

2010-10-19(Tue)

マルウェア対策研究人材育成ワークショップ(MWS2010)



マルウェア対策のための研究用データセット ～MWS 2010 Datasets～

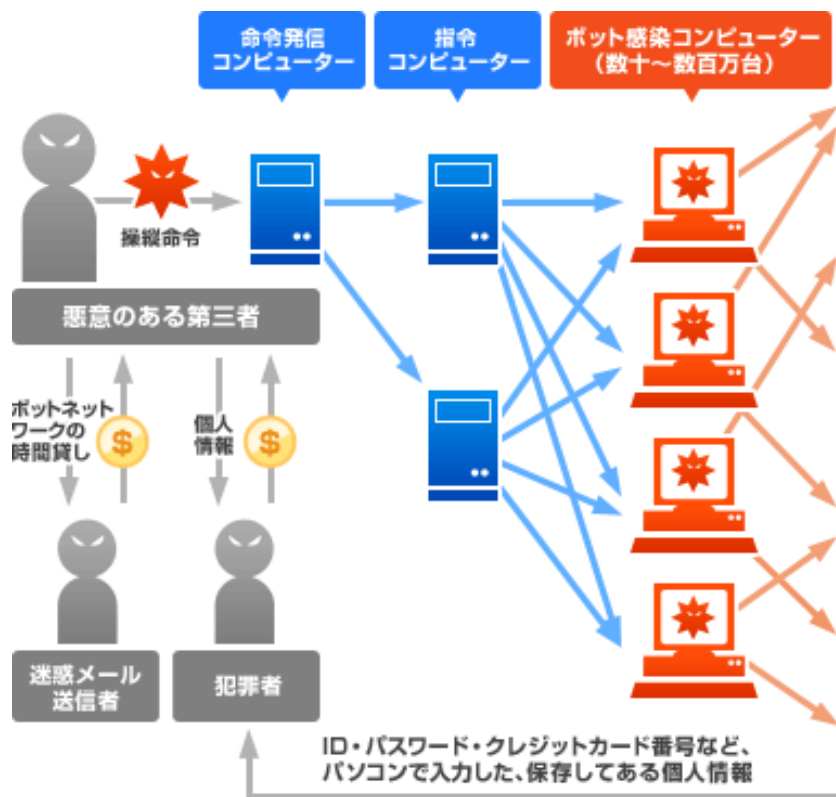
畑田充弘 (NTTコミュニケーションズ)、中津留勇 (JPCERT/CC)、
秋山満昭 (NTT PF研)、三輪信介 (NICT)

目次

- ▶ 課題と目的
- ▶ MWS 2010 Datasets
 - ▶ CCC DATASet 2010
 - ▶ MARS for MWS 2010
 - ▶ D3M 2010
- ▶ 実績(速報)
- ▶ おわりに

課題

- ▶ 共通の教材がないこと
- ▶ 研究用データを手に入れること自体が難しくなっていること
- ▶ DARPAの最新は2001年、CDX Datasetsは2009年だがマルウェアによる攻撃ではない



(<https://www.ccc.go.jp/bot/index.html>)

目的



- ▶ 研究用データセットの提供
 - ▶ CCC DATAsset 2008
 - ▶ CCC DATAsset 2009

- ▶ 研究成果を共有する場、切磋琢磨する環境作り
 - ▶ MWS 2008
 - ▶ MWS 2009

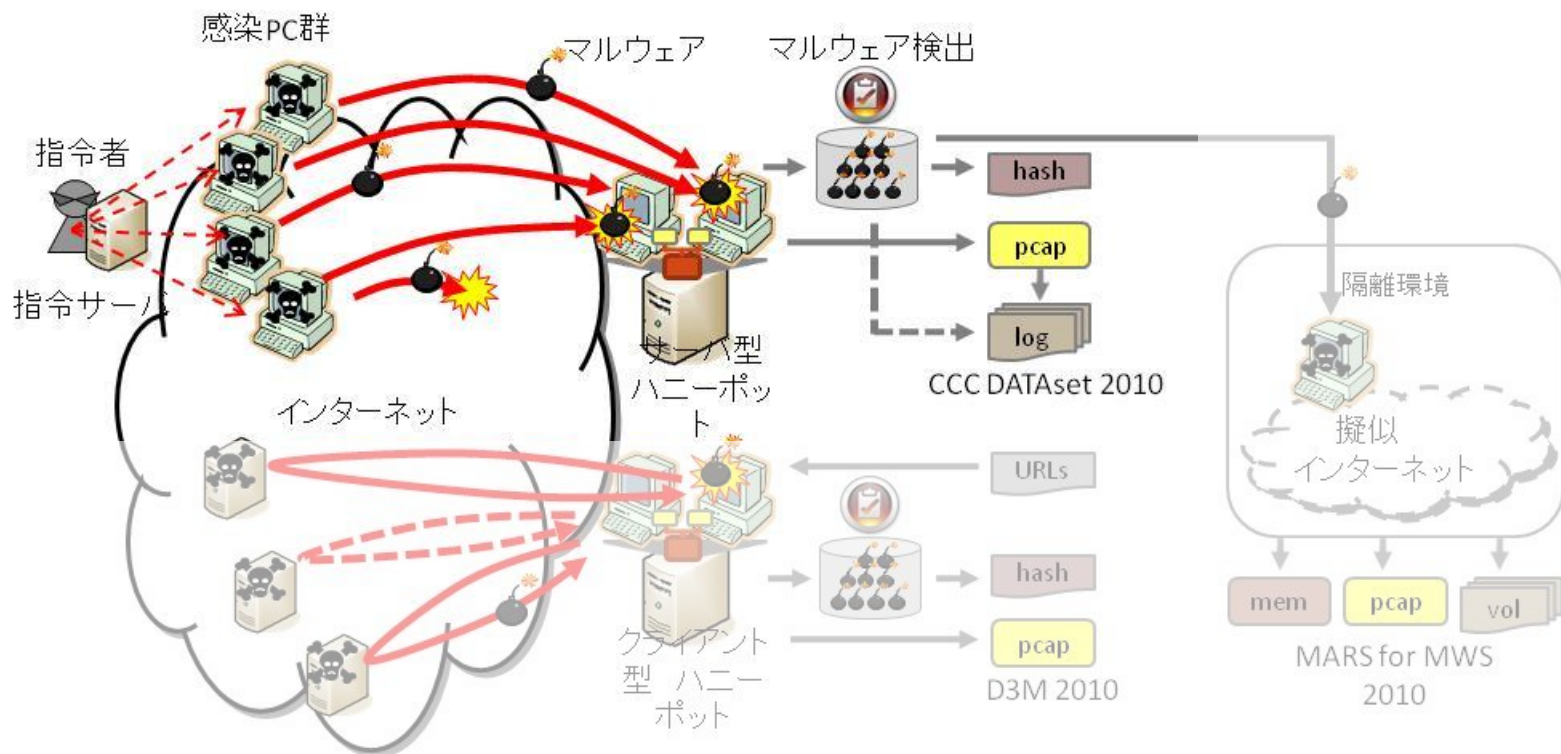


MWS 2010 Datasets

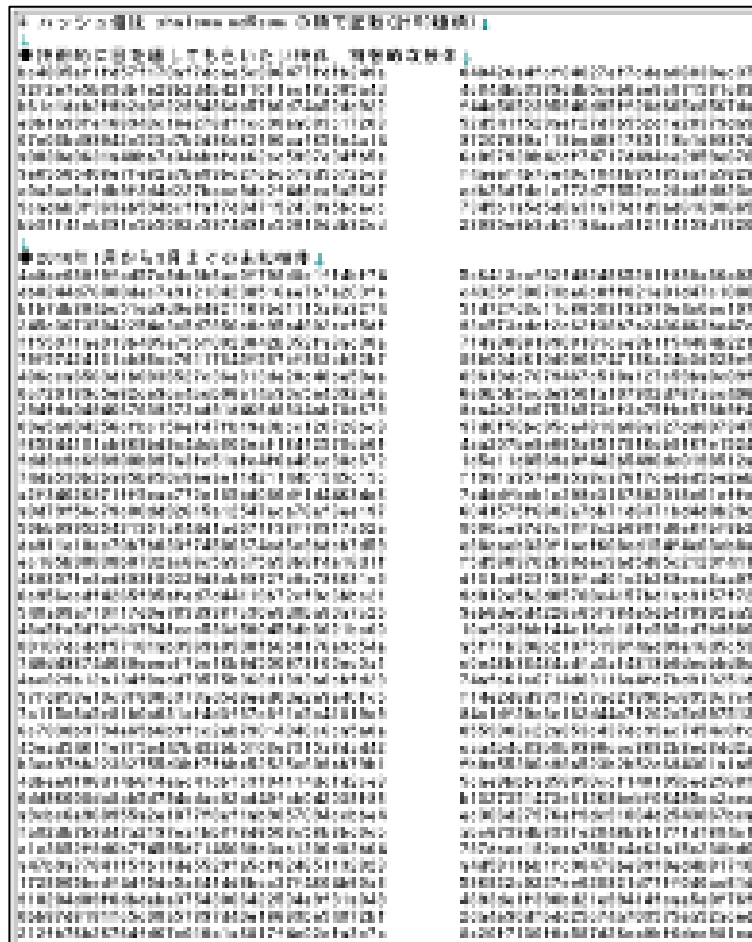
- ▶ CCC DATASet 2010 (NTTコミュニケーションズ/CCC)
 - ▶ CCCが提供するサーバ型ハニーポットで収集したデータ群
- ▶ MARS for MWS 2010 (CSEC研究会/NICT)
 - ▶ CCC DATASet 2010のマルウェア検体を擬似環境で動作させて得た一次解析結果のデータ群
- ▶ D3M 2010 (NTTコミュニケーションズ/NTT PF研)
 - ▶ クライアント型ハニーポットで収集したWeb感染型マルウェアに関するデータ群

CCC DATAsset 2010

- ▶ マルウェア検体
- ▶ 攻撃通信データ
- ▶ 攻撃元データ



CCC DATaset 2010 – マルウェア検体

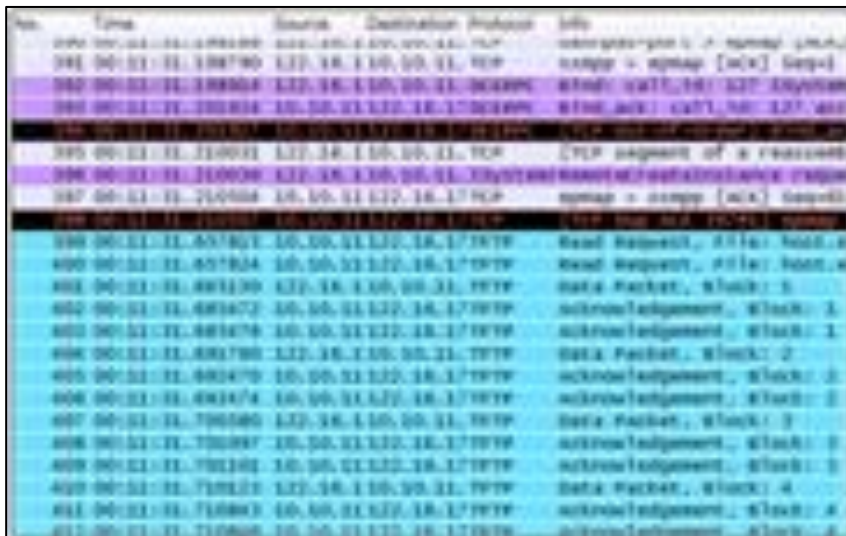



▶ 50検体のハッシュ値

▶ 解析結果を照合できる検体: 10検体

▶ 未知検体: 40検体

CCC DATAsset 2010 – 攻撃通信データ



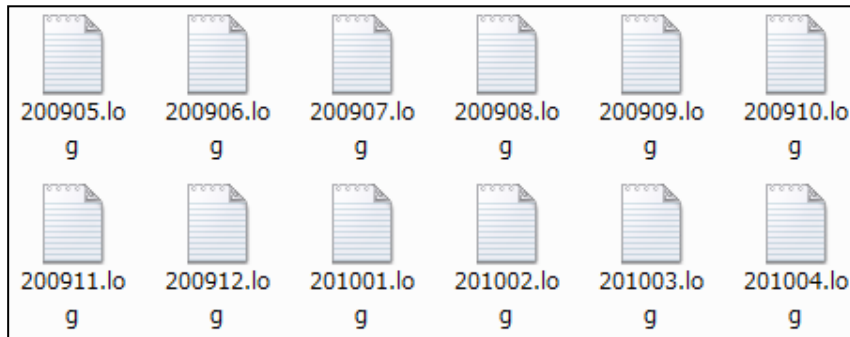
▶ サーバ型ハニーポット2台の
パケットキャプチャデータ

▶ Windows XP SP1+α

▶ 2010年3月5日～11日

▶ 2200万パケット、3.5GB

CCC DATAsset 2010 – 攻撃元データ



- ▶ ハニーポット92台のマルウェア取得時のログ
- ▶ 116万件 (TCP: 105万件)
- ▶ 3万種 (ハッシュ)、1000種 (ウイルス名称) の検体

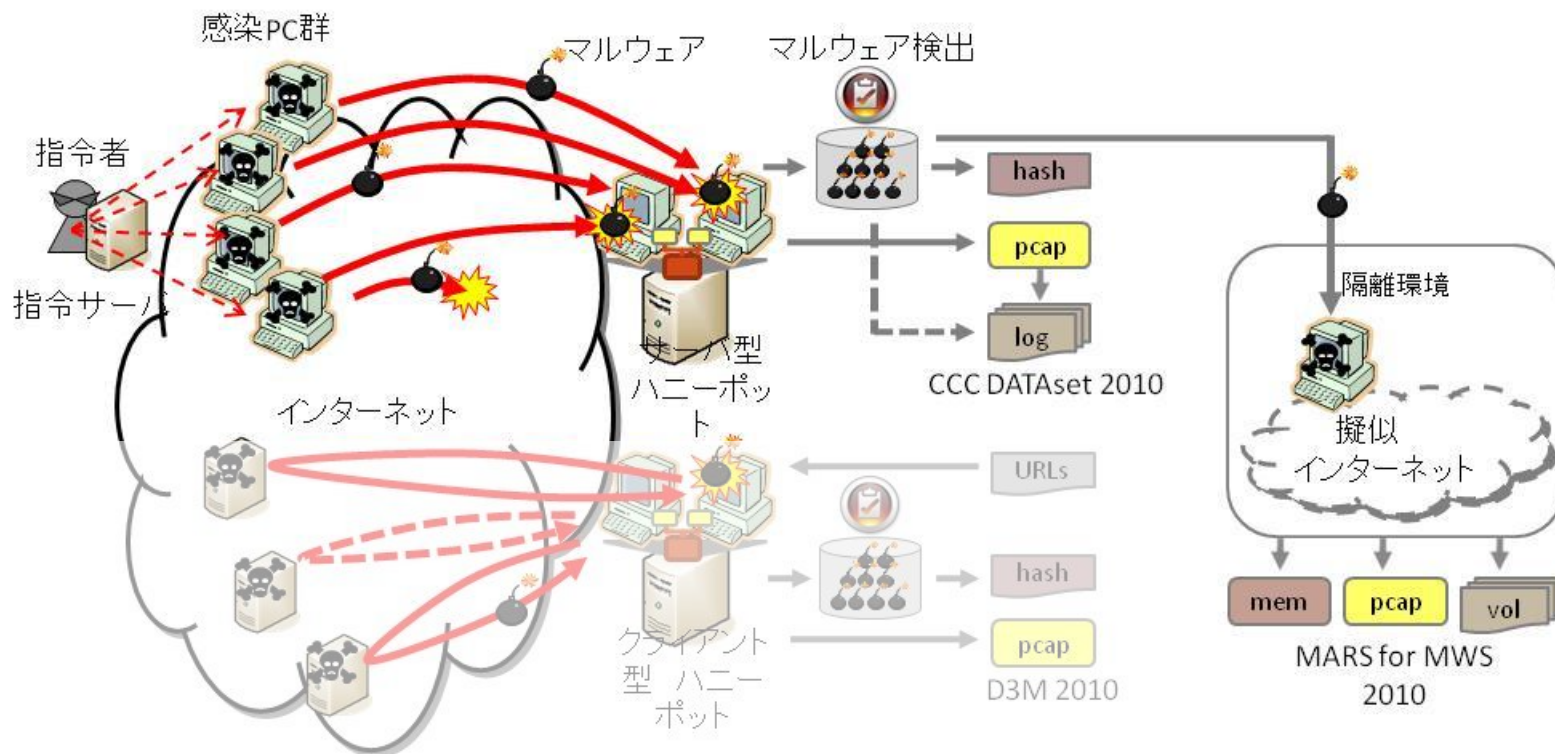
ログ項目	例(一部を*でマスク)
マルウェア検体の取得時刻	2010-03-05 03:02:41
送信元IPアドレス	honey001
送信元ポート番号	1028
宛先IPアドレス	** .243.167
宛先ポート番号	5824
TCPまたはUDP	TCP
マルウェア検体のハッシュ値 (SHA1)	*****bc3c850cf68a39c9e8013f2169d408a9d90
ウイルス名称	WORM_DOWNAD.AD
ファイル名	C:¥WINDOWS¥system32¥dhnlr.dll

CCC DATAsset 2010 – 2008/2009比較

項目	2008	2009	2010
マルウェア検体			
検体数	1	10	50
選定条件	多機能, 解読困難	解析結果あり, 関連性のある複数検体, 特徴的な機能	解析結果あり, 特徴的な機能, 2010年1月～3月に収集した未知検体
攻撃通信データ			
ハニーポット	honey001, honey002	honey003, honey004	honey001, honey002
収集日	2008/4/28, 2008/4/29	2009/3/13, 2009/3/14	2010/3/5～2010/3/11
総パケット数	15,901,943	3,511,850	22,486,674
攻撃元データ			
ハニーポット数	112台	94台	92台
ハニーポットID	なし(ダウンロードホストと通信方向のみ)	あり	あり
収集期間	2007/11/1～2008/4/30	2008/5/1～2009/4/30	2009/5/1～2010/4/30
全レコード数	2,942,221	2,470,766	1,162,093

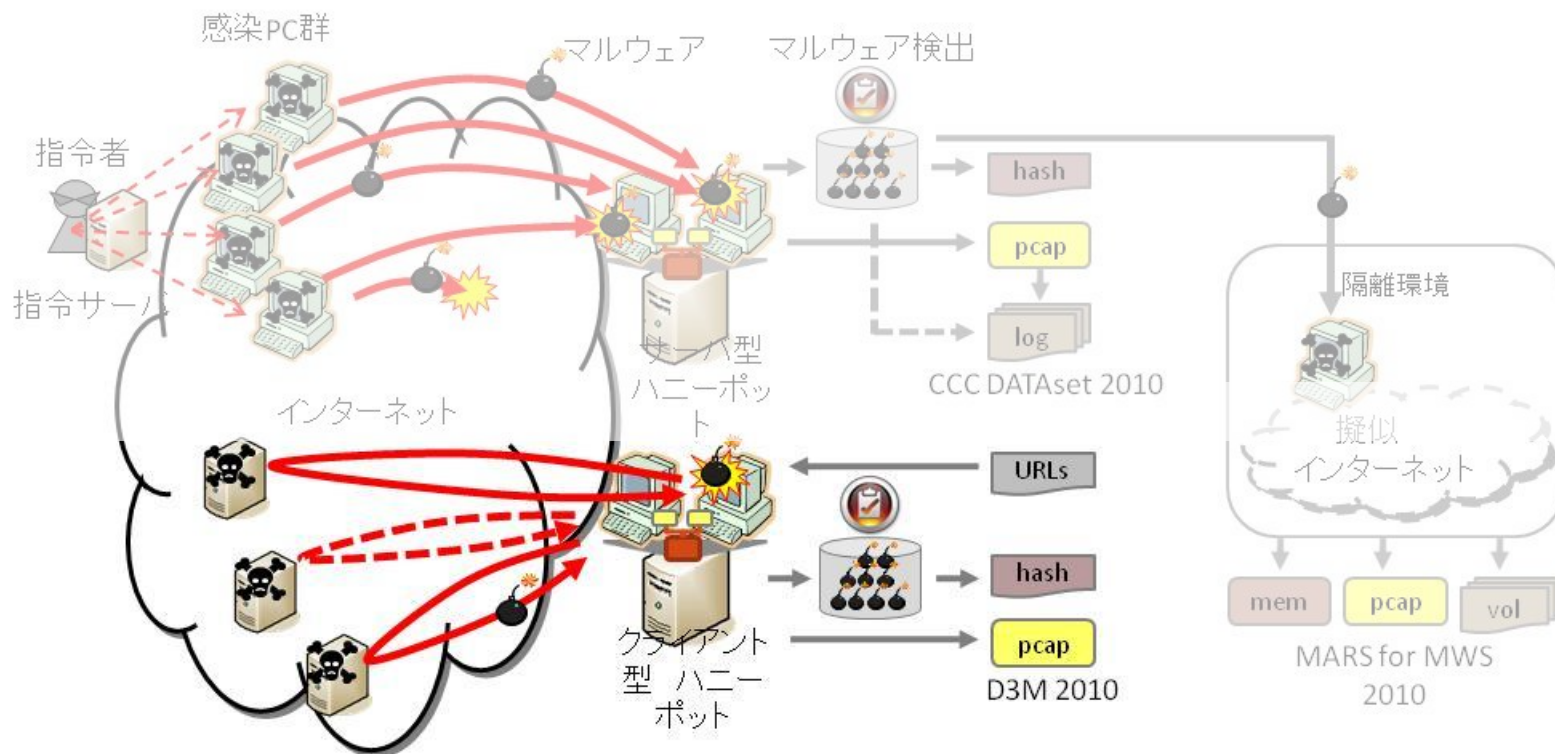
MARS for MWS 2010

- ▶ CCC DATAsset 2010のマルウェア検体を擬似環境で動作させて得た一次解析結果のデータ群
- ▶ 解析結果の応用によるマルウェア解析技術の研究



D3M 2010

- ▶ クライアント型ハニーポットで収集したWeb感染型マルウェアに関するデータ群
- ▶ マルウェア解析技術、感染手法の検知技術の研究



D3M 2010



No.	Type	Source	Destination	Protocol	Size
201	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
202	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
203	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
204	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
205	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
206	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
207	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
208	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
209	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
210	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
211	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
212	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
213	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
214	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
215	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
216	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
217	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
218	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
219	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60
220	2010-03-08 14:00:00	192.168.1.100	192.168.1.100	TCP	60



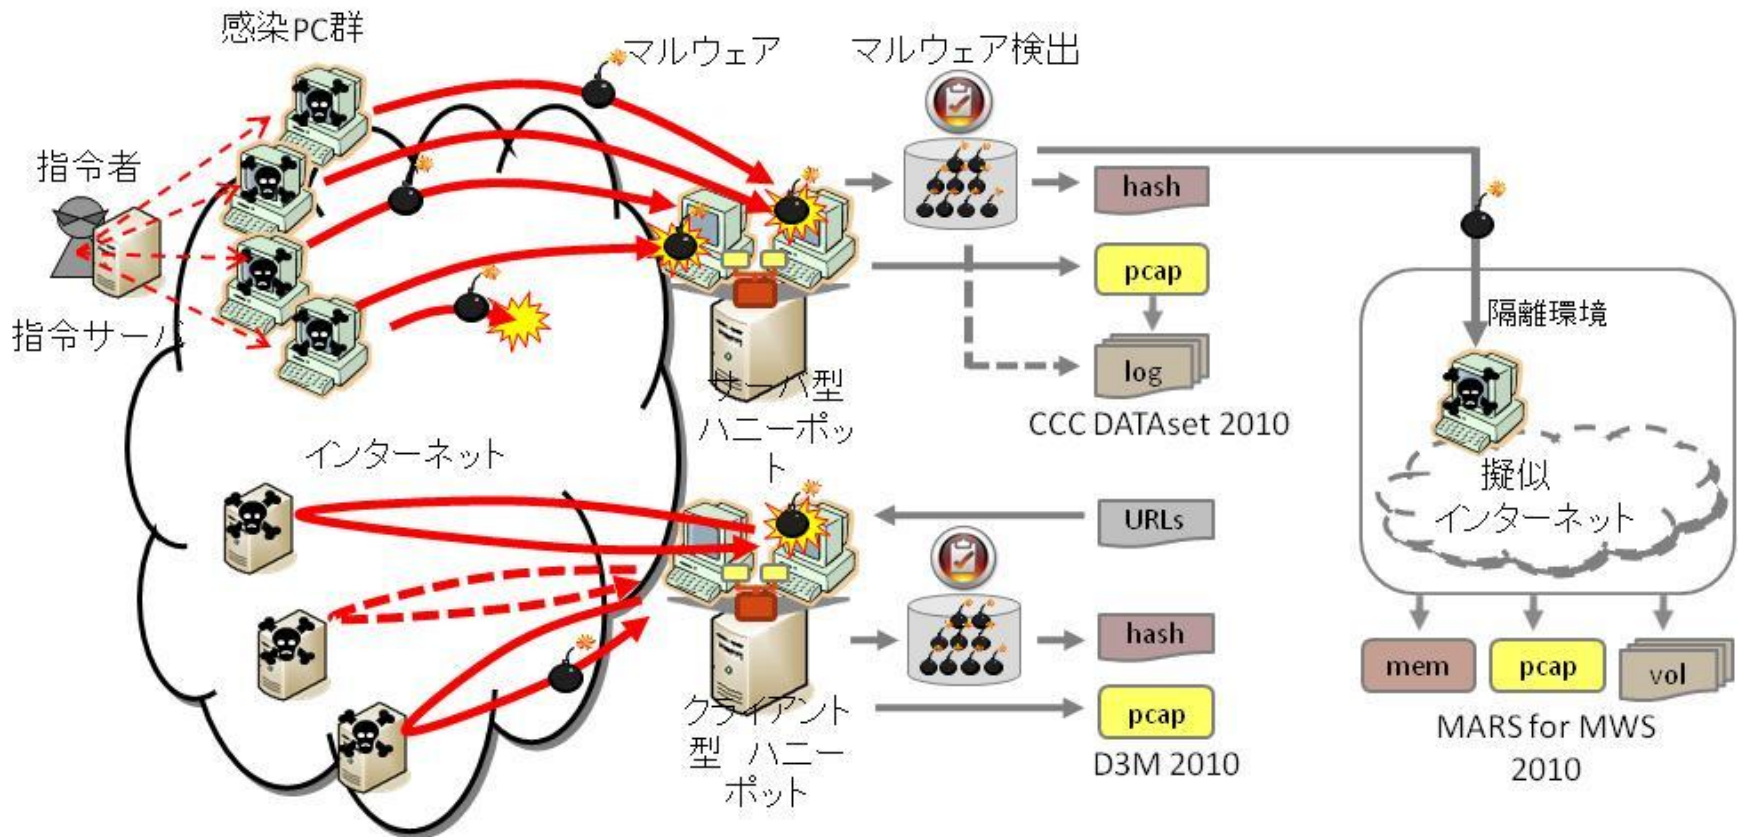
- ▶ マルウェア検体
 - ▶ 3検体のハッシュ値
 - ▶ Gumblar: 8080系
- ▶ 攻撃通信データ
 - ▶ Windows XP SP2
 - ▶ 2010年3月8、9、11日
 - ▶ 入り口URL
 - malwaredomainlist.com
 - ▶ 各日で205、180、172個
 - ▶ 133MB

研究用データセットの利用実績

		2008	2009	2010
CCC DATASET	マルウェア検 体	5	7	6
	攻撃通信デー タ	9	14	5
	攻撃元データ	8	6	5
MARS				1
D3M				4
総括			1	1
合計		22(8)	28(15)	22(10)

今後の課題

- ▶ データ種類、収集環境の網羅性、期間、運用/構成情報
- ▶ 正常データも



MWS201x これからが本番

参考文献

- ▶ MIT Lincoln Laboratory, DARPA Intrusion Detection Evaluation Data Sets, <http://www.ll.mit.edu/mission/communications/ist/corpora/ideval/index.html>
- ▶ B. Sangster, et al.: Toward Instrumenting Network Warfare Competitions to Generate Labeled Datasets, 18th USENIX Security Symposium CSET'09 (2009.08)
- ▶ サイバークリーンセンター, <https://www.ccc.go.jp/>
- ▶ 畑田充弘, 他: マルウェア対策のための研究用データセットとワークショップを通じた研究成果の共有, 情報処理学会シンポジウムシリーズ, Vol.2009, No.11, CSS2009(MWS2009), pp.1-8 (2009.10)
- ▶ 畑田充弘: 研究用データセットを用いたマルウェア対策研究人材育成ワークショップ, 情報処理, Vol.51, No.3, pp.284-287 (2010.03)
- ▶ 竹森敬祐, 他: MWS Cup 2009, 情報処理, Vol.51, No.3, pp.296-299 (2010.03)
- ▶ マルウェア対策研究人材育成ワークショップ, <http://www.iwsec.org/mws/2010/>
- ▶ 三輪信介, 他: 小規模攻撃再現テストベッドによる動作記録データセットの生成, 情報処理学会シンポジウムシリーズ, Vol.2009, No.11, CSS2009(MWS2009), pp.931-936 (2009.10)
- ▶ N. Petroni, et al: FATKit: A Framework for the Extraction and Analysis of Digital Forensic Data from Volatile System Memory, Digital Investigation Journal 3(4) (2006.12)
- ▶ Mitsuaki Akiyama, et al: Design and Implementation of High Interaction Client Honeypot for Drive-by-download Attacks, IEICE Transactions on Communication, Vol.E93-B No.5 pp.1131-1139 (2010.05)