, jako jeho přiblížení, otočení, zmenšení a v neposlední řadě i pohyb kamery.

Obecným typem pohybu objektů na ploše je perspektivní transformace, která je běžně využívána při fotbalových přenosech.

Nejjednodušším typem pohybu tuhého objektu je pohyb v rovině, kdy je připuštěna pouze translace a někdy i rotace objektu. Těleso příliš nemění tvar, vzhled ani velikost. Takovéto typy těles je možné nalézt pomocí metody estimace (odhad) pohybu. Jednodušší metody zjišťují změny po sobě jdoucích snímcích tím, že odečtou hodnoty jejich pixelů. Pracují buď po blocích, nebo ohraničí celou oblast a snaží se v blízkém okolí najít její nový výskyt, tím je vytvořen jednoduchý vektor pohybu.

Když odečteme vektor pohybu a ohraničíme dále se pohybující oblasti, jsme schopni identifikovat pohybující se objekty a tedy určit jejich tvar. Takovéto vizuální těleso je možné obalit konvexní obálkou a zaznamenat jeho souřadnice do databáze. Pokud je doplněno časové razítko (číslo rámce), získáme časoprostorový lokátor objektu.

6 Získávání znalostí z databází

Na konci 80. let a zejména v 90. letech minulého století výrazně vzrostly schopnosti generovat, sbírat a ukládat různá data. V oblastech vědy, obchodu a výroby a státní správy začal projevovat rostoucí problém přesycení přílišným množstvím informací. Díky dostupnosti obrovského množství uložených dat v elektronické podobě se dostala do popředí potřeba přeměny dat na užitečné informace a znalost, využitelných v řadě aplikací včetně analýzy trhu, podpory řízení, správy a rozhodování. Jedním z možností jak řešit uvedený problém se snažily informační technologie za pomoci vytváření datových skladů a aplikací různých dotazovacích a analytických nástrojů OLAP, schopných prezentovat různé agregované údaje v co nejnázornější podobě. Nástroje OLAP jsou určeny pro interakční datovou analýzu. Výsledkem snažení o poskytnutí nástrojů, metod a technik, které by výsledky analýzy dat určitým způsobem automatizovaly, byl vznik nového směru v oblasti počítačových věd nazvaný *Knowledge Discovery in Databases*.

Získávání znalostí z databází představují extrakci netriviálních, skrytých, dříve neznámých a potenciálně užitečných modelů dat a vzorů z velkých objemů dat. Tyto modely a vzory reprezentují znalosti získané z dat. Netriviální znamená, že se nejedná o jednoduchou informaci, kterou lze získat např. pomocí nějakého SQL dotazu nad databází, nýbrž je potřeba použít sofistikovanější postup.

Nejběžnější úlohy zabývající se získáváním znalostí z databází je např. analýza nákupního košíku. Cílem je nalezení častých vzorků tedy zboží, které nejčastěji zákazníci společně kupují. K tomu slouží asociační pravidla, která vyjadřují určitý závěr vyplývající z analýzy jednotlivých nákupů, např. že si zákazník koupí nový počítač a současně s ním i operační systém. Další velkou oblastí potenciálních aplikací získávání znalostí z databází jsou finanční analýzy a řízení rizik. Patří sem analýza predikce cash flow, analýza a predikce vývoje cen v čase, predikce rizika poskytnutí půjčky apod.

6.1 Proces získávání znalostí z databází

Proces získávání znalostí z databází se skládá z několika kroků, které se zpravidla v určitých iteracích opakují. Celkový pohled na schéma procesu viz Obrázek 1: Proces získávání znalostí z databází.

Proces se skládá z následujících kroků [4]:

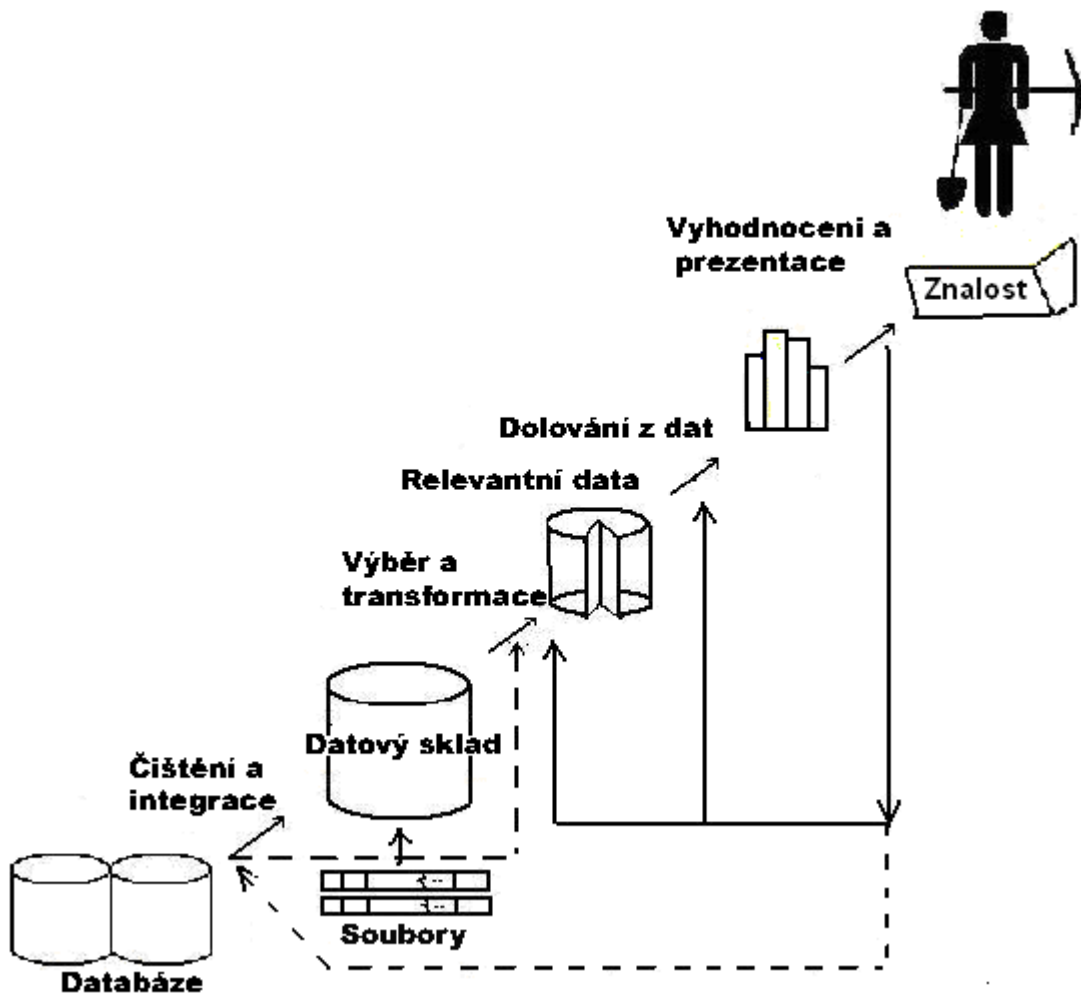
- 1. Čištění dat:** Převážná většina reálných databází, které jsou využívány k dolování, nejsou zpravidla ve stavu, kdy bychom jejich data mohli bezprostředně podrobit dolovacímu algoritmu. Cílem tohoto kroku je data předzpracovat, tedy doplnit scházející data, odstranit šum případně vyřešit nekonzistenci dat. Důvodem proč jsou data neúplná, může být celá řada. Mezi nejčastější případy patří nezadaná hodnota nebo hodnota byla nekonzistentní, a proto nebyla přidána. Zašumění dat je způsobeno atributy, které obsahují nesprávně případně odlehle hodnoty. A v poslední řadě nekonzistence dat vzniká např. i při integraci dat z více úložišť. Neочиštěním dat by vedlo k nepřesným nebo dokonce nesprávným závěrům vyplývajícím z vydolované znalosti. Proto je tento krok nedílnou součástí celého procesu získávání znalostí.
- 2. Integrace dat:** cílem je seskupit data pocházející z více datových zdrojů do jednoho koherentního zdroje. V převážné většině případů je tento krok společný s procesem čištění, jelikož vyčištěná data potřebujeme někam ukládat. Problém vznikající při integraci dat z více zdrojů je ve většině případů vzniklá nekonzistence, proto současně s tímto krokem probíhá i čištění dat. Mezi další problémy spojené s integrací dat patří konflikt schématu, hodnot a identifikace.
- 3. Výběr dat:** cílem je vybrat data, která jsou podstatná pro dosažení korektních výsledků. Jedná-li se o relační databázi, kde data jsou v tabulkách, výběr dat představuje výběr relevantních sloupců. V případě datových skladů výběrem jsou dimenze.
- 4. Transformace dat:** cílem je transformovat data do podoby vhodné pro dolování. Transformace dat může zahrnovat operace vyhlazení, agregace, generalizace, normalizace, konstrukce atributů. Operace vyhlazení odstraní šum z dat. V případě použití agregace jsou detailní hodnoty agregovány. Při generalizaci se zdrojová data nahrazují koncepty z konceptuální hierarchie. Normalizace provádíme proto, jelikož to vyžaduje dolovací algoritmus, a nebo nenormalizovaná data by nepříznivě ovlivnily výsledek. Samotná operace normalizace mapuje numerické hodnoty na specifický interval typicky $\langle -1.0, 1.0 \rangle$ nebo

<0.0, 1.0>. Poslední operací, kterou lze použít v procesu transformace dat je konstrukce atributů. Jejímž cílem je vytvoření nového atributu, které zkvalitní nebo usnadní dolování, jejichž hodnoty jsou odvozeny od atributů jiných. Ty se potom použijí pro dolování místo atributů původních.

- 5. Dolování dat:** zde probíhá samotný proces dolování. Základní typy dolovacích úloh můžeme rozdělit do dvou skupin. První skupinu tvoří úlohy deskriptivní, charakterizují obecné vlastnosti dolovaných dat. Základním typem úlohy je popis konceptu/třídy. U tohoto typu mohou být data asociována s určitým konceptem nebo třídou. Dalším typem dolovací úlohy jsou úlohy zaměřené na odhadování vztahů mezi atributy, patří sem dolování frekventovaných vzorů, korelací a asociací. Jak již název napovídá frekventované vzory, jsou vzory, které se často vyskytují v datech. Asociační pravidla jsou vytvářena z nalezených frekventovaných množin, tedy položek, které splňují podmínku minimální podpory. V případě generování silných asociačních pravidel z frekventovaných množin, musí tato pravidla splňovat podmínku minimální podpory a spolehlivosti. Duhou skupinu dolovacích úloh tvoří prediktivní, mezi něž patří klasifikace a predikce. Cílem klasifikace je nalézt takový model, který popisuje a současně rozlišuje data do tříd. Celý proces se skládá z trénování, kdy je vytvořen potřebný klasifikační model na základě analýzy trénovací množiny. Po té následuje testování dat, které určí, jak dobře jsou data klasifikována do daných tříd. V posledním kroku vytvořený klasifikační model klasifikuje neznámá data, u nichž není známá výsledná třída. V prvních dvou krocích je třída známa. Klasifikace se používá k predikci hodnot diskretních. Pro hodnoty spojitých atributů používáme predikci. V tomto případě předikujeme chybějící nebo nedostupnou numerickou hodnotu. Nejčastější metodou predikce je regresní analýza. Dalším typem úlohy je shluková analýza. Na rozdíl od klasifikace a predikce, které při vytváření klasifikačního modelu analyzují datové objekty, jejichž přiřazení do tříd je známé, shlukování analyzuje datové objekty bez znalosti přiřazení do tříd. Cílem shlukování je třídy objektů, které mají co nejvíce společného a naopak se od ostatních tříd co nejvíce liší nalézt.
- 6. Hodnocení modelů a vzorů:** cílem je identifikovat skutečně zajímavé vzory. Zajímavé vzory můžeme vymezit čtyřmi základními vlastnostmi, které je charakterizují. První nutnou vlastností je snadná srozumitelnost pro člověka. Následujícími vlastnosti jsou platnost, potenciální užitečnost a novost. Míry zajímavosti mohou být objektivní nebo subjektivní. Existuje několik veličin, které používáme pro objektivní posouzení zajímavosti. Jsou založeny na struktuře objevených vzorů a statistických údajů, které se k nim vztahují. Pro objektivní posouzení se používá veličina podpora a spolehlivost. Podpora udává četnost výskytu daného pravidla v databázi transakcí, kterou analyzujeme. Hodnoty jsou udávány jako relativní

v procentech nebo absolutní, tedy obsahují počet transakcí. Podpora tedy vyjadřuje pravděpodobnost $P(X \cup Y)$, kde $X \cup Y$ značí, že transakce obsahuje jak položky množin X a Y v transakcích společně. Neumožňuje určit zda-li neexistuje mnoho transakcí, které obsahují položky množiny X , ale neobsahují položky množiny Y . Proto se zavádí ještě jedna veličina nazvaná spolehlivost. Tato veličina ohodnocuje stupeň jistoty platnosti daného asociačního pravidla. Přestože objektivní míry zajímavosti identifikují zajímavé vzory, jsou nedostatečné, pokud se nekombinují se subjektivním posouzením daným uživatelem.

7. **Prezentace znalostí:** cílem je prezentace výsledků dolování využitím vizualizace a reprezentace znalostí uživateli.



Obrázek 1: Proces získávání znalostí z databází (převzato z [4])

7 Získávání znalostí z Multimédií

Proces získávání znalostí z multimediálních dat se skládá ze skupiny procesů, které na sebe navazují. Vstupem jsou běžná audiovizuální data (AV) a výstupem nové, zajímavé a užitečné informace. Získávání znalostí je interaktivní, což představuje vlastní výběr požadované znalostní podmínky uživatelem, při jejíž změně se proces získávání znalostí opakuje.

Pod pojmem dolování dat z multimediálních databází si můžeme představit souhrn metod založených na umělé inteligenci, která data klasifikují, shlukují, objevují zajímavé vlastnosti atd.

Nabízejí se dva přístupy k identifikaci multimediálních dat. Prvním přístupem je vyhledávání podle popisu dat. Druhým je vyhledávání podle obsahu, jak je zřejmé tak tento způsob je efektivnější. Pro tento typ lze použít i několik dolovacích metod jako je diskriminace a charakterizace, shlukování nebo asociační analýza.

7.1 Klasifikace

Klasifikace je proces vyhledávání různých vlastností dat a na základě těchto vlastností se provádí separace do tříd. Tedy každá třída má zpravidla jednu dominantní vlastnost, kterou se vyznačují všechny prvky uvnitř takovéto třídy.

Proces přiřazování prvků do tříd se nazývá algoritmem „učícím“, který je prováděn na vybrané trénovací množině dat, kde je již předem známá příslušnost prvků do jednotlivých tříd.

Klasifikace probíhá ve dvou fázích. V první fázi jak již bylo řečeno, jsou z databáze vybrány vzorky dat. U těchto dat je podmínkou znát jejich zařazení do tříd. Tyto vzorky dat jsou vstupem pro klasifikátor, jehož úkolem je vhodným způsobem zjistit tzv. klasifikační pravidla. Pomocí těchto pravidel lze s jistou přesností zařadit neznámý objekt do dané třídy. Ve druhé fázi probíhá testování daného klasifikátoru. I v tomto případě jsou vybrány vzorky dat z množiny nazvané testovací, u nichž je předem známa klasifikační třída. Tyto vzorky musí být nezávislé na předchozích datech, neměly by být vybrány z trénovací množiny. Data jsou již naučeným klasifikátorem zařazována do patřičných tříd, přičemž díky znalosti skutečné třídy, kam daný vzorek patří, se procentově určí, v kolika případech provedl klasifikátor správnou klasifikaci. Na základě získaných výsledků může být rozhodnuto, zda klasifikátor může být použit v budoucnu pro data, u nichž není známo, do jaké třídy patří.

Porovnání klasifikačních metod se provádí podle následujících kritérií: [citace]

- **Přesnost předpovědi** – vyjádřena v procentech úspěšnost klasifikování dat, která nebyla obsažena v trénovací množině.
- **Rychlost** – výpočetní složitost pro vytvoření a použití klasifikačních pravidel.
- **Robustnost** – vytvoření správného modelu i v případě, že jsou data zašuměna, případně hodnoty scházejí.
- **Stabilita** – vytvoření modelu i pro velké množství dat.
- **Interpreovatelnost** – složitost daného modelu pro pochopení.

Pro efektivní predikční a klasifikační analýzu je vhodné provést úpravy vstupních dat. Mezi základní úpravy patří:

- **Čištění dat** – odstranění šumu v datech a chybějících hodnot. Nahradit chybějící hodnoty lze např. hodnotami, které se nejčastěji vyskytují v databázi.
- **Významnostní analýza** – odstranění nepotřebných atributů např. unárních typů.
- **Transformace dat** – převod dat na jiný formát. Typicky se používá transformace dat ke zobecnění dat jistých spojitých hodnot do konkrétních intervalů. Speciálním typem transformace dat je normalizace. Je vhodná tam, kde se např. vyžadují vstupní hodnoty pouze v jistých intervalech.

Klasifikační model může mít různou podobu jako například klasifikačních IF-THEN pravidel, rozhodovací strom, matematické formule, Bayesovská klasifikace, SVM (Support Vector Machine) nebo neuronová síť.

7.2 Asociační pravidla

Cílem asociační analýzy je nalezení vztahů mezi analyzovanými daty. Vztahy mezi daty jsou vyjádřeny za pomoci asociačních pravidel, které určí závislosti hodnot atributů vyskytujících se společně. Mezi typické aplikace asociační analýzy patří analýza nákupního košíku.

Asociační pravidlo z hlediska matematického se zapisuje ve tvaru $A \Rightarrow B$ tímto zápisem slovně říkáme: „Obsahuje-li např. obrázek objekt A, pak obsahuje též objekt B“, kde A, B mohou obecně představovat množiny položek $I = \{i_1, i_2, i_3, \dots, i_k\}$. Říkáme, že transakce T obsahuje A i B, pokud $A \subset T, B \subset T$ a $A \cap B \neq \emptyset$

Pravidlo se zapisuje ve tvaru: $i_1 \wedge i_2 \wedge \dots \wedge i_k \Rightarrow i_{k+1} \wedge i_{k+2} \wedge \dots \wedge i_{k+l}$, kde číslo k+l označuje celkovou kardinalitu nebo-li mohutnost k asociačnímu pravidlu.

Asociační pravidla mohou být získána z libovolného typu multimediálních dat a jejich skladů. Existují zde vztahy mezi obsahem média, jako je barva, tvar, textura, tón nebo pohyb a jeho popisem. Lze získat i asociace obsahu dat s jejich lokalizací v prostoru a čase.

U asociačních pravidel se využívá podpora (support) S . Je definována jako procentní pravděpodobnost P , se kterou se v transakci D objeví současně položky A i B , tedy matematický zápis podpory je následující: $S(A \Rightarrow B) = P(A \cup B)$.

Další metrikou pravidla je spolehlivost (confidence) C , která určuje pravděpodobnost, s jakou se vyskytuje v transakcích D , které obsahují A , také B . S využitím pravděpodobnosti lze tedy napsat

$$C(A \Rightarrow B) = P(B | A) = \frac{S(A \Rightarrow B)}{S(A)}.$$

Tyto dva parametry vypovídají o četnosti výskytu pravidla v databázi (podpora) a o síle pravidla (spolehlivost). Pravidla, která splňují minimální mez podpory S_{\min} tvoří frekventované množiny, splňují-li i navíc minimální spolehlivost C_{\min} , taková pravidla jsou pak nazývána silná.

Proces získávání pravidel lze rozdělit do dvou částí:

- Prvním krokem je nalezení frekventovaných množin. Tedy ze všech vygenerovaných množin jsou vybrány jen ty položky, které splňují podmínku minimální podpory definované uživatelem.
- V druhém kroku z vytvořené frekventované množiny jsou vybrána jen pravidla, která jsou silná, tedy splňují podmínku minimální spolehlivosti a podpory jejichž hodnota je definována uživatelem. Můžeme prohlásit, že pravidlo $AB \Rightarrow CD$ platí, jestliže:

$$\frac{S(ABCD)}{S(AB)} = C(AB \Rightarrow CD) \geq C_{\min}, \text{ kde } S \text{ značí podporu a } C \text{ spolehlivost je silné}$$

asociační pravidlo.

7.3 Shluková analýza

Je podobná klasifikaci s tím rozdílem, že nejsou předem známy vlastnosti, podle kterých se prvky shlukují. Principem shlukové analýzy je nalezení maximálních podobných vlastností uvnitř shluku a vzájemné minimální podobnosti mezi jednotlivými shluky. Podobnost objektů se posuzuje na základě hodnot jednotlivých atributů objektů a často se využívá i tzv. vzdálenostní funkce.

Shluková analýza je využívána v nejrůznějších aplikacích, mezi které patří například rozpoznávání vzorů, datová analýza, zpracování obrazů nebo průzkum trhu. Jako nástroj pro získávání znalostí z databází umožňuje shluková analýza zjistit distribuci dat a nalezení charakteristik pro jednotlivé třídy. Při shlukování je možné se zaměřit jen na určité třídy a ty dále analyzovat. Shluková analýza je v některých případech používána k předzpracování dat pro další algoritmy, jako jsou algoritmy pro klasifikaci a charakterizaci. Ve shlukové analýze jsou využívány poznatky z mnoha vědních oborů, především ze statistiky, z oblastí technologie databází a získávání dat, ze strojového učení a z biologie. Z pohledu strojového učení představuje shlukování způsob učení bez učitele. Tedy shluková analýza nevyžaduje žádnou trénovací množinu, jak je tomu u klasifikace.

Konceptuální shlukování patří mezi speciální případy shlukování, při němž je hledána třída objektů, které odpovídají předem definovanému konceptu. Tento typ shlukování objekty shluků představují třídu pouze tehdy, pokud odpovídají nějaké třídě konceptu.

Z pohledu využití shlukování pro získávání znalostí z databází nás zajímají metody, které jsou schopné účinně a efektivně zpracovávat rozsáhlé databáze. Na shlukové metody jsou kladeny následující požadavky:

- **Škálovatelnost** – jelikož mnoho shlukovacích algoritmů pracuje dobře na malém objemu dat, ale při získávání znalostí je obvykle potřeba zpracovávat rozsáhlejší databáze. Celá databáze je nahrazena pouze vzorkem objektů, ovšem jejich následná analýza může vést ke zkreslení výsledků, proto je potřeba použít vysoce škálovatelné algoritmy.
- **Schopnost zpracovávat různé typy atributů** – v praxi aplikace vyžadují schopnost shlukování různých typů dat, ne jen numerických, ale také např. binárních, ordinálních typů.
- **Vytváření shluků různého tvaru** – podpora pro vytváření nejen tříd na základě Euklidovské, Manhattanovské vzdálenostní funkce, ale také shluky, které lépe odpovídají hledaným třídám dat.
- **Minimální požadavky na znalost problému při určování parametrů** – mnoho shlukovacích metod vyžaduje jako vstupní parametr počet shluků. Ovšem tato hodnota má vliv na výslednou kvalitu nalezených shluků. V praxi je hodně obtížné najít vhodnou hodnotu vstupního parametru.

- **Schopnost vyrovnat se s daty obsahujícími šum** – většina databází obsahuje určité procento záznamů, které obsahují chybná, neznámá nebo chybějící data. Kvůli takovýmto záznamům může být snížena kvalita shluků.
- **Necitlivost na pořadí vstupních záznamů** – u některých algoritmů pro stejná vstupní data dostáváme různé shluky, jestliže jsou záznamy zpracované databází jinak uspořádány. Proto jsou žádané jen takové algoritmy, které nejsou citlivé na pořadí záznamů v databázi.
- **Schopnost shlukování na základě omezování** – cílem je nalézt třídy dat, které splňují požadované omezení.
- **Interpretovatelné a použitelné shluky** – výsledkem shlukové analýzy musí být interpretovatelné, srozumitelné a použitelné shluky. Součástí shlukování musí být i modul zabezpečující srozumitelnou reprezentaci dosažených výsledků.

Provádíme-li shlukování nad množinou dat, která obsahuje n objektů a každý objekt může být popsán p atributy. Nejčastější shlukovací algoritmy používají jednu ze dvou datových struktur. První je datová matice. Tato matice je reprezentována n objekty pomocí p proměnných. Výsledná struktura má podobu relační tabulky, nebo-li matice $n \times p$. Druhou strukturou je podobnostní matice. Tato struktura obsahuje vzdálenosti pro všechny dvojice objektů.

8 Závěr

Výsledná práce semestrálního projektu pojednává pouze teoreticky o databázích jako celku se zaměřením na multimediální data a získávání znalostí z nich.

Práce se rozšíří v rámci diplomové práce o praktické zkušenosti získávání rysů z audiovizuálních dat a jejich klasifikování. Výsledná práce bude demonstrovat dříve zmíněné metody na datové sadě TRECVID, kdy úložištěm metadat bude sloužit buď XML dokument anebo případně databáze Oracle s možností real-time proudů audia a videa použitím Helix platformy. Aby bylo možné ukládat metadata je potřeba je nejprve vytvořit. K tomu bude sloužit nástroj MPEG-7 XM pro převod audiovizuálních dat do MPEG-7.

Literatura

- [1] KOSCH, Harald. Distributed Multimedia Database Technologies Supported by MPEG-7 and MPEG-21. CRC Press, 2003
- [2] CHMELAŘ, Petr. Multimediální databáze. 2006
- [3] Diane, J., Cook, Lawrence, B., Holder. MINING GRAPH DATA. Wiley, 2007
- [4] Zendulka, J. a kol. Získávání znalostí z databází. Brno, 2006. 160 s. Studijní opora.
- [5] KOLÁŘ, D. Postrelační databáze, Přednášky [online]. 2000-2002.
URL: <https://www.fit.vutbr.cz/study/courses/PRD/private/>.
- [6] ISO/IEC JTC1/SC29/WG11. MPEG-7 Overview [online]. Martínez, José M. Palma de Mallorca : 2004.
URL: <http://www.chiariglione.org/mpeg/standards/mpeg-7/mpeg-7.htm>.
- [7] X. Zhu, A. E. X. Wu, A. Feng, and L. Wu. Video data mining: Semantic indexing and event detection from the association perspective. IEEE Transactions on Knowledge and Data Engineering vol. 17, no. 5, 2005, pp. 665-677.