

**Esercizio su curva ROC**  
**(esempio tratto dall'analisi  $H \rightarrow ZZ^{(*)} \rightarrow 4\text{leptoni}$ )**

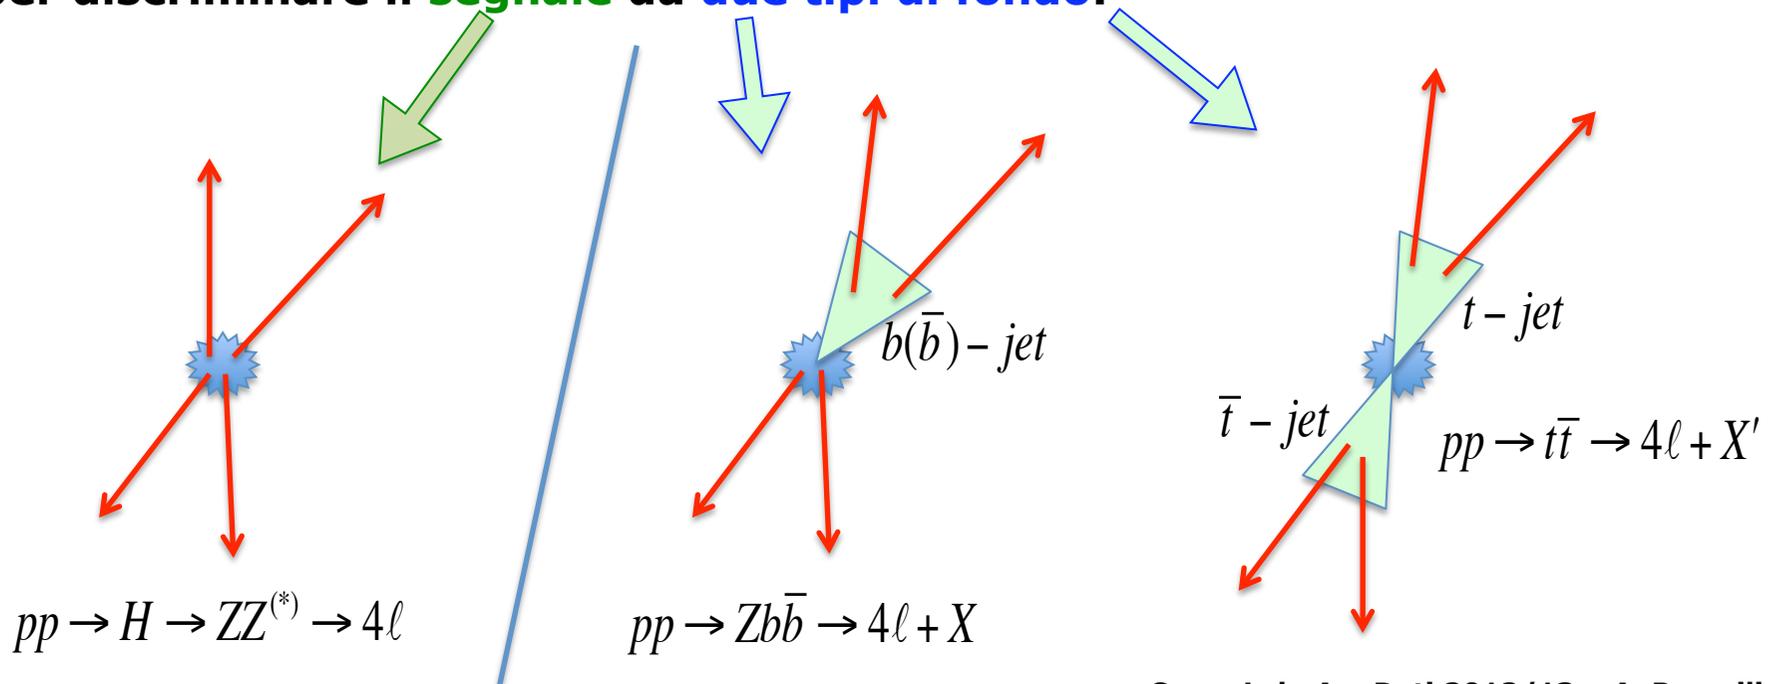
**Corso Lab. An. Dati 2012/13 – A. Pompili**

## Descrizione - I

Nella ottimizzazione dei criteri di selezione del canale  $H \rightarrow ZZ^{(*)} \rightarrow 4\ell$  si sono sviluppati - in CMS - vari algoritmi p.es. di vertexing e isolamento dei leptoni.

Con questo esercizio vediamo un esempio di confronto delle prestazioni di due (leggermenti diversi) algoritmi di "vertexing" aventi lo scopo di rigettare il fondo, effettuato sulla basi di dati simulati di segnale e fondo.

Sostanzialmente l'operazione consiste nell'usare due diverse *statistiche* per discriminare il **segnale** da **due tipi di fondo**:



## Descrizione - II

$$m(H) \approx 150 \text{ GeV}/c^2$$

$$E_{cms} = \sqrt{s} \approx 10 \text{ TeV}$$

Root-upla di **segnale**: `H150_ZZ_4l_10TeV_GEN_HLT_Presel_glb_2e2mu_2e2mu_merged.root`

Root-upla di **fondo Zbbar**: `LLBB_4l_10TeV_Presel_4l_2e2mu_merged.root`

Root-upla di **fondo ttbar**: `TT_4l_10TeV_Presel_4l_2e2mu_merged.root`

In `main.C` l'indice `i` etichetta i 3 casi: `i=0`(segnale), `i=1`(ttbar), `i=2`(Zbbar)

---

Statistiche: `"var1"`: `"LeptIP3D_worst"`  
`"var2"`: `"LeptSTIP_SLIP_worst"`

Queste osservabili sono descritte nelle slide seguenti.

Le relative stringhe vengono passate alla macro `main.C` al momento dell'esecuzione:

```
root> .L main.C
root> main("LeptIP3D_worst", "LeptSTIP_SLIP_worst", "30nov", "png")
```

...dal momento che in `main.C` si ha l'interfaccia:

```
void main(TString var1, TString var2, TString date, TString extens){...}
```

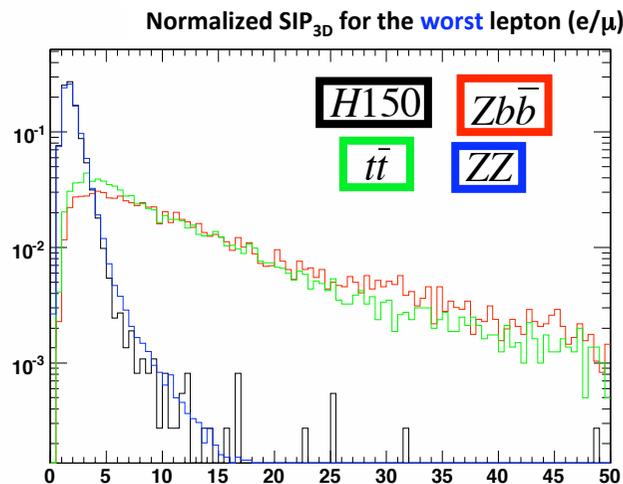
# Statistiche (osservabili) - I

Statistica dall'algoritmo1: **var1** ("LeptIP3D\_worst")

Three-dimensional ( $IP_{3D}$ ) distance - from the Primary Vertex (PV) - of the point of closest approach to PV for the "back propagated" lepton track is calculated. [Propagators are specific for muons & electrons].

Significance ( $SIP_{3D}$ ) is obtained by dividing  $IP_{3D}$  for the relative uncertainty (by full error computation):

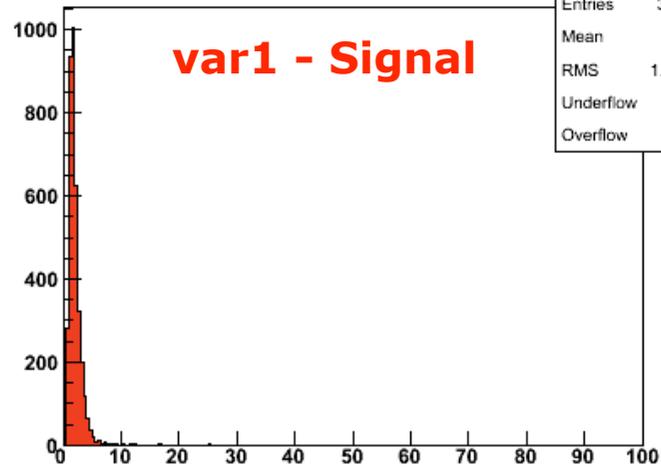
$$SIP_{3D} = \frac{IP_{3D}}{\sigma(IP_{3D})}$$



In  $Zb\bar{b}$ ,  $t\bar{t}$  and generic multi-jet background events the impact parameters of 2 or 4 leptons (in generic 4-leptons final state) are - in average - naturally **larger** w.r.t. those of signal.

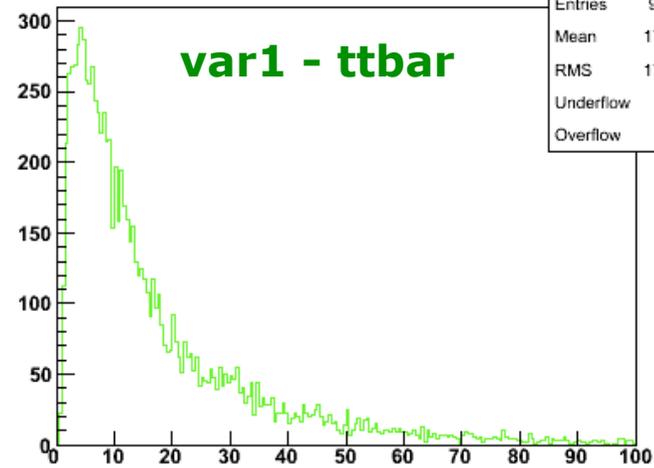
# Statistiche (osservabili) - II

IP3D for the worst lepton of bestH



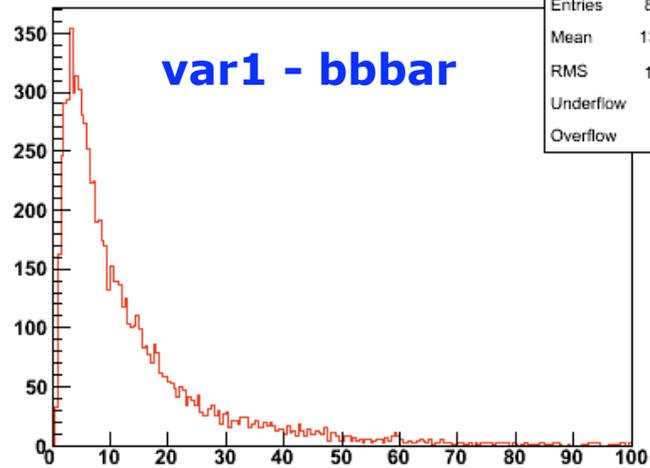
hLeptIP3D_worst	
Entries	3681
Mean	2.11
RMS	1.688
Underflow	0
Overflow	1

IP3D for the worst lepton of bestH



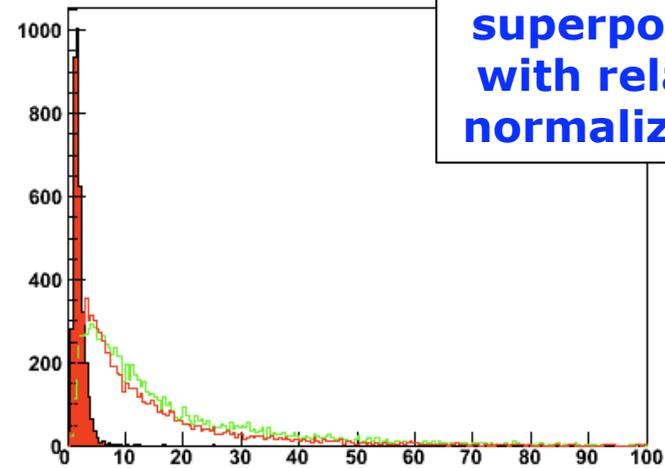
hLeptIP3D_worst	
Entries	9627
Mean	17.25
RMS	17.02
Underflow	0
Overflow	100

IP3D for the worst lepton of bestH



hLeptIP3D_worst	
Entries	8017
Mean	13.57
RMS	14.11
Underflow	0
Overflow	33

IP3D for the worst lepton of bestH



hLeptIP3D\_worst

# Statistiche (osservabili) - III

Statistica dall'algoritmo2: var2 ("LeptSTIP\_SLIP\_worst")

Transverse (TIP) and longitudinal (LIP) distances - from PV - of lepton track, "back-propagated" w.r.t. to PV, are calculated.

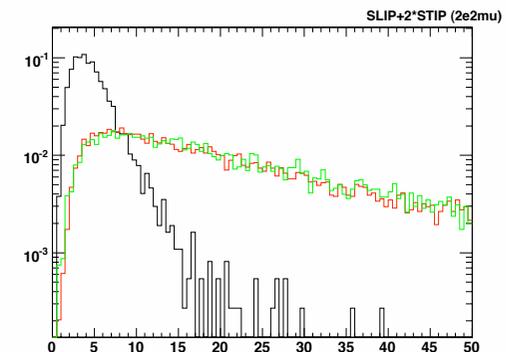
[Propagators are specific for muons & electrons].

Significances (STIP, SLIP) are taken by dividing them for the relative uncertainty (by full error computation - correlation included).

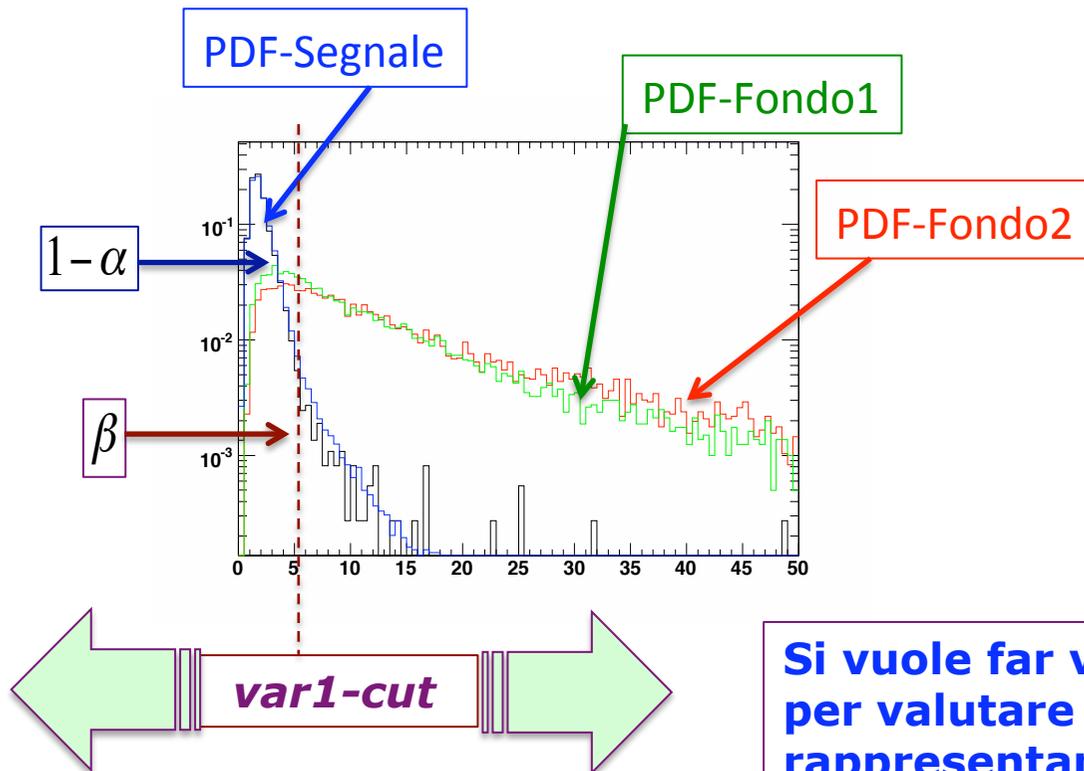
The discriminating observable used here is the following suitable weighted combination of SLIP and STIP:

$$SLIP(4^{th} \ell) + 2 * [STIP(\ell^+) + STIP(\ell^-)] \quad \text{where } \ell^+, \ell^- \text{ are from } Z^*$$

The idea is that the leptons from b-quarks (having typically higher STIP value) in both relevant backgrounds events - tend likely to mimic the 2 leptons involved in the  $Z^*$  reconstruction.

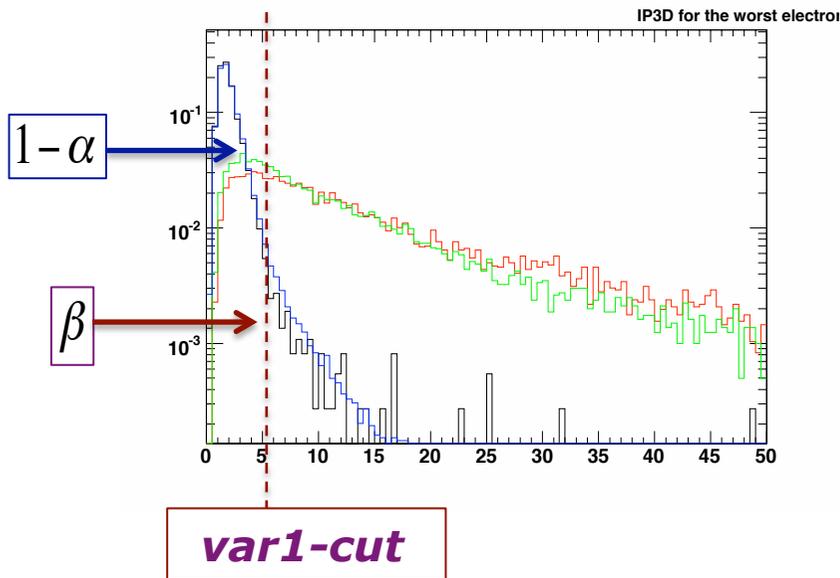


# Discriminazione Segnale-vs-Fondo - I



Si vuole far variare *var1-cut* con continuita' per valutare come variano i 2 integrali e rappresentarne la variazione una contro l'altra (curva ROC)!

# Discriminazione Segnale-vs-Fondo - II



Siccome le "PDF" sono "binnate" gli integrali parziali  $1-\alpha$  e  $\beta$  corrispondenti a valori progressivi di *var1-cut* saranno calcolati dal primo bin al *j*-esimo bin parziale fatto crescere progressivamente in un for-loop.

Siccome queste "PDF" sono PDF effettive solo se normalizzate, devo dividere gli integrali parziali per quelli totali !

```
for (int i=0; i<3; i++)  
{  
    TotIntegral1[i] = hVar1[i]->Integral(1,201);  
    nBins1 = hVar1[i]->GetNbinsX();  
    for(int j=1; j<nBins1+1; j++)  
    {  
        PartIntegral1[i] = hVar1[i]->Integral(1,j);  
        Eff1[i] = PartIntegral1[i]/TotIntegral1[i];  
        IntegralCounts1[i][j-1]=Eff1[i]; hVarRatio[i]->Fill(Eff1[i]);  
    }  
}
```

# Discriminazione Segnale-vs-Fondo - III

Nel doppio loop della slide precedente ...

viene riempita la matrice  $3 \times 200$  `IntegralCounts1(i,j)` per la `var1`, con i 200 valori degli integrali:

- $(1-\alpha)$  per  $i=0$
- $\beta$  per  $i=1$
- $\beta$  per  $i=2$

Analogamente nella macro si procede con la `var2`.

Infine si fanno i cosiddetti scatter plot per le varie combinazioni.

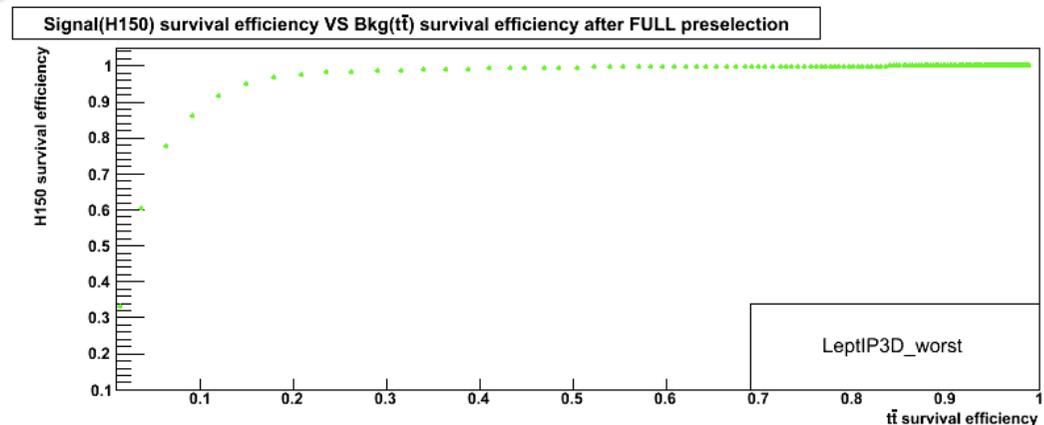
Per esempio, per la `var1`:

```
gr_h150_TT_vtx = new TGraph(nBins1, IntegralCounts1[1], IntegralCounts1[0]);
```

Vettore = riga della Matrice per  $i=1$

Vettore = riga della Matrice per  $i=0$

... e si ottiene:

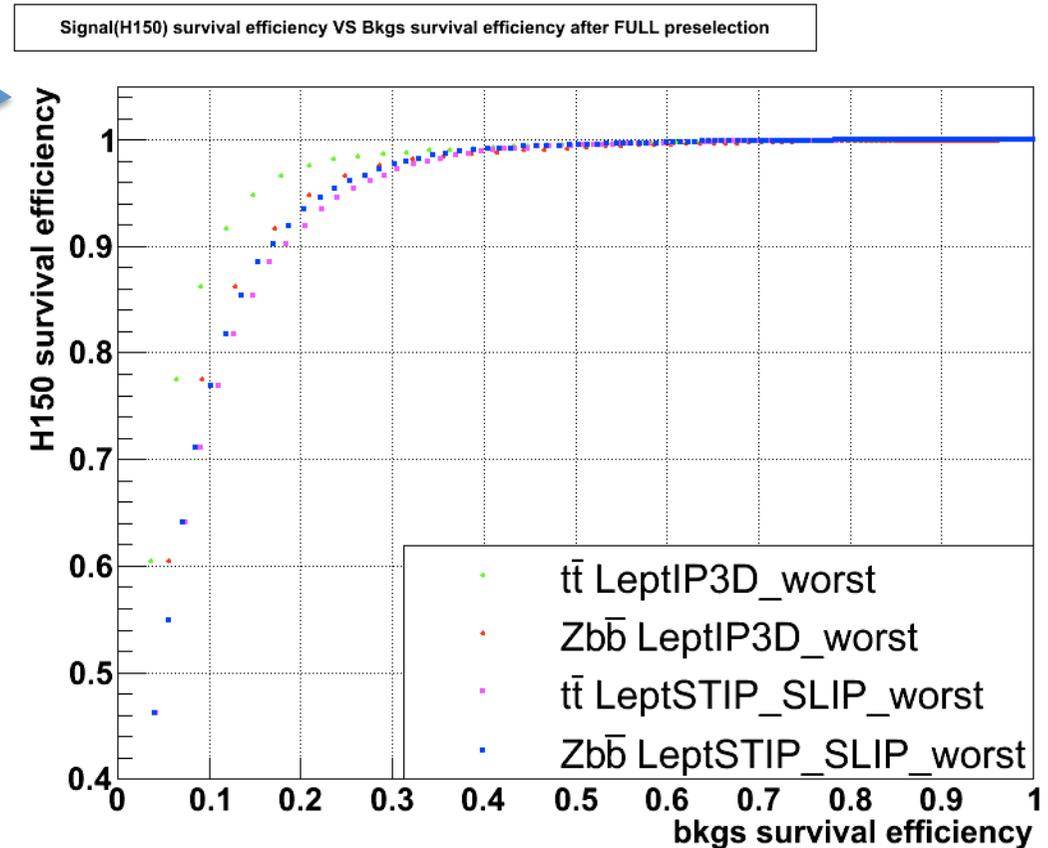


# Discriminazione Segnale-vs-Fondo - IV

Infine i 4 scatter plot vengono sovrapposti :

Per confrontare i due algoritmi bisogna confrontare:

**verde** vs **rosa** (reiezione  $t\bar{t}$ )  
**rosso** vs **blu** (reiezione  $Zb\bar{b}$ )



**Breve conclusione:**

- 1) la statistica var1 e' migliore della var2 ;**
- 2) il vantaggio di var1 e' apprezzabile nella reiezione del fondo  $t\bar{t}$  (meno in quella del fondo  $Zb\bar{b}$ )**