

# **Die Bedeutung der klinischen Relevanz für die Machbarkeit klinischer Studien – Eine Herausforderung für den Kliniker und Biometriker**

***Prof. Dr. Dieter Hauschke***

***Köln, den 18.06.2010***



# Gliederung

- VFA ↔ Biometrie ↔ IQWIG
- Biometrische ‚Praxis‘
- Regulatorische Anforderungen
- Klinische Relevanz in COPD-Studien
  - Bewertung mittels Konfidenzintervalle
  - Überlegungen zur Güte (Power)
- Gold Standard Design
- Literatur

# Position des IQWIG



*Institute for Quality and Efficiency in Health Care*

## Allgemeine Methoden

Version 3.0 vom 27.05.2008

# Position des IQWIG

Für die Beurteilung der klinischen Relevanz von Studienergebnissen gibt es noch kein breit akzeptiertes methodisches Vorgehen. Nur in wenigen Leitlinien finden sich Hinweise auf die Definition von relevanten beziehungsweise irrelevanten Unterschieden zwischen Gruppen. Ein erster Ansatz zur Beurteilung der klinischen Relevanz von Studienergebnissen ist die Bewertung des Effektschätzers und des dazugehörigen Konfidenzintervalls mithilfe medizinischer Sachkenntnis. Ein formales Relevanzkriterium kann die Beurteilung der (im Falle von günstigen Effekten) unteren Konfidenzgrenze für den Effektschätzer beziehungsweise die Anwendung eines statistischen Tests mit Verschiebung der Nullhypothese zum statistischen Nachweis relevanter klinischer Effekte sein [382]. Eine weitere Möglichkeit liegt darin, ein Relevanzkriterium individuell zu formulieren, zum Beispiel im Sinne einer Responderdefinition [229]. Darüber hinaus spielt die individuelle Einschätzung der Betroffenen eine wesentliche Rolle. Anhaltspunkte hierfür wird im Einzelfall die Darlegung patientenrelevanter Endpunkte liefern. Das Institut nimmt die Bewertung der klinischen Relevanz problemorientiert unter Berücksichtigung dieser Aspekte vor.

# **Position des IQWIG**

IQWiG-Berichte – Jahr: 2009 Nr. 55

## **Selektive Serotonin- und Noradrenalin- Wiederaufnahmehemmer (SNRI) bei Patienten mit Depressionen**

Das Literaturscreening wurde von 2 Reviewern unabhängig voneinander durchgeführt. Nach einer Bewertung der Studienqualität wurden die Ergebnisse der einzelnen Studien nach Prüfsubstanzen und Zielgrößen geordnet gegenübergestellt und beschrieben. Wenn möglich und sinnvoll, wurden Meta-Analysen durchgeführt. Für Ergebnisse kontinuierlicher Skalen war für einen Nutzennachweis zusätzlich zur statistischen Signifikanz des Gruppenunterschieds notwendig, dass der Effekt eine definierte Größe überschritt (Relevanzgrenze Cohen's d / Hedges' g = 0,2).

# Position des IQWIG

Tabelle 2 (Fortsetzung): Zusammenfassung zum Vergleich von Duloxetin mit Placebo bzw. SSRI

| Zielgröße     | Ergebnis der Meta-Analysen bzw. Einzelstudien<br>Gruppenunterschied [95 %-KI] |                                    |                                 |                       |
|---------------|---|------------------------------------|---------------------------------|-----------------------|
|               | DUL vs. Plc <sup>a</sup>  |                                    | DUL vs. SSRI <sup>a</sup>       |                       |
|               | Kurzzeit-Akuttherapie   | Langzeit-Akuttherapie <sup>b</sup> | Rückfallprävention <sup>b</sup> | Kurzzeit-Akuttherapie |
| Schmerz (VAS) | -4,56 [-6,79; -2,33] <sup>e</sup><br>-0,20 [-0,30; -0,10] <sup>g</sup>        |                                    |                                 |                       |

Bei der Interpretation der Effektstärken wurde das Konfidenzintervall zur Relevanzgrenze von 0,2 im Cohen's d / Hedges' g in Relation gesetzt. Lag das Konfidenzintervall vollständig oberhalb der Relevanzgrenze wurde von einer relevanten Effektgröße ausgegangen und ein Nutzenbeleg oder -hinweis attestiert. Lag das Konfidenzintervall teilweise oder komplett unterhalb dieser Grenze, so konnte die Relevanz des vorliegenden Effekts nicht mit ausreichender Sicherheit eingeschätzt werden. Es blieb somit unklar, ob die Effektstärke eine so relevante Größenordnung erreichte, dass von einem Nutzen gesprochen werden konnte. In diesen Fällen blieb der Nutzen unklar und ein Nutzen war nicht belegt.

f: relevante Effektgröße (Cohen's d / Hedges' g)

g: Relevanz des vorliegenden Effekts nicht mit ausreichender Sicherheit einzuschätzen (Cohen's d / Hedges' g)

# Position des VFA

## Beurteilung klinischer Relevanz von Ergebnissen klinischer Studien

Joachim Röhmel

Bremen, 1. Dezember 2009

Interessenkonflikt: Der Autor wurde vom vfa gegen ein Honorar beauftragt, eine Stellungnahme abzugeben zur Beurteilung klinischer Relevanz von Ergebnissen klinischer Studien unter Berücksichtigung der Praxis des IQWiG, eine Relevanzgrenze für die Effektgröße (ES) bei  $d=0.2$  fest zusetzen und sich dabei auf Cohen (1988) zu berufen.

# **Position des IQWiG**

Kommentar zur Stellungnahme von Prof. Dr. Joachim Röhmel (Bremen)

**"Beurteilung klinischer Relevanz von Ergebnissen klinischer Studien"**

Prof. Dr. Ralf Bender, Dr. Beate Wieseler, Dr. Guido Skipka,  
Dr. Thomas Kaiser, PD Dr. Stefan Lange (IQWiG)

Köln, den 22.03.2010

# Position des VFA/Sonofi-Aventis

## Gutachten

### Methodische Aspekte bei der Festlegung von Kenngrößen in der Meta-Epidemiologie klinischer Studien

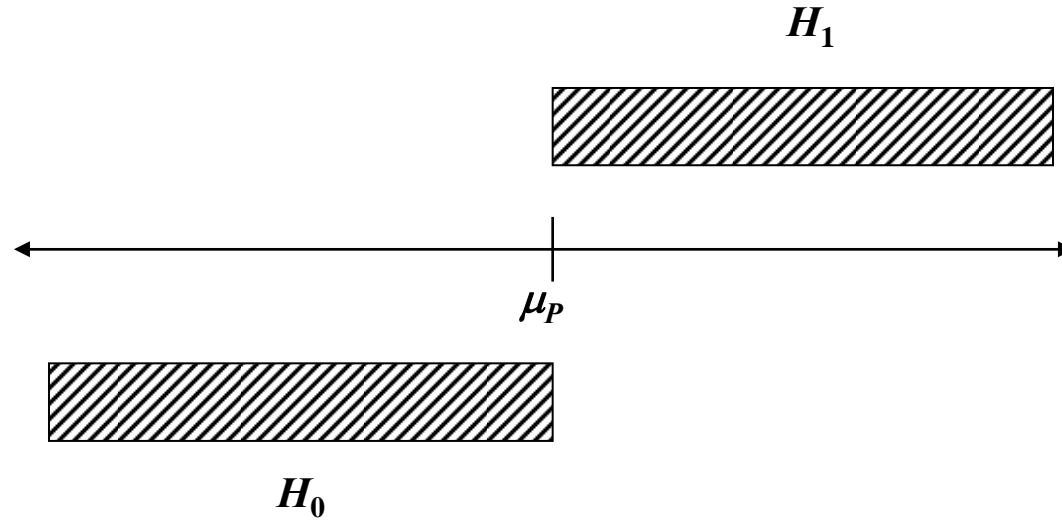
20. April 2009

Prof. Dr. Ulrich Mansmann  
IBE, LMU München  
[mansmann@ibe.med.uni-muenchen.de](mailto:mansmann@ibe.med.uni-muenchen.de)

**Interessenkonflikt:** Der Autor wurde von der Firma Sonofi-Aventis gegen die Zahlung eines Honorars beauftragt, die vorhandene methodische Literatur zu meta-epidemiologischen Untersuchungen klinischer Studien zu sichten und im Hinblick auf deren Relevanz für Bewertungen im IQWIG-Abschlußbericht zu *Langwirksame Insulinanaloga zur Behandlung des Diabetes mellitus Typ 2* zu diskutieren.

# Statistische Signifikanz

$H_0$ : unterlegen  $H_1$ : überlegen



**Annahme: höhere Werte der Zielvariablen bedeutet größere Wirksamkeit**

# Statistische Signifikanz

$$\left[ \bar{X}_T - \bar{X}_P - z_{0.975} \sigma \sqrt{\frac{2}{n}}, \bar{X}_T - \bar{X}_P + z_{0.975} \sigma \sqrt{\frac{2}{n}} \right]$$

$$n = 2(z_{0.975} + z_{0.8})^2 \frac{\sigma^2}{\Delta^2}, \Delta = \mu_T - \mu_P$$

**Lehne  $H_0$  ab, falls die untere Grenze des zweiseitigen 95%-KI oberhalb von 0 ist**

# Biometrische ‘Praxis’

1. A sample size of 334 in each group will have 80% power to detect a difference in means of 50.000 assuming that the common standard deviation is 230.000 using a two group t-test with a 0.050 two-sided significance level (nQuery)
  
2. A sample size of 334 in each group will have 80% power to detect a minimal important difference in means of 50.000 assuming that the common standard deviation is 230.000 using a two group t-test with a 0.050 two-sided significance level

# Biometrische ‘Praxis’

- Kontrollierte klinische Studien verfehlten wegen zu geringen Stichprobenumfängen oft ihr Ziel, eine überzeugende Aussage über die Wirksamkeit bzw. Überlegenheit einer Behandlung zu machen.
- Statistische Methoden in kontrollierten klinischen Studien führen häufig zu irreführenden und kontroversen Ergebnissen.

*Aktuelle Probleme in kontrollierten klinischen Studien. Die Medizinische Welt (1986), Martin Schumacher*

# **Regulatorische Anforderungen**

**ICH-E4-Note for Guidance on Dose Response  
Information to Support Drug Registration (1994)**

**It should be demonstrated, however, that the lowest dose(s) tested, if these are to be recommended, have a statistically significant and clinically meaningful effect.**

# Regulatorische Anforderungen

## CHMP (2005): Guideline on the Choice of the Non-Inferiority Margin

The next step interpreting a superiority trials is to consider whether the difference from placebo is **clinically relevant**. This is the clinical judgment stage of the ICH (E10) combination of both **statistical reasoning and clinical judgment**

# Regulatorische Anforderungen

CHMP (2005): Establishing a clinically relevant benefit of the difference between the test product and placebo is accomplished by considering the **point estimates** of the difference between the test product and placebo and addressing its clinical relevance, either using the original scale or by considering **responder rates**

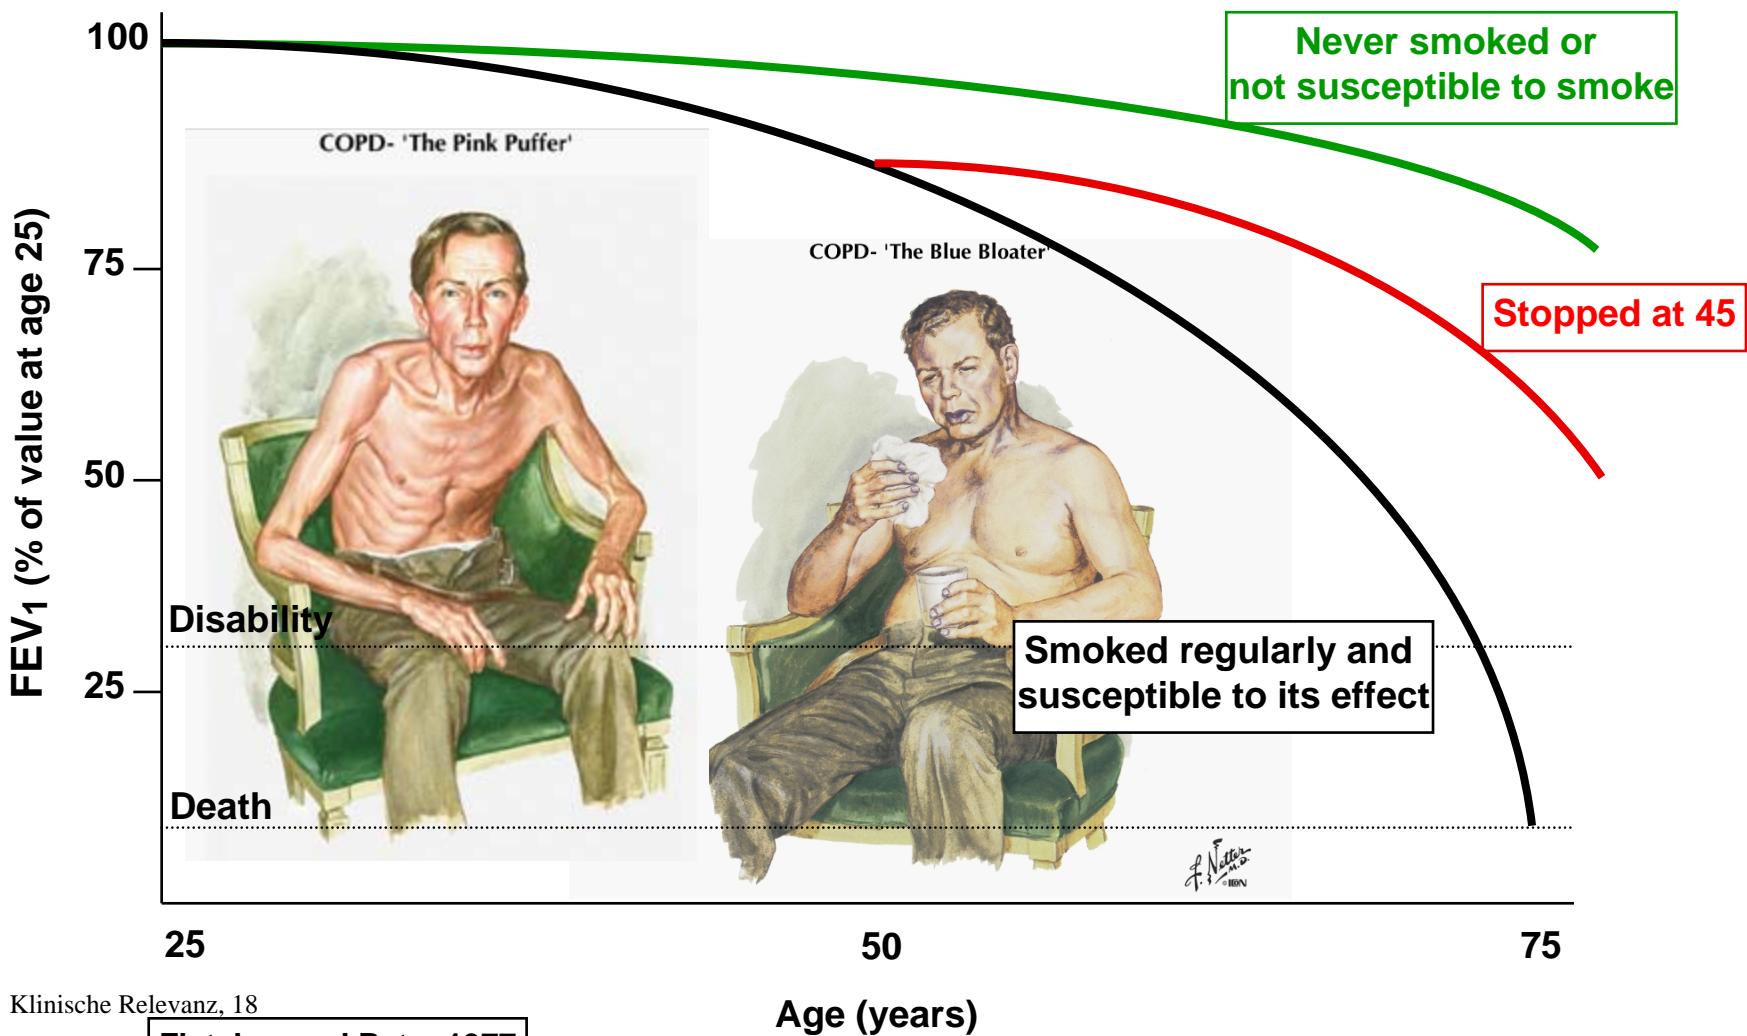
# Responder Analyse

- **CPMP-Guideline Diabetes Mellitus (2002)**

- primary variable: glycohaemoglobin ( $\text{HbA}_{1\text{C}}$ )
- primary analysis “should evaluate the **difference in evolution** from baseline of  $\text{HbA}_{1\text{C}}$ .”
- “The applicant should **also justify the clinical relevance** of the effect size observed. One method might be a **responder analysis** comparing the portion of patients who reached an absolute value of 7%.”

# COPD = Chronic Obstructive Pulmonary Disease

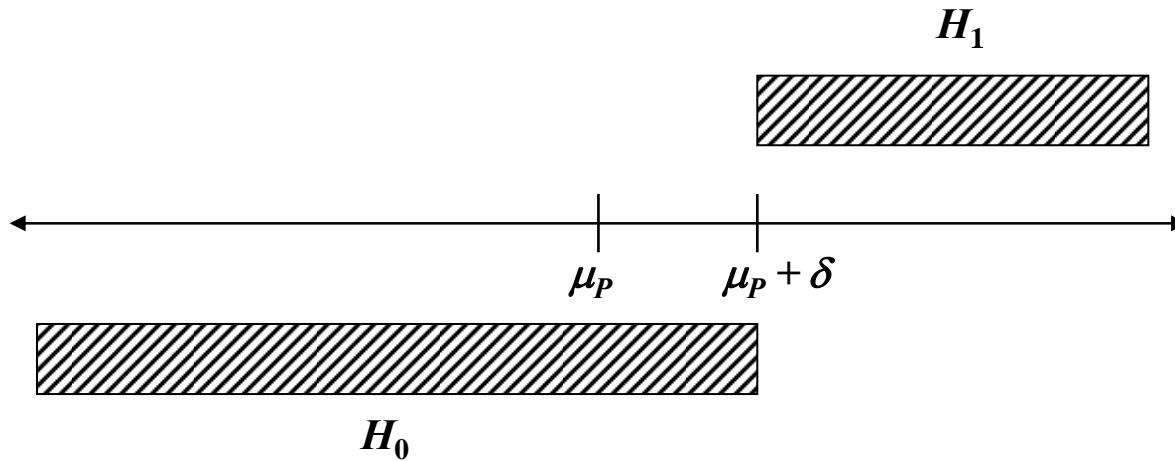
## Model of Annual Decline in FEV<sub>1</sub>



# Statistische und Klinische Signifikanz

$H_0$ : nicht relevant überlegen

$H_1$ : relevant überlegen



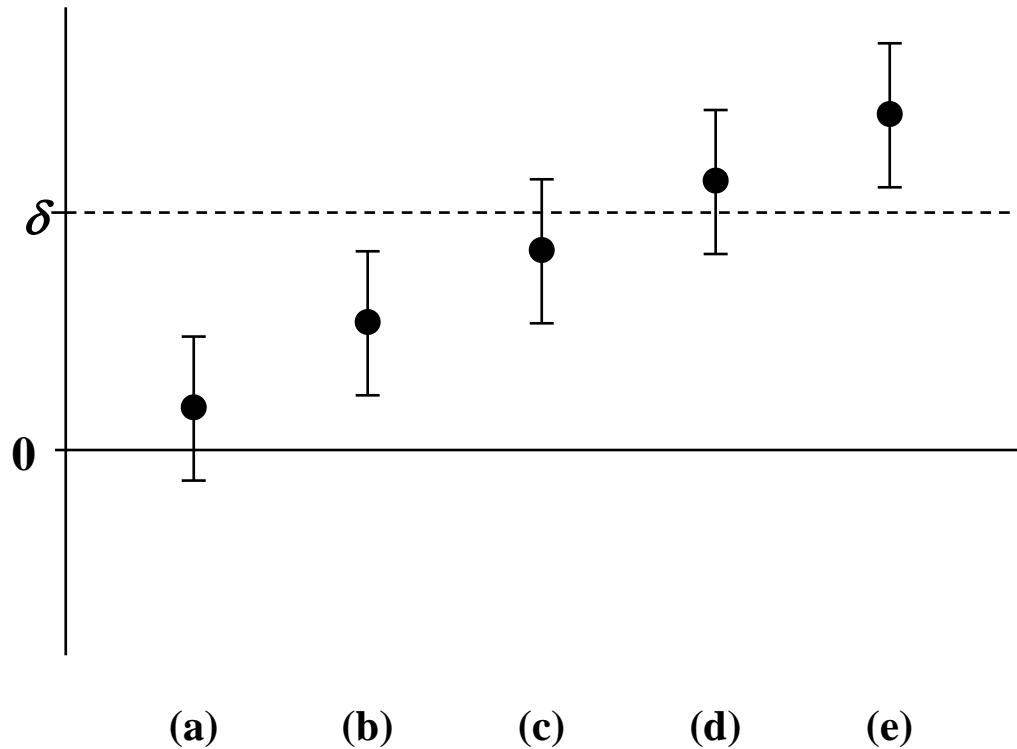
# Statistische und Klinische Signifikanz

$$\left[ \bar{X}_T - \bar{X}_P - z_{0.975} \sigma \sqrt{\frac{2}{n}}, \bar{X}_T - \bar{X}_P + z_{0.975} \sigma \sqrt{\frac{2}{n}} \right]$$

$$n = 2(z_{0.975} + z_{0.8})^2 \frac{\sigma^2}{(\delta - \Delta)^2}, \Delta = \mu_T - \mu_P$$

Lehne  $H_0$  ab, falls die untere Grenze des zweiseitigen 95%-KI oberhalb von  $\delta$  ist

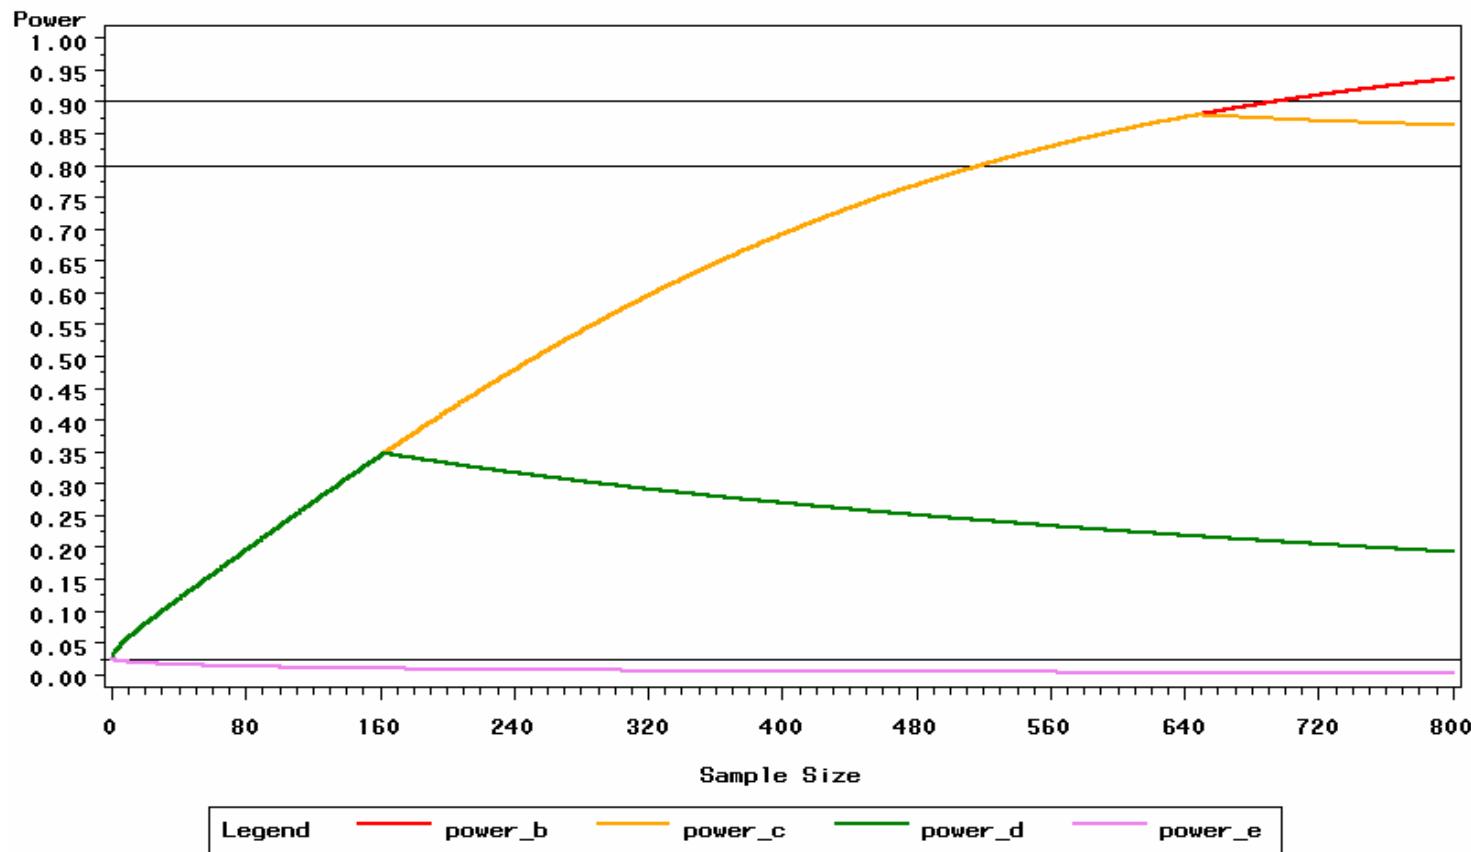
# Test – Placebo, zweiseitige 95% Konfidenzintervalle



# Power für FEV<sub>1</sub>

The SELECTED POWER APPROACHES for a GIVEN EXPECTED DIFFERENCE

One-sided alpha: 0.025, Standard deviation: 230 ml  
Clinically relevant delta: 50 ml  
Given expected delta: 40 ml



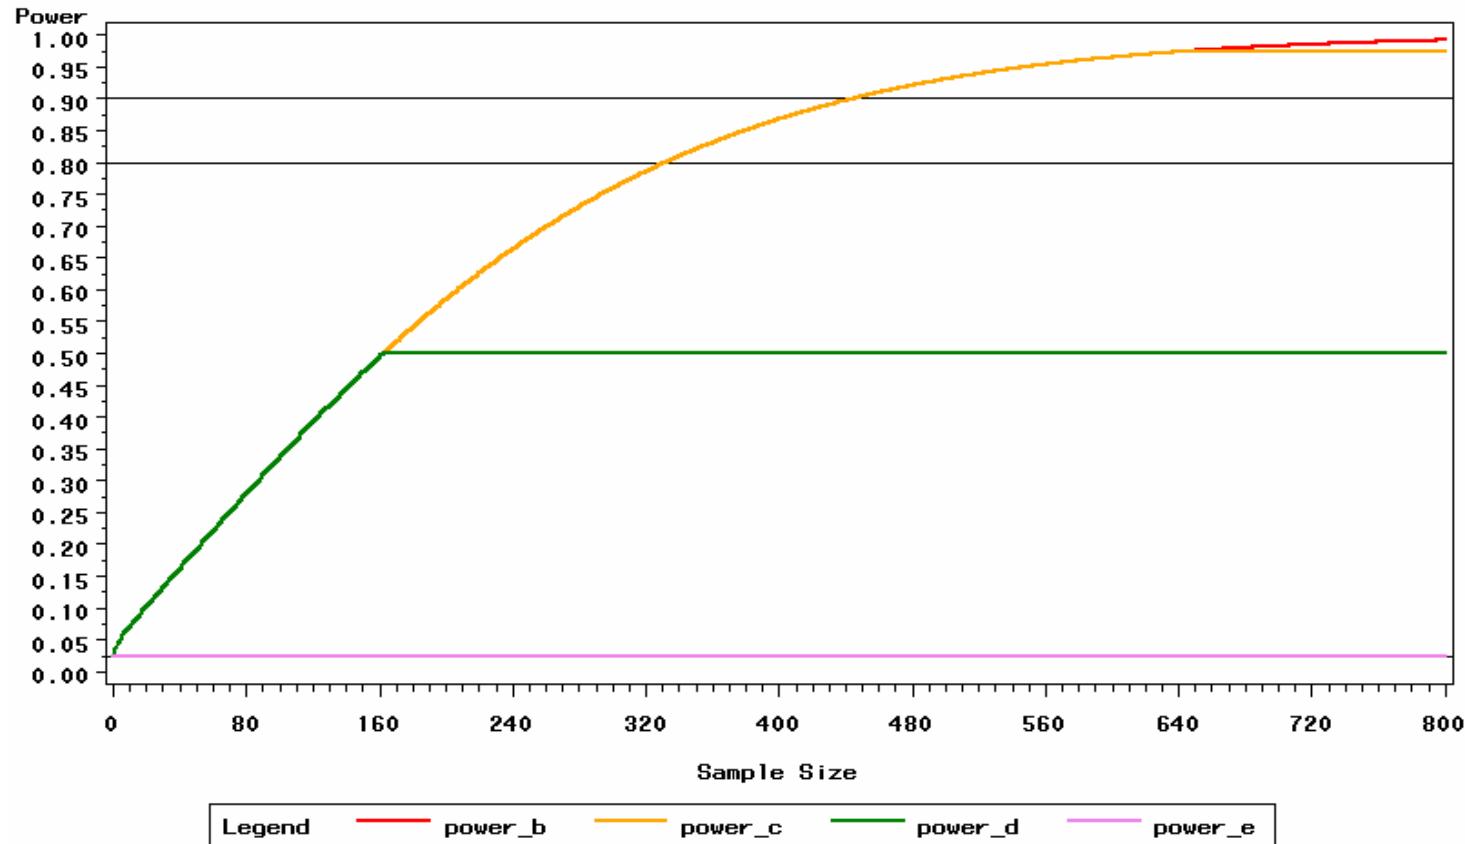
# Power für FEV<sub>1</sub>

The SELECTED POWER APPROACHES for a GIVEN EXPECTED DIFFERENCE

One-sided alpha: 0.025, Standard deviation: 230 ml

Clinically relevant delta: 50 ml

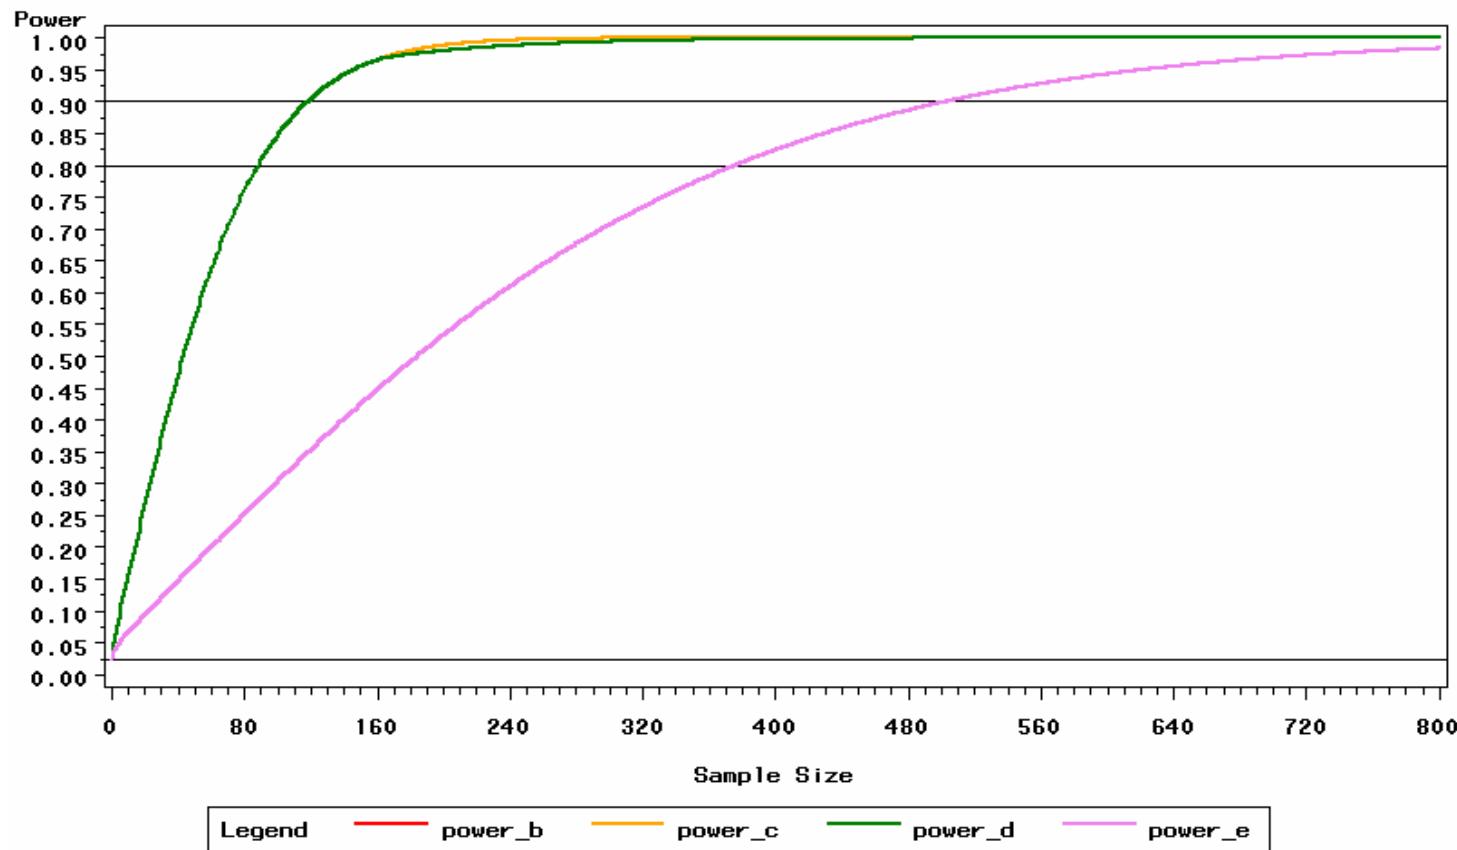
Given expected delta: 50 ml



# Power für FEV<sub>1</sub>

The SELECTED POWER APPROACHES for a GIVEN EXPECTED DIFFERENCE

One-sided alpha: 0.025, Standard deviation: 230 ml  
Clinically relevant delta: 50 ml  
Given expected delta: 97 ml



# Konklusion

## *Assessment of clinical relevance by considering point estimates and associated confidence intervals*



Meinhard Kieser<sup>1,2,\*†</sup> and Dieter Hauschke<sup>3</sup>

<sup>1</sup>Department of Biometry, Dr. Willmar Schwabe Pharmaceuticals, Karlsruhe, Germany

<sup>2</sup>Medical Biometry Unit, University of Heidelberg, Germany

<sup>3</sup>Department of Biometry, Altana Pharma, Konstanz, Germany

*For the proof of efficacy of a new drug in a placebo-controlled clinical trial it is not sufficient merely to demonstrate a statistically significant treatment difference. In recent years, regulatory authorities have strongly recommended assessing additionally whether the observed effect size is also of clinical relevance. This opinion is reflected in various guidelines which are of the utmost importance for the successful approval of a new drug. Clinical relevance can be investigated by responder analyses or by considering the point estimates on the original scale together with the associated confidence intervals. In this paper, we focus on the latter approach and discuss the suitability of different criteria which are commonly applied in medical research. Copyright © 2005 John Wiley & Sons, Ltd.*

**Keywords:** *clinically important difference; clinical relevance; statistical significance; sample size; statistical power*

# Konklusion

**CHMP (2005)** Clinical judgment is applied to assess whether the observed difference from placebo is clinically relevant. The existence of the reference arm (active control) can assist in making this judgment

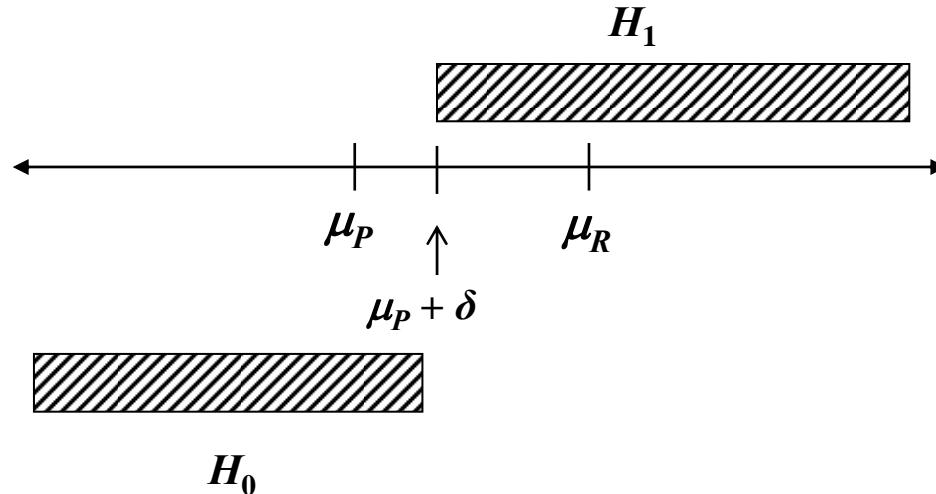


**Hauschke, Pigeot (2006)** Proof of Efficacy in the Gold Standard Design (Placebo, Test, Active Control)

# Gold Standard Design

$H_0$ :nicht relevant überlegen

$H_1$ :relevant überlegen



# Gold Standard Design

I.Piegeot & J. Röhmel

- Ulcerative colitis
- Crohn's disease
- Migraine
- Psoriasis
- Depression
- Bipolar Disorders
- Parkinson's Disease
- Allergic Rhino-Conjunctivitis
- Asthma
- Pain
- Schizophrenia
- Multiple Sklerosis

# Gold Standard Design



European Medicines Agency  
*Evaluation of Medicines for Human Use*

London, 18 November 2004  
CHMP/EWP/2454/02 corr

**COMMITTEE FOR MEDICINAL PRODUCTS FOR HUMAN USE  
(CHMP)**

**GUIDELINE ON CLINICAL INVESTIGATION OF MEDICINAL  
PRODUCTS INDICATED FOR THE TREATMENT OF PSORIASIS**

# Gold Standard Design

Parallel group, double-blind, vehicle and active comparator controlled studies are recommended. Only three-arm trials allow comparison of the efficacy and safety of a new agent both with the vehicle and an active comparator, and thereby a proper assessment of benefit/risk ratio. In addition, since response to established topical agents (comparators) is variable, vehicle arm is needed to ascertain assay sensitivity. In designing a non-inferiority study, a non-inferiority margin should be prospectively defined by taking into account both the established efficacy of the vehicle and the efficacy of the active comparator over vehicle (or emollient).

For trials aiming to show superiority of a new drug to the known active treatment, two-arm trials without placebo control are acceptable. If superiority is not shown, non-inferiority can not be claimed due to the lack of a placebo arm as an internal validation.

# Gold Standard Design



European Medicines Agency  
*Evaluation of Medicines for Human Use*

London, 26 January 2006  
Doc. Ref. CPMP/EWP/252/03 Rev. 1

**COMMITTEE FOR MEDICINAL PRODUCTS FOR HUMAN USE  
(CHMP)**

**DRAFT**

**GUIDELINE ON CLINICAL MEDICINAL PRODUCTS INTENDED FOR THE  
TREATMENT OF NEUROPATHIC PAIN**

# Gold Standard Design

## 3.2 Therapeutic Confirmatory Studies

### Study design

Randomised, double blind, placebo controlled studies are required to establish efficacy in neuropathic pain.

Neuropathic pain is usually present as a chronic situation and the study duration should take this in consideration.

As there is an increasing number of drugs approved for neuropathic pain, in those clinical conditions for which there is an established treatment option a three-arm study (study drug – comparator - placebo) should be provided in order to allow the assessment of comparative efficacy and safety of a new product.

# VFA und Biometry und IQWIG

**Workshop Meta-Analyses for Drug Assessment  
06.09.2010, 55. Annual Meeting of the GMDS**

**Guido Schwarzer (Working group in systematical reviews), Ralf Bender (IQWIG), Friedhelm Leverkus (Pfizer), Dieter Hauschke (University Freiburg)**

**Session 1: Incorporating clinical relevance (Dieter Hauschke)**

**Speaker: Stefanie Thomas, Jürgen Windeler, Joachim Röhmel, Stefan Lange, Armin Koch**

**Session 2: Indirect Comparisons (Guido Schwarzer)**

**Speaker: Sybille Sturtz, Ralf Bender, Peter Jüni, Georgia Salanti, Gerd Antes**

# Literature

**Victor (1987) On clinically relevant difference and shifted null hypotheses.** *Methods of Information in Medicine* 26, 110-116

**Kieser, Röhmel, Friede (2004)** Power and sample size determination when assessing the clinical relevance of trial results by responder analysis. *Statistics in Medicine* 23, 3287-3305

**Kieser, Hauschke (2005)** Assessment of clinical relevance by considering point estimates and associated confidence intervals. *Pharmaceutical Statistics* 4, 101-107

**Hauschke, Pigeot (2006)** Establishing efficacy of a new experimental treatment in the gold standard design. *Biometrical Journal* 6, 782-786