

5

UNIVERSITA' DEGLI STUDI DI NAPOLI "FEDERICO II"



**FACOLTÀ DI INGEGNERIA
DIPARTIMENTO DI INGEGNERIA DEI TRASPORTI
"L.TOCCHETTI"**

**CORSO DI LAUREA SPECIALISTICA IN INGEGNERIA CIVILE
PER L'AMBIENTE E IL TERRITORIO
CURRICULUM GOVERNO DELLE TRASFORMAZIONI TERRITORIALI**

**ABSTRACT
TESI DI LAUREA**

**CALIBRAZIONE DEI MODELLI DI SIMULAZIONE
MICROSCOPICA DEL TRAFFICO:
ANALISI DI SENSITIVITÀ DI FUNZIONI OBIETTIVO E
ALGORITMI DI OTTIMIZZAZIONE**

Relatore:

Ch.mo Prof. Ing. Vincenzo Punzo

Correlatore:

Ing. Biagio Ciuffo

Candidato:

Nicola Di Guida

Matr. 324/58

A. A. 2008/2009

Recentemente, grazie anche alla disponibilità di crescenti capacità di calcolo, sono stati realizzati strumenti di simulazione in grado di riprodurre il comportamento del deflusso veicolare con un livello di dettaglio del singolo veicolo. La scala di approfondimento di tali modelli, detti pertanto microscopici, unita alla complessità dei fenomeni da simulare – si pensi ai comportamenti umani coinvolti e alla relativa aleatorietà – ne rende particolarmente complessa la struttura e particolarmente numerosi i parametri. A fronte delle enormi potenzialità, la loro applicazione risulta pertanto un compito estremamente difficoltoso e tutt'altro che immune da errori. Perciò l'obiettivo focale della ricerca, a cui si informa la presente tesi, è sviluppare, implementare e promuovere metodologie e procedure di supporto all'uso della simulazione del traffico, specialmente su argomenti di calibrazione e validazione.

La calibrazione prende generalmente la forma di un problema di ottimizzazione in cui si cercano i valori di un set di parametri che minimizzino la distanza tra output del sistema e output del modello. Nello specifico dei modelli di micro – simulazione, non analitici, si tratta di un problema di ottimizzazione nella forma di un modello *black – box* o *simulation based* e si presenta come un'ottimizzazione (vincolata), non – lineare e non – convessa, indipendentemente dall'algoritmo usato.

Le difficoltà insite nei suddetti processi sono legate ad una complessità computazionale ed alla efficacia della soluzione trovata.

La sua **complessità computazionale**, tipicamente tempo di calcolo richiesto per la soluzione è noto essere di natura esponenziale, per cui il problema risulta essere intrattabile dipendendo esponenzialmente sia dal numero dei parametri che dalla precisione numerica (*digits accuracy*).

Per l'**efficacia della soluzione trovata**, assumendo che nessuna delle tecniche risolutive assicura che venga trovato l'ottimo globale, nulla si riesce a conoscere sulla veridicità della soluzione, né tantomeno su quanto questa soluzione sub-ottima disti da quella ottimale.

Per far fronte ai problemi posti in essere, si può agire innanzitutto metodologicamente. Gli step individuati sono:

1. Definizione del problema – **scenario di traffico di riferimento**.
2. Individuazione dei **parametri di ottimizzazione sensibili** (discreti e continui).
3. Identificazioni e scelta delle **Measure of Performance (MoP)**, nonché del loro livello di aggregazione (**Measurement Interval Length - MIL**).
4. Scelta della funzione obiettivo (**Goodness of Fit – Gof**) e dell'**algoritmo di ottimizzazione**.

Per ciò che ha riguardato le prime tre fasi, si fa riferimento a studi precedenti¹, nei quali attraverso un'analisi di sensitività e ANOVA dei risultati del modello, si è ridotto il numero di parametri sensibili da 32 a 4, (Reaction Time, Maximum Acceleration, Speed Acceptance, Coefficient of Variation), parametri che spiegano la più alta percentuale della varianza degli output. Dai risultati della stessa analisi si è dedotto anche che la migliore MoP risulta la velocità, non solo in termini di varianza spiegata, ma anche in relazione alla più facile riconoscibilità della

¹ Ciuffo B., Punzo V. Influence of different Goodness of Fit Measures on the calibration of traffic simulation models - Methodological issues, TRB 2010

condizione di funzionamento di traffico, e inoltre che il MIL più consono è di *tre minuti*, vista la dipendenza del modello dalla fisicità dei parametri.

La fase seguente, e specificamente trattata nel presente lavoro, concerne invece l'individuazione della migliore GoF, strettamente legata alla scelta dell'algoritmo risolutivo per quanto affermano i "No Free Lunch theorems".

Per la teoria NFL, un minimo cambiamento della natura del problema comporta una differenza di risultati finali; con ciò si vuole sottolineare che si definisce l'algoritmo migliore sempre solo in relazione ad una specifica classe di problemi. Questa è anche la motivazione per cui ci si è spinti a testare numerosi combinazioni GoF/Algoritmo, col fine di individuare "classi-benchmark" di problemi che possano essere trattati alla medesima maniera.

Da studi precedenti delle sensibilità di diverse funzioni obiettivo, sono state prese in considerazione sei GoF, che riassumono le caratteristiche migliori:

1. Mean Absolute Error *MAE*
2. Mean Absolute Normalized Error *MANE*
3. Root Mean Square Error *RMSE*
4. Root Mean Square Normalized Error *RMSNE*
5. Geoffrey E. Havers statistic *-GEH1*
6. Theil's Inequality Coefficient *U*

La costruzione di queste funzioni obiettivo è stata ottenuta con l'impiego di *dati sintetici* ricavati da sperimentazioni di laboratorio, che consentono di garantire l'efficacia della soluzione trovata. Tale fase risulta determinata per verificare l'adattamento del binomio GoF/ Algoritmo; ha spinto infatti verso una riduzione della complessità del modello black – box ad un problema analitico di più facile trattazione e che fornisca maggiori informazioni sulla natura del problema da affrontare. Ciò è supportato anche dall'ipotesi di poter calibrare indipendentemente le due coppie di parametri (Reaction Time, Maximum Acceleration) e (Speed Acceptance, Coefficient of Variation), come mostrano i risultati dell'ANOVA per cui ciascuna delle due coppie è correlabile a condizioni di deflusso differente, rispettivamente "congested flow" e "free flow".

Ecco quindi che facendo variare due parametri sui quattro del modello sono state ottenute i dati necessari alla costruzione delle superfici obiettivo, costruite tramite meta-modelli di approssimazioni di tipo kriging; il vantaggio di utilizzare meta-modelli kriging risiede nella loro capacità, rispetto ai consueti modelli di regressione polinomiale, di riprodurre più vaste aree sperimentali. Sono infatti definiti meta-modelli globali rispetto agli altri che sono locali.

In aggiunta sono state costruite anche superfici con l'imposizione di un prefissato rumore sui dati sintetici, così da verificare l'effetto degli errori casuali nelle misure di traffico, ed ancora con l'imposizione di un prefissato rumore sui parametri di caso in caso considerati costanti nel modello, così da verificare l'ipotesi di calibrazione indipendente dei parametri.

La fase successiva è consistita nel lanciare gli algoritmi presi in considerazione:

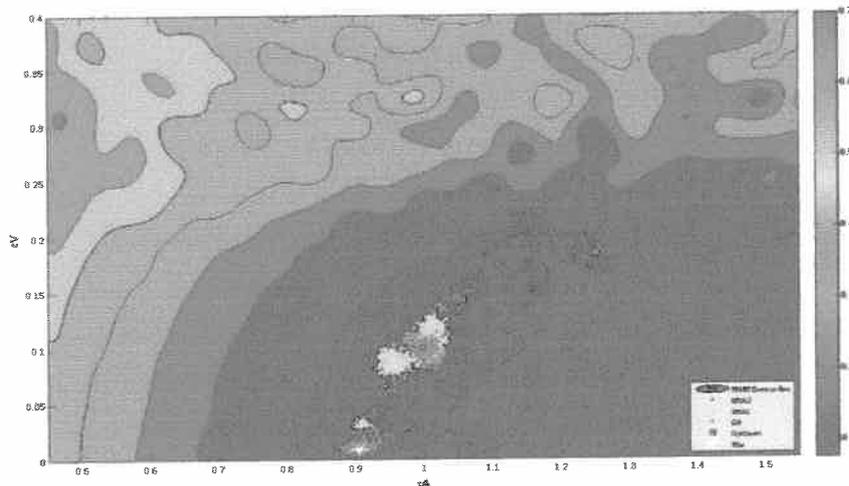
- Simultaneous Perturbation Stochastic Approximation nelle sue due varianti

- SPSA I (con due misure della funzione obiettivo)
- Enhanced SPSA II (con quattro misure della funzione obiettivo)
- OptQuest/Multistart
- Genetic Algorithm

Per ciascuna combinazione Algoritmo/GoF (192 combinazioni totali) sono state eseguite 1000 esperimenti di ottimizzazione, dove ciascuno algoritmo considerava un massimo di 1000 iterazioni, implementati su una medesima macchina Pentium 4 con frequenza di 3.00 GHz e 2.50 GB di RAM.

I risultati sono stati elaborati, considerando per ogni 1000 simulazioni tre indicatori:

- **indice di convergenza** $\%_{i,j}$ (verifica se gli ottimi trovati coincidono coll'ottimo globale).
- **indice medio della f. o. normalizzato** $|\overline{f.o.}| + 1/|\min(f.o.)| + 1$ (indice di posizione).
- **raggio di dispersione medio** $r = \frac{1}{N} \sum_{i=1}^N \sqrt{\left(\frac{X_i - \min X^*}{\min X^*}\right)^2 + \left(\frac{Y_i - \min Y^*}{\min Y^*}\right)^2}$ (indice di dispersione).



Dall'analisi dei diagrammi risultanti si evince come per le superfici (rT,mA) l'algoritmo migliore sia l'OptQuest, e peggiora con GA e gli SPSA.

La situazione cambia sulle superfici (sA,cV) dove il GA risulta essere il più robusto, anche rispetto all'OptQuest, che si nota rimanere a volte intrappolato in minimi locali molto vicini all'ottimo vero, probabilmente per il suo alto livello di digit accuracy. Gli SPSA performano bene solo nel caso della f. o. con True parameter e True data, dove addirittura risultano essere più convergenti del GA, per poi decadere sulle altre superfici.

Guardando alle sole superfici (rT,mA) si denota una tendenza degli algoritmi ad avere un calo di rendimento in corrispondenza di -GEH1, nel passaggio dalla configurazione True parameter a Noise parameter. Differentemente nel passaggio dalla configurazione True data a Noise data ne risentono soprattutto la U, l'RMSNE e l'RMSE. Con molta probabilità sulle superfici (sA,cV) non si ripropongono gli stessi trend essendo superfici completamente diverse (le (rT,mA) sono più

planari, le (sA,cV) più concave); infatti non si osservano cose particolari se non quanto già detto riguardo all'algoritmo migliore, GA.

In ultimo si è creato un *indicatore di preferibilità* $x_{ij} = \frac{\%_{ij}}{\sum_i \%_{ij}}$ quali-quantitativo adimensionale col quale esprimere, per la stessa f. o., l'aliquota di prevalenza di un algoritmo su un altro. Confrontando poi i valori ottenuti per tutte le GoF di una stessa classe di problemi si è evidenziato l'algoritmo migliore

| | BEST ALGORITHM/GoF |
|------------------------------------|--------------------|
| (rT,mA)_True Parameter True Data | OPTQUEST/RMSE |
| (rT,mA)_True Parameter Noise Data | OPTQUEST/MAE |
| (rT,mA)_Noise Parameter True Data | OPTQUEST/RMSE |
| (rT,mA)_Noise Parameter Noise Data | OPTQUEST/RMSE |
| (rT,mA) | OPTQUEST/RMSE |

| | BEST ALGORITHM/GoF |
|------------------------------------|------------------------|
| (sA,cV)_True Parameter True Data | OPTQUEST/-GEH1 |
| (sA,cV)_True Parameter Noise Data | OPTQUEST/RMSNE e U |
| (sA,cV)_Noise Parameter True Data | GENETIC ALGORITHM/MANE |
| (sA,cV)_Noise Parameter Noise Data | GENETIC ALGORITHM/MANE |
| (sA,cV) | GENETIC ALGORITHM/MANE |

| [(rT,mA)(sA,cV)] | ALGORITHM/GoF | VALORE DELL'INDICE | |
|------------------|------------------------|--------------------|-------------|
| | | ASSOLUTO | PERCENTUALE |
| 1) | GENETIC ALGORITHM/MANE | 4.63 | 58% |
| 2) | OPTQUEST/RMSE | 4.26 | 53% |
| 3) | OPTQUEST/-GEH1 | 3.94 | 49% |

Come si vede i risultati sono stati poi aggregati sui problemi di livello superiore, per definire in ultimo una graduatoria di adattamento Algoritmo/GoF allo specifico modello di simulazione del traffico.

Ne scaturisce come conclusione finale che mediamente GENETIC ALGORITHM/MANE, seguiti da OPTQUEST/RMSE, sono le coppie Algoritmo/GoF che restituiscono migliori performance, rispettivamente col 58% e 53% di preferibilità nei casi analizzati.

