



Suche nach \tilde{t} in hadronische Endzustände mithilfe von multivariaten Methoden mit dem ATLAS-Detektor

Jonas Graw, betreut von Nicolas Köhler

Max-Planck-Institut für Physik
(Werner-Heisenberg-Institut)

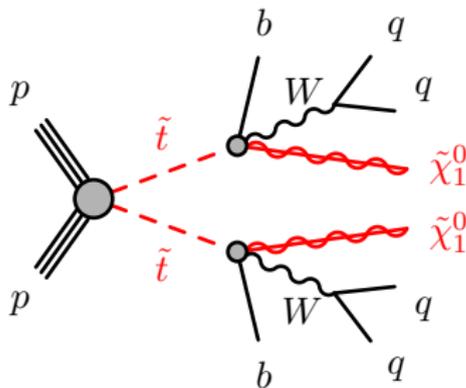
27. März 2017



Bundesministerium
für Bildung
und Forschung

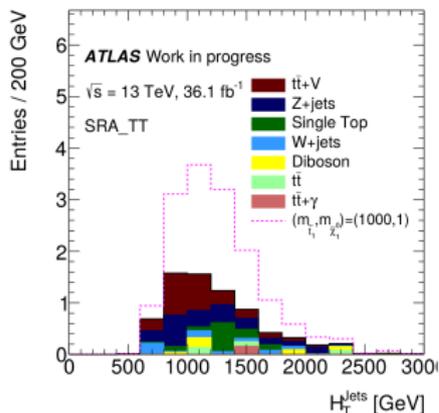


MAX-PLANCK-GESellschaft



- Keine Leptonen
- min. 6 Jets
- min. 2 b-Jets

$$m_{\tilde{t}} \gg m_{\tilde{\chi}_1^0}$$

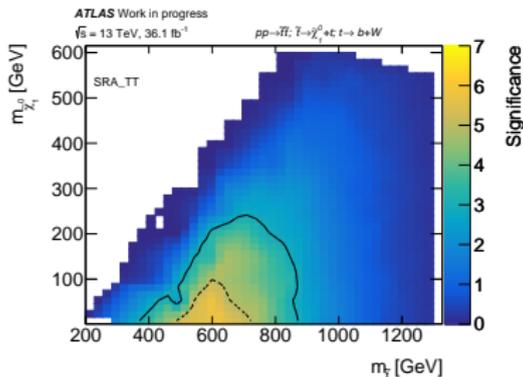


- Variablendefinitionen:

$$H_T^{Jets} = \sum^{Jets} p_T$$

$$H_{T,sig} = \frac{E_T^{miss}}{\sqrt{H_T^{Jets}}}$$

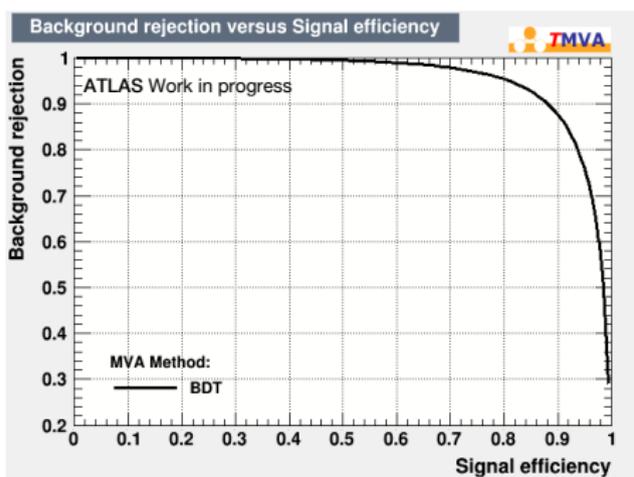
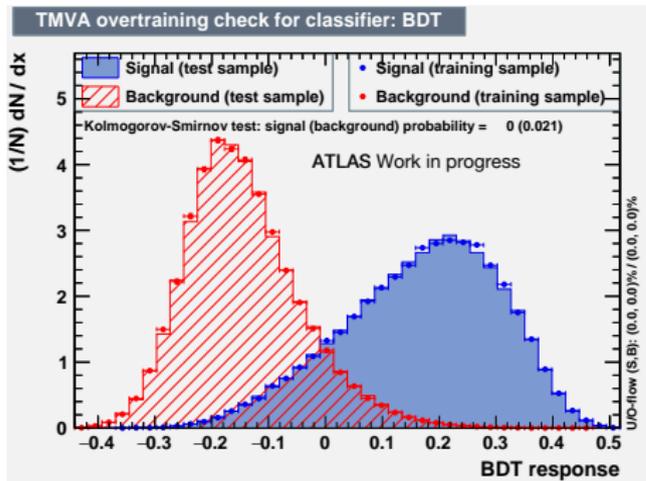
- Verwendung von diskriminierenden Variablen um möglichst viel Untergrund zu eliminieren
- Schnitt auf diskriminierende Variablen um möglichst große Parameterräume mit hoher Signifikanz zu erreichen



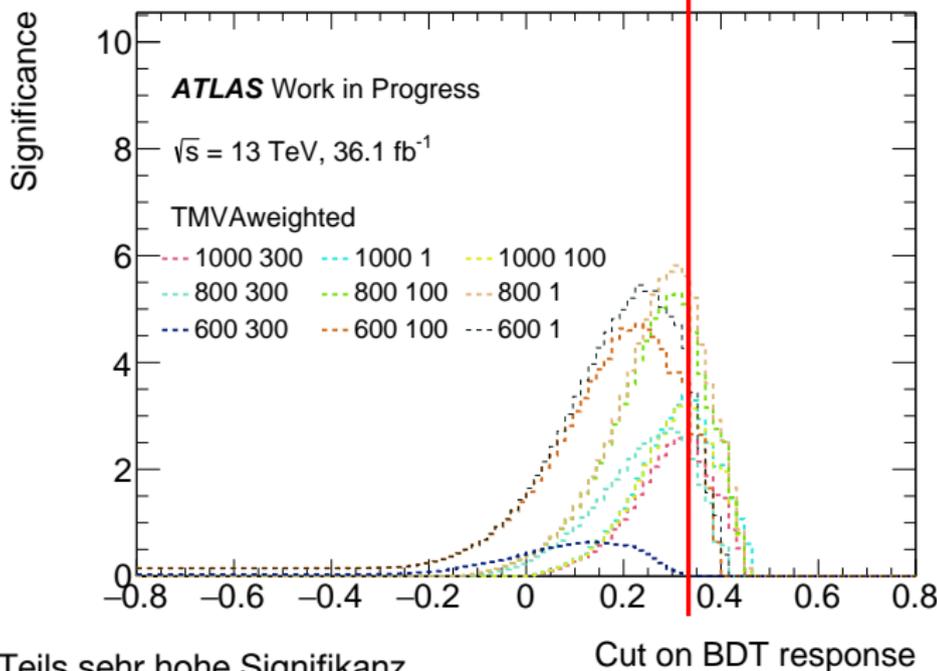
- Optimiert für $m_{\tilde{t}} = 1000 \text{ GeV}$ und $m_{\tilde{\chi}^0} = 1 \text{ GeV}$
- Wichtige Variablen:
 $m_{T2}, m_T^{b,min}, m_T^{b,max},$
 $m_{jet,R=1.2}^0, m_{jet,R=1.2}^1, m_{jet,R=0.8}^0$

- Wie kann man Parameterräume mit hoher Signifikanz in Zukunft vergrößern?
- Wie kann man Variablen mittels multivariater Methoden besser verwenden?

- Boosted Decision Tree (BDT) verwendet um Benutzung der Diskriminanzvariablen zu optimieren
- BDT response ist Indikator, wie wahrscheinlich Ereignis Signal bzw. Untergrund ist

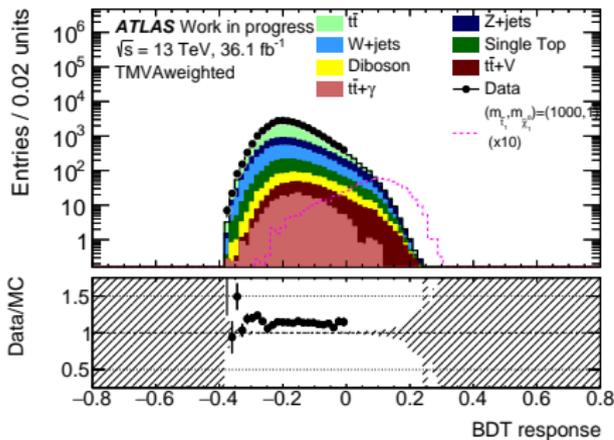


- Test- und Trainingsdaten stimmen sehr gut überein
- Kein Übertraining

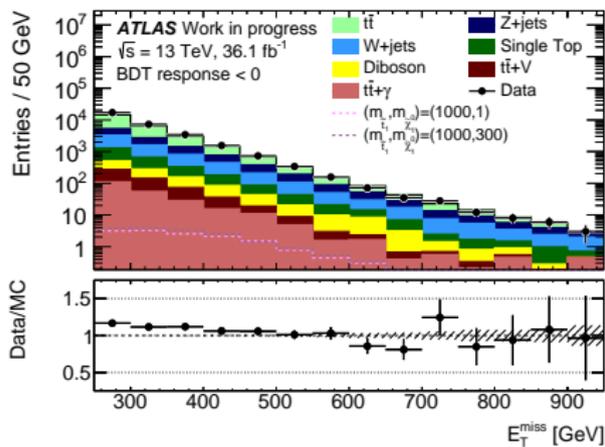


- Teils sehr hohe Signifikanz
- Wichtige Variablen: E_T^{miss} , m_{T2} , $p_T(top)$
- Schneiden bei BDT-response $\geq 0,34$

¹Training für Modell mit $m_{\tilde{t}} \geq 1000 \text{ GeV}$

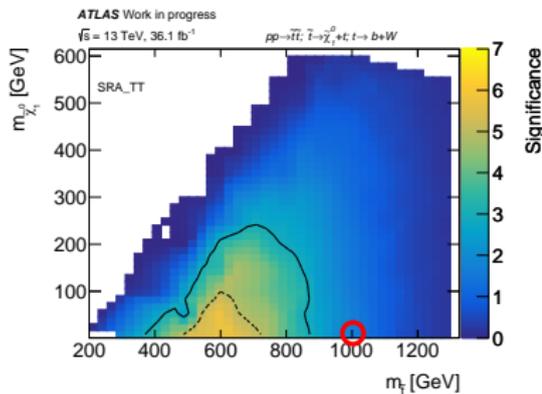


- Blinded für BDT response > 0
- Kleine Abweichung zwischen Daten und Vorhersagen sichtbar

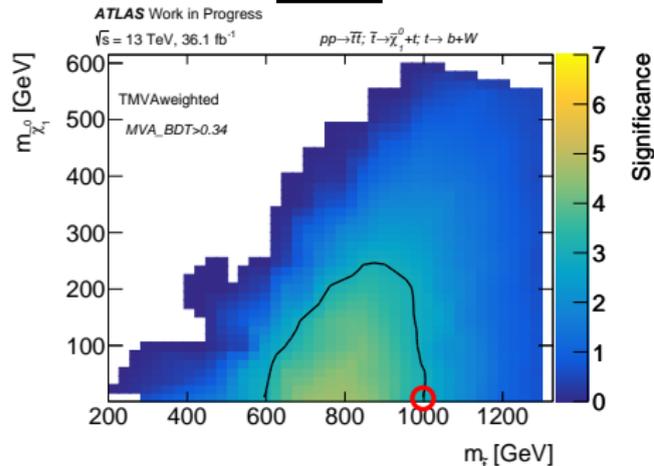


- Gute Übereinstimmung der Daten mit der Untergrundvorhersage

Schnittbasierte Methode



BDT²



SRATT	BDT
-------	-----

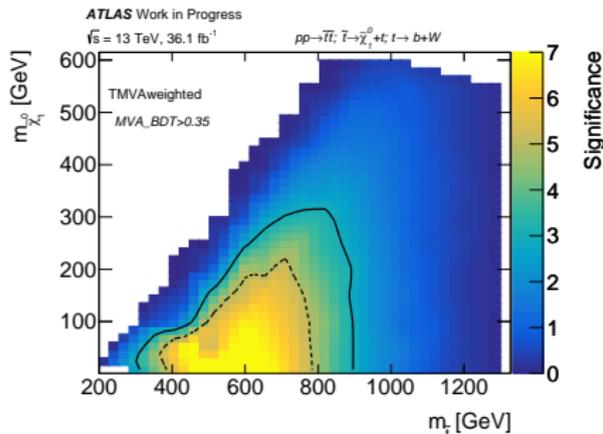
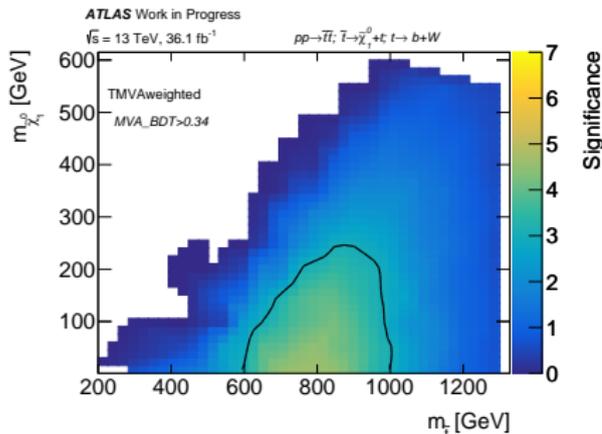
1,7 σ	2,9 σ
--------------	--------------

→ Erwartete Signifikanz von 3 σ
 bis $m_{\tilde{t}} = 1000 \text{ GeV}$

²Training für Modell mit $m_{\tilde{t}} \geq 1 \text{ TeV}$

- Training für Modell mit $m_{\tilde{t}} \geq 1000$ GeV

- Training mit allen $\tilde{t} \rightarrow t + \tilde{\chi}_1^0$ Modellen

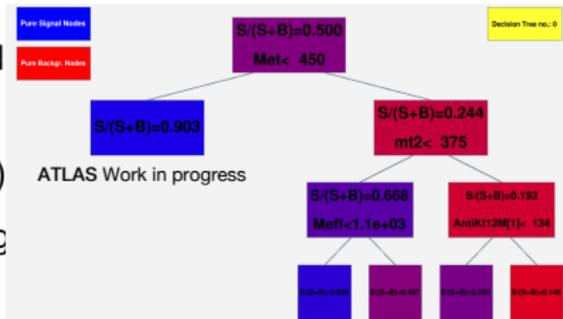


- Deutliche Vergrößerung der signifikanten Fläche, v.a. Richtung Diagonale
- Bei $m_{\tilde{t}} = 600$ GeV und $m_{\tilde{\chi}_1^0} = 300$ GeV erreicht Training mit allen Modellen Signifikanz von $0,8\sigma$
- Für große $m_{\tilde{t}}$ ist Training mit $m_{\tilde{t}} \geq 1000$ GeV vielversprechender

- Multivariate Optimierung von Signalregion für $\tilde{t} \rightarrow 0\ell$ -Analyse
- BDT führt zu Erhöhung von Signifikanz
- Training mit Datensätzen mit $m_{\tilde{t}} \geq 1000$ GeV $\rightarrow 3\sigma$ bis 1000 GeV
- Training mit allen Datensätzen $\rightarrow 3\sigma$ für $m_{\tilde{t}} = 600$ GeV, $m_{\tilde{\chi}_1^0} = 250$ GeV
- Wie kann man die Phasenräume vergrößern?
- **Plan:**
 - Optimierung entlang der Diagonalen
 - Optimierung für hohe \tilde{t} -Massen
 - Verwendung von anderen multivariaten Analysemethoden

ANHANG

- Aufteilung Prozesse: Signal und Untergrund
- Abzweigentscheidung wird durch genau eine Diskriminanzvariable getroffen (Schnitt)
- gewählte Diskriminanzvariable gibt bestmög Untergrund an



- **Boosting:** Training eines neuen Baumes, wobei falsch klassifizierte Ereignisse stärker gewichtet werden
- Verwendung eines Entscheidungswaldes anstatt eines Entscheidungsbaums

- BDT response $r(i) \in [-1, 1]$ eines Ereignisses i :

Klassifizierungsmaß abhängig von den Bäumen, wobei Grenzfälle:

$$\left\{ \begin{array}{l} r(i) = +1 \\ r(i) = -1 \end{array} \right\} : \text{Alle Bäume klassifizieren } i \text{ als } \left\{ \begin{array}{l} \text{Signal} \\ \text{Untergrund} \end{array} \right\}$$

- Nach Training: Vergleiche wahren Wert der Testprobe y_i mit Vorhersage s_i .
 w_i : Wichtungen, wobei $\sum_i w_i = 1$
- Fehlerquotient: $e = \sum_i w_i 1_{s_i \neq y_i}$
- Boostfaktor $\alpha = \beta \cdot \ln\left(\frac{1-e}{e}\right)$ mit β konstant, meist $\beta \in [0, 1]$
- Neue Gewichte: $w_i \rightarrow w_i \cdot \exp(\alpha \cdot 1_{s_i \neq y_i})$
- BDT response des Ereignisses i : $r_i = \frac{\sum_m \alpha_m (s_i)_m}{\sum_m \alpha_m}$, wobei

$$(s_i)_m = \begin{cases} 1 & \text{falls Tree } m \text{ Signal vorhergesagt} \\ -1 & \text{falls Tree } m \text{ Untergrund vorhergesagt} \end{cases}$$

- $N(i)$: Anzahl Events mit $BDT - response \leq i$. Dann $N(i) = B(i) + S(i)$
- N_B : Die Anzahl der beobachteten Untergrund-Ereignisse. Dann:
 $p - value = p(N_B \geq N)$

