

**PENGINTEGRASIAN DATA EXTENSIBLE MARKUP LANGUAGE (XML)
KE DALAM PANGKALAN DATA HUBUNGAN MENGGUNAKAN COMMON
WAREHOUSE METAMODEL (CWM)**

WAN MOHD HAFFIZ BIN MOHD NASIR

Tesis ini dikemukakan
sebagai memenuhi syarat penganugerahan
ijazah Sarjana Sains (Sains Komputer)

Fakulti Sains Komputer dan Sistem Maklumat
Universiti Teknologi Malaysia

SEPTEMBER 2007

ABSTRAK

Permintaan kepada pengintegrasian data secara pantas menjadi semakin tinggi dengan semakin banyak sumber-sumber maklumat yang terdapat di dalam perusahaan moden. *Extensible Mark-up Language* (XML) telah menjadi satu piawaian baru bagi perwakilan dan pertukaran data dalam *World Wide Web* (WWW), contohnya di dalam aplikasi *Business to Business* (B2B) pada e-dagang. Ini memerlukan alatan analisis data untuk mengendalikan data XML di samping format data tradisional. Tujuan penyelidikan ini adalah bagi meningkatkan kaedah pengintegrasian data XML ke dalam data hubungan berikutan berlakunya beberapa masalah daripada hasil proses pengintegrasian seperti kehilangan data. Kaedah yang dicadangkan daripada penyelidikan ini adalah melalui pengaplikasian *Common Warehouse Metamodel* (CWM) sebagai piawaian bagi pertukaran dan pengurusan metadata yang menggabungkan satu perkongsian metamodel bagi sintak dan semantik metadata. Hasil daripada penyelidikan ini adalah satu cadangan peningkatan senibina dan pendekatan pengintegrasian melalui pengaplikasian CWM serta satu perisian antaramuka yang telah dibangunkan bagi memudahkan proses pengintegrasian sebagai penyelesaian kepada masalah kehilangan data.

ABSTRACT

The demand for rapid data integration is getting higher as more and more information sources appear in modern enterprises. Extensible Mark-up Language (XML) is fast becoming the new standard for data representation and exchange on the World Wide Web, e.g., in B2B e-commerce, making it necessary for data analysis tools to handle XML data as well as traditional data formats. The purpose of this research is to enhance the technique for XML data integration into relational data to solve integration problems such as missing data. The method that had been proposed is to apply Common Warehouse Metamodel (CWM) for metadata interchange and metadata management that incorporates a common shared metamodel for metadata syntax and semantics. The results of this research are the enhancement of the integration architecture and approach by applying CWM as well as the development of an interface software to simplify the integration process as a solution for the missing data problem.

KANDUNGAN

BAB	PERKARA	MUKA SURAT
	PENGESAHAN STATUS TESIS	
	PENGESAHAN PENYELIA	
	JUDUL	i
	PENGAKUAN PENULIS	ii
	DEDIKASI	iii
	PENGHARGAAN	iv
	ABSTRAK	v
	ABSTRACT	vi
	KANDUNGAN	vii
	SENARAI JADUAL	viii
	SENARAI RAJAH	ix
	SENARAI SINGKATAN	xiii
	SENARAI ISTILAH	xxi
	SENARAI SIMBOL	xxiii
	SENARAI LAMPIRAN	xxiv
1	PENGENALAN	1
1.1	Pengenalan	1
1.2	Latarbelakang Masalah	2
1.3	Penyataan Masalah	4

1.4	Matlamat Utama	5
1.5	Objektif	5
1.6	Skop Penyelidikan	6
1.7	Kepentingan Penyelidikan dan Sumbangan Ilmiah	6
1.8	Struktur Thesis	8
2	KAJIAN LITERASI	10
2.1	Pengenalan	10
2.2	Penyelidikan Pengintegrasian Data	11
2.3	XML	12
2.4	Metadata	12
2.5	Perbincangan	14
2.6	Pengintegrasian Data	16
	2.6.1 Sejarah dan Contoh Pengintegrasian Data	16
	2.6.2 Contoh Pengintegrasian Data	18
2.7	Common Warehouse Metamodel (CWM)	19
	2.7.1 Struktur CWM	20
2.8	Meta Integration	23
2.9	Pendekatan dan Senibina Pengintegrasian Sedia Ada	24
2.10	Kesimpulan	27
3	METODOLOGI PENYELIDIKAN	28
3.1	Pengenalan	28
3.2	Rangka Kerja Penyelidikan	30
	3.2.1 Formulasi Masalah (Fasa 1)	30
	3.2.1.1 Kajian Literasi	32
	3.2.1.2 Analisis Sistem Semasa	32
	3.2.1.3 Proposal Penyelidikan	33
	3.2.2 Pembangunan Sistem (Fasa 2)	33
	3.2.3 Implementasi dan Integrasi (Fasa 3)	34
	3.2.4 Penulisan Laporan (Fasa 4)	35

3.3	Sumber Data dan Peralatan	35
3.4	Proses Pergerakan Data	36
3.5	Perolehan Maklumat	37
3.6	Langkah-Langkah Proses Pergerakan Data	38
	3.6.1 Penakrifian Stor Sumber Data	38
	3.6.1.1 Pengurangan Sumber Data	39
	3.6.1.2 Penganalisaan Kandungan	40
	dan Struktur Data	
	3.6.2 Penakrifian Stor Destinasi	41
	3.6.3 Aplikasi Transformasi Data	42
	3.6.3.1 Kemungkinan-Kemungkinan	42
	Aplikasi Transformasi Data	
	3.6.3.2 Penentuan Transformasi-Transformasi Data	43
	3.6.4 Penentuan Antaramuka	44
	3.6.5 Penakrifian Keteguhan	44
	3.6.6 Senibina Aplikasi	45
	3.6.7 Penghasilan Senario Pengujian	45
	3.6.8 Migrasi Akhir dan Kriteria Kejayaan	46
3.7	Aplikasi Kepada Maklumat Data Elektronik	46
3.8	Cadangan Senibina Pengintegrasian	53
3.9	Rumusan	55
4	PERLAKSANAAN	57
4.1	Pengenalan	57
4.2	Perbandingan Perlaksanaan Pengintegrasian	58
4.3	Antaramuka Pengintegrasian	59
4.4	Penyediaan Data dan Metadata	64
4.5	Pergerakan Data XML	69
4.6	Implementasi Pengintegrasian Data eBusiness	70
	4.6.1 Langkah-Langkah Awal	71
	4.6.2 Elemen-Elemen yang Digunakan	72

4.6.3 Proses Pemetaan	74
4.6.4 Penjanaan Migrasi Data	82
4.7 Kesimpulan	87
5 PENGUJIAN DAN ANALISIS	88
5.1 Pengenalan	88
5.2 Persekutaran Pengujian	89
5.3 Kriteria Perbandingan	90
5.4 Contoh Penyataan Pertanyaan	91
5.5 Matrik Pengujian Perbandingan	93
5.6 Pengujian Perbandingan Sebelum Peningkatan	94
5.6.1 Kajian Kes 1: e-Business	94
5.6.2 Kajian Kes 2: Sumber Manusia	100
5.7 Perbandingan Sebelum dan Selepas Peningkatan Pendekatan	102
5.8 Perbincangan	109
6 PERBINCANGAN DAN KESIMPULAN	110
6.1 Pengenalan	110
6.2 Hasil Penyelidikan	111
6.3 Pencapaian Objektif Kajian	112
6.4 Kebaikan dan Kelemahan Pendekatan Pengintegrasian	113
6.5 Cadangan Pembaikan	115
6.6 Penyelidikan Masa Hadapan	115
6.7 Kesimpulan	116
RUJUKAN	117
Lampiran A - C	121 - 134

SENARAI JADUAL

NO JADUAL	TAJUK	MUKA SURAT
3.1	Skema Data dan Contoh Data bagi Pengujian	46
4.1	Perbandingan Pengintegrasian Sebelum dan Selepas Peningkatan	58
5.1	Contoh Penyataan Pertanyaan	91
5.2	Matrik Perbandingan Pengujian	93
5.3	Bilangan Kehilangan Data bagi P1	95
5.4	Bilangan Kehilangan Data bagi P2	96
5.5	Bilangan Kehilangan Data bagi P3	97
5.6	Bilangan Kehilangan Data bagi P4	98
5.7	Bilangan Kehilangan Data Kajian Kes 1	99
5.8	Bilangan Kehilangan Data Kajian Kes 2	101

5.9	Bilangan Kehilangan Data P1, P2, P3, dan P4 selepas Peningkatan	103
5.10	Peratusan Perbandingan Kehilangan Data bagi P1, P2, P3, dan P4	104
5.11	Bilangan Kehilangan Data Kajian Kes 2 selepas Peningkatan	106
5.12	Peratusan Perbandingan Kehilangan Data bagi P5,P6, dan P7	107
5.13	Peratusan Pengurangan Kehilangan Data Keseluruhan	108

SENARAI RAJAH

NO RAJAH	TAJUK	MUKA SURAT
2.1	Skema bagi Gudang Data	17
2.2	Common Warehouse Metamodel	21
2.3	Senibina Pengintegrasian Data Mikael R. Jensen	24
3.1	Rangka Kerja Operasi	31
3.2	Sumber Data dan Instrumentasi	36
3.3	DTD bagi Dokumen Jualan	48
3.4	Contoh Dokumen XML yang menuruti DTD	49
3.5	DTD bagi Dokumen Pemetaan	50
3.6	Dokumen XML bagi Pemetaan	50
3.7	DTD bagi Dokumen Komponen	51
3.8	Dokumen Komponen XML	53

3.9	Senibina Pengintegrasian Data and Metadata XML	54
4.1	Skrin ‘Splash’ bagi Data Integration Interface	59
4.2	Menu Utama bagi Data Integration Interface	60
4.3	Antaramuka Data Integration Interface	61
4.4	Menu “About” bagi Data Integration Interface	62
4.5	Menu “Setting Manager” bagi Data Integration Interface	63
4.6	Antaramuka bagi Meta Integration Model Bridge (MIMB)	64
4.7	Dokumen XML bagi Tempahan Belian	66
4.8	DTD bagi Tempahan Belian	67
4.9	Model CWM bagi Pangkalan Data Jualan	68
4.10	Penggunaan MIMB dalam Penukar Model Data	69
4.11	Pengintegrasian Data eBusiness	72
4.12	Operasi pada Pemetaan Atribut “ShipAddress”	76
4.13	Klaus ‘Where’ pada Pemetaan Kelas “Orders”	78
4.14	Pemetaan Kelas “ <i>Orders_Details</i> ”	81

4.15	Persediaan bagi Penjanaan Kod	82
4.16	Penentuan Destinasi	83
4.17	Set Paramater Masa Larian	84
4.18	Pemindahan Perpustakaan yang diperlukan bagi Penjanaan Kod	85
4.19	Hierarki Hasil Pemindahan Perpustakaan	85
4.20	Penjanaan Kod daripada <i>Command Line</i>	86
5.1	Graf Perbandingan Bagi Pertanyaan P1	96
5.2	Graf Perbandingan Bagi Pertanyaan P2	97
5.3	Graf Perbandingan Bagi Pertanyaan P2	98
5.4	Graf Perbandingan Bagi Pertanyaan P4	99
5.5	Graf Perbandingan Bagi Pertanyaan P1,P2,P3, dan P4	100
5.6	Graf Perbandingan Bagi Pertanyaan P5, P6, dan P7	102
5.7	Graf Perbandingan Sebelum dan Selepas Peningkatan bagi Kajian Kes 1	105
5.8	Graf Perbandingan Sebelum dan Selepas Peningkatan bagi Kajian Kes 2	107

5.9	Graf Perbandingan Purata Kehilangan Data	108
-----	------------------------------------------	-----

SENARAI SINGKATAN

CWM	-	Common Warehouse Metamodel
XML	-	Extensible Mark-up Language
DTD	-	Document Type Definition
MIW	-	Meta Integration Works
MIMB	-	Meta Integration Model Bridge
B2B	-	Business To Business
OLAP	-	Online Analytical Processing
ETL	-	Extract, Transform, & Load
BI	-	Bussiness Intelligence
OMG	-	Object Management Group
UML	-	Unified Modeling Language
URL	-	Uniform Resource Locator
OIM	-	International Organization for Migration
WWW	-	World Wide Web

SENARAI ISTILAH

Sistem Pengurusan Pangkalan Data	-	<i>Database Management System</i>
Capaian semula maklumat	-	<i>Information retrieval</i>
Pertanyaan	-	<i>Query</i>
File Teks	-	<i>Text file</i>
Hubungan	-	<i>Relation</i>
Jadual	-	<i>Table</i>
Bahasa Pertanyaan Berstruktur	-	<i>Structured Query Language</i>

SENARAI LAMPIRAN

NO LAMPIRAN	TAJUK	MUKA SURAT
A	Aturcara kod bagi “Data Integration Interface”	121
B	Kod Aturcara Menu Utama Data Integration Interface	126
C	Contoh Sebahagian Kandungan Model Data CWM	129

RUJUKAN

- Agosta, L. (2001). Reports of the demise of metadata are premature.DM Review 3
- Auth, G. dan Etil, V.M. (2002). A Software Architecture for XML-based Metadata Interchange in Data Warehouse Systems.
- Bertino E. dan Ferrari E. (2001). XML and Data Integration. IEEE Internet Computing.
- Bremeau C. (2001). [XML Data Movement Components for Teradata.](http://www.metaintegration.com)
www.metaintegration.com, July 2004.
- DAMA (2005). "*Metadata Based Impact and Lineage Analysis Across Heterogeneous Metadata Sources*". Wilshire Meta-Data Conference. 24-25 May 2005.
- Do, H. H., Rahm, E. (2000). On metadata interoperability in data warehouses. Technical Report 1- 2000, Institute Informatics, University Leipzig.
- Haag, S., Cummings, M., dan McCubbery, D.J (2002). Alain Pinsonneault,Richard Donvan: *Managements Information System for the Information Age*, Third Canadian Edition, McGraw-Hill Ryerson.

- Halevy, A.Y, Ashish N., Bitton, D., Carey, M.J., Draper, D., Pollock, J., Rosenthal, A., dan Sikka, V. (2005). "Enterprise information integration: successes, challenges and controversies". *SIGMOD 2005*, 778-787.
- Holzner, S., (1997). XML Complete. McGraw-Hill
- Inmon, W.H., dan Hackathorn R.D. (2001). *Using the Data Warehouse*, John Wiley & Sons.
- Jensen, M. R., Møller, T.H., dan Pedersen, T.B. (2001a). Specifying OLAP Cubes On XML Data. *Tech Report R-01-5003*, Department Of Computer Science, Aalborg University.
- Jensen, M. R., dan T. H. Møller (2001b). Constructing OLAP Cubes From XML Data. *Tech Report R-02-5003*, Department Of Computer Science, Aalborg University.
- Kimball, R. dan Ross, M.(2002). *The Data Warehouse Toolkit: The Complete Guide to Dimensional Modeling (Second Edition)*, John Wiley & Sons.
- Koshafian, S. dan Abnous, R. (1995). Object Orientation – Concepts, Analysis, and Design, Languages, Databases, Graphical User Interfaces, Standard. 2nd ed. Wiley.
- Lahiri, T et. al. Ozone (1999). Integrating Structured and Semi structured Data, *Proceedings of the Seventh International Conference on Database Programming Languages*, Kinloch Rannoch, Scotland.
- Lenz, H., (1997). Summarizability in OLAP and Statistical Databases, *Proceedings of the Ninth International Conference on Statistical and Scientific Database Management*, 39-48.

Lenzerini, M. (2002). "Data Integration: A Theoretical Perspective".
PODS 2002, 243-246.

Mimno, P. (2002). Succesful Real-Time Business Analytics: A Data Warehousing Strategy. White Paper. Informatica Corporation.

Pedersen, et. al.(2000). Extending OLAP Querying To External Object Databases,
Proceedings of the Ninth International Conference on Information and Knowledge Management, ms. 405-413.

Pledge, K. dan McGarry, J. (2001). Data Warehousing for Actuaries. Versi (1.2): 3-12.

Poole, J., Chang, D., Tolbert, D., dan Mellor, D. (2003). Common Warehouse Metamodel Developer's Guide. John Wiley & Sons Inc.

Poole, J. (2000). The Common Warehouse Metamodel as a Foundation for Active Object Models in the Data Warehouse Environment. Position paper to ECOOP 2000 workshop on Metadata and Active Object-Model Pattern Mining – Cannes, France.

Pyle dan Dorian (2003) *Business Modeling and Data Mining*. Morgan Kaufmann,

Rafanelli, M. 1990). STORM: A Statistical Object Representation Model, *Proceedings of the Fifth Conference on Statistical and Scientific Database Management*, 14-29.

Shanmugasundaram, et. al (1999). Relational Databases for Querying XML Documents: Limitations and Opportunities, *Proceedings of the Twenty-Fifth International Conference on Very Large Databases*, Edinburgh, Scotland.

Shukla, A. (1996).Storage Estimation for Multidimensional Aggregates in the Presence

- of Hierarchies, *Proceedings of Very Large Databases*, pp. 522-531.
- Silicon Integration Initiative (2000). *The Electronic Component Information Exchange QuickData Architecture*.
- Thomsen, E., (1997). *OLAP Solutions: Building Multidimensional Information Systems*, John Wiley & Sons, Inc.
- W3C (2001). World Wide Web Consortium, *The XML Query Algebra*, W3C Working Draft,<http://www.w3.org/TR/query-algebra>, Dec. 4 2000.
- Ziegler, P. dan Dittrich, K.R (2004). "Three Decades of Data Integration - All Problems Solved?". *WCC 2004*, 3-12.