

DANDD INSTANCE GENERATION IN TEXTILE PLOT ENVIRONMENT

Natsuhiko KUMASAKA
Faculty of Science and Technology
Keio University

BACKGROUND

- Variety of data sources
 - Flat files (CSV, TSV, fixed format,...)
 - RDBMS (PostgreSQL, Access, etc...)
 - Spread sheet (Excel,...)
 - Webpage (HTML, CGI,...)
- DandD project
 - DandD instance
 - XML document describing data and its attributes
 - DandD client-server system (Yokouchi and Shibata 2004)
 - Integrate different data sources
 - Employ DandD Instance as an intermediate entity
 - DandDEditor (Yokouchi 2005)
 - Create / Edit DandD instances
 - Restricted in well organised data sources


TEXTILE PLOT ENVIRONMENT

(KUMASAKA AND SHIBATA 2007)

- Previous features
 - Open DandD instance
 - Modify textile plots
 - Remove/replace columns, cases and observations
 - Add/Remove/Modify attributes
 - Re-organise data structure
 - Save DandD instance
 - Audit description of data analysis
- New feature in 2008
 - Open various data sources
 - Extract tables embedded in data files or databases
 - Separate attributes from tables
 - Divide tables into a set of datavectors
 - Check consistency in datavectors




2007




2008

TARGET DATA SOURCES

- Relational Databases
 - RDBMS
 - PostgreSQL, Access, MySQL
 - Oracle (not tested yet)
- Data File
 - Flat file
 - Fixed format
 - Free format (CSV, TSV)
 - Non-flat file
 - Excel
 - HTML



STRATEGY



HTML

- Extract target <TABLE>s
 - 1. Create DOM Tree
 - DOM Level 1 (W3C 2008)
 - CyberNeko HTML Parser 1.9.6.1 (Clark 2008)
 - 2. Find <TABLE>s
 - 3. Count the number of <TR> and <TD>
 - 4. Select <TABLE>s which have a number of cells
- Separate header from table body
 - 1. Search <TBODY> and <THEAD>
 - 2. Find disjoint sets of <TR>s
 - 3. Measure dissimilarity between disjoint <TR>s
 - 4. Using clustering algorithm
- Merge <TABLE>s according to header information
- Divide into datavectors and check consistency

EXTRACT TARGET <TABLE>S

<TR>: 1, <TD>: 1
Num of cells: 1



<TR>: 1, <TD>: 2
Num of cells: 2

--	--

<TR>: 21, <TD>: 9
Num of cells: 189

--	--

<TR>: 1, <TD>: 1
Num of cells: 1

SEPARATE HEADER FROM BODY: FIND DISJOINT SETS OF <TR>S

成田線(千葉県)の賃貸住宅 (賃貸マンション、賃貸アパート、賃貸一戸建て) - Yahoo!不動産 - Mozilla Firefox

ファイル(F) 編集(E) 表示(V) 履歴(S) ブックマーク(B) ツール(T) ヘルプ(H)

Firefox を使ってみよう 最新ニュース

成田... 東京都の... HTML解... NekoHT... Binomial... DOMに... バイナリ...

821 件中241~260 件を表示しています。 前へ 9 10 11 12 13 14 15 16 17 18 次へ

一覧表示 間取り表示 選択した物件をまとめて 詳細表示 お問い合わせ

画像	交通 住所	バス 徒歩	賃料 管理費等	礼金(保証金) 敷金(敷引)	間取り 専有面積	築年月 (築年数)	詳細	選択
	成田線/安食 印旛郡栄町安食 間取り図 写真	— 7分	5.00万円 2,000円	なし 1か月	2DK 44.72m²	'95/02 (築14年)	詳細を見る	<input type="checkbox"/>
	成田線/安食 印旛郡栄町安食 間取り図 写真	— 7分	5.00万円 2,000円	なし 1か月	2DK 44.72m²	'95/02 (築14年)	詳細を見る	<input checked="" type="checkbox"/>
	総武本線/佐倉 佐倉市大崎台2丁目 間取り図 写真	— 12分	5.00万円 2,000円	なし 2か月	4K 42.97m²	'97/03 (築11年)	詳細を見る	<input type="checkbox"/>
	成田線/湖北 我孫子市古戸 間取り図 写真	— 19分	4.90万円 3,000円	なし 2か月	2DK 40.57m²	'93/02 (築16年)	詳細を見る	<input type="checkbox"/>
	成田線/湖北 我孫子市古戸 間取り図 写真	— 19分	4.90万円 3,000円	なし 2か月	2DK 40.57m²	'93/02 (築16年)	詳細を見る	<input type="checkbox"/>
	成田線/湖北 我孫子市古戸 間取り図 写真	— 10分	4.90万円 —	なし —	2DK 40.57m²	'93/02 (築16年)	詳細を見る	<input type="checkbox"/>

<http://rent.realestate.yahoo.co.jp/>

FIND DISJOINT SETS OF <TR>S: NESTED BODY

【アットホーム】 借りる(賃貸) : 賃貸アパート・賃貸マンション・賃貸住宅 : 検索結果(一覧で表示) [東京都 (JR京葉線 新浦安)] | 住まいを探す

ファイル(E) 編集(E) 表示(V) 履歴(S) ブックマーク(B) ツール(I) ヘルプ(H)

Firefox を使ってみよう 最新ニュース

一覧で表示 間取図で表示 地図で表示 情報の見方

選択をすると、まとめてお問合せまたは検討中リストへ追加ができます。 すべての物件を選択する

交通▲ 所在地▼	駅徒歩▲ (バス停徒歩)	賃料▲ (管理費等)	敷金/保証金 礼金	間取り▼ 面積▼	物件種目▼ 築年月▼	画像▼	選択
・JR京葉線/新浦安 浦安市入船4丁目	10分	4.5万円 (3,000円)	2ヶ月 / なし なし	1K 16.00m ²	賃アパート 1985年10月	  ▶ 詳細	<input type="checkbox"/>
・ピタットハウス新浦安店 スターツピタットハウス(株) (JR京葉線/新浦安 徒歩4分) TEL:047-354-9011							<input checked="" type="checkbox"/>
・JR京葉線/新浦安 浦安市海楽2丁目	12分	4.6万円 (2,000円)	1ヶ月 / なし 1ヶ月	ワンルーム 16.29m ²	賃マンション 1991年10月	  ▶ 詳細	<input type="checkbox"/>
・ユニオン不動産(株) (東京メトロ東西線/浦安 徒歩1分) 浦安で住まいをお探しの際は是非御来店下さい TEL:047-351-2300							<input checked="" type="checkbox"/>
・JR京葉線/新浦安 浦安市海楽1丁目	14分	4.8万円 (1,000円)	2ヶ月 / なし なし	1K 19.61m ²	賃アパート 1985年11月	  ▶ 詳細	<input type="checkbox"/>
・住宅情報館(株)ファーストジョイ (東京メトロ東西線/浦安 徒歩1分) ワンルームからファミリー物件まで物件豊富！ TEL:047-855-1511							<input checked="" type="checkbox"/>
・JR京葉線/新浦安 浦安市海楽2丁目	15分	4.8万円 (-)	2ヶ月 / なし 1ヶ月	ワンルーム 17.00m ²	賃アパート 1987年8月	  ▶ 詳細	<input type="checkbox"/>
・(株)明和地所 浦安駅前支店 (東京メトロ東西線/浦安 徒歩1分) 何でも揃う「住まいのコンビニ」としてご利用下さい！ TEL:0120-380-794							<input checked="" type="checkbox"/>


<http://www.athome.co.jp/>

FIND DISJOINT SETS OF <TR>S: NESTED HEADER



毎日の全国データ一覧表(日別値詳細版:2008年03月07日 17時現在)

地点	気圧				気温				蒸気圧		湿度		風向・風速				日照時間	全天日射量	平均雲量	降水量			降雪 深さ 合計	天気概況				
	現地海面		最低海面		最高		最低		平均		平均		最小		平均		最大		最大瞬間									
	平均	平均	値	起時	値	起時	値	起時	値	起時	値	起時	風速	風速	風向	風速	風速	風向	風速	風向	起時	1時間	起時	10分間	起時	1時間	起時	10分間
札幌	1015.6	15.52	3.9	13:32	-4.7	05:44		40	12:29		6.2	北北西	14:10	9.0	北北西	14:16	5.0	13.2		0.0/-					3]	76]		
稚内	1013.1	17.00	3.2	12:13	-3.4	06:08		66	12:30		7.0	西南西	13:00	11.4	西	12:33	9.8	15.4		0.0/-					3]	35]		
北見枝幸	1013.3	16.26	3.9	11:53	-2.8	06:00		44	13:23		6.3	西	14:30	10.6	西	16:06	5.1			0.0/-					2]	65]		
旭川	1015.1	16.07	2.1	14:59	-6.7	05:02		56	14:54		5.9	西南西	15:20	9.2	西南西	15:20	3.5	12.1		0.5]					4]	61]		
留萌	1015.2	17.00	2.5	14:28	-3.6	06:20		60	15:06		6.6	西南西	16:20	9.8	西	14:48	4.5	11.6		5.0]					10]	42]		
羽幌	1014.7	17.00	2.9	14:23	-3.8	04:11		58	15:01		5.9	西	15:10	8.9	西	15:27	5.7			1.0]					2]	70]		
岩見沢	1015.8	16.07	3.0	14:41	-5.6	03:25		57	14:36		3.3	西南西	13:50	5.9	北西	15:00	6.7			0.0/-					—	88]		
小樽	1015.6	16.12	3.7	12:47	-2.9	03:32		39	12:50		4.2	西南西	17:00	7.7	西南西	16:32	6.8			0.0/-					1]	96]		
寿都	1016.5	15.56	3.5	12:32	-2.9	06:21		47	12:49		3.7	北西	13:30	9.8	北西	13:36	5.3	11.2		1.0]					2]	37]		
俱知安	1016.1	16.07	2.8	12:18	-7.5	06:27		46	12:46		6.2	北北西	15:00	9.8	西北西	14:44	7.4			3.5]					8]	171]		
網走	1013.7	17.00	2.2	13:35	-4.1	06:30		41	14:49		4.2	北西	13:00	7.6	西北西	13:07	1.4	12.0		0.0/-					6]	62]		
紋別	1013.2	15.49	3.3	12:34	-3.1	03:34		43	12:20		6.2	西	16:30	9.7	西	16:25	3.7			0.0/-					—	41]		
雄武	1013.3	16.59	3.8	14:14	-2.8	03:06		42	13:55		6.4	西南西	14:50	10.2	西	14:48	3.9			0.0/-					—	41]		
根室	1013.8	15.53	1.5	13:14	-4.4	06:58		59	13:15		4.5	北北西	14:40	6.6	北北西	14:32	3.9	13.6		0.0/-					—	—		
釧路	1014.3	14:52	1.4	12:59	-4.6	06:31		67	13:21		6.7	南西	13:30	8.5	南西	12:49	8.4			0.0/-					—	—		
帶広	1013.4	15:39	4.8	14:01	-6.7	06:20		37	13:29		6.8	西北西	15:10	11.3	西北西	14:59	10.2	17.3		0.5]					2]	16]		
広尾	1014.1	15:49	1.7	16:33	-6.5	06:01		59	16:33		3.4	西	06:00	5.0	東南東	11:36	10.6			0.0/-					—	47]		
室蘭	1016.2	16:35	3.3	14:31	-2.1	06:36		60	16:11		5.5	西	13:40	7.6	西北西	14:12	9.9	17.1		0.0/-					3]	9]		
苦小牧	1016.0	16:06	2.4	16:07	-7.3	06:23		60	16:17		4.1	南東	11:20	5.2	北	13:11	7.3			0.0/-					1]	8]		
浦河	1015.8	16:35	2.5	14:54	-5.2	06:14		61	08:12		8.6	西	13:30	12.1	西北西	15:18	10.4	17.2		0.0/-					—	—		
函館	1016.6	16:27	4.2	12:44	-4.6	04:44		38	12:21		6.6	北西	14:20	10.0	西北西	14:09	7.0	14.2		0.5]					3]	18]		
江差	1017.1	16:05	5.0	12:27	-0.5	07:50		43	12:45		6.6	西北西	04:00	12.2	北西	00:52	6.9			1.5]					1]	11]		
青森	1017.4	14:54	4.8	13:12	-2.4	06:58		54	15:01		6.4	西南西	10:30	10.7	西北西	14:58	4.7	13.2		0.5]					2]	43]		
八戸	1017.1	14:43	4.2	10:21	-2.3	06:00		48	10:24		5.6	南西	10:00	10.5	南西	10:59	4.7			0.0/-					—	1]		
深浦	1018.4	15:32	4.8	12:35	-1.0	08:53		48	12:00		7.8	北西	08:50	14.6	北西	08:43	0.8			3.0]					5]	22]		
むつ	1017.0	16:19	2.6	14:46	-5.6	01:48		66	14:43		4.2	南南西	13:10	7.9	西	08:06	3.0]			3.5]					8]	11]		
秋田	1018.9	16:38	3.1	11:43	-2.4	02:13		75	10:54		7.5	西北西	11:50	14.0	北北西	11:50	3.2	10.8		8.5]					11]	5]		
盛岡	1017.4	15:00	5.3	12:29	-5.0	06:22		37	12:23		6.4	西	13:10	10.6	南西	12:50	6.6	14.6		0.5]					—	—		
大船渡	1016.8	14:52	7.0	13:41	-2.3	06:42		32	13:49		5.6	北北西	15:30	11.4	西北西	15:19	7.1			0.0/-					—	—		
宮古	1017.0	13:53	6.6	11:07	-3.8	06:08		45	13:13		5.3	東南東	13:40	7.6	東南東	13:32	1.8			0.5]					2]	3]		
仙台	1017.6	14:29	8.0	11:32	-0.3	06:27		32	11:37		9.2	西北西	14:10	13.9	西北西	15:40	7.5	15.8		0.0/-					—	—		
石巻	1017.2	14:54	6.0	11:40	-0.9	06:42		21	14:49		10.1	西北西	16:00	15.0	西北西	16:56	9.1			0.0/-					—	—		

DISSIMILARITY MEASURE BETWEEN DISJOINT <TR>S



DISSIMILARITY MEASURE BETWEEN DISJOINT <TR>S




Text Node and Null Node

CLUSTERING ALGORITHM



Header

- Body



0 2 1 5 15 19 14 3 4 8 10 7 9 6 11 12 13 16 18 20 17

Header

Body

MERGE <TABLE>S ACCORDING TO HEADER INFORMATION

Same headers

Different bodies

The screenshot shows a web browser window displaying four separate tables from the Japan Meteorological Agency's website. Each table has a red box drawn around its first row, highlighting the header information. The tables are arranged vertically and appear to be different datasets or years. The browser interface includes a title bar, menu bar, and status bar at the bottom.

http://www.atomehome.co.jp/

CHECK CONSISTENCY IN DATAVECTOR

- Find Missing / Invalid
 - “NA”, “-”, “?”, “”, “.”, space, null
- Estimate Data Type
 - Numeric (1.34, 12,000,...)
 - Check data range
 - Double -> Measurement
 - Integer -> Ordinal Number
 - Non-negative Integer -> Count
 - {0, 1} -> Logical
 - Semi-numeric (2000yen, 5min,...)
 1. Find pattern (e.g. “2,000 yen”, “3,000 yen”)
 2. Separate value and unit (e.g. “2,000yen” -> “2,000”, “yen”)
 3. Go to numeric
 - Character (Hiyoshi, Tsunashima,...)
 - Check repeated values -> Category; otherwise -> ID



EXCEL

- Extract tables from a sheet
 - 1. Create Sheet Object
 - JExcelAPI (JExcel API group, 2008)
 - 2. Find disjoint sets of cells
 - 3. Determine rectangle hull for each set
- Separate header and body
 - 1. Check table type
 - 2. Cell type clustering
- Merge tables
- Divide into datavectors and check consistency

DISJOINT CELLS: LIBOR DATA

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X
1	EUR	1-Dec-99	2-Dec-99	3-Dec-99	6-Dec-99	7-Dec-99	8-Dec-99	9-Dec-99	10-Dec-99	13-Dec-99	14-Dec-99	15-Dec-99	16-Dec-99	17-Dec-99	20-Dec-99	21-Dec-99	22-Dec-99	23-Dec-99	24-Dec-99	27-Dec-99	28-Dec-99	29-Dec-99	30-Dec-99	31-Dec-99
2	1w	3.07375	3.07563	3.07000	3.07375	3.07188	3.06000	3.04750	3.03000	3.00125	3.00000	3.01875	3.05250	3.06125	3.02750	3.00000	3.00375	4.06000	2.97250	4.04375	4.09375	3.11125	3.11750	
3	1m	3.51063	3.51963	3.52125	3.53125	3.54500	3.54000	3.54688	3.54825	3.54438	3.55000	3.55000	3.55375	3.56250	3.57500	3.56500	3.59398	3.53475	3.53375	3.53500	3.17875	3.17250		
4	2m	3.45000	3.45000	3.45000	3.46000	3.45875	3.45875	3.45700	3.44938	3.44500	3.45000	3.45750	3.45750	3.44875	3.44938	3.45000	3.44250	3.44625	3.26625	3.26125				
5	3m	3.45000	3.45000	3.45000	3.46000	3.45875	3.45875	3.45863	3.45688	3.45688	3.45625	3.46375	3.46688	3.46563	3.45750	3.44813	3.45000	3.44750	3.44875	3.34625	3.33875			
6	4m	3.45000	3.45000	3.45575	3.46000	3.46000	3.46000	3.46000	3.46000	3.46063	3.46063	3.46875	3.47938	3.48000	3.48000	3.47000	3.45000	3.47000	3.41375	3.41000				
7	5m	3.46000	3.46000	3.46463	3.46813	3.47000	3.47063	3.47375	3.47063	3.47438	3.47875	3.48000	3.50000	3.51000	3.50375	3.45000	3.50500	3.50625	3.46500	3.46688				
8	6m	3.46938	3.47313	3.48000	3.48113	3.48000	3.48000	3.48313	3.48375	3.48688	3.49000	3.49625	3.50250	3.53938	3.54000	3.55000	3.55000	3.45188	3.55000	3.51750				
9	7m	3.50750	3.51000	3.51563	3.51625	3.51688	3.51875	3.52000	3.52000	3.53198	3.52000	3.53875	3.54750	3.59000	3.59625	3.60000	3.60000	3.47700	3.60000	3.60125	3.57750	3.57688		
10	8m	3.55125	3.55588	3.56000	3.56000	3.56000	3.56000	3.56000	3.55938	3.56000	3.59000	3.59875	3.64250	3.65125	3.66000	3.65125	3.50463	3.65625	3.65650	3.63750	3.63688			
11	9m	3.60250	3.60063	3.60875	3.60713	3.60375	3.60000	3.60000	3.60000	3.61000	3.63375	3.65250	3.70375	3.71000	3.72000	3.71000	3.54000	3.71875	3.71625	3.69125	3.69813			
12	10m	3.65000	3.65000	3.66000	3.65938	3.65000	3.65250	3.65013	3.65000	3.66000	3.68000	3.70000	3.76438	3.77000	3.78000	3.77000	3.57838	3.77125	3.77125	3.75500	3.76000			
13	11m	3.70375	3.70875	3.71938	3.71400	3.71000	3.70875	3.71000	3.71000	3.72000	3.73750	3.75500	3.82000	3.83000	3.83000	3.83225	3.61813	3.82250	3.82250	3.81125	3.81813			
14	12m	3.76375	3.76588	3.78000	3.77825	3.77000	3.77000	3.77438	3.77163	3.77000	3.77800	3.79875	3.81375	3.89000	3.89000	3.89750	3.88500	3.88000	3.87875	3.88000	3.87250	3.87813		
15																								
16	USD	1-Dec-99	2-Dec-99	3-Dec-99	6-Dec-99	7-Dec-99	8-Dec-99	9-Dec-99	10-Dec-99	13-Dec-99	14-Dec-99	16-Dec-99	17-Dec-99	20-Dec-99	21-Dec-99	22-Dec-99	23-Dec-99	24-Dec-99	27-Dec-99	28-Dec-99	29-Dec-99	30-Dec-99	31-Dec-99	
17	1w	5.57375	5.55631	5.57406	5.57281	5.57656	5.60750	5.62688	5.63375	5.62436	5.62313	5.60125	5.60125	5.58281	5.61250	5.60281	7.71875	7.75625			5.92344	5.92344		
18	1m	6.47875	6.47875	6.47875	6.46875	6.46750	6.46750	6.46250	6.46250	6.46125	6.46125	6.46125	6.46125	6.47125	6.47125	6.48125	6.49000			5.82750	5.82750			
19	2m	6.16625	6.16875	6.17125	6.17000	6.17000	6.17125	6.17125	6.17125	6.17250	6.18000	6.18625	6.18750	6.20000	6.20250			5.90375	5.90375					
20	3m	6.12125	6.12125	6.12375	6.12000	6.12000	6.12000	6.12125	6.12125	6.12000	6.14000	6.15250	6.16250	6.17500	6.18000			6.00375	6.00375					
21	4m	6.09875	6.10125	6.11000	6.11000	6.10875	6.11000	6.11125	6.11000	6.11000	6.13000	6.14375	6.15375	6.16250	6.17000			6.05250	6.05250					
22	5m	6.08250	6.08500	6.10000	6.10000	6.09875	6.10000	6.10125	6.10000	6.10125	6.12000	6.13750	6.14500	6.15375	6.16250			6.09375	6.09375					
23	6m	6.07125	6.07750	6.09000	6.09000	6.08875	6.09000	6.09125	6.09000	6.09125	6.11785	6.13250	6.13875	6.15000	6.16000			6.13000	6.13000					
24	7m	6.10375	6.11000	6.12250	6.12125	6.12000	6.12250	6.12125	6.12000	6.12250	6.15000	6.18600	6.18875	6.20625	6.21250			6.19375	6.19375					
25	8m	6.14375	6.14500	6.15750	6.15250	6.15125	6.15000	6.15125	6.14875	6.15125	6.18875	6.19375	6.23250	6.23500	6.25265	6.26000			6.25375	6.25375				
26	9m	6.18000	6.18250	6.19250	6.18125	6.18000	6.18375	6.18000	6.19000	6.22265	6.23375	6.28125	6.30375	6.31000			6.31000	6.31000						
27	10m	6.22000	6.22375	6.23500	6.22125	6.22250	6.22000	6.22375	6.21875	6.23000	6.27125	6.28125	6.33375	6.35625	6.36750			6.37500	6.37500					
28	11m	6.25750	6.26250	6.27625	6.26125	6.26000	6.26500	6.26250	6.25750	6.26875	6.31500	6.32875	6.38750	6.41000	6.41875			6.43625	6.43625					
29	12m	6.29250	6.29750	6.31265	6.30000	6.30000	6.30500	6.29875	6.29250	6.30750	6.37500	6.43000	6.43375	6.46125	6.47375			6.50000	6.50000					
30																								
31	GBP	1-Dec-99	2-Dec-99	3-Dec-99	6-Dec-99	7-Dec-99	8-Dec-99	9-Dec-99	10-Dec-99	13-Dec-99	14-Dec-99	16-Dec-99	17-Dec-99	20-Dec-99	21-Dec-99	22-Dec-99	23-Dec-99	24-Dec-99	27-Dec-99	28-Dec-99	29-Dec-99	30-Dec-99	31-Dec-99	
32	1w	5.44875	5.37500	5.31094	5.25000	5.37563	5.37688	5.31388	5.15188	5.20203	5.62750	5.28453	5.12625	4.93125	4.90781	4.81063	4.49250	4.23438			4.00000	3.75000		
33	1m	5.90094	5.89141	5.88641	5.87813	5.84391	5.85344	5.84719	5.63641	5.62063	5.71984	5.73484	5.72219	5.71000	5.69719	5.67078	5.63250	5.43875			5.41172	5.40813		
34	2m	6.00000	6.01125	6.02266	6.00375	6.00125	6.00000	5.87563	5.86840	5.87750	5.92016	5.92781	5.92875	5.93125	5.92906	5.93000	5.88813			5.90750	5.90406			
35	3m	6.04906	6.05906	6.08109	6.08625	6.05653	6.06281	6.03644	5.99500	5.98234	5.97969	6.00625	6.04297	6.06094	6.06906	6.06938	6.07438	6.08547			6.07719	6.07844		
36	4m	6.08968	6.10547	6.11547	6.10641	6.10265	6.10141	6.04781	6.04172	6.04047	6.07811	6.10766	6.12063	6.12250	6.12888	6.13875	6.14078			6.15188	6.15109			
37	5m	6.13125	6.14141	6.14656	6.14703	6.14266	6.14406	6.14881	6.09813	6.09344	6.09594	6.15031	6.17172	6.18281	6.18500	6.19141	6.19594	6.20109	6.20469			6.21578	6.22609	
38	6m	6.17656	6.19266	6.19594	6.19344	6.19094	6.19703	6.19719	6.15906	6.15484	6.15734	6.21203	6.24109	6.25000	6.25000	6.26500	6.27750	6.28406			6.28563	6.29031		
39	7m	6.25000	6.25125	6.25215	6.25125	6.25625	6.25750	6.21359	6.21859	6.22219	6.26891	6.30172	6.32188	6.34000	6.35109	6.35422			6.35758	6.36422				
40	8m	6.31406	6.31406	6.32438	6.31531	6.31625	6.31875	6.31750	6.28000	6.28266	6.28566	6.32381	6.36938	6.39969	6.40078	6.41078	6.42375			6.42250	6.42719			
41	9m	6.37813	6.37625	6.37813	6.37813	6.38063	6.38063	6.34422	6.33969	6.35281	6.39078	6.43531	6.47328	6.47828	6.48344	6.49625	6.49750	6.49875			6.50000	6.50000		
42	10m	6.43844	6.43594	6.43875	6.43875	6.44031	6.44063	6.40234	6.40359	6.41484	6.45047	6.49750	6.53422	6.54063	6.54453	6.55391	6.55606	6.55656			6.56219	6.56094		
43	11m	6.50000	6.50000	6.50000	6.50000	6.50000	6.50000	6.46469	6.46469	6.46469	6.47703	6.51391	6.55981	6.59891	6.60594	6.62688	6.62375			6.62938	6.63063			
44	12m	6.56281	6.56094	6.56156	6.56156	6.56125	6.56094	6.52891	6.53781	6.60047	6.62438	6.67016	6.68250	6.68250	6.69281	6.69313	6.69156			6.70578	6.70813			
45																								
46	JPY	1-Dec-99	2-Dec-99	3-Dec-99	6-Dec-99	7-Dec-99	8-Dec-99	9-Dec-99	10-Dec-99	13-Dec-99	14-Dec-99	16-Dec-99	17-Dec-99	20-Dec-99	21-Dec-99	22-Dec-99	23-Dec-99	24-Dec-99	27-Dec-99	28-Dec-99	29-Dec-99	30-Dec-99	31-Dec-99	
47	1w	0.07125	0.07125	0.07250	0.07250	0.07250	0.07250	0.07125	0.07375	0.07625	0.09250	0.08875	0.08125	0.08250	0.187500	0.52500	0.60250			0.12750	0.12625			
48	1m	0.62125	0.64000	0.61125	0.61125	0.61750	0.57875	0.49125	0.41250	0.38500	0.36625	0.36625	0.65750	0.68125	0.67125	0.87500	1.58125	1.58750			0.14125	0.15250		
49	2m	0.39625	0.39000	0.40250	0.41375	0.40500	0.38000	0.32688	0.29625	0.27000	0.26625	0.27500	0.40750	0.41000	0.40500	0.39313	0.46875	0.65625	0.76875			0.15875	0.16500	
50	3m	0.32000	0.32875	0.33750	0.33125	0.33125	0.31125</td																	

TARGET TABLE TYPE



CHECK TABLE TYPE

EUR	1-Dec-99	2-Dec-99	3-Dec-99	6-Dec-99	7-Dec-99	8-Dec-99
1w	3.07375	3.07563	3.07000	3.07375	3.07188	3.06000
1m	3.51063	3.51963	3.52125	3.53125	3.54500	3.54000
2m	3.45000	3.45000	3.45000	3.46000	3.46000	3.45875
3m	3.45000	3.45000	3.45000	3.46000	3.46000	3.45875
4m	3.45000	3.45000	3.45575	3.46000	3.46000	3.46000
5m	3.46000	3.46000	3.46463	3.46813	3.47000	3.47000
6m	3.46938	3.47313	3.48000	3.48113	3.48000	3.48000
7m	3.50750	3.51000	3.51563	3.51625	3.51688	3.51875
8m	3.55125	3.55588	3.56000	3.56000	3.56000	3.56000
9m	3.60250	3.60063	3.60875	3.60713	3.60375	3.60000
10m	3.65000	3.65000	3.66000	3.65938	3.65000	3.65000
11m	3.70375	3.70875	3.71938	3.71400	3.71000	3.70875
12m	3.76375	3.76588	3.78000	3.77825	3.77000	3.77000

CHECK TABLE TYPE

Table header

EUR	1-Dec-99	2-Dec-99	3-Dec-99	4-Dec-99	5-Dec-99	6-Dec-99	7-Dec-99	8-Dec-99
1w	3.07375	3.07563	3.07000	3.07375	3.07188	3.06000		
1m	3.51063	3.51963	3.52125	3.53125	3.54500	3.54000		
2m	3.45000	3.45000	3.45000	3.46000	3.46000	3.45875		
3m	3.45000	3.45000	3.45000	3.46000	3.46000	3.45875		
4m	3.45000	3.45000	3.45575	3.46000	3.46000	3.46000		
5m	3.46000	3.46000	3.46463	3.46813	3.47000	3.47000		
6m	3.46938	3.47313	3.48000	3.48113	3.48000	3.48000		
7m	3.50750	3.51000	3.51563	3.51625	3.51688	3.51875		
8m	3.55125	3.55588	3.56000	3.56000	3.56000	3.56000		
9m	3.60250	3.60063	3.60875	3.60713	3.60375	3.60000		
10m	3.65000	3.65000	3.66000	3.65938	3.65000	3.65000		
11m	3.70375	3.70875	3.71938	3.71400	3.71000	3.70875		
12m	3.76375	3.76588	3.78000	3.77825	3.77000	3.77000		

Row Header

Column Header

Table Body

FREE FORMAT

- Separate header from body
 - Clustering technique
 - Distance between value types
 - Numeric (1.45, 25000, etc...)
 - Semi-Numeric (4,000yen, 5min, etc...)
 - Character (Hiyoshi, Shibuya, etc...)
 - Minimum distance algorithm
- Divide into datavectors and check consistency

RDB AND FIXED FORMAT

- Header and body are separated
- Value type of each column is given by
 - Metadata (VARCHAR, INTEGER, DOUBLE,...)
 - Format text (F3.1, S5,...)

FUTURE WORKS

- HTML documents generated by CGI and JavaScript
- Excel with Common header
- Free format file with a lot of missing values
- Large RDB

REFERENCES

- Clark, A. (2008) CyberNeko THML Parser Home Page,
<http://nekohtml.sourceforge.net/>.
- JExcelApi Group (2008) JExcel API Homepage:
<http://jexcelapi.sourceforge.net/>
- Kumasaka, N. and Shibata, R. (2007) Textile Plot Environment, 統計数理特集号「統計データの可視化」, **55** pp. 47-68.
- Yokouchi, D. and Shibata, R. (2004) DandD Client-Server System,
Proceedings in COMPSTAT 2004.
- W3C (2008) DOM Homapage: <http://www.w3c.org/DOM/>