# Sistemi di Monitoraggio Distribuiti Automonitoranti

Aldo Franco Dragoni, Paolo Giorgini, Andrea Corsi

Istituto di Informatica, Università di Ancona,
via Brecce Bianche, 60131, Ancona (Italy)
{dragon,giorgini}@inform.unian.it

**Abstract.** La fusione e l'interpretazione di dati provenienti da sensori, sono operazioni critiche in caso di conflitto. Se il modello descrittivo del sistema monitorato è corretto ed i componenti lavorano correttamente, allora le incompatibilità tra i dati possono essere imputate solo al deterioramento, o a rotture permanenti, di uno o più sensori.
L'articolo introduce e discute tre semplice idee:

1. La "Model-Based Diagnosis" classica può essere estesa direttamente per incorporare il modello dei sensori nella descrizione del sistema, in modo tale da diagnosticare anche i malfunzionamenti degli stessi (*sensors' faults*)
2. dall'analisi storica dei *conflitti minimali* diagnosticati tra i sensori, si possono trarre interessanti conclusioni riguardanti la loro *attendibilità* relativa (attraverso il Condizionamento Bayesiano)
3. l'attendibilità stimata dei sensori è utile per valutare (attraverso la Regola di Combinazione di Dempster) lo *stato attuale* del sistema fisico monitorato, anche in caso di dati conflittuali e non ridondanti.

## 1 Introduzione

Frequentemente, le attrezzature scientifiche, i sistemi di controllo industriali ed i dispositivi diagnostici, elaborano dati provenienti da più sensori. Di solito, i dati ricevuti sono confrontati con un modello teorico del processo/fenomeno monitorato in modo tale da individuarne lo stato (in caso di un sistema di controllo) o per validare la teoria (nel caso di esperimenti scientifici). Le discrepanze tra il modello teorico ed i dati forniti dai sensori, possono essere imputati sia ai sensori, sia alla teoria (o ad entrambi). Possiamo distinguere tre casi:

1. almeno un sensore non ha fornito il valore corretto della grandezza misurata
2. il modello teorico non è (completamente) applicabile al sistema monitorato attuale poiché:
   a) la teoria (scientifica) deve essere raffinata (interpretazione *oggettiva*)
   b) il sistema fisico non sta lavorando come dovrebbe (interpretazione *teleonomica*)

Il caso 1, spesso indicato come *Sensor Data Validation* (SDV), ha guadagnato molto interesse negli ultimi anni [1,2,3,4]. Come illustrato in [5], i metodi presenti in letteratura possono essere distinti in tre categorie:

SDV1. *data*-based: metodi che si basano su modelli statistici ottenuti dai dati osservati

SDV2. *model*-based: metodi che si basano su un modello analitico del sistema monitorato

SDV3. *knowledge*-based: metodi che si basano sulla conoscenza (esperienza) di esperti

Il caso 2 è stato studiato approfonditamente nell'ambito dell'Intelligenza Artificiale, o come un problema di *Revisione della Conoscenza* (Belief Revision, BR; si veda [6] per una rassegna) o come un problema di diagnosi basata su modello (Model Based Diagnosis, MBD; si veda [7] per una rassegna). Ci sembra evidente che la BR e la MBD sono problemi duali. Nell'ultima decade, la MBD è passata dalla fondazione teorica [8][9] ad alcune applicazioni pratiche (si veda ad esempio [10]). Nella MBD, le diagnosi sono trovate come discrepanze tra le osservazioni e quello che ci si aspetta di osservare. Il passo intermedio è la generazione esaustiva dei "conflict sets" per la terna (*SD*,*COMPS*,*OBS*), nella quale la descrizione del sistema (*S*ystem *D*escription) e le osservazioni (*OBS*ervations) sono insiemi di sentenze del primo ordine ed i componenti (*COMP*onent*S*) un insieme finito di costanti ognuna delle quali rappresenta un componente del sistema [11]. Una diagnosi è un sottoinsieme di *COMPS* che copre tutti i conflict sets.

Un problema importante insito nella MBD, è che ognuno dei suoi tre passi fondamentali, predizione, rilevazione dei conflitti e generazione di candidati, presenta un'esplosione combinatoriale per dispositivi di grandi dimensioni [12]. Comunque, il problema peggiore è relativo al caso 2a visto sopra: è difficile trovare un modello corretto del sistema da diagnosticare. Questo articolo non tratta tali problemi: li eluderemo entrambi imponendo la relativa semplicità dell'apparato che deve essere controllato o diagnosticato. Invece, questo articolo introduce, discute e presenta risultati sperimentali riguardo ai seguenti tre punti:

1. il problema dell'individuazione dei sensors' faults, può essere interamente ricondotto all'interno del framework della MBD (sezione 2)
2. dai sensors' faults diagnosticati, si possono formulare interessanti conclusioni a riguardo delle attendibilità relative dei sensori (sezione 3)
3. dall'attendibilità stimata dei sensori, si può ipotizzare lo stato del sistema fisico monitorato anche in caso di dati conflittuali e non ridondanti (sezione 4).

Ai sensori sono associate delle importanti caratteristiche (precisione, tempo di vita medio, ...) necessarie per stimarne le *attendibilità a priori*. Per attendibilità di un sensore, intendiamo la *probabilità* che il sensore stia fornendo il valore corretto della grandezza misurata (tenendo conto della precisione dello stesso). L'*attendibilità attuale* di un sensore può essere minore di quella a priori a causa di eventi sconosciuti o imprevedibili che possono essere occorsi nella fase di assemblaggio o nell'uso corrente nel sistema monitorato. Naturalmente la condizione del sensore può essere valutata attraverso un appropriato dispositivo di testing. Ma, a parte il problema accademico della regressione infinita (quale dispositivo testerà il dispositivo di testing, e così via ...), una questione concreta è che il testing ha i suoi costi. Per esempio, nell'apparato di monitoraggio di una linea di produzione automatica, alcuni sensori ottici possono essere alterati in conseguenza ad una temporanea rottura del dispositivo di condizionamento che ripulisce l'aria dalle particelle di polvere prodotte dal generatore di potenza. Poiché testare i sensori implica fermare il processo di produzione, alcune informazioni riguardo al loro possibile malfunzionamento, saranno sicuramente utili. Nel caso di sensori termici situati in prossimità del nucleo di una centrale nucleare, una evidenza circa il deterioramento di un numero limitato di sensori, ridurrà drasticamente i costi di manutenzione. Il punto 2 sopra menzionato, suggerisce che tale evidenza, può essere estratta dal modello teorico del processo/fenomeno monitorato e dal dato *globale* fornito dall'apparato di monitoraggio *distribuito*. Il gruppo dei sensori agisce come un dispositivo di testing per ognuno dei suoi membri. Naturalmente, la valutazione dipende dalla media delle attendibilità di tutti i sensori del gruppo (inclusi quelli corrotti) e dalla precisione del modello del sistema monitorato. In ogni caso, queste stime non saranno comparabili (né per qualità né per tipologia) con le valutazioni effettuate da specifici dispositivi di testing. Così facendo, non si interferisce in alcun modo nel processo di produzione e gli unici costi da sostenere sono quelli per una CPU, per alcune schede di acquisizione dati e per un dispositivo di memorizzazione. L'idea chiave di questo lavoro è il "minimal conflict". Intuitivamente, se si è rilevato un conflitto minimale tra i sensori A e B (confrontando i dati ricevuti con il modello teorico) e, successivamente, un'altra incompatibilità minimale coinvolge B e C, è ragionevole supporre come più probabile il deterioramento di B piuttosto che quello contemporaneo di A e C. Trattando con le probabilità, non vogliamo reinventare la ruota poiché il Condizionamento Bayesiano [13] (sezione 3) sembra uno strumento appropriato per eseguire tale compito. Semplicemente, la nuova attendibilità di un sensore S, sarà calcolata come la probabilità che S abbia fornito il valore corretto, alla luce del fatto che esso sia stato coinvolto in qualche minimal conflicts. Più grande è la cardinalità di questi minimal conflicts, più grande sarà la probabilità che S sta lavorando correttamente. Il caso peggiore è quando S viene coinvolto in un minimal conflict di cardinalità uno (ad esempio quando S esce dal range dei valori compatibili con il modello teorico) cosicché la sua nuova attendibilità è zero. L'attendibilità corrente di ogni sensore verrà stimata statisticamente.

Ci sono dei casi in cui il costo per testare un sensore è infinito, ovvero la valutazione delle condizioni del sensore è impossibile o non conveniente. Pensiamo, ad esempio, all'apparato sensoriale di una stazione satellitare priva di personale a bordo o a domini real-time, nei quali si ricevono dati impossibili (o altamente improbabili) e non si ha il tempo per controllare i sensori. Questi casi ricadono nella classica disciplina del *supporto alle decisioni sotto incertezza*. In queste circostanze, la graduatoria delle attendibilità stimate gioca un ruolo importante, benché rozzo: essa fornisce una stima più giustificata ed aggiornata di quella a priori. In aggiunta, le attendibilità stimate possono essere utilizzate per determinare la credibilità dei dati. Eseguiamo tale compito attraverso lo strumento della Regola di Combinazione di Dempster così come Shafer e Srivastava l'hanno applicata nel campo dell'"auditing" [14] (sezione 4).

La sezione 5 descrive due tra i vari esperimenti simulati condotti nell'ultimo anno; la sezione 7 riporta alcune conclusioni che possono essere tratte dai nostri esperimenti, puntando l'attenzione al più grande ostacolo che ci siamo trovati ad affrontare: la *sovraesposizione* relativa di alcuni sensori.

## 2 Diagnosi dei sensors' faults

Benché queste idee provengono da una linea indipendente di ricerca [15], la diagnosi dei sensors' faults può essere fatta all'interno del framework della MBD estendendo la descrizione del sistema (Fig. 1-A) per incorporare i modelli dei sensori (Fig. 1-B).

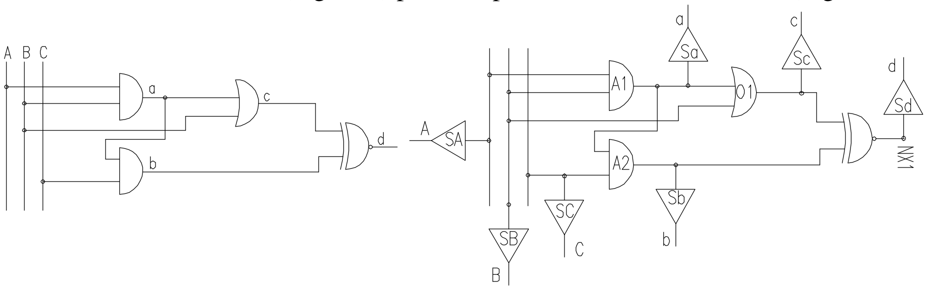


**A** **B**

**Fig. 1**. Si estende la nozione di sistema per incorporare i modelli dei sensori

Naturalmente, la SD sarà estesa congruentemente (sotto in neretto):

*COMP* :{ A1, A2, O1, NX1, $\mathbf{S_A, S_B, S_C, S_a, S_b, S_c, S_d}$ }

*SD* : $ANDG(x) \wedge \neg AB(x) \Rightarrow out(x) = and(in1(x), in2(x))$

$NXORG(x) \wedge \neg AB(x) \Rightarrow out(x) = nxor(in1(x),in2(x))$

$ORG(x) \wedge \neg AB(x) \Rightarrow out(x) = or(in1(x),in2(x))$

$\mathbf{SENS(x) \wedge \neg AB(x) \Rightarrow out(x) = in(x)}$

ANDG(A1), ANDG(A2), NXORG(NX1), ORG(O1)

**SENS($S_A$), SENS($S_B$), SENS($S_C$), SENS($S_a$), SENS($S_b$), SENS($S_c$), SENS($S_d$)**

out(A1) = in1(O1), out(A1) = in1(A2), out(A2) = in2(NX1), out(O1) = in1(NX1)

in2(A1) = in2(O1), in($S_A$) = IN1(A1), in($S_B$) = IN2(A1), in($S_C$) = IN2(A2),

in($S_a$) = OUT(A1), in($S_b$) = OUT(A2), in($S_c$) = OUT(O1), in($S_d$) = OUT(NX1)

$in1(A1) = 0 \vee in1(A1) = 1$, $in2(A1) = 0 \vee in2(A1) = 1$, $in2(A2) = 0 \vee in2(A2) = 1$

*OBS* : un insieme finito di sentenze del primo ordine ground

Ricordando da [9], un *conflict set* per (*SD*,*COMPS*,*OBS*) è un sottoinsieme $\{x_1,\ldots,x_k\}$ di *COMPS* tale che $SD \cup OBS \cup \{\neg AB(x_1),\ldots,\neg AB(x_k)\}$ è inconsistente. Un conflict set per (*SD*,*COMPS*,*OBS*) è minimale se e solo se nessun suo sottoinsieme proprio è un conflict set per (*SD*,*COMPS*,*OBS*). Ogni *minimal hitting set* per la collezione di tutti i minimal conflict sets sarà una *diagnosi* per (*SD*,*COMPS*,*OBS*).

La potenza di questo framework è la capacità di diagnosticare contemporaneamente il malfunzionamento dei componenti e dei sensori (trattando così entrambi i casi 1 e 2a visti in precedenza). Comunque, spesso i sensori osservano sistemi fisici in cui manca la nozione di componente (ad esempio un sistema di monitoraggio sismico distribuito [17,18]). In questi casi, *COMPS* contiene solo i sensori, *SD* si riduce al modello matematico (magari molto complesso) del fenomeno osservato e *OBS* è un semplice vettore di dati numerici e/o booleani. Come esempio, consideriamo una barra metallica, riscaldata ad una estremità e monitorata attraverso dei termometri come mostrato in Fig. 2.

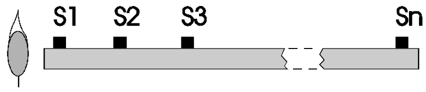


**Fig. 2**. Diagnosi di faults in un sistema sensoriale puro

Anche ignorando l'equazione di trasferimento del calore nella barra, possiamo ancora modellare il sistema con semplici vincoli (in neretto il caso di soli tre sensori):

*COMP* :{$S_1$, $S_2$, $S_3$}

*SD* : SENSOR(x) $\wedge$ $\neg$AB(x) $\Rightarrow$ out(x) = in(x), SENS($S_1$), SENS($S_2$), SENS($S_3$)

**out($S_1$) $\geq$ out($S_2$), out($S_2$) $\geq$ out($S_3$)**

*OBS* : una tripla di valori numerici

Per esempio, da *OBS*={out($S_1$)=153°C, out($S_2$)=175°C, out($S_3$)=168°C} possiamo derivare i minimal conflict sets {{$S_1$, $S_2$}, {$S_1$, $S_3$}} e le diagnosi {{$S_1$}, {$S_2$, $S_3$}}.

Un concetto importante nell'utilizzo della MBD nel SDV, è quello di *good* (così come lo abbiamo chiamato per l'ovvia dualità con il *nogood* di de Kleer, chiamato"minimal conflict set" da Reiter), cioè un sottoinsieme {$x_1$,…,$x_k$} di *COMPS* tale che *SD*$\cup$*OBS*$\cup${$\neg$AB($x_1$),…,$\neg$AB($x_k$)} è *consistente* e tale che lo stesso è inconsistente per i *super*insiemi propri di {$x_1$,…,$x_k$}. Ogni good è il complemento di una diagnosi rispetto a *COMP*, cioè, un insieme massimamente consistente di sensori. I goods giocano un ruolo importante quando si cerca di valutare lo stato del sistema in presenza di dati conflittuali. Infatti, a causa della dualità tra goods e diagnosi, scegliere la diagnosi più probabile, significa scegliere il good più probabile e cioè la ricostruzione dello stato del sistema più probabile (e completa).

Un problema della MBD applicata al SDV è che, indipendentemente dall'accuratezza di SD, la teoria *SD*$\cup$*OBS*$\cup${$\neg$AB(x)| x$\in$*COMPS*} può essere *consistente* anche in caso di sensors' faults. Questi *faults nascosti* possono verificarsi, ad esempio, nel caso della rottura contemporanea di più sensori, tale che l'output globale sia ancora possibile (benché errato).

## 3 Stima dell'attendibilità attuale dei sensori

Poiché i faults nascosti costituiscono un problema, la rilevazione con successo di *minimal* conflicts offre una grande opportunità per stimare, statisticamente, l'attendibilità attuale dei sensori a partire da quella a "priori". Il modo più ovvio per far questo, è attraverso il Condizionamento Bayesiano, poiché abbiamo definito l'attendibilità del sensore, come la probabilità che il sensore fornisca il valore corretto della grandezza misurata. Indichiamo con $R_i$ e $NR_i$, rispettivamente, l'attendibilità a "priori" ed a "posteriori" del sensore $S_i$, e indichiamo con $S$ l'insieme *COMPS* ristretto ai sensori. Sotto l'assunzione che il deterioramento di ogni sensore è un evento indipendente (!?!), l'ipotesi che solo quei sensori appartenenti a $\Phi\subseteq S$ stiano funzionando correttamente, ha la probabilità combinata a "priori"

$R(\Phi)=\prod_{S_i\in\Phi} R_i \cdot \prod_{S_i\notin\Phi}\left(1-R_i\right)$. Risulta che $\sum_{\Phi\in 2^S} R(\Phi)=1$.

Naturalmente, dopo l'identificazione di un minimal conflict $\phi$, $NR(\Phi)=0$ per ogni $\Phi \supseteq \phi$, ed ogni altro $\Phi$ è soggetto al Condizionamento Bayesiano cosicché $\sum_{\Phi \in 2^S \wedge \phi \not\subset \Phi} NR(\Phi)=1$. L'attendibilità a "posteriori" di $S_i$ è definita come $NR_i = \sum_{S_i \in \Phi} NR(\Phi)$.

Se $S_i$ è coinvolto in un *minimal* conflicts, allora $NR_i \leq R_i$, altrimenti $NR_i = R_i$.

Stimando le attendibilità correnti $CR_i$ di un sensore $S_i$ da $R_i$ e dalla storia dei minimal conflicts individuati, seguiamo un procedimento statistico. Negli esperimenti della sezione 5, prendiamo per $CR_i$ la media di tutte le $NR_i$ calcolate durante la vita del sistema di monitoraggio distribuito[1]. Come vedremo, tale $CR_i$ fornisce un interessante ordinamento relativo delle attendibilità. Il sistema sensoriale distribuito, agisce come un dispositivo di testing per ognuno dei suoi membri, da cui il titolo di questo articolo.

## 4 Scegliere il good preferito

Nella versione multi-sorgente di Shafer e Srivastava del framework delle "Belief Function" (funzioni di credibilità) [14], i gradi di attendibilità delle sorgenti sono tradotti in valori delle Belief Function sui dati forniti. Nel nostro metodo seguiamo i sopra citati, considerando l'attendibilità stimata $CR_i$ come un'*evidenza* primaria in favore del dato $s_i$ fornito da $S_i$. Sia $\Omega$ l'insieme di tutte le possibili configurazioni del sistema monitorato, con $[s_i] \subseteq \Omega$ indichiamo solo quelle compatibili con $s_i$. L'assunzione chiave è che *un sensore attendibile non può fornire informazioni false, mentre un sensore non attendibile può fornire dati corretti*; l'ipotesi che "$S_i$ è attendibile" è compatibile solo con $[s_i]$, mentre l'ipotesi che "$S_i$ è *non* attendibile" è compatibile con $\Omega$ intero. Ogni $S_i$ dà un'evidenza per $\Omega$ e genera il seguente *assegnamento di probabilità base* (basic probability assignment; *bpa*) $m_i$ sugli elementi $X$ di $2^\Omega$:

$$m_i(X) = \begin{cases} CR_i & \text{se } X = [s_i] \\ 1 - CR_i & \text{se } X = \Omega \\ 0 & \text{altrimenti} \end{cases}$$

Tutte queste *bpa* saranno combinate attraverso la Regola di Combinazione di Dempster (DRC):

$$m(X)=m_1(X)\otimes\ldots\otimes m_n(X)=\frac{\sum_{X_1\cap\ldots\cap X_n=X} m_1(X_1)\cdot\ \ldots\ \cdot m_n(X_n)}{\sum_{X_1\cap\ldots\cap X_n\neq\emptyset} m_1(X_1)\cdot\ \ldots\ \cdot m_n(X_n)}$$

[1] $NR_i$ è calcolata solo alla rilevazione di dati conflittuali. Un'altra questione importante riguarda le dimensioni della finestra temporale, cioè, quanto ci dobbiamo spingere nel passato per registrare i dati conflittuali; intuitivamente, più grande è la finestra, maggiore è l'inerzia del meccanismo nell'individuare il deterioramento dei sensori.

Dalla *bpa m*, la credibilità di un insieme di dati *s* (e quindi anche di un good) è data da: $Bel(s) = \sum_{X \subseteq [s]} m(X)$

Un importante problema insito nel formalismo delle funzioni di credibilità è la complessità computazionale della DRC; l'applicazione diretta della regola è esponenziale nella cardinalità di Ω e nel numero dei sensori. Comunque, molti sforzi sono stati compiuti nel ridurne la complessità. Tali metodi vanno da implementazioni efficienti, [19] ad approcci qualitativi [20] ed a tecniche approssimate [21].

## 5 Esperimenti e risultati

Abbiamo sviluppato un simulatore per studiare le prestazioni del meccanismo proposto. Abbiamo eseguito una serie di esperimenti mirati a valutare la sua *sensibilità* (capacità di distinguere piccole differenze tra le attendibilità dei sensori) e la sua *robustezza* (capacità di fornire prestazioni accettabili in presenza di situazioni molto degradate). Il simulatore prende in input il reale grado di capacità dei sensori ($C_i$), il loro grado di attendibilità a "priori" ($R_i$), il modello del sistema monitorato e la lunghezza della simulazione. Ad ogni ciclo esso:

1. simula una acquisizione dati corretta
2. simula un errore (altera il dato di ogni sensore $S_i$ in accordo con $C_i$ presa come frequenza di errore)
3. se i dati risultanti contrastano con R, esegue il meccanismo proposto.

Negli esperimenti che seguono, il grado delle attendibilità a "priori" sono fissati a $R_i$=0.9.

### 5.1 Esperimenti con la barra riscaldata simulata

Abbiamo eseguito diversi esperimenti con la barra riscaldata di Fig. 2 modellata come descritto nella sezione 2. Per valutare l'eventuale dipendenza delle prestazioni del sistema dal numero dei sensori e dal range dei loro possibili valori di output (discreti), abbiamo eseguito le seguenti differenti simulazioni:

A. Tre sensori con valori di output {0,1,2,3,4,5,6,7,8,9}
B. Cinque sensori con valori di output {0,1,2,3,4}
C. Cinque sensori con valori di output {0,1,2}
D. Sette sensori con valori di output {0,1,2}.

*Sensibilità*
Per valutare la sensibilità del sistema, abbiamo realizzato alcune simulazioni con un solo sensore deteriorato. La Fig. 3 mostra un tipico andamento del caso B.

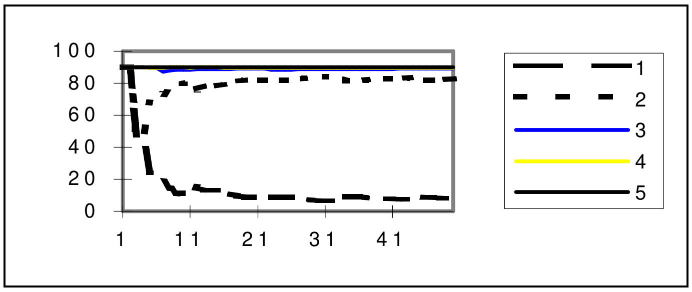


**Fig. 3**

Ricapitoliamo qui i risultati principali:

- il sistema è in grado di individuare il sensore corrotto con sufficiente velocità ed indipendentemente dalla sua capacità
- il tempo necessario per individuare il sensore corrotto aumenta con la sua capacità
- i risultati non dipendono dal range dei valori di output (probabilmente, ciò è dovuto alla particolare tipologia dell'errore considerata)
- i risultati migliorano con il numero dei sensori.

Naturalmente, individuando sempre il sensore corrotto, il meccanismo è in grado di scegliere l'insieme corretto di dati massimamente consistente attraverso la DRC.

*Robustezza*

Abbiamo fatto altre simulazioni con due o più sensori deteriorati. Le Fig. 4 e Fig. 5 mostrano andamenti tipici; in particolare, la Fig. 4 riguarda un caso di due sensori corrotti ($S_1$ e $S_3$: $C_1$=$C_3$=0.2), e la Fig. 5 un caso con tre sensori malfunzionanti ($S_1$, $S_2$ e $S_3$: $C_1$=$C_2$=$C_3$=0.2). Si può dedurre che:

- il meccanismo è ancora capace di individuare i sensori corrotti
- i gradi di attendibilità stimati dei sensori corrotti non sono così marcatamente diversi da quelli dei sensori che lavorano correttamente
- il meccanismo necessita di un tempo maggiore per scoprire i sensori corrotti
- i sensori corrotti sono innocentemente coinvolti in più minimal conflicts cosicché il loro grado di attendibilità diminuisce.

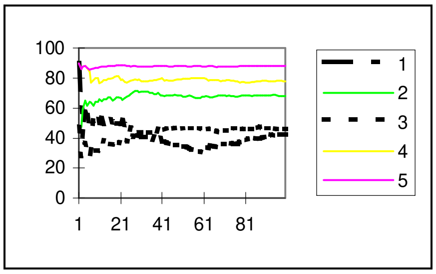


**Fig. 4**

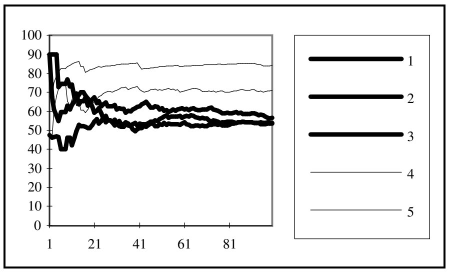


**Fig. 5**

In Fig. 6, ogni curva rappresenta la percentuale dei good corretti ottenuti con la DRC (dopo 50 cicli) per un dato numero di sensori deteriorati (2,3,4 e 5) con differenti capacità (0.9, …,0.2). Possiamo comparare i risultati ottenuti con quelli ricavati attraverso una scelta casuale (Fig. 7).

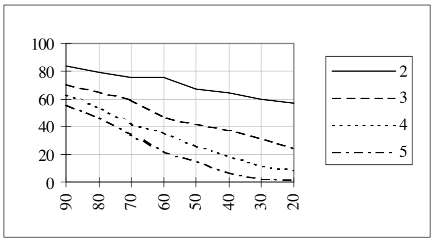


Fig. 6

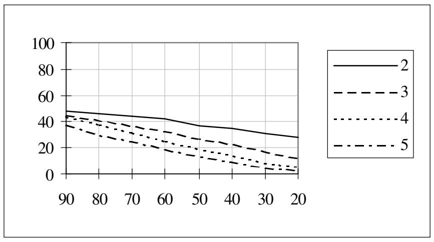


Fig. 7

## 5.2 Esperimenti con un circuito digitale

*Sensibilità*

Abbiamo simulato il sistema monitorante per il circuito digitale di Fig. 1.B. Ancora, abbiamo compiuto alcune simulazioni con un solo sensore deteriorato (con una capacità di 0.5); per esempio, il sensore *d* in Fig. 8 e il sensore *A* in Fig. 9.

In questi casi si può dedurre che:

- il meccanismo è ancora capace di individuare il sensore corrotto abbastanza rapidamente ed indipendentemente dalla sua capacità
- il meccanismo trova il sensore corrotto ma l’attendibilità stimata dipende dal particolare sensore (si notino in Fig. 8 e 9 i differenti andamenti per i sensori *A* e *d*).

Ancora, trovando sempre il sensore corrotto, il sistema sceglie sempre l’insieme di dati massimamente consistente corretto.

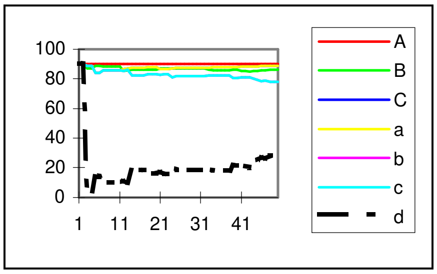


Fig. 8

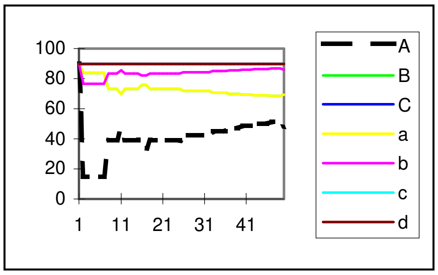


Fig. 9

*Robustezza*

In questo caso per valutare la robustezza, abbiamo eseguito alcune simulazioni con due o più sensori con capacità 0.5. Tab. 1 e Tab. 2 mostrano i risultati di due prove significative con due sensori deteriorati.

| *Sensore* | *Capacità* | *Attendibilità stimata* |
|---|---|---|
| A | 100 | 86.7 |
| **B** | **50** | **56.3** |
| C | 100 | 84.1 |
| **a** | **50** | **45.4** |
| b | 100 | 84.7 |
| c | 100 | 82.6 |
| d | 100 | 84.9 |

**Tab. 1**

| *Sensore* | *Capacità* | *Attendibilità stimata* |
|---|---|---|
| A | 100 | 83.67 |
| B | 100 | 71.68 |
| **C** | **50** | **80.42** |
| **a** | **50** | **37,9** |
| b | 100 | 85.76 |
| c | 100 | 88.81 |
| d | 100 | 87.55 |

**Tab. 2**

Si può notare che nella prima simulazione (Tab. 1) il sistema individua correttamente i sensori deteriorati, ma nella seconda (Tab. 2) attribuisce un valore di attendibilità troppo alto al sensore C.

La Fig. 10 mostra la percentuale di scelte corrette ottenute con la DRC al variare della particolare coppia di sensori corrotti. Possiamo comparare i risultati ottenuti con quelli ricavati attraverso una scelta casuale (Fig. 11).

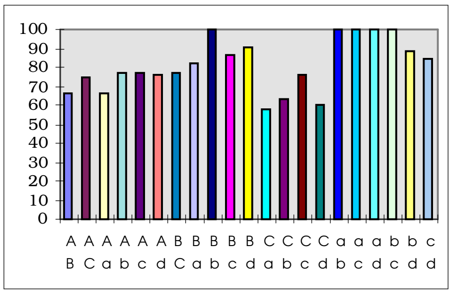


**Fig. 10**

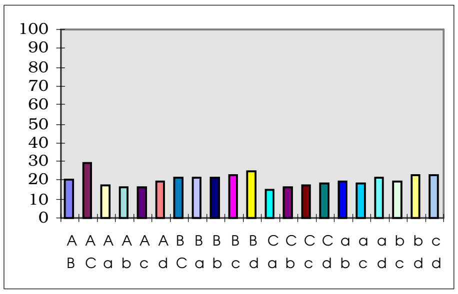


**Fig. 11**

Dalla Fig. 10 possiamo osservare che c'è una dipendenza delle prestazioni del sistema dai particolari (coppia) sensori corrotti. Abbiamo chiamato questo effetto *sovra-esposizione*: per sovra-esposizione di un sensore intendiamo la sua alta probabilità di essere coinvolto in minimal conflicts. Abbiamo tentato di individuare alcuni fattori di correzione per limitare l'impatto di questo effetto indesiderato; il problema sta nel fatto che tali fattori non sono numeri fissi ma funzioni delle reali capacità (non conosciute) dei sensori.

## 6 Lavori connessi

I lavori del SDV confrontabili con il sistema da noi proposto, appartengono alle categorie SDV1 e SDV2. I metodi model-based presuppongono l'esistenza di un modello analitico del sistema e condividono una metodologia comune: generazione di segnali che sono sensibili ai faults (*residui*) ed analisi degli stessi. Gli approcci principali proposti per la generazione dei residui si possono classificare in approcci che fanno uso della *ridondanza analitica* (es.: *parity space*) e approcci con l'*osservatore* (es.: *filtro di Kalman* [1]). I metodi model-based sono efficienti specialmente in quei casi in cui si dispone di un modello del sistema ben conosciuto e lineare. Parallelamente ai metodi sviluppati nell'ambito dei controlli automatici, si possono trovare in letteratura approcci al problema che fanno riferimento all'Intelligenza Artificiale. Sicuramente interessante è il lavoro svolto da S. C. Lee in [2]. In questo lavoro viene presentata una tecnica di validazione basata sulla ridondanza analitica. La tecnica presentata necessita di una conoscenza perfetta del processo fisico in esame. Anche il lavoro svolto da Washio in [22] propone un approccio basato sul modello del processo da monitorare per l'individuazione dei sensors' faults. I sensors' faults vengono individuati contestualmente alla diagnosi dei componenti all'interno dello stesso framework. In particolare tramite l'approccio proposto dall'autore è possibile diagnosticare: componenti non lineari, sensori e componenti e ampiezza del fault.

Esistono sicuramente delle applicazioni in cui la variabile tempo non compare ed il modello del processo da monitorare risulta statico. Ad esempio, Scarl et altri [16] hanno realizzato il sistema LES per il controllo del caricamento dell'ossigeno liquido nei serbatoi esterni dello Shuttle. LES opera su un dominio che può essere rappresentato come una gerarchia di controllo diretta senza anelli di retroazione ed in cui non sono presenti oggetti che hanno a che fare con lo stato. Conoscendo le relazioni funzionali tra comandi impartiti, componenti del sistema monitorato e le grandezze misurate, LES analizza la discrepanza tra valori attesi e misurati e determina lo stato di funzionamento dei componenti e dei sensori. Un limite di LES è quello di diagnosticare solo single-fault.

Anche se i metodi appartenenti all'area dell'intelligenza artificiale superano il problema delle non linearità, tutti i metodi model-based sono però sensibili agli errori di modellizzazione. Di conseguenza quando non è disponibile un modello preciso del sistema, una via alternativa è quella di utilizzare una descrizione qualitativa costituita da un insieme di regole derivate dall'esperienza umana: i metodi di validazione knowledge-based. Esempi tipici di tali metodi possono essere i sistemi esperti classici (costituiti da una base della conoscenza e da un motore inferenziale) e sistemi esperti fuzzy. Ad esempio, i sistemi model-based non possono essere applicati quando del processo si conoscono solo determinate relazioni espresse sotto forma di disequazione.

Noi abbiamo proposto un metodo che si basa sulla conoscenza del fenomeno/processo non necessariamente in termini di modello matematico così come inteso nei controlli automatici. Esso richiede un qualsiasi tipo di conoscenza dalla quale poter estrarre i *minimal conflicts*. Di conseguenza è possibile trattare oltre che con equazioni anche con vincoli di disuguaglianza ricalcando delle situazioni reali del tipo "se la temperatura è più alta di 100 °C la spia deve accendersi"; i sistemi model-based non possono gestire tale tipo di vincoli.

Nel SDV si assumono i componenti del sistema perfettamente funzionanti; questo vincolo può essere superato dall'approccio presentato, effettuando un'opportuna estensione.

Il sistema presentato si basa su un'analisi storica dei dati. Ciò consente di utilizzare le informazioni ricavate in precedenza per risolvere le situazioni di incertezza future che si presentano nel momento in cui bisogna scegliere tra una serie di possibili diagnosi per spiegare un insieme di dati inconsistente. I sistemi proposti in [22] e [16] non forniscono indicazioni su come effettuare queste scelte né introducono il concetto di attendibilità come strumento di selezione.

## 7 Conclusioni

L'elaborazione dei dati provenienti da più sorgenti risulta critica quando emergono conflitti tra i dati ricevuti. Questo articolo ha introdotto, discusso e riportato risultati sperimentali a riguardo dei seguenti tre punti:

1. il problema dell'individuazione dei sensors' faults, può essere interamente ricondotto all'interno del framework della model-based diagnosis
2. dalla storia dei sensors' faults è possibile formulare interessanti conclusioni a riguardo delle attendibilità relative dei sensori, attraverso l'uso del Condizionamento Bayesiano
3. dall'attendibilità stimata dei sensori, si può ipotizzare lo stato del sistema fisico monitorato anche in caso di dati conflittuali e non ridondanti, attraverso lo strumento della Regola di Combinazione di Dempster.

Il problema più grande presente in questo metodo è quello che abbiamo chiamato "effetto della sovra-esposizione". Crediamo che la soluzione di questo problema dipenda dal particolare dominio applicativo.

## Bibliografia


[1] Alag S. and A. M. Agogino, "A Methodology for Intelligent Sensor Validation, Fusion and Sensor Fault Detection for Dynamic Systems" #95-0301-P, 1995.

[2] S. C. Lee, "Sensor Value Validation Based on Systematic Exploration of the Sensor Redundancy for Fault Diagnosis KBS", IEEE Transactions on Systems, Man, and Cybernetics, Vol 24, n° 4, April 1994.

[3] S. Iksch, W. Horn, C. Popow, F. Paky, "Context-sensitive data validation and data abstraction for knowledge-based monitoring", in ECAI 94. 11th European Conference on Artificial Intelligence, 1994, pp. 48-52.

[4] D. Himmelblau and M. Bhalodia, "On-Line Sensor Validation of Single Sensor Using Artificial Neural Networks", in Proceedings of the 1995 American Control Conference, vol. 1, 1995, pp 766-770.

[5] Stephane Canu,"Sensor Data Validation: a Review", in $EM^2S$ Esprit European Project.

[6] Dragoni A.F., Belief Revision: from theory to practice, "The Knoledge Engineering Review", vol 12, n° 2, Cambridge University Press, 1997.

[7] de Kleer, J., Hamsher, W. C., Console, L., (Eds.): Readings in Model-Based Diagnosis, Morgan Kaufmann, 1992.

[8] de Kleer, B., C., Williams, Diagnosing Multiple Faults, Artificial Intelligence 32, pp. 97-130, 1987.

[9] R. Reiter, A Theory of Diagnosis from First Principles, Artificial Intelligence 32, pp. 57-95, 1987.

[10] Beschta, A., Dressler, O., Freitag, H., Montag, M., Stru§, P., A model-based approach to fault localisation in power transmission networks, Intelligent Systems Engineering, 2(1), IEE Publisher, pp. 3-14, 1993.
[11] de Kleer, J., Mackworth, A. K., Reiter, R., Characterizing Diagnoses, Proceedings of 1990 Conference of the American Association for Artificial Intelligence, pp 324-330, 1990.
[12] Johan de Kleer, Focusing on Probable Diagnoses, Proceedings of 1991 Conference of the American Association for Artificial Intelligence, pp 842-848, 1991.
[13] T. Bayes, "An essay towards solving a problem in the doctrine of chances." Philosophical Transactions Royal Soc'y London 53:370-418, 1763. Reprinted in various publications, e.g. Biometrika 45:293-315.
[14] Shafer G. and Srivastava R., The Bayesian and Belief-Function Formalisms a General Perpsective for Auditing, in G. Shafer and J. Pearl (eds.), Readings in Uncertain Reasoning, Morgan Kaufmann Publishers, 1990.
[15] A.F. Dragoni, P. Giorgini, P. Puliti, "Finding Inconsistencies as a Basis for Evaluating the Reliability of Different Information Sources", in Binaghi, E., Brivio, P.A. and Rampini, A. (Eds.), Soft Computing in Remote Sensing Data Analysis, Series in Remote Sensing, vol 1, World Scientific Publishing, 1996.
[16] Scarl Ethan a., Jamieson, Delaune. "Diagnosis and Sensor Validation trough Knoledge of Stucture and Function". IEEE Transactions on Systems, Man and Cybernetics, Vol 17, n° 3, May/June 1987.
[17] Mason, C., An Intelligent Assistant for Nuclear Test Ban Treaty Verification, IEEE Expert, vol 10, no 6, 1995.
[18] Cindy L. Mason and Rowland R. Johnson, datms: A Framework for Distributed Assumption Based Reasoning, in L. Gasser and M. N. Huhns eds., Distributed Artificial Intelligence 2, Pitman/Morgan Kaufmann, London, pp 293-318, 1989.
[19] Kennes, R., Computational Aspects of the Möbius Transform of a Graph, IEEE Transactions in Systems, Man and Cybernetics, 22, pp 201-223, 1992.
[20] Parson, S., Some qualitative approaches to applying the Demster-Shafer theory, Information and Decision Technologies, 19, pp 321-337, 1994.
[21] Moral, S. and Wilson, N., Importance Sampling Monte-Carlo Algorithms for the Calculation of Dempster-Shafer Belief, Proceeding of IPMU'96, Granada, 1996.
[22] Washio, Sakuma, Kitamura. "A new approch to quantitative and credible diagnosis for multiple faults of components and sensors". Arificial Intelligence Vol 91 pp. 103-130.