



Introduzione all'Analisi Multivariata

I. Analisi a tagli

Pietro Biassoni^{1,2}

¹INFN Milano

²Dipartimento di Fisica
Università degli Studi di Milano

Metodologie di Analisi dei Dati
18 Dicembre 2009



Outline

- 1 Introduzione
- 2 Presentazione delle variabili
- 3 Ottimizzazione 1D
- 4 Ottimizzazione 2D



Outline

- 1 **Introduzione**
- 2 Presentazione delle variabili
- 3 Ottimizzazione 1D
- 4 Ottimizzazione 2D



Analisi a Tagli

Lo scopo della lezione di oggi è di effettuare una analisi a tagli.

Il campione che ci apprestiamo ad utilizzare
`/home/comune/AnalisiDati/mva1_sample.root`
contiene due variabili che hanno un buon potere discriminante tra segnale
e fondo.

Cosa impareremo a fare:

- Presentare le variabili in modo comprensibile.
- Ottimizzare un taglio in una dimensione.
- Ottimizzare un taglio in due dimensioni.



Outline

- 1 Introduzione
- 2 Presentazione delle variabili
- 3 Ottimizzazione 1D
- 4 Ottimizzazione 2D



Introduzione

Nel nostro file `.root` esistono due alberi: *signal* e *bkg*. Ciascun albero contiene due variabili.

Cosa dobbiamo fare:

- Aprire i files e accedere agli alberi
- Plottare le variabili in modo da avere un confronto grafico.



Accede agli alberi

Dobbiamo aprire il file root e recuperare gli alberi

```
TFile *f = new TFile("mva1_sample.root","READ");  
TTree *tsig = (TTree*)f->Get("signal");  
TTree *tbkg = (TTree*)f->Get("bkg");
```

a questo punto vogliamo disegnare le variabili. La cosa piu' semplice da fare è usare il metodo di TTree

```
Draw(const char* varexp, const TCut& selection, Option_t*  
option = "");
```

varexp è il nome della variabile che volete disegnare (es. "var1");
selection è una espressione che viene interpretata come un taglio (es. "var2<0.5"): verranno disegnati solo i dati che soddisfano questo taglio;
option sono le opzioni per la grafica (ad es. "SAME" per disegnare immagini sovrapposte).



TCanvas

La TCanvas è l'oggetto che ROOT usa per contenere disegni

```
TCanvas *c1 = new TCanvas("name","title",1);
```

un metodo utile della TCanvas è

```
c1->Divide(ncolonne,nrighe);
```

in questo modo la TCanvas è divisa in *pads*, che sono numerati da 1 a n , da sinistra a destra dall'alto in basso.

Per disegnare due oggetti in pads diversi

```
c1->cd(1); //scelgo il pad 1  
tree->Draw("var1"); //disegno var1 nel pad 1  
c1->cd(2); //scelgo il pad 2  
tree->Draw("var2"); //disegno nel pad 2
```



Esercizio



Aprire il file `mva1_sample.root`, recuperare gli alberi e disegnare `var1` e `var2`, nei due pad di una canvas. In ogni pad disegnare sia la distribuzione del segnale che quella del fondo




Esercizio

```
TFile *f = new TFile("mva1_sample.root");  
TTree *tsig = (TTree*)f->Get("signal");  
...  
TCanvas *c1 = new TCanvas(...);  
c1->Divide(2);  
  
c1->cd(1);  
tsig->Draw("var1");  
tbkg->Draw("var1","", "SAME");  
...
```



Esercizio



Questo plot è decisamente brutto. Non si capisce che variabili sono plottate, non si distinguono le due distribuzioni.



Recuperare gli istogrammi

Se vogliamo utilizzare le opzioni grafiche degli istogrammi, dobbiamo avere accesso ad essi:

```
tsig->Draw("var1>>htemp(40)");
```

fa sì che l'istogramma sia disegnato in un istogramma di nome "htemp" di 40 bin.

Per recuperarlo:

```
TH1F* htemp = (TH1F*)gROOT->FindObject("htemp");  
htemp-> ... //Operazioni sull'istogramma
```

Ovviamente se dobbiamo disegnare 4 istogrammi dobbiamo usare 4 nomi diversi e recuperarli tutti e 4 con 4 puntatori TH1F* diversi...



Opzioni grafiche

Togliere il colore grigio alla canvas

```
gROOT->SetStyle("Plain");
```

Cambiare colore/stile alla linea (Attenzione: è necessario cambiare non solo il colore, ma anche lo stile nel caso in cui chi legge stampi in b/n...)

```
htemp->SetLineColor(N); //N è un intero  
htemp->SetLineStyle(N); //N è un intero
```

Togliere le statistiche

```
htemp->SetStats(kFALSE);
```

Cambiare il range dell'asse, assegnare un titolo

```
htemp->GetXaxis()->SetRangeUser(min,max);  
htemp->GetXaxis()->SetTitle("pippo");
```



Legenda

Una cosa utilissima è aggiungere una legenda al grafico

```
TLegend *leg =new TLegend(0.1,0.1,0.2,0.2);
```

Per aggiungere voci alla legenda


```
leg->AddEntry(htemp,"Segnale","L")
```

L'ultimo argomento indica il tipo di simbolo nella legenda: "L" = linea, "P" = punto, "F" = riempimento.

```
c->cd(1) // Selezione il pad  
leg->Draw();  
leg->SetFillColor(0); // Colore dello sfondo  
leg->SetTextSize(0.05); // Grandezza carattere
```



Presentazione delle variabili



Con un po' di lavoro questo è il risultato



Esercizio (a casa)



Rendete il vostro plot più presentabile




Outline

- 1 Introduzione
- 2 Presentazione delle variabili
- 3 Ottimizzazione 1D
- 4 Ottimizzazione 2D



Introduzione



Vogliamo ora ottimizzare un taglio su var_1 e var_2 *separatamente*.
 Vogliamo cioè trovare un taglio che ottimizzi una certa figura di merito (FOM) per ciascun taglio



Ottimizzazione della Significanza

Vogliamo ottimizzare la figura di merito

$$FOM = \frac{n_S}{\sqrt{n_S + n_B}}$$

dove n_S (n_B) è il numero di eventi che passa il taglio.

Come traduciamo questo in codice?

Vogliamo

- fare un *ciclo* e provare diversi valori del taglio
- per ogni taglio ottenere n_S e n_B
- per ogni taglio calcolare $\epsilon_{S,B} = n_{(S,B)} / N_{(S,B)}^{tot}$

Per ottenere il numero di eventi che superano il taglio basta fare

```
int s = tsig->Draw("var1","var1<0.2");
```



Ottimizzazione della Significanza

String

```
int s = tsig->Draw("var1","var1<0.2");
```

il valore del taglio deve cambiare *ad ogni ciclo*.

Si puo' usare la funzione *sprintf* (ma è C !) In C++ si usano string e stringstream.

string è un contenitore di carattere, ma ha il difetto di non potervi inserire variabili. Cioè non è possibile fare

```
double vcut = 0.1; //valore del taglio da incrementare
string cut; //dichiaro la stringa
cut="var1<"; //inserisco "var1<" nella stringa
cut+=vcut; //NON FUNZIONA!!!
```



Ottimizzazione della Significanza

Stringstream

stringstream è un contenitore usato per riempire le stringhe con valori variabili.

Ha la stessa sintassi di cout.

```
double vcut = 0.1; //valore del taglio
...
for(int i .....){ //ciclo
stringstream buffer; //dichiaro stringstream
buffer <<"var1<" <<vcut;
int s = tsig->Draw("var1",(buffer.str()).c_str());
...
vcut+=.... //incremento del taglio
...
} //fine del ciclo
```

buffer.str() trasforma stringstream in string

.c_str() trasforma string in char*



Ottimizzazione della Significanza

Plot

Per ciascuna delle variabili vogliamo avere un plot di

- Efficienza del segnale vs valore del taglio
- Reiezione ($1 - \epsilon$) del fondo vs valore del taglio
- FOM vs valore del taglio
- ROC curve: reiezione del fondo vs efficienza del segnale

Quindi a ogni step del ciclo vogliamo riempire 4 TGraph

```
for(int i...){ //ciclo
...
gr1->SetPoint(i,vcut,eff_signal); //grafico eff.  segnale
gr2->SetPoint(i,vcut,rej_bkg); //reiezione bkg
gr3->SetPoint(i,vcut,FOM); //grafico FOM
gr4->SetPoint(i,eff_signal,rej_bkg); //ROC curve
...
} //fine del ciclo
```






Esercizio



Producete i quattro grafici per var_1 e var_2



Introduzione






Outline

- 1 Introduzione
- 2 Presentazione delle variabili
- 3 Ottimizzazione 1D
- 4 Ottimizzazione 2D



Introduzione

Una cosa interessante e' provare a ottimizzare un taglio nel piano
 $var_1 \times var_2$



probabilmente il nostro taglio sarà una box del tipo $[0, var_1^{cut}] \times [0, var_2^{cut}]$



Strategie di Ottimizzazione

Scan

Una prima strategia di ottimizzazione è possibile grazie all'*ansatz* sulla forma della box di segnale $[0, var_1^{max}] \times [0, var_2^{max}]$.

Possiamo infatti fare uno scan sui possibili valori di $var_{(1,2)}$ nel range $[0, var_{(1,2)}^{max}]$.

Per ogni punto possiamo calcolare la nostra FOM e scegliere come coppia $(var_1^{cut}, var_2^{cut})$ quella per cui la FOM è massima.

La possibilità di fare questo scan in modo semplice è data dal fatto che stiamo variando solo uno dei due estremi della box di segnale.



Strategie di Ottimizzazione

Monte Carlo

Una strategia di ottimizzazione alternativa è di fare uno scan “casuale”. Con un generatore di numeri casuali estraiamo i quattro valori $(var_{(1,2)}^{lowcut}, var_{(1,2)}^{upcut})$ e calcoliamo la FOM nel box $[var_1^{lowcut}, var_1^{upcut}] \times [var_2^{lowcut}, var_2^{upcut}]$.

■ Vantaggi:

- Concettualmente semplice
- Facile da essere implementato in N dimensioni ($N > 2$)
- Complessità computazionale inferiore per $N \gg 2$

■ Svantaggi:

- Più lento nel caso $N \sim 2$
- Difficile stabilire quando fermare la ricerca

Una buona ottimizzazione potrebbe essere fare un primo scan Monte Carlo su tutto il range possibile e poi fare un scan fine in zone dove il metodo Monte Carlo indica un alto valore della FOM.



Strategie di Ottimizzazione

Bump-Hunter

Il metodo migliore per ottimizzare un taglio a box è il Bump Hunter. Come è possibile implementare tale algoritmo?

- 1) Ad ogni passaggio restringiamo i quattro lati del box in modo *casuale*.
- 2) Controlliamo che:
 - a) il numero di eventi tagliati sia minore di $N_{tot} * peel$.
 - b) FOM nella box sia maggiore della FOM iniziale.
- 3) Accettiamo la nuova box se le due condizioni sono verificate
- 4) Reiteriamo fino a che la condizione risulta non soddisfatta per un numero n_{max} di volte consecutive
- 5) Proviamo ad allargare ciascun taglio (di una quantità piccola) e accettiamo la nuova box se la FOM cresce (*pasting*).

Non ho mai provato a implementare un Bump Hunter (ma lo farò per esercizio!). Un'idea utile potrebbe essere generare lo spostamento del punto 1) con una distribuzione gaussiana e non uniforme.



Esercizio



Ottimizzate il taglio 2D $var_1 \times var_2$ usando un Bump Hunter.