

## Il controllo di qualità delle rilevazioni FIM: dai punteggi sul questionario a misure valide e affidabili

di Anna Simone

Tecnico Statistico

Luigi Tesio

Primario Fisiatra, Direttore dell'Unità di Ricerca, Valutazione Funzionale e Verifica di Qualità in Riabilitazione, IRCCS Fondazione Salvatore Maugeri, Pavia

### IL PROBLEMA: CONVALIDARE PUNTEGGI SOGGETTIVI

Le rilevazioni su questionari — fra le quali rientra la misura di autosufficienza — vengono definite "soggettive" perché non hanno un corrispettivo in dati strumentali quali una radiografia, un elettrocardiogramma, un dato di laboratorio. D'altro canto non esiste altro modo pratico di misurare l'autosufficienza che non sia quello di "dare un voto" all'autosufficienza stessa. Evidentemente la mancanza di questo tipo di oggettività rappresenta un difetto e un ostacolo per chiunque voglia utilizzare queste misure a fini di controllo di qualità, o addirittura a fini di controllo economico dell'assistenza. Una possibilità di "oggettivazione" di queste misure, tuttavia, esiste. La strategia più affermata consiste nell'analisi di verosimiglianza (*likelihood*), secondo tecniche statistiche definite nel loro complesso *item-response analysis-IRT*, laddove il termine *item* indica qualsiasi voce di un questionario. L'analisi di Rasch è la versione più avanzata di IRT per applicazioni all'area della Riabilitazione. Si tenterà ora una sintesi delle proprietà e delle applicazioni del modello, con richiami esemplificativi alle sue applicazioni alla scala FIM.

### UN NUOVO ORIZZONTE METODOLOGICO: IL MODELLO DI GEORG RASCH

Il modello proposto negli anni 1960/1980 dal matematico danese Georg Rasch si sta affermando in Riabilitazione sia per la costruzione, sia per la validazione di scale comportamentali item/risposta. Inoltre si stanno affermando anche le sue applicazioni al controllo di qualità dei dati. Infatti, una volta che si sia stabilita la validità della scala il modello si presta molto bene al controllo di verosimiglianza delle risposte ai questionari.

Il modello prescrive che la probabilità di risposta categorica (0 invece che 1, no/sì ecc.) a un certo item (per esempio: alimentazione, locomozione, comprensione ecc.) sia dettata da due parametri soltanto: la difficoltà intrinseca dell'item e la abilità intrinseca del soggetto, lungo una stessa variabile unidimensionale che rappresenta un costrutto concettuale continuo "da meno a più".

A partire da una matrice di risposte ordi-

nali grezze (diversi items con risposte no/sì = 0/1, oppure no/lieve/medio = 0/1/2 ecc.) il modello stima in un quadro probabilistico la "massima verosimiglianza" dei due parametri (difficoltà e abilità, per ciascun item e per ciascun soggetto), ovvero i valori che più avvicinano i dati osservati a dati modello-compatibili. Soggetti più abili avranno più probabilità di superare uno qualsiasi degli items, rispetto a soggetti meno abili. Items più difficili avranno maggiori probabilità di "resistere" ad uno qualsiasi dei soggetti, rispetto ad items più facili. La relazione che lega fra loro la probabilità di successo (per un soggetto rispetto a un item, o viceversa) e questi due parametri è dettata da un'equazione relativamente semplice che rappresenta il cuore stesso del modello di Rasch. Appositi algoritmi producono la stima "massimamente verosimile" di abilità dei soggetti e di difficoltà degli items. Inoltre, anche se la spiegazione va oltre gli scopi di questo articolo è importante sapere che il metodo risolve classici problemi psicometrici quali:

- la discontinuità e la non proporzionalità dei punteggi ordinali: che cosa impedisce di definire i livelli "dipendente/autonomo con ausilio/indipendente" con livelli 0/4/7/9 invece che 0/1/2? Che cosa impone di credere che la differenza fra 2 e 1 rappresenti veramente (e non soltanto quanto a simboli numerici) lo stesso intervallo quantitativo che separa 1 da 0?
- la stima di eventuali risposte mancanti. Che cosa ci impone di ritenere che due soggetti che rispondano a 9 items su 10 abbiano davvero conseguito la sessa misura (9/9 o, se si preferisce, 9/10), se ciascuno omette un diverso item con difficoltà diversa?

### LA CONVALIDA DEI PUNTEGGI: CORRISPONDENZA FRA PREVISIONI DEL MODELLO E DATI OSSERVATI

Poiché il modello di Rasch si muove in un orizzonte probabilistico si calcola anche il margine di errore delle stime di abilità e di difficoltà. Viene quindi misurata l'aderenza ("fit") delle risposte osservate (per esempio le 18 risposte al questionario FIM) alle attese del modello.

Se le attese sono rispettate i punteggi di un certo soggetto o di un certo item vengono in qualche modo convalidati (si parla di *objective measurement*). Viceversa, soggetti o items che accumulino troppe risposte inattese divengono oggetto di una vera e propria procedura diagnostica molto sofisticata e sensibile che è volta a definire le cause di questa non-verosimiglianza.

Per esempio è dimostrato che nella FIM l'autosufficienza nell'alimentazione risulta una prestazione più probabile, in qualsiasi patologia, rispetto all'autosufficienza nel salire le scale. Che cosa si deve pensare di un questionario FIM dal quale il soggetto appaia autosufficiente nel fare le scale ma non nell'alimentarsi? Vi è stato un errore di codifica? Oppure il paziente presenta caratteristiche

cliniche molto atipiche? E se invece vi fosse molti soggetti con lo stesso schema di punteggio? In questo caso vi potrebbe essere un difetto nella omogeneità (*unidimensionality*) degli stessi items. La domanda diviene: alimentazione e scale rappresentano una stessa variabile, così da fornire punteggi cumulabili, oppure rappresentano variabili con scarsa o nulla relazione fra loro, il che spiega il loro rapporto erratico nei diversi soggetti? Oppure ancora il rilevatore compie un errore sistematico nell'attribuire i punteggi ad uno dei due items: per esempio, egli sopravvaluta le difficoltà incontrate nell'alimentazione?

### LA TRASFORMAZIONE DEI PUNTEGGI GREZZI IN MISURE INTERVALLARI

La unidimensionalità è il primo requisito non soltanto perché i punteggi dei diversi items siano sommabili, ma anche perché essi siano riproducibili. Se il punteggio di un item varia in modo erratico rispetto a quello degli altri items, molto probabilmente anche il punteggio totale varierà in modo erratico da una rilevazione all'altra.

Con l'analisi di Rasch l'osservazione comportamentale diviene correlabile appropriatamente a classiche misure intervallari (per esempio fisiche o econometriche). Il termine *intervallare* ricorda che i simboli numerici non sono soltanto ordinati in sequenza come le quantità che rappresentano (per esempio, 2 chilogrammi vuol dire "più peso" di 1 chilogrammo), ma che essi sono anche proporzionali al "vero intervallo" che separa le grandezze che essi rappresentano. Per esempio, l'intervallo di peso che separa la misura di 1 chilogrammo dalla misura di 2 chilogrammi è pari alla metà dell'intervallo di peso che separa la misura di 5 chilogrammi dalla misura di 7 chilogrammi. Al contrario, non è affatto noto — a meno, appunto, di trasformazioni come quelle consentite dall'analisi di Rasch — quale differenza di autosufficienza rappresenti il passaggio da un punteggio FIM di 1 ad un punteggio di 2, rispetto al passaggio da un punteggio di 5 ad un punteggio di 7.

La stima di misure veramente intervallari della abilità dei soggetti rende più valide le procedure statistiche che presuppongano variabili intervallari (ad esempio, test sulle medie invece che sulle mediane, correlazioni, analisi della varianza, regressioni ecc.).

### APPLICAZIONI DELLA STIMA DI "VEROSIMIGLIANZA"

a) *Applicazione a soggetti e rilevatori: identificazione dei casi atipici, per il controllo delle rilevazioni su questionari*

Se si pensa ad un utilizzo di queste misure per scopi gestionali e di controllo di qualità diviene particolarmente interessante la possibilità di stimare la coerenza di una serie di risposte rispetto alle attese del modello. Il punteggio totale non basta: evidentemente, anche risposte date completamente a caso potrebbero produrre un punteggio cumulativo verosimile. La disponibilità di una

banca-dati di riferimento (come, per la FIM, la banca-dati italiana e ancor più quella americana) consente di fornire "valori di ancoraggio" di difficoltà dei singoli items, ovvero stime pre-definite che costituiscano standard di riferimento. Questi standard sono molto precisi: di conseguenza diviene molto precisa anche la stima di una eventuale "incoerenza" dello schema di risposta di ogni soggetto. Il responsabile di uno studio che utilizzi questionari ha quindi a disposizione un valido strumento di controllo di qualità dei dati che gli pervengono. Misure "incoerenti" impongono procedure diagnostiche e correttive: per esempio una critica delle procedure di punteggio eseguite da un certo rilevatore. Talvolta, invece, la non-verosimiglianza corrisponde a procedure assistenziali atipiche che privilegiano o penalizzano certe attività del paziente rispetto ad altre.

**b) Applicazione alla scala: stima generalizzabile della riproducibilità delle sue misure**

Le misure che risultino convalidate con analisi di Rasch hanno una riproducibilità intrinseca notevole. Non è necessario confermarla con misure ripetute quali, per esempio, rilevazioni contemporanee ad opera di più osservatori oppure misure successive eseguite — assumendo come stabili le condizioni cliniche — alla dimissione da un reparto ed al contemporaneo ingresso in un altro. Infatti il modello di Rasch presenta in se stesso una grande generalizzabilità: se il paziente presenta punteggi ben centrati nei limiti di confidenza predetti per ciascun item, verosimilmente egli riprodurrà coerentemente lo stesso schema di risposta anche in qualsiasi altra circostanza.

Nel metodo di Rasch le misure ripetute sono comunque molto utili, ma vengono eseguite prevalentemente nella fase di costruzione e di validazione di una scala di misura e non — come nella psicometria classica — in ogni fase di applicazione per studiare la riproducibilità di un certo campione di soggetti e di osservatori. Infatti nel metodo di Rasch le misure ripetute servono a studiare una forma più sofisticata di riproducibilità: la *stabilità* intrinseca degli items. Con questo termine si intende la invarianza degli intervalli di difficoltà reciproca degli items, rispetto alle più diverse variabili indipendenti: tempo 0 vs. tempo 1, maschi vs. femmine, emiplegici verso paraplegici, questionari italiani verso questionari stranieri ecc. Il requisito che viene verificato è quello che la scala di misura mantenga sempre lo stesso significato: così come i numeri segnati lungo un righello devono restare allineati in un certo ordine e con certe distanze reciproche, quale che sia l'oggetto da misurare e quale che sia la sua lunghezza.

Per esempio, si possono confrontare due osservatori che attribuiscono ad un paziente un punteggio FIM totale identico ma composto in modo completamente diverso? Supponiamo che esso sia comprensivo di un 7 nell'alimentazione e di un 2 nel salire le scale in

un caso, e viceversa nell'altro caso. Analogamente: che cosa si può dire di una scala che presenti gerarchie di difficoltà sistematicamente diverse in pazienti emiplegici ed in pazienti paraplegici? Essa sta ancora misurando la stessa variabile nelle due categorie di pazienti? Questo tipo di analisi esplora quello che in gergo si chiama *item bias*, ovvero la suscettibilità degli items a interferenze sistematiche nel loro valore di difficoltà reciproca.

Infine, va ricordato che i test classici misurano l'accordo:

- a) fra i punteggi di singoli items o su punteggi cumulativi comunque questi ultimi siano composti, e non sull'intero schema di risposte
- b) su punteggi non intervallari. Per quanto essi siano ordinati gerarchicamente, questi punteggi rappresentano intervalli ignoti, e in più
- c) si assume anche che essi siano privi di errore (cioè che "2" sia veramente "2" e non qualche cosa che sarebbe potuto essere "1" o "3" in altre circostanze). Accordo e disaccordo, dunque, riguardano quantità definite in modo piuttosto arbitrario. Infine
- d) i test riguardano i singoli campioni di misure in esame (osservatore 1 verso osservatore 2, per esempio) così che rimane aperto il problema della generalizzabilità (L'accordo fra questi due osservatori non garantisce l'accordo fra altri due in altre circostanze).

L'analisi di Rasch, invece, mette a confronto:

- (a) la verosimiglianza di un intero schema di risposta
- (b) in termini di misure intervallari che — come si è già detto — sono anche
- (c) provviste di una stima di errore. Il tutto, viene posto a confronto con
- (d) le attese molto generalizzabili del modello.

**LA SCALA FIM: RIPRODUCIBILITÀ E STABILITÀ**

Per quanto attiene la FIM esiste ormai una vastissima letteratura che conferma:

- a) riproducibilità "classica" (riproducibilità dei punteggi grezzi intra-inter osservatori con Cohen's K o ICCs)
- b) stabilità intesa come riproducibilità dei punteggi totali grezzi *cross-modality*: telefonica vs. intervista diretta; anamnestica vs. osservazione. La Letteratura si riferisce prevalentemente a dati americani (si veda al sito [www.ud-smr.org](http://www.ud-smr.org)) ma è stato concluso con esito del tutto favorevole anche uno studio italiano di riproducibilità intra-inter osservatori.
- c) riproducibilità e stabilità secondo analisi di Rasch.

In sintesi, dati americani e dati italiani concordano nel suggerire che la scala FIM mantenga sostanzialmente lo stesso significato se applicata, per

esempio, a pazienti emiplegici invece che protesizzati d'anca, oppure a pazienti in degenza riabilitativa ospedaliera invece che in casa di riposo. Procedure diagnostiche apposite consentono di identificare instabilità non dovute a errori di misura ma che indichino, in generale, particolari procedure assistenziali. Per esempio in casa di riposo l'autonomia sfinterica tende ad essere meno elevata rispetto all'autonomia locomotoria. Un motivo può essere rappresentato dall'obiettivo di rendere i pazienti liberamente deambulanti grazie al ricorso a presidi per l'incontinenza. Il contrario si osserva in riabilitazione ospedaliera, ove il paziente deambulante di solito non è o non è più incontinente. Una volta che sia stato scoperto, questo *bias* suggerisce di calcolare valori di riferimento specifici che consentano controlli di qualità specifici per la struttura cronico-geriatrica o per quella ospedaliera. La letteratura rivela anche che il rapporto fra punteggio FIM e minuti assistenziali è comunque simile in qualsiasi tipo di contesto assistenziale. Di conseguenza il confronto fra punteggi rimane possibile purché li si interpreti come indicatori di carico assistenziale complessivo, indipendentemente dal tipo di assistenza che ciascun punteggio comporta.

È facile comprendere come questo tipo di ragionamenti sia supportato bene dall'analisi di Rasch, e molto meno bene da misure ottenute con tecniche convenzionali.

**BIBLIOGRAFIA**

**Modello di Rasch e scale funzionali in riabilitazione**

- 1) WRIGHT BD, STONE MH  
*Best test design*. MESA Press, Chicago-IL 1979
- 2) ANDRICH D  
*Rasch models for measurement*. Sage University Papers Series on Quantitative Applications in the Social Sciences. Sage, Beverly Hills, CA 1988
- 3) TESIO L  
*Quality assessment of the FIM — Functional Independence Measure — ratings through Rasch analysis*. *Eur Med Phys* 1997; 33: 69-78
- 4) TESIO L, GRANGER CV, FIEDLER RC  
*A unidimensional pain/disability measure for low-back pain syndromes*. *Pain* 1997; 69: 269-278
- 5) PENTA M, THONNARD JL, TESIO L  
*ABILHAND: a Rasch-built measure of manual ability*. *Arch Phys Med Rehabil* 1998; 79: 1038-1042 ■