

SVT – Tagung vom 29. März 2012, Universität Irchel, Zürich

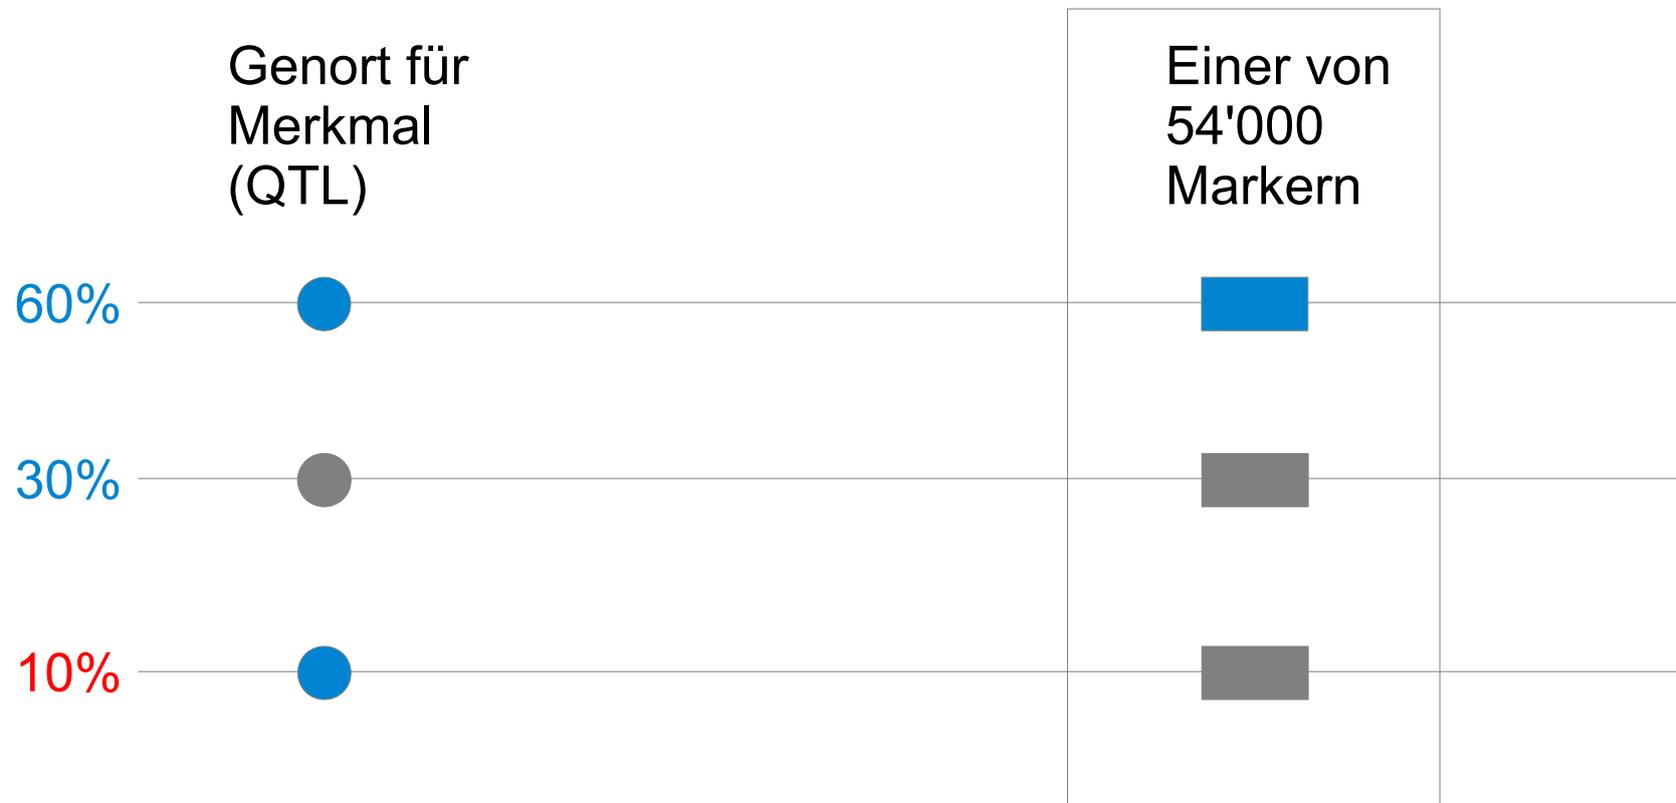
# Zukünftige Entwicklungen und Anwendungen der genomischen Selektion (GS)

Ruedi Fries und Hubert Pausch  
Lehrstuhl für Tierzucht  
Technische Universität München

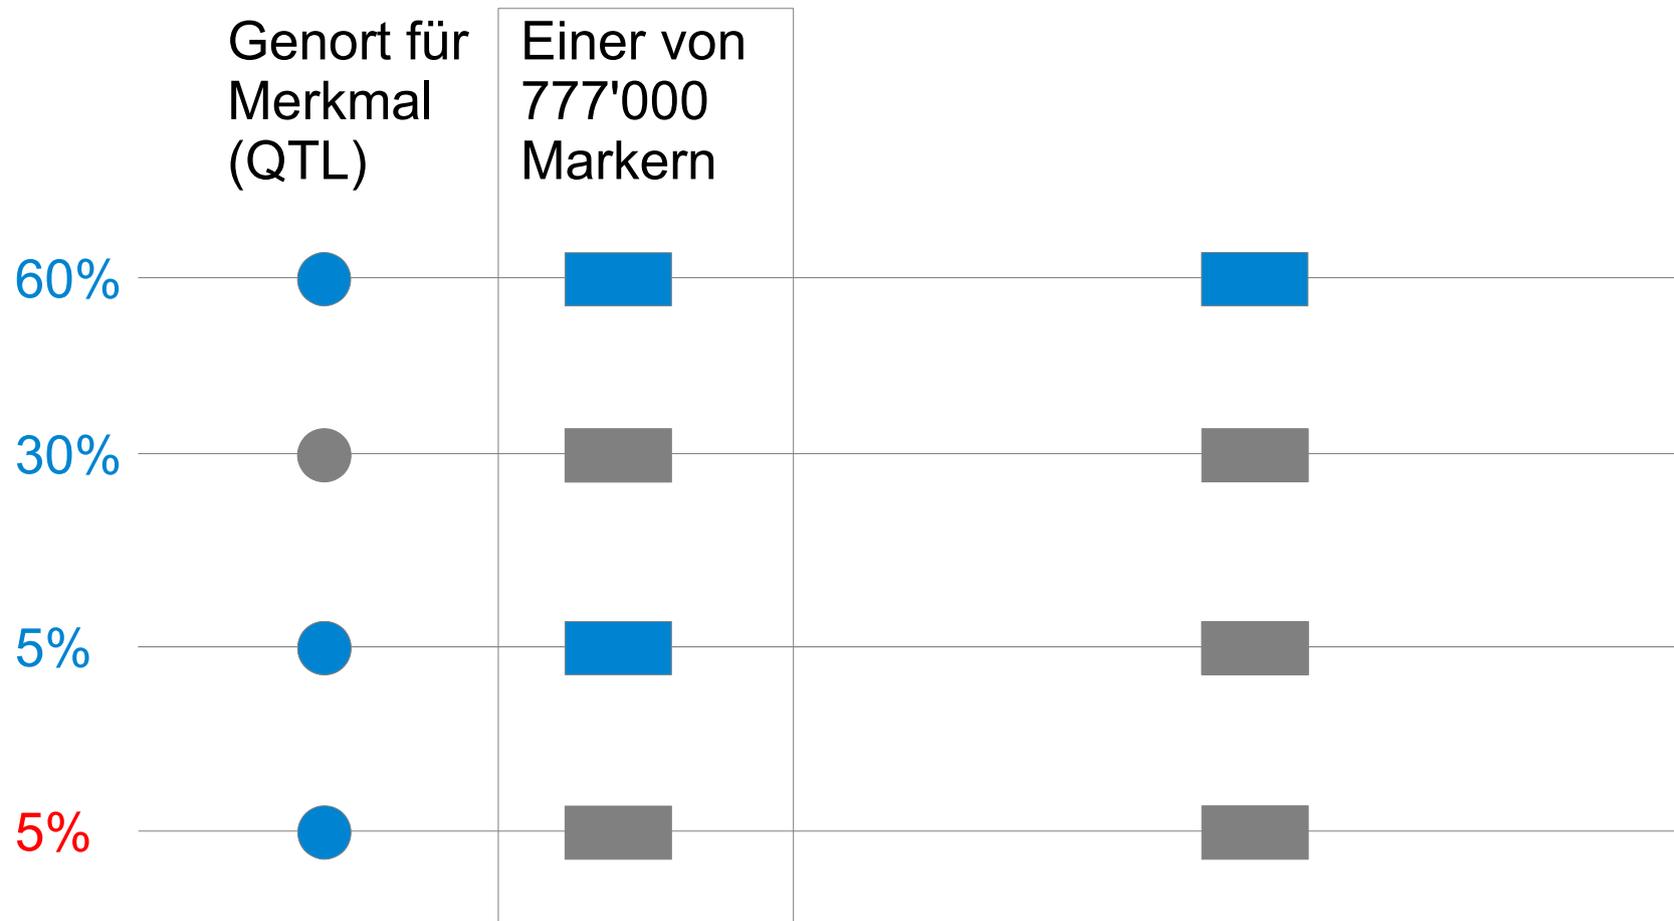
# GS 1.0 beim Milchrind

- Die Vorhersage des QTL – Status basiert auf gekoppelten Markern.
  - Das Kopplungsungleichgewicht ist über Generationen und Populationen hinweg nicht stabil.
- Die QTL-Architektur ist nicht bekannt
  - Nicht-additive Effekte werden nicht berücksichtigt.
- Ist teuer und deshalb im Wesentlichen auf männliche Tiere beschränkt.

# GS 1.0 – 54'000 Marker



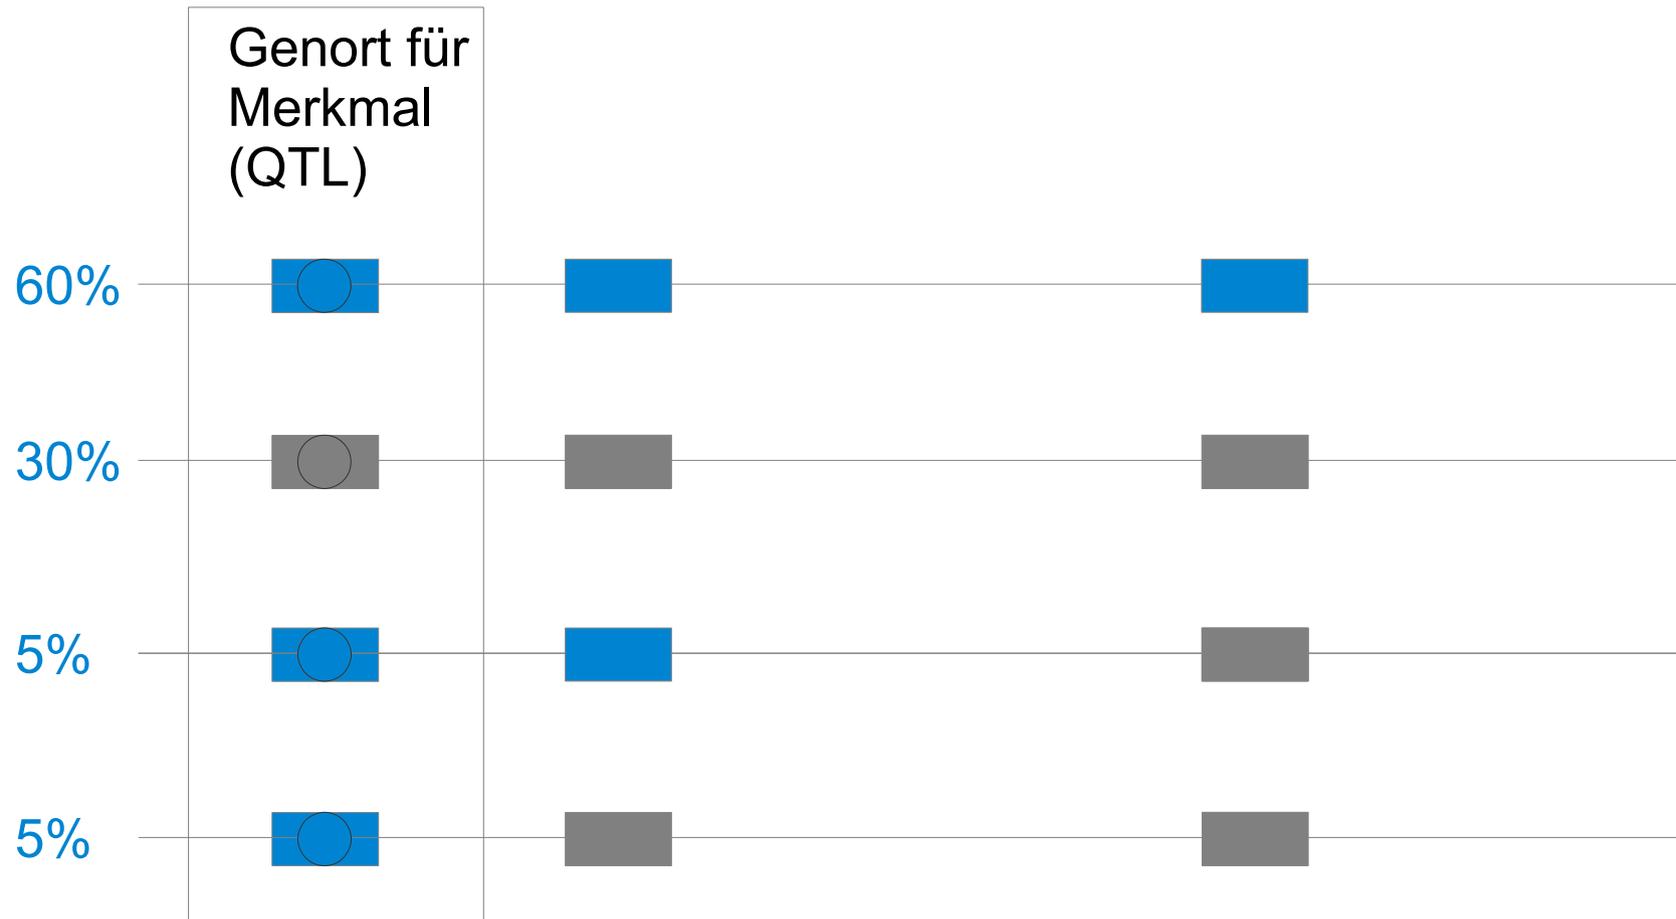
# GS 1.5 – 777'000 Marker



# GS 2.0 beim Milchrind

- Direkte Erfassung der QTL durch die Sequenzierung individueller Genome
- Berücksichtigung der QTL-Architektur
- “Flächendeckende”, kostengünstige genomische Evaluierung
- Vorhersage des genomischen Produktionswertes von Tieren

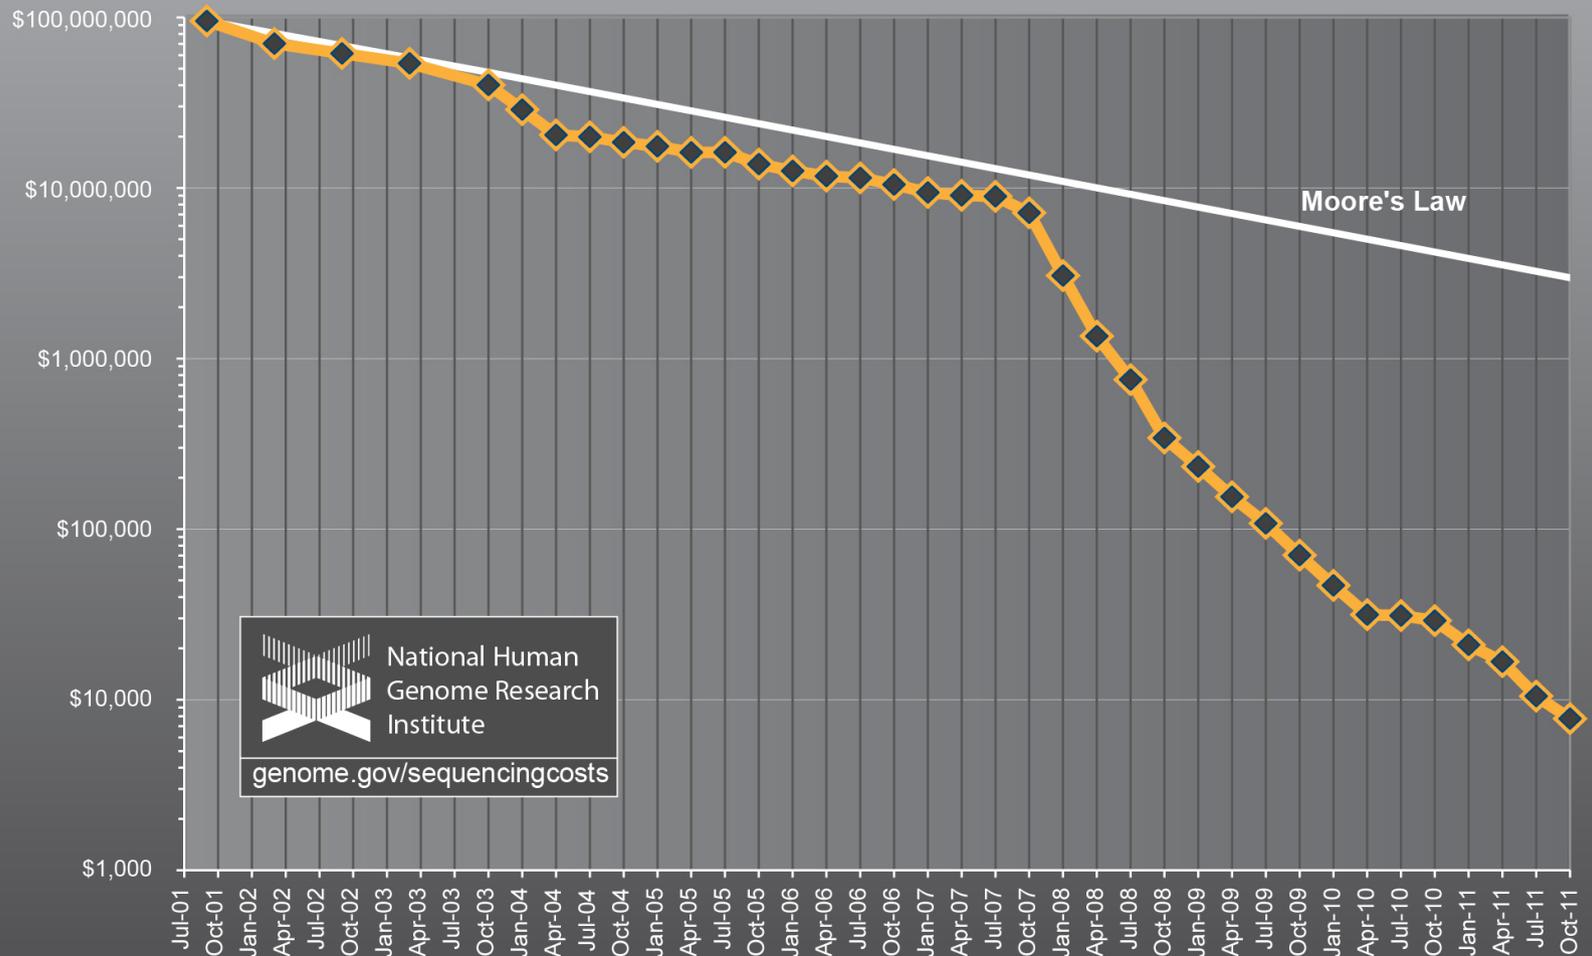
# GS 2.0 – Sequenz



# Sequenzierung individueller Genome

# „More than Moore“

## Cost per Genome



  
National Human  
Genome Research  
Institute  
[genome.gov/sequencingcosts](http://genome.gov/sequencingcosts)

# Hochdurchsatz-Sequenzierung: „State-of-the-art“ Frühling 2012

	ABI	Roche	ABI*	Illumina
	ABI 3730	GSFLX	SOLiD 4	HiSeq 2000
Basen / Lauf	70 kb	400 Mb	300 Gb	600 Gb
Leselänge	750 bp	400 bp	75 bp	100 bp

\*Life Technologies

# Herbst 2012?

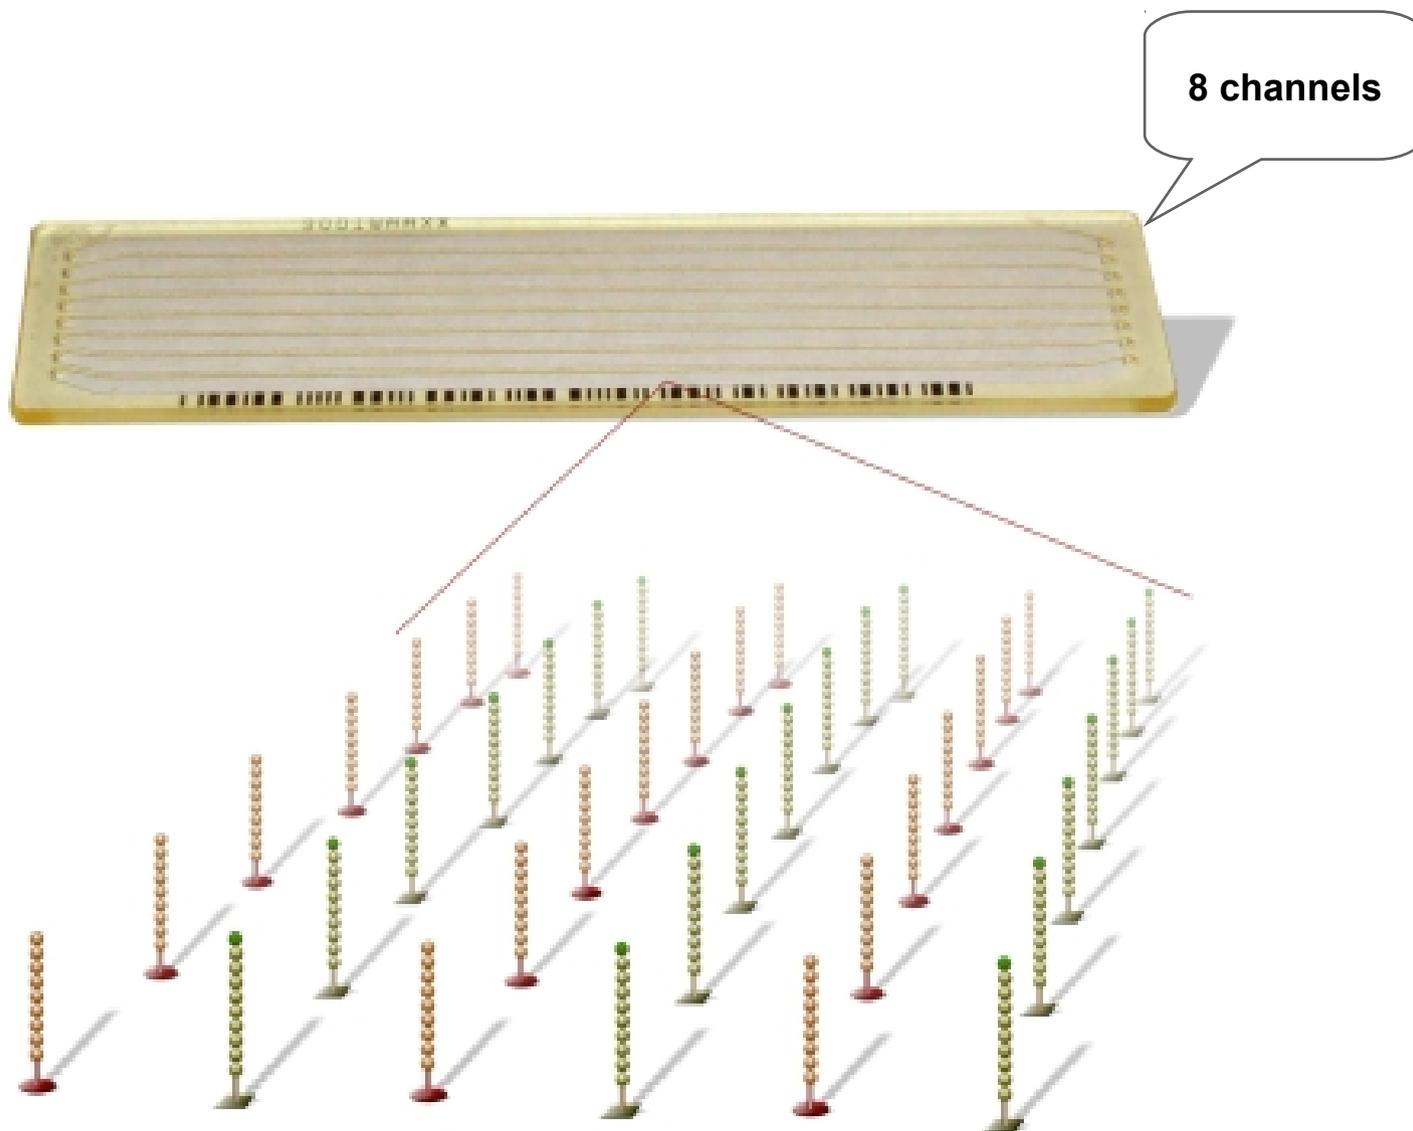


„Sequenzierautomat“ der 3. Generation (Oxford Nanopore)

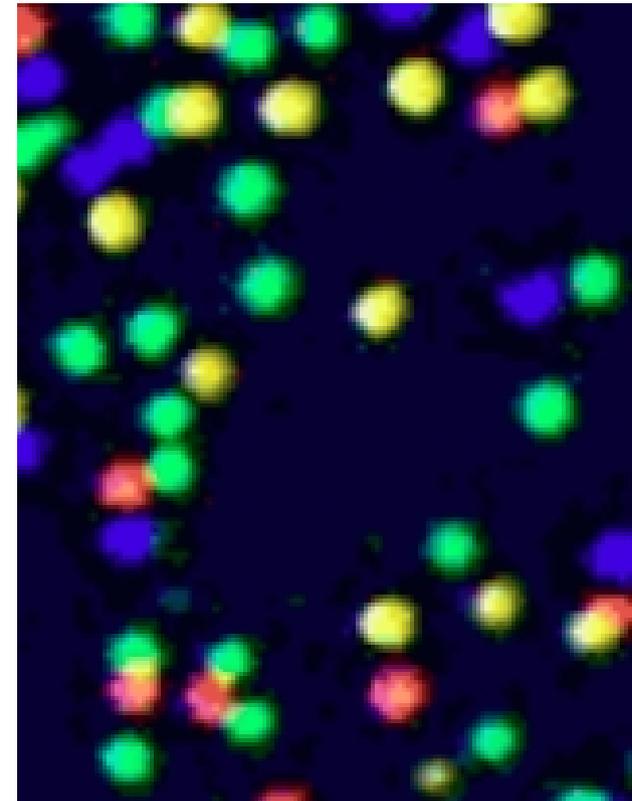
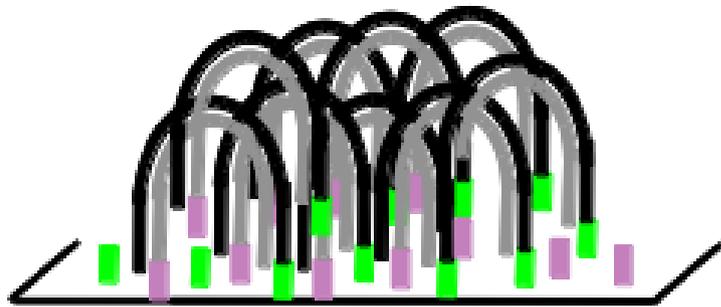
# “BGI's sequencing power”



# HiSeq 2000: Flow cell



$2 \times n^*$  pictures / cluster



\*n = Sequenzierlänge

# HiSeq2000 output: Two *fastq* files per lane (20 – 50 Gigabytes per file)

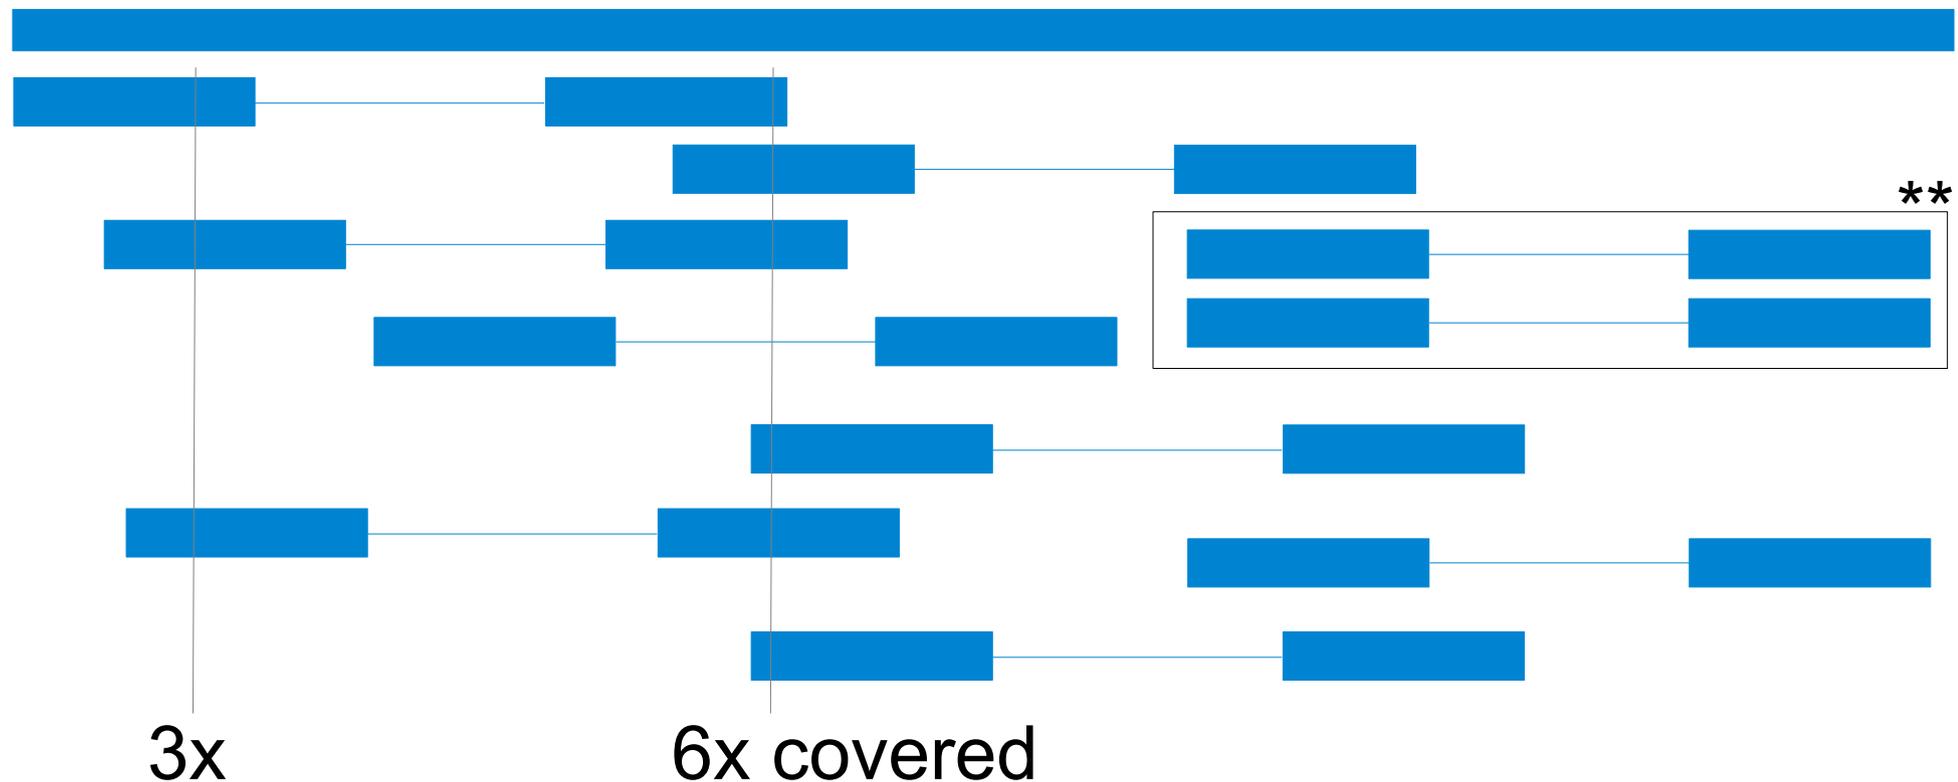
```
@HWI-ST506_0058:2:1101:6926:174667#0/1
CAGCTTCAGGTGTCCACCCGAGACCCTCTCCCCACCCTCTCCTGTGGGCTAAAGG
AACTACACTATCTGAAATCCTATCTCTGGAGTTTCTTGTCTGGCT
+
HHHHHHHHHHHHHHHHHHHCGGGGGHGHFHHHEHHHHCGHHHHFHHFHHHHDHHFG
HHFHDDHHHFFFHBHEHHFHEFHFFFHEHHEDCFGGEE1?DD<EA=
```

```
@HWI-ST506_0058:2:1104:17618:61439#0/1
GTTCGCGTGTGCAGCTTGCCCTACCAGGTGGTGGGCAGCCACTGACAGGCCCTGT
GCTGACTCTGTCCTGCAGCCAGTGCCTCCCCCAGACAAGAGCCAGG
+
FFFFEFFEDEAB@@@EDEEEFFEDFFFFFFCECEEFFFFDBEEEECB>=EC5C7B<==
>=EE?D>ADDCDF@>F=413)807*44B=CCCB37;09;76
```

Phred quality: 0 - 93, ASCII 33 - 126 (python: *ord* und *chr* functions)

# Alignment with *bwa* → *bam*\*

Reference sequence: UMD3.1, 2.66 billion bases



\* Binary version of *sam* (sequencing alignment / mapping) - format

\*\* PCR duplicate (arising during library construction)

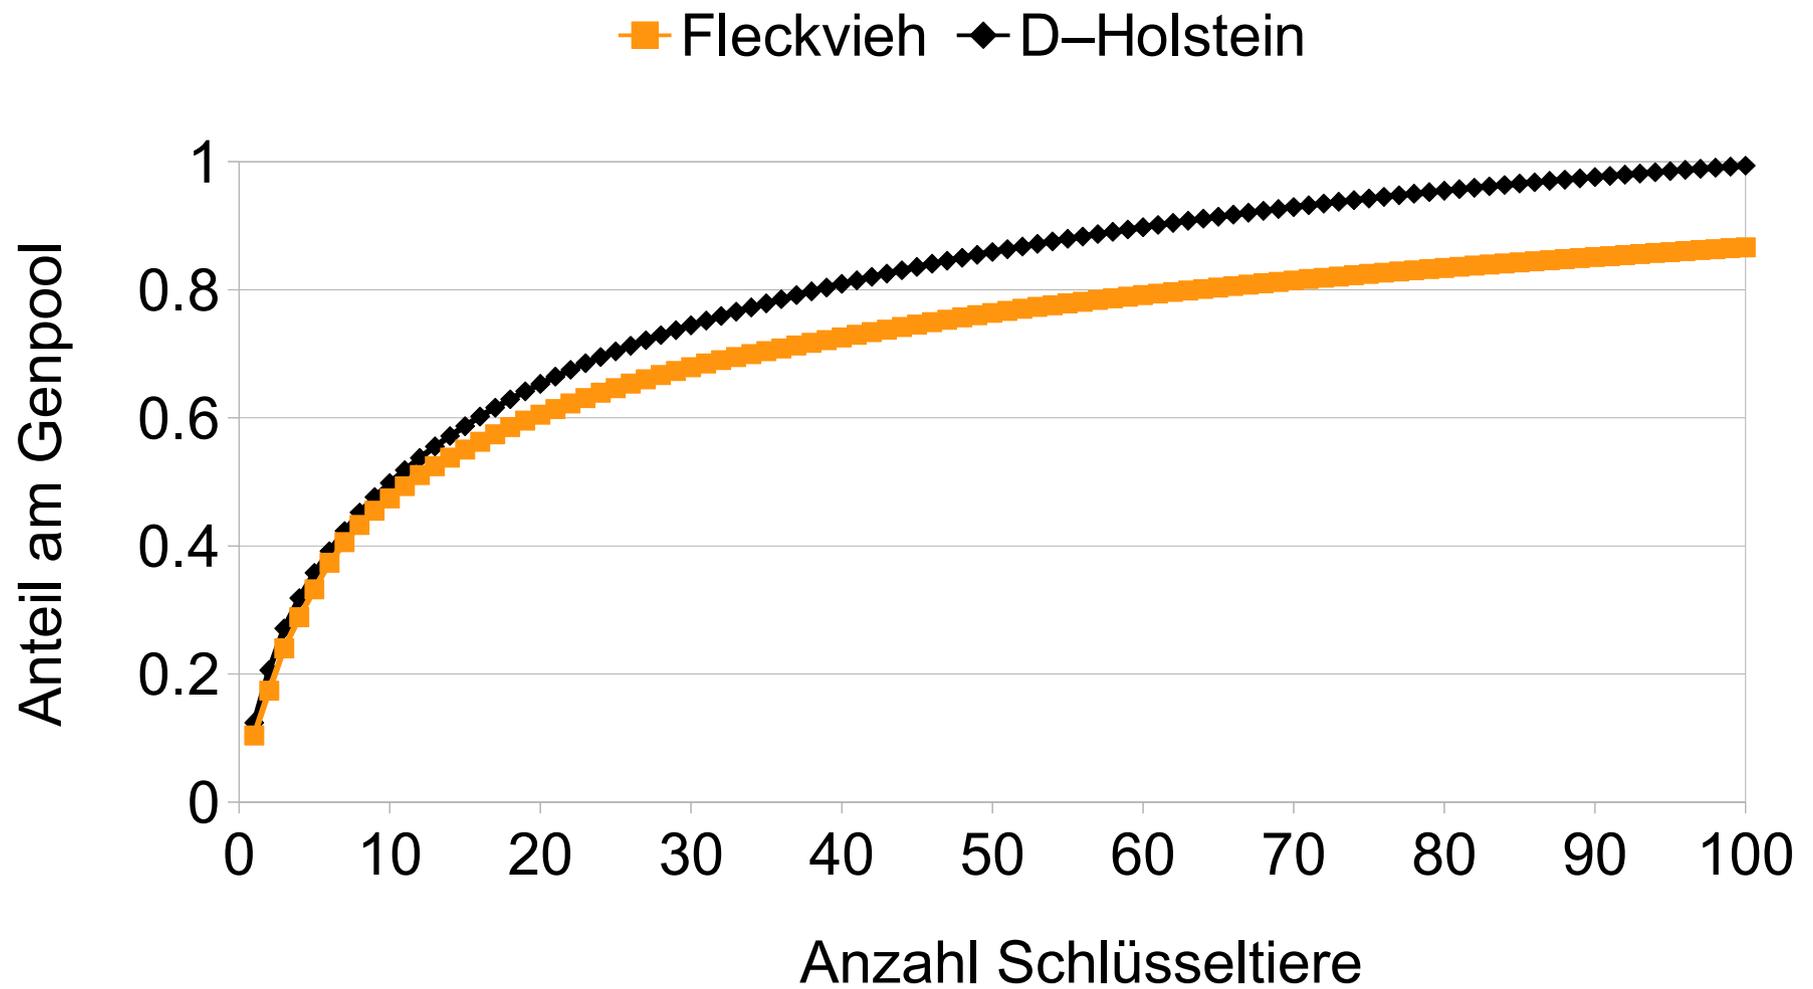


# Sequenzierung von Schlüsseltieren

- Die Sequenzierung von Tausenden von Individuen einer Populationen ist (noch) nicht möglich.
- Sequenzierung von **Schlüssel-Tieren!**
- **Populationsweite Imputation** der Sequenz

# Identifizierung von Schlüsseltieren

- Schlüsseltiere = Tiere, die möglichst viel zum aktuellen Genpool beitragen.
- Anzahl hängt von der effektiven Populationsgröße ab.
  - $N_e$  Holstein ca. 80
  - $N_e$  Fleckvieh ca. 140



# Sequenzierung von 43 Schlüssel-Tieren der Fleckviehrasse

- Decken 68% des Genpools ab
- Durchschnittlich 7.4-fache Sequenzabdeckung mit Illumina Instrumenten
- 17.3 Millionen variable Positionen

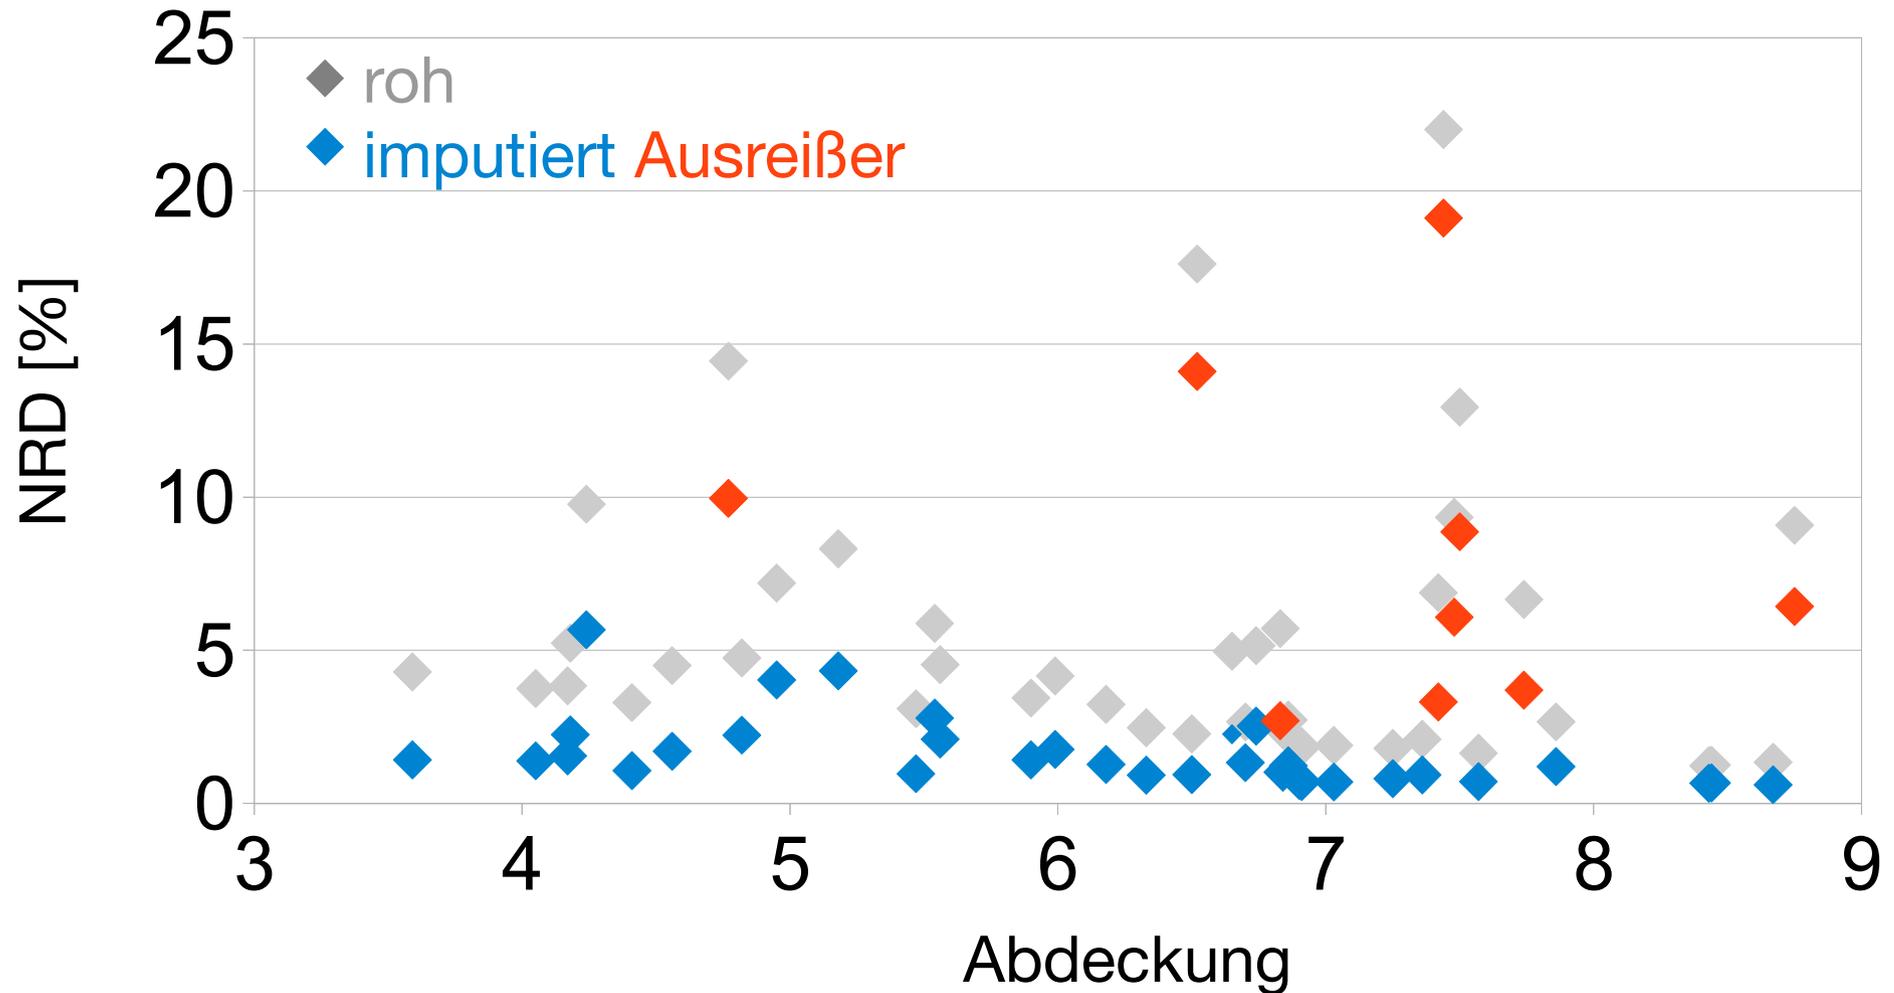
# Abweichung von HD (777K) -Genotypen (Non-Reference-Discrepancy-Rate, NRD)

## HD-Genotypen

Seq. Genotypen		AA	AB	BB
	AA	1	2	3
	AB	4	5	6
	BB	7	8	9
	--	10	11	12

$$\text{NRD} = \frac{\text{rot}}{\text{blau} + \text{rot}}$$

# Effekt der *Beagle-Imputation* auf NRD



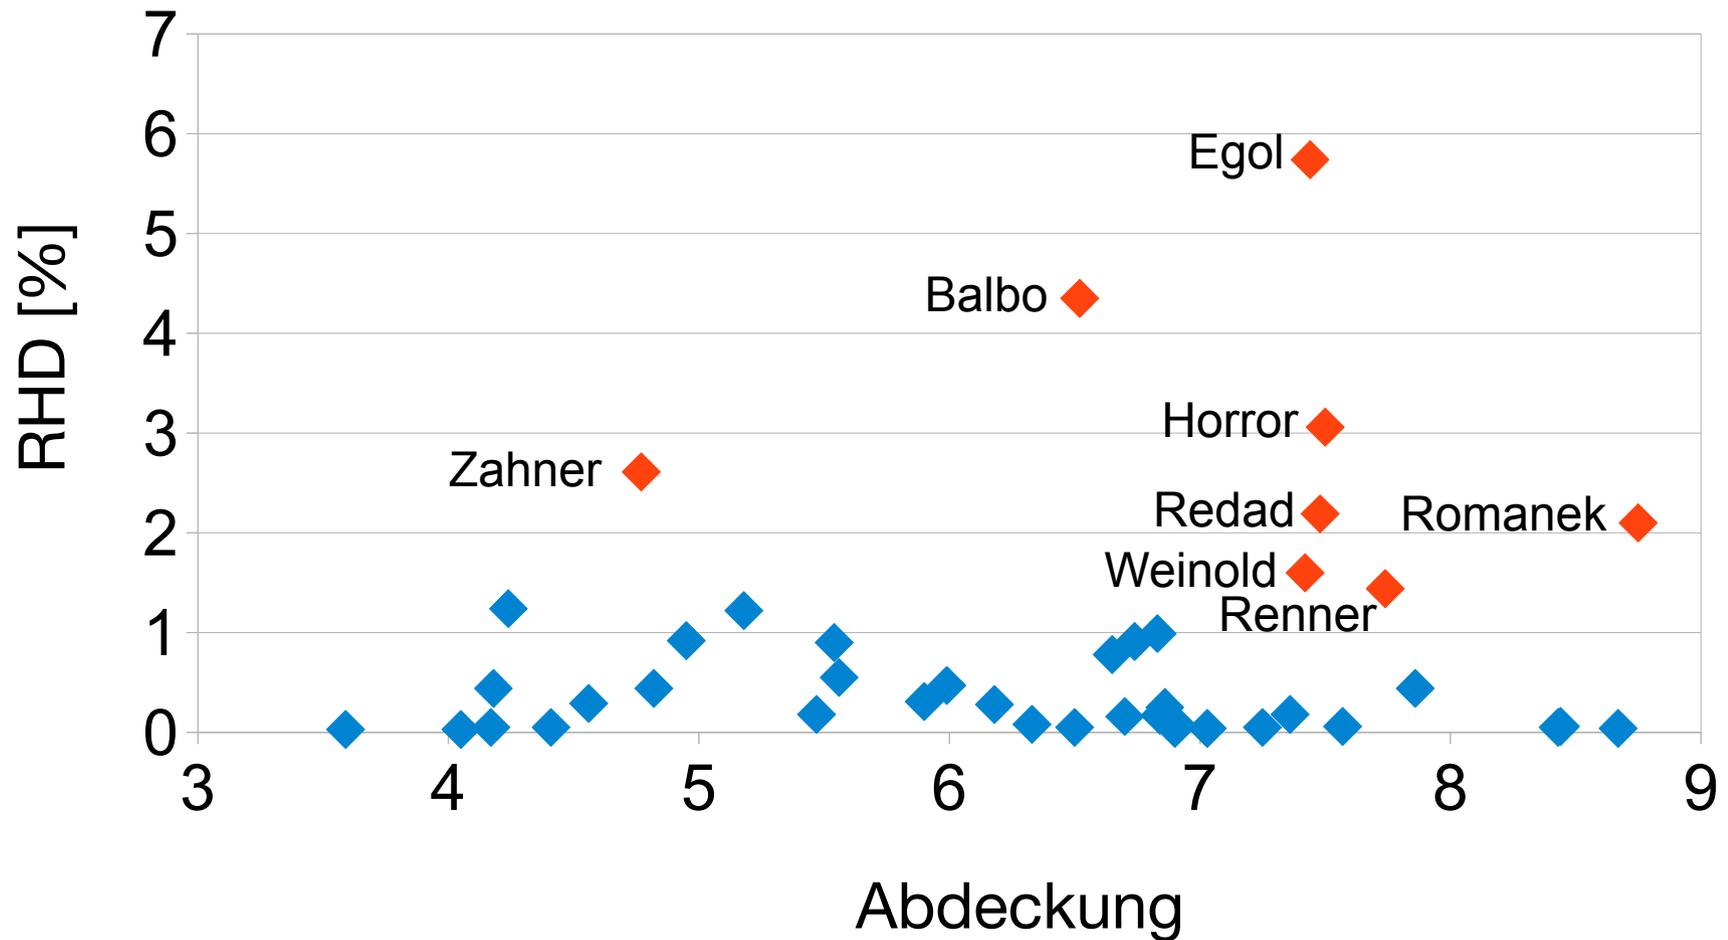
# „Reference homozygosity discrepancy rate“ (RHD)

## HD Genotypen

	AA	AB	BB
AA	1	2	3
AB	4	5	6
BB	7	8	9
--	10	11	12

$$\text{RHD} = \frac{\text{red}}{\text{blue} + \text{red}}$$

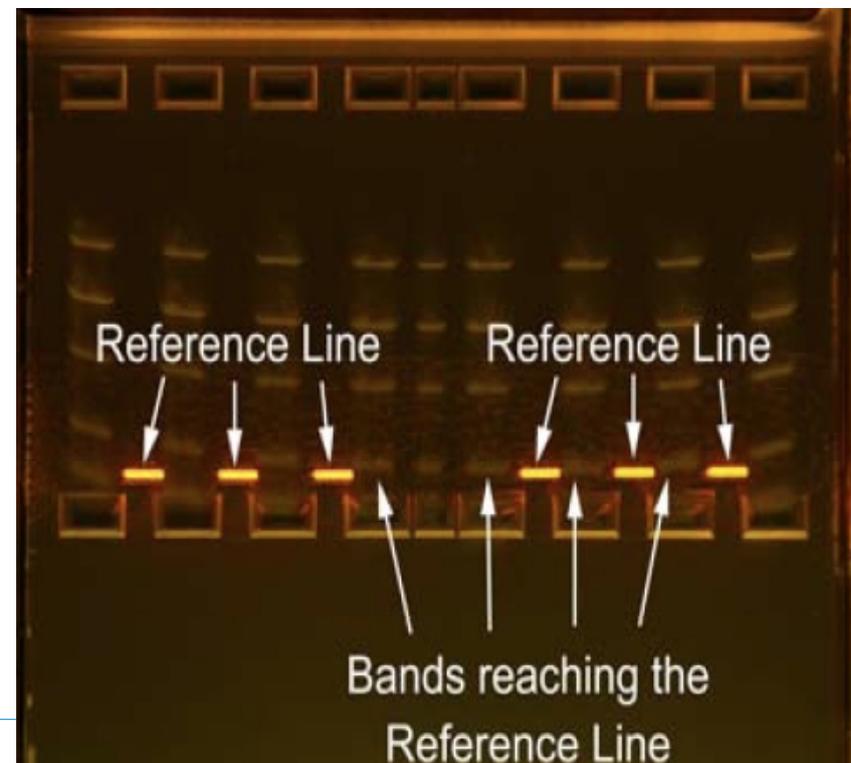
# RHD: Kontamination



# Contamination during fragment-size-selection step of library preparation

- Open electrophoresis system
- Samples can diffuse, leading to cross-well contamination

E-Gel® SizeSelect  
Agarose Gels  
(Invitrogen)



# Populationsweite Sequenz-Imputation

# Imputation 1. Schritt: Erstelle **Haplotypen-Bibliothek** bei den sequenzierten Schlüsseltieren

A	G	A	
A	G	G	
C	C	T	
G	G	C	
T	A	T	
A	A	T	...
T	C	T	
T	T	C	
A	A	C	
T	C	T	

# Imputation 2. Schritt: Populationsweite Genotypisierung (54K, 777K)

A	G	A	
<b>A</b>	G	<b>G</b>	
C	C	T	
G	G	C	
T	A	T	
A	A	T	...
T	C	T	
<b>T</b>	T	<b>C</b>	
A	A	C	
T	C	T	

# Imputation 3. Schritt: Leite Sequenz ab

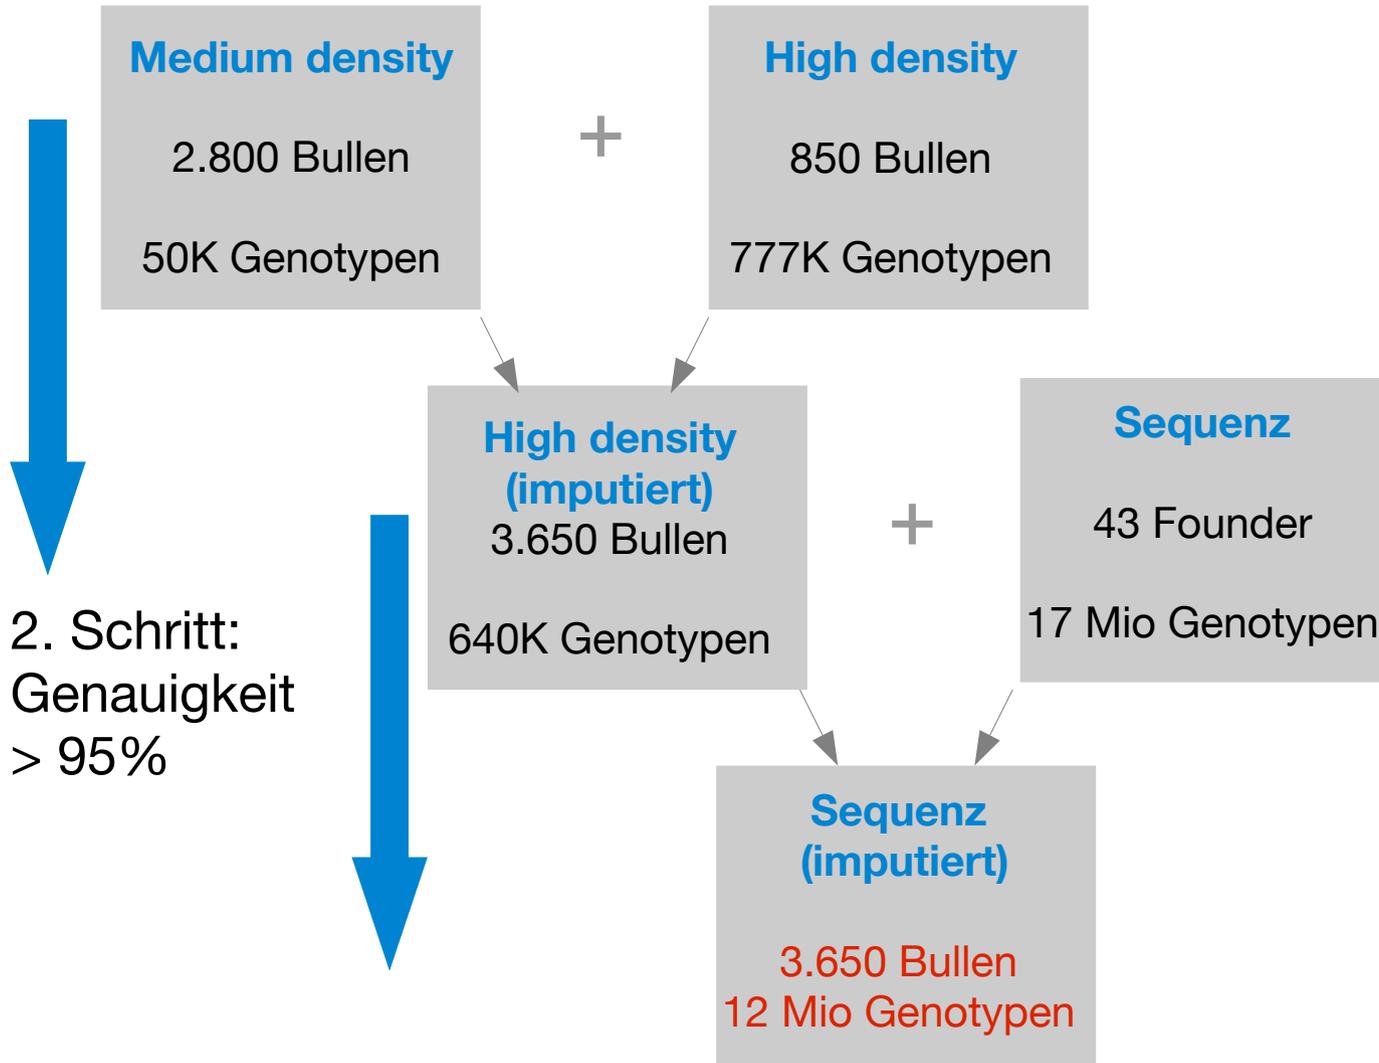
A	G	A	AA
A	G	G	AG
C	C	T	CT
G	G	C	GC
T	A	T	TT
A	A	T	AT
T	C	T	TT
T	T	C	TC
A	A	C	AC
T	C	T	TT



# Sequenzimputation

Intel E5620  
48 GB RAM  
16 threads

1. Schritt:  
Genauigkeit  
> 99.5%



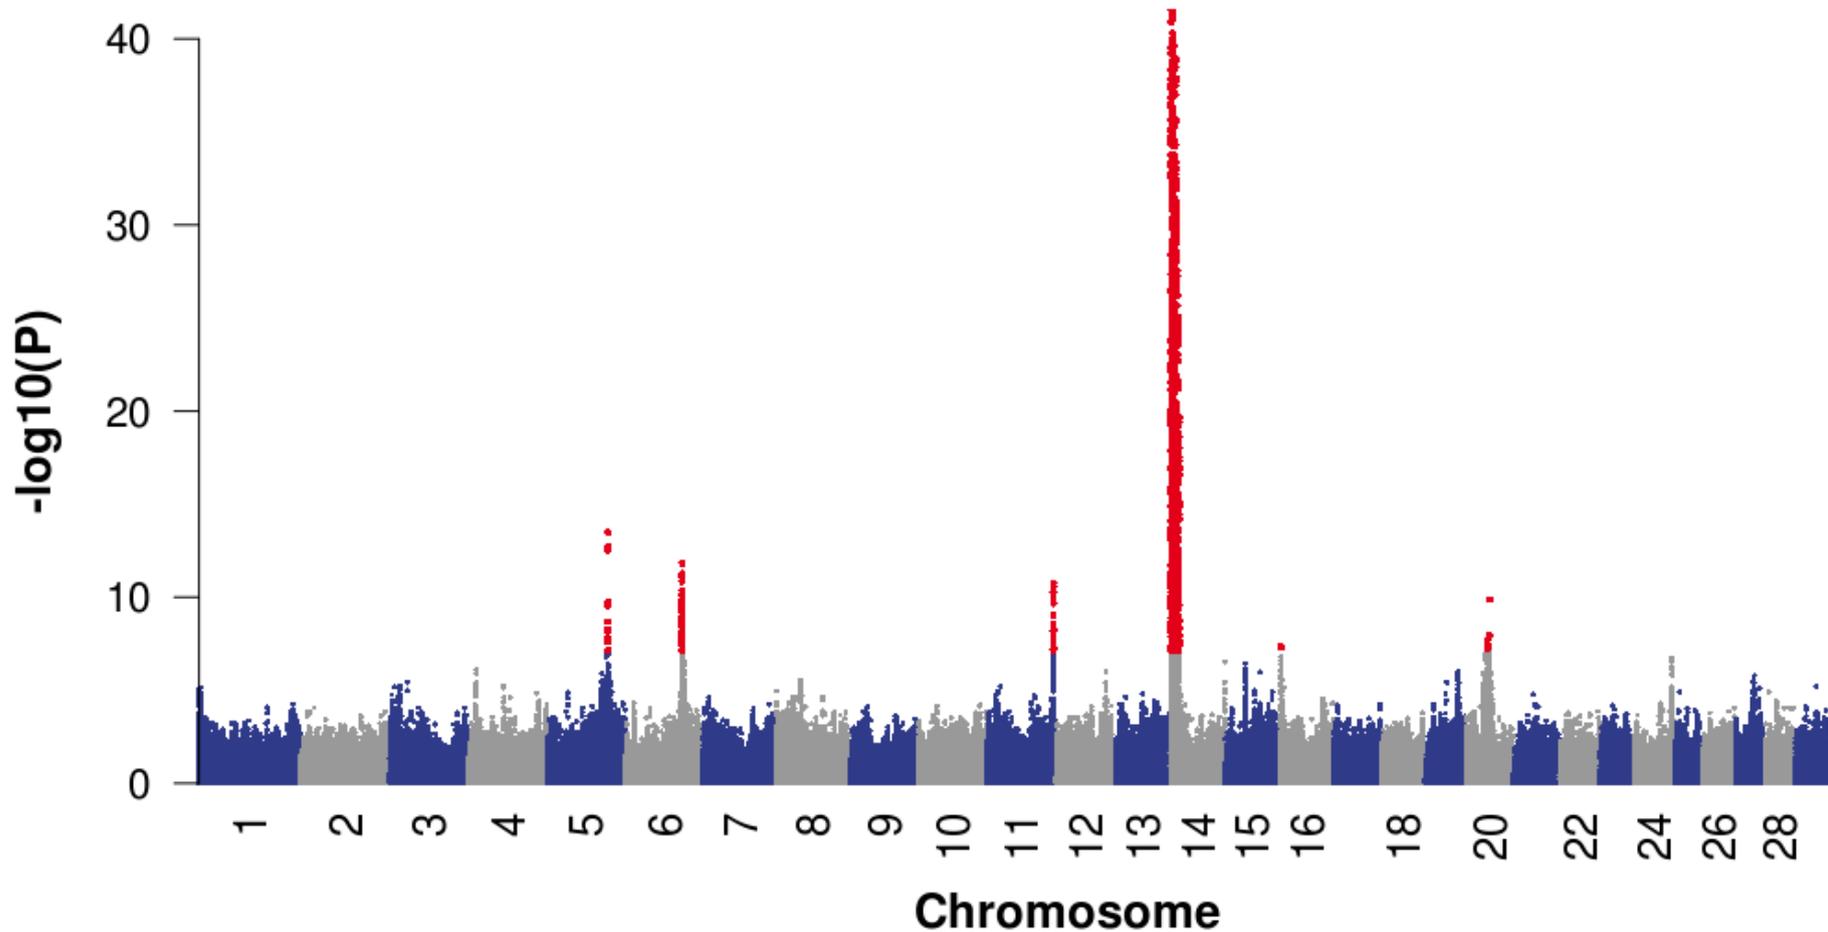
2. Schritt:  
Genauigkeit  
> 95%

# Auf dem Weg zur GS 2.0 (1)

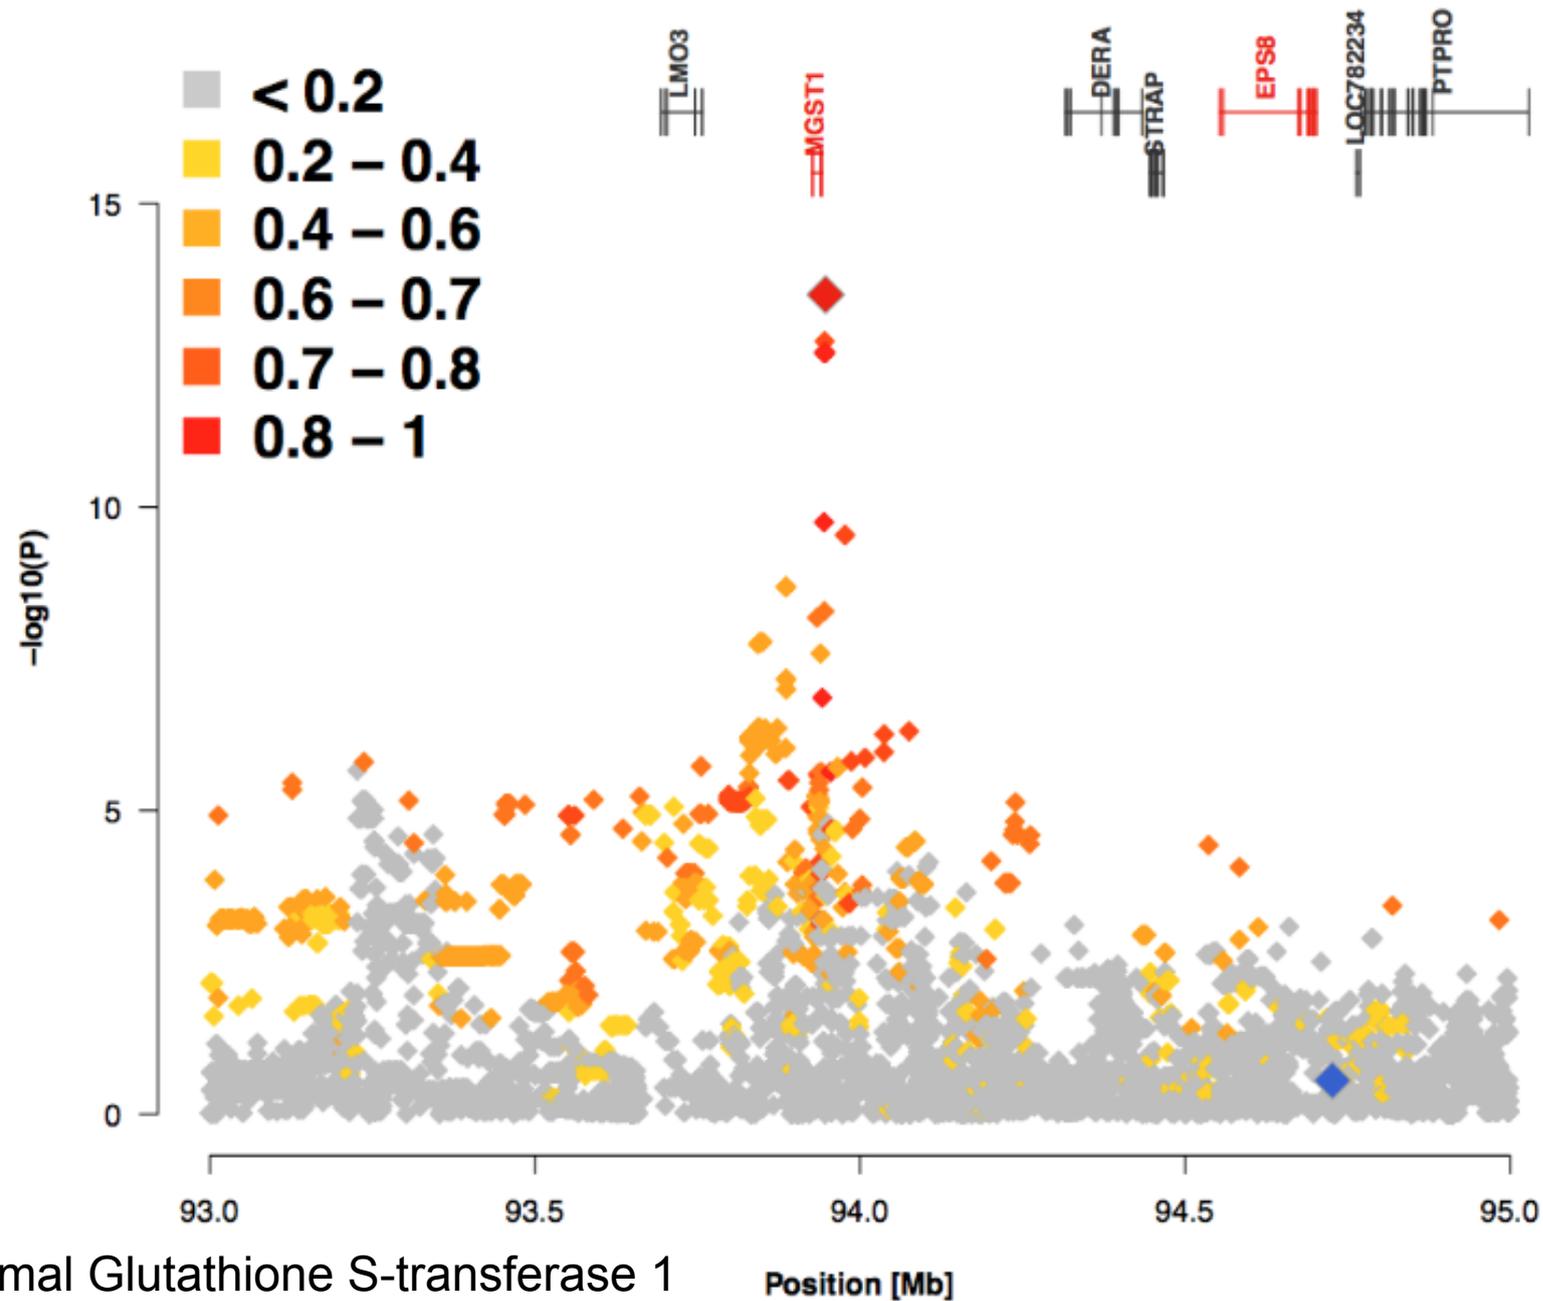
- Identifizierung von “**very important QTL**” (**VIQ**) mit genomweiten Assoziationsstudien
  - ca. 5 pro Merkmal und Population
- Identifizierung von **quasi-kausalen Varianten** im Bereich der **VIQ**
- Untersuchung **nicht-additiver Effekte** der VIQ bei Kühen

# FV: Genomweite Assoziationsstudie

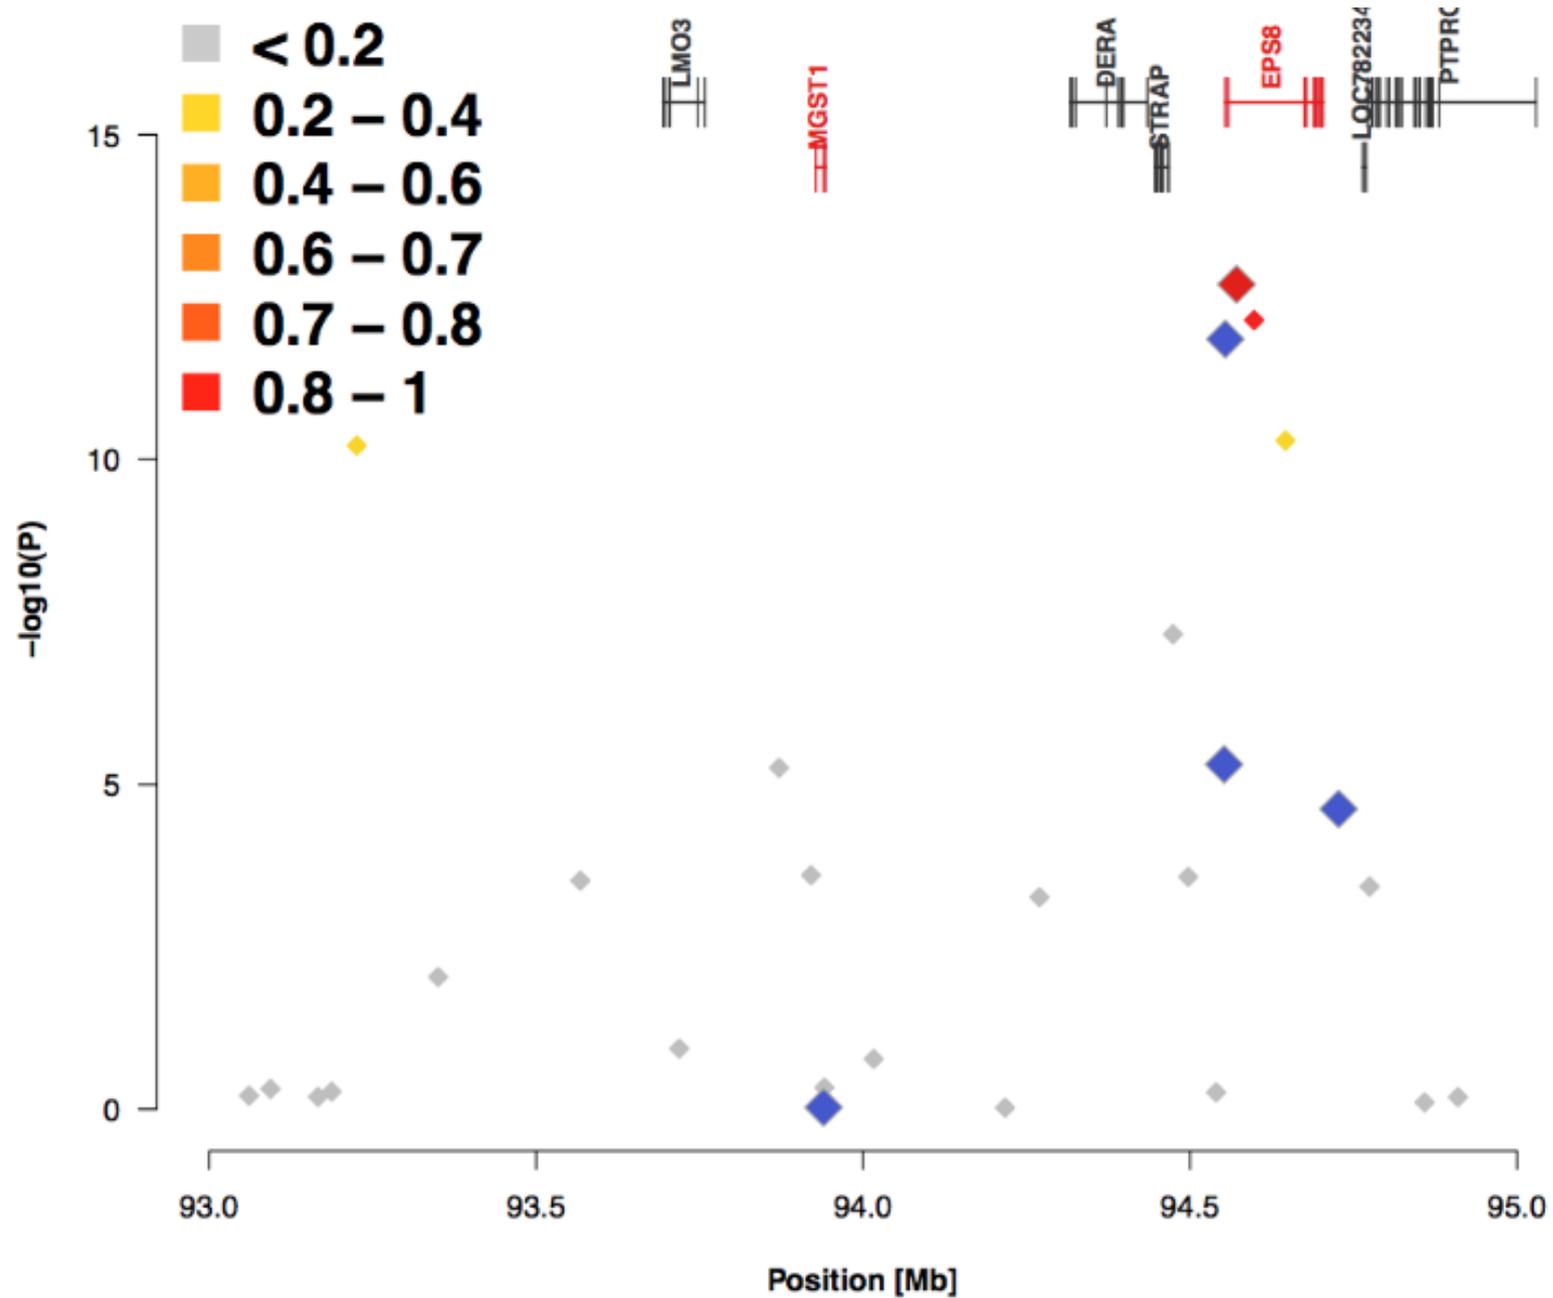
3600 Bullen, 12 Mio SNPs, Fett% 305 Tage



# FV: Fett-% QTL auf Chromosom 5 – 12 Mio SNPs

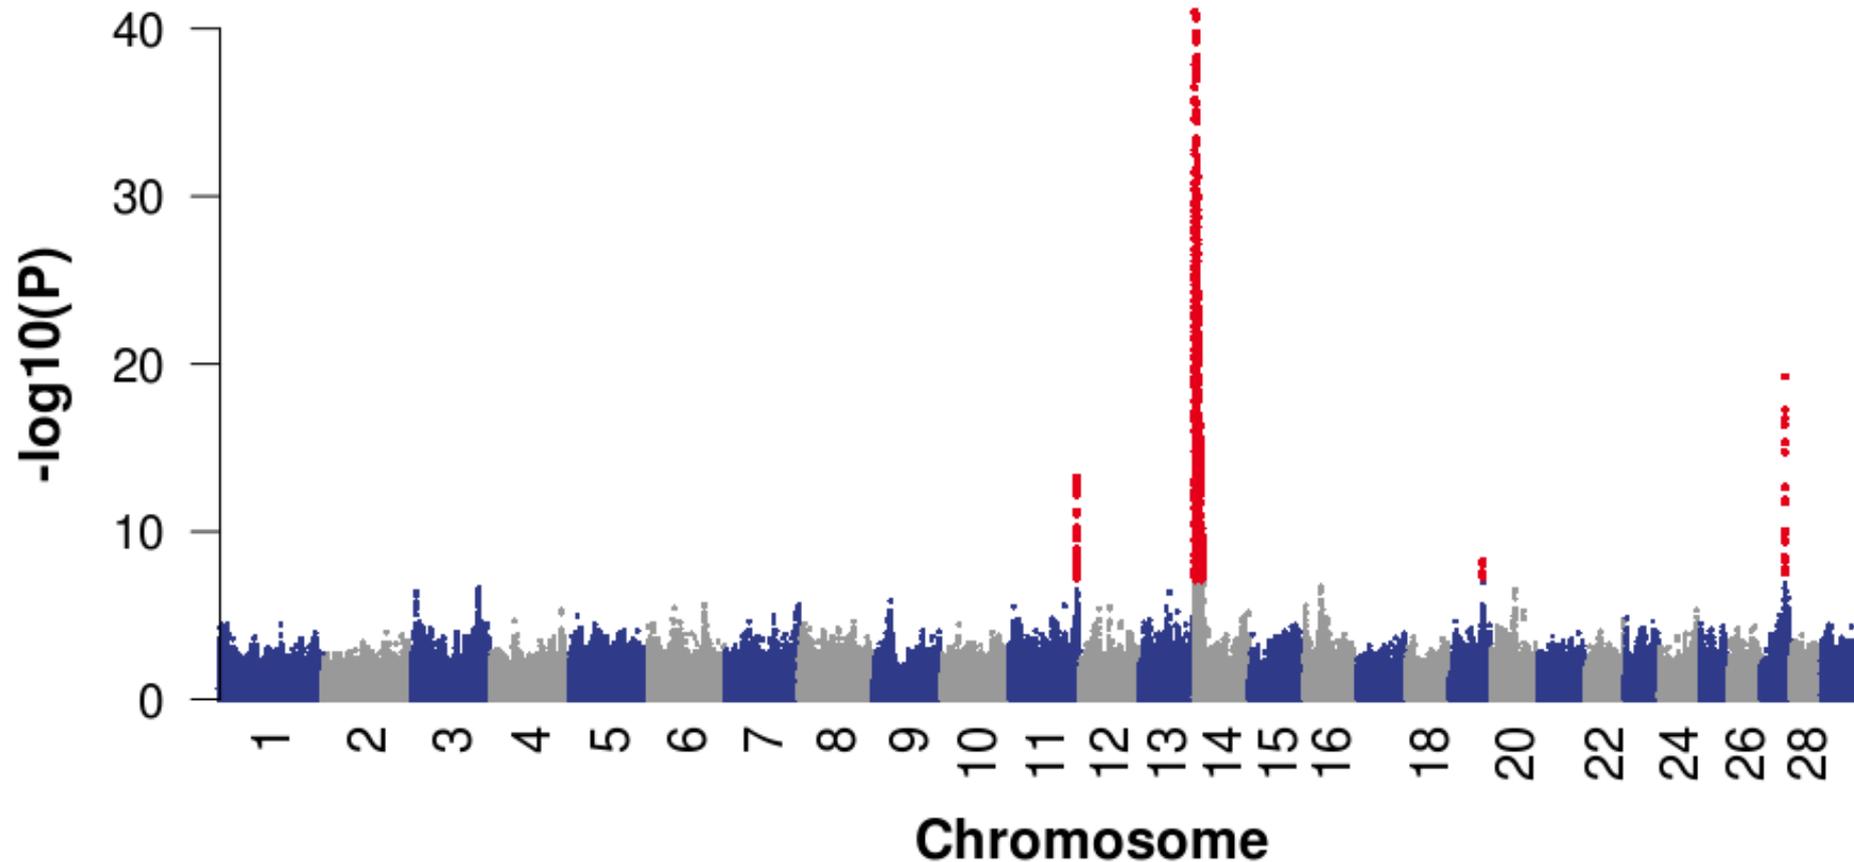


# HF: Fett-% QTL auf Chromosom 5 – 54K SNPs

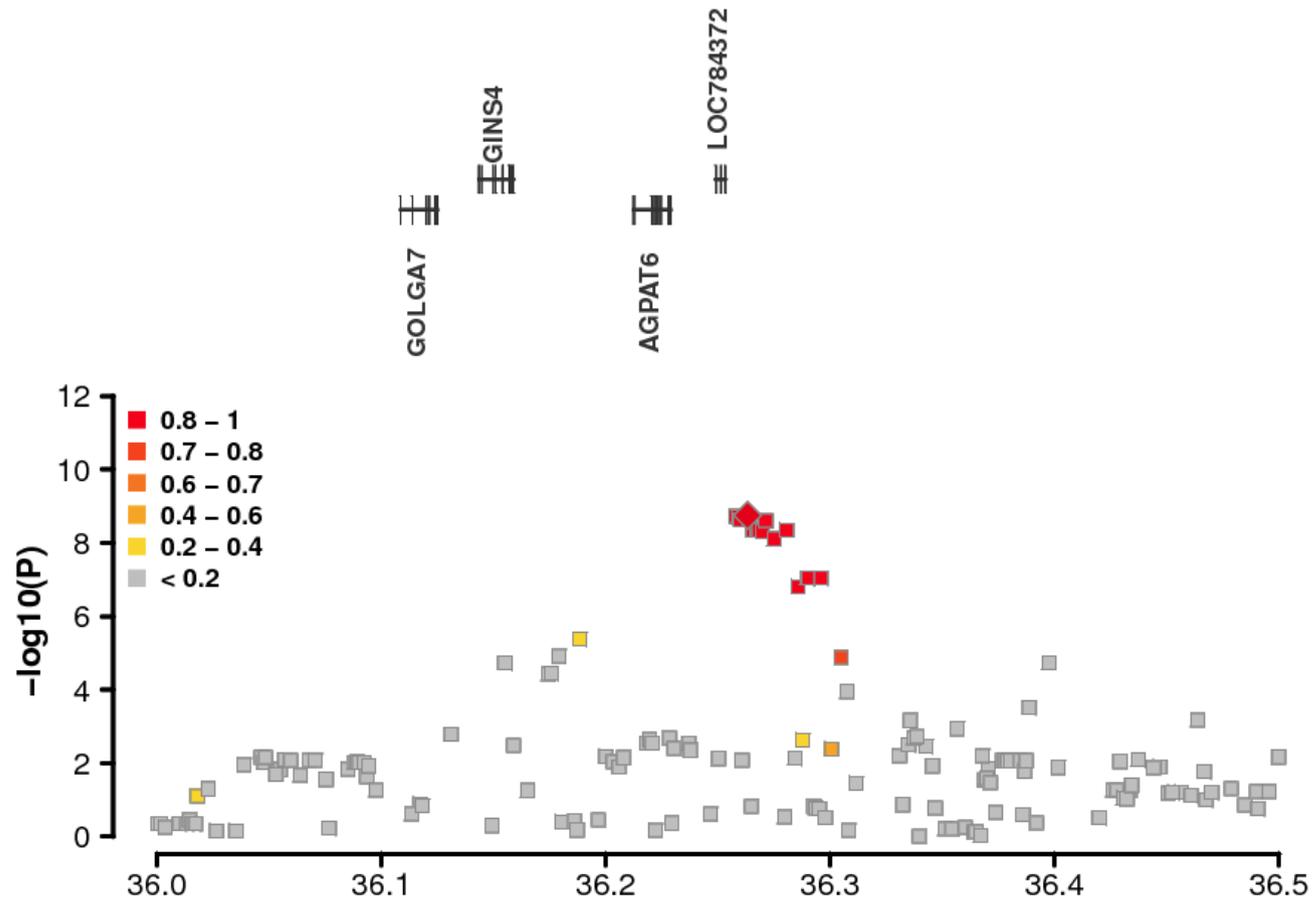


# FV: Genomweite Assoziationsstudie

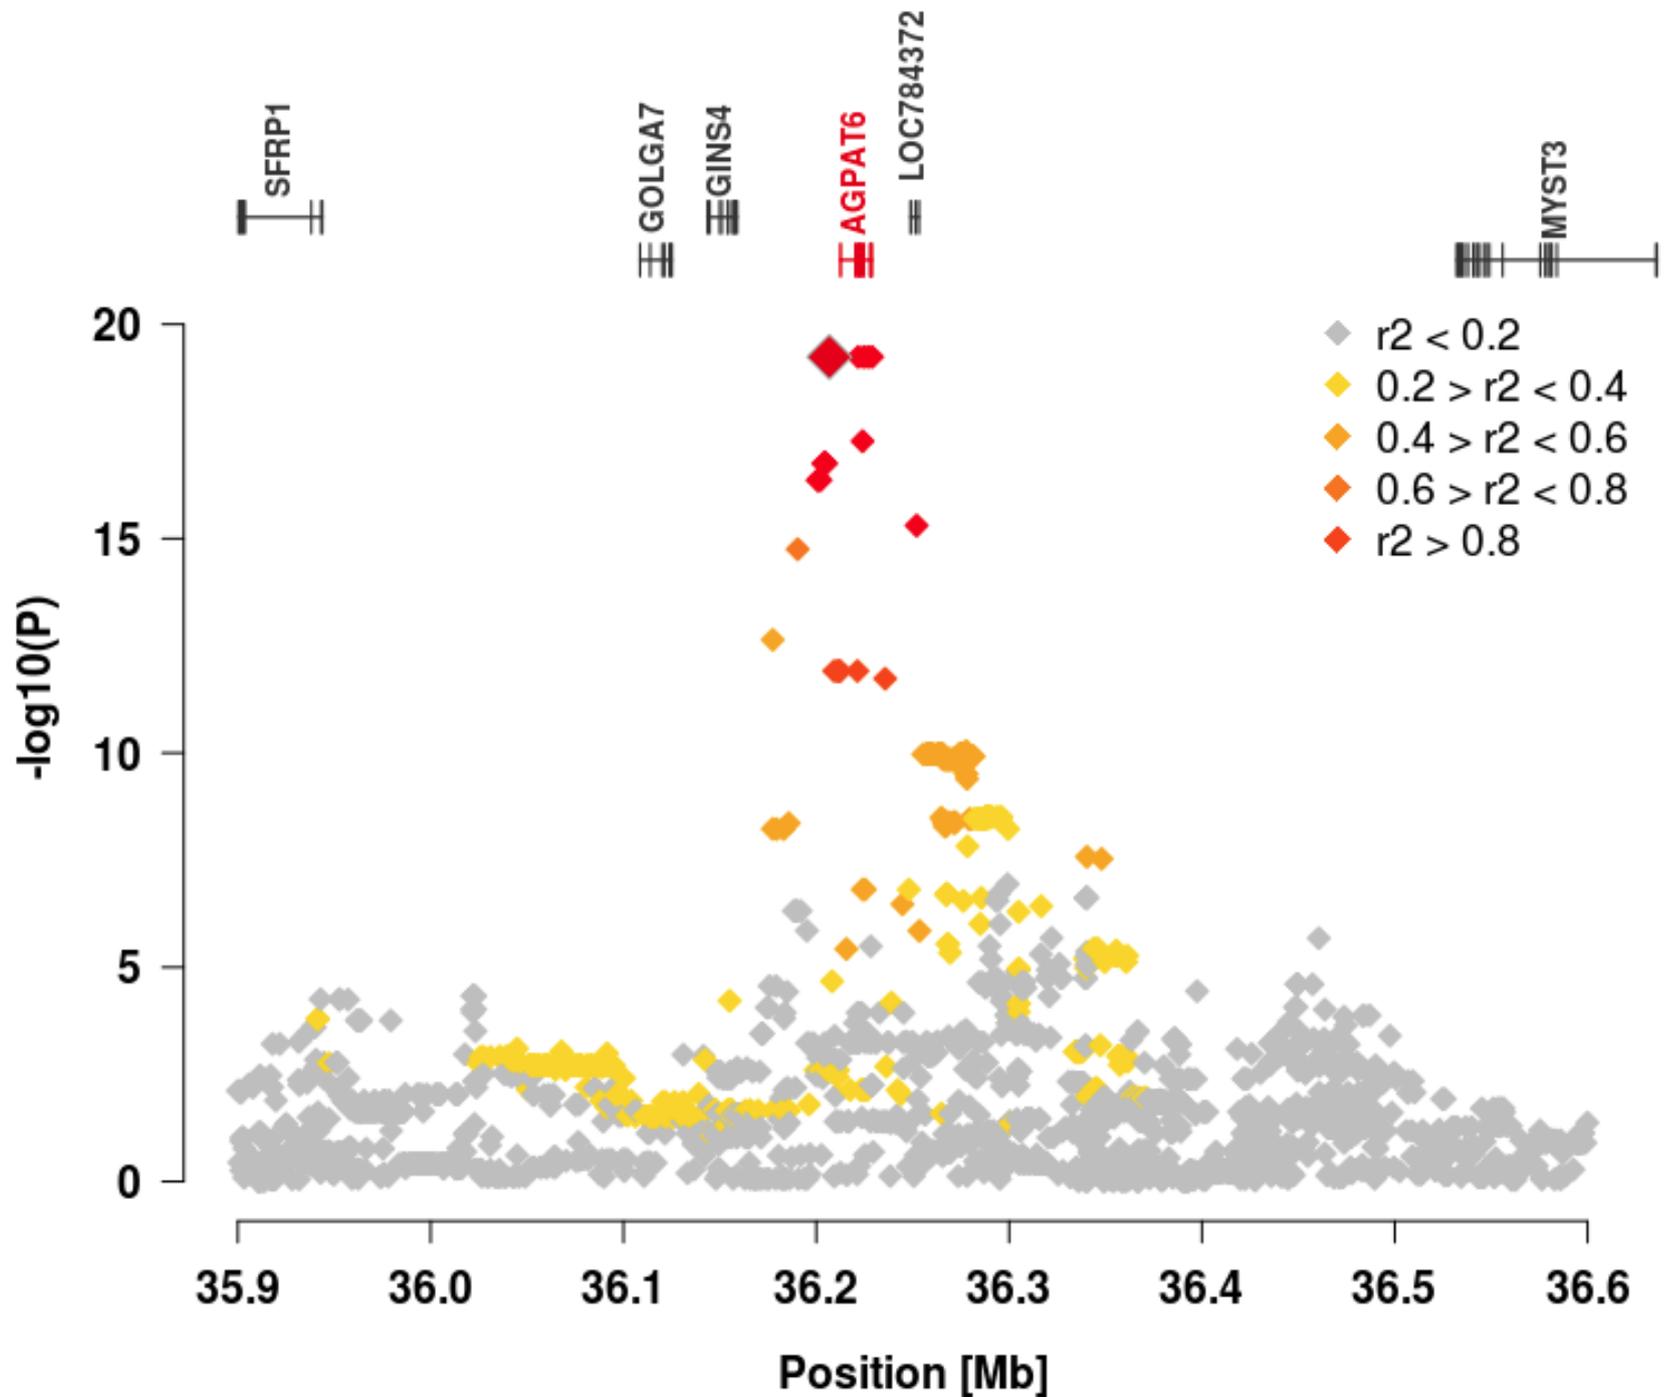
3600 Bullen, 12 Mio SNPs, Fett% Tage 8-12

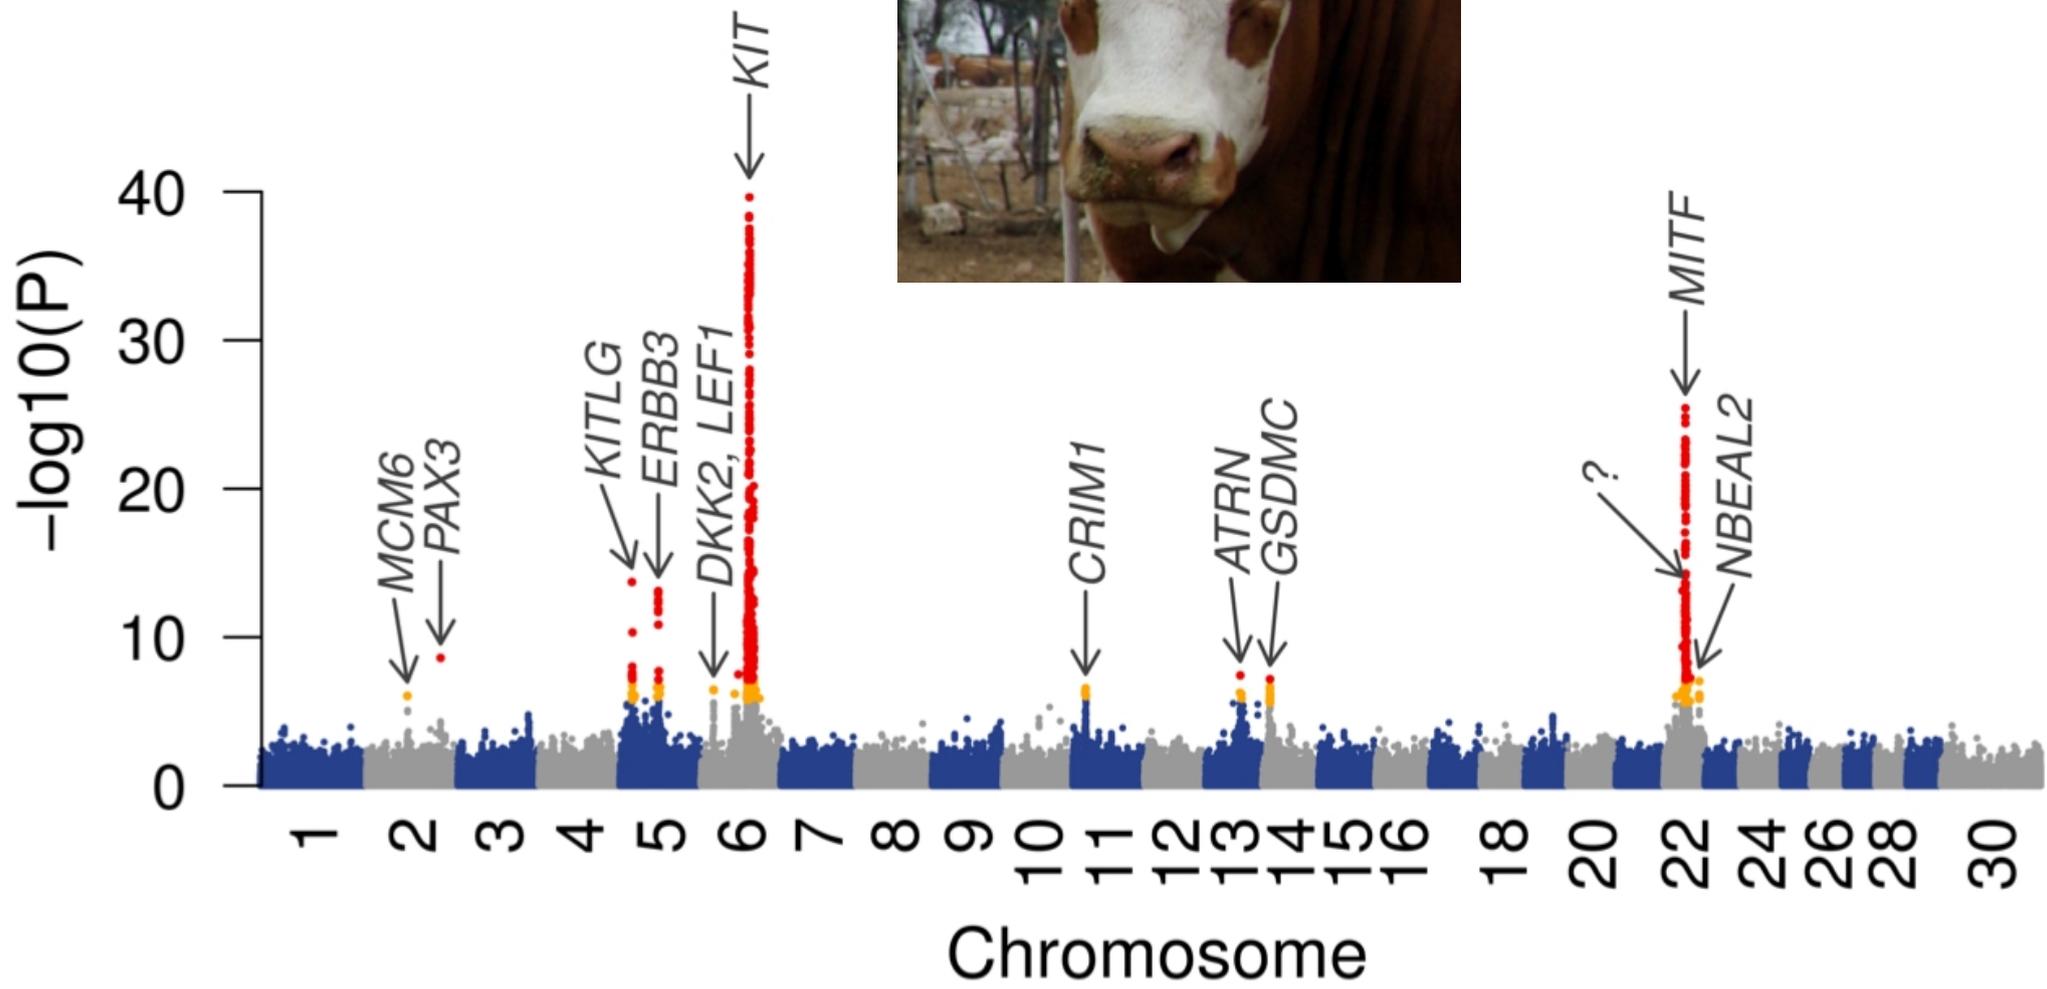


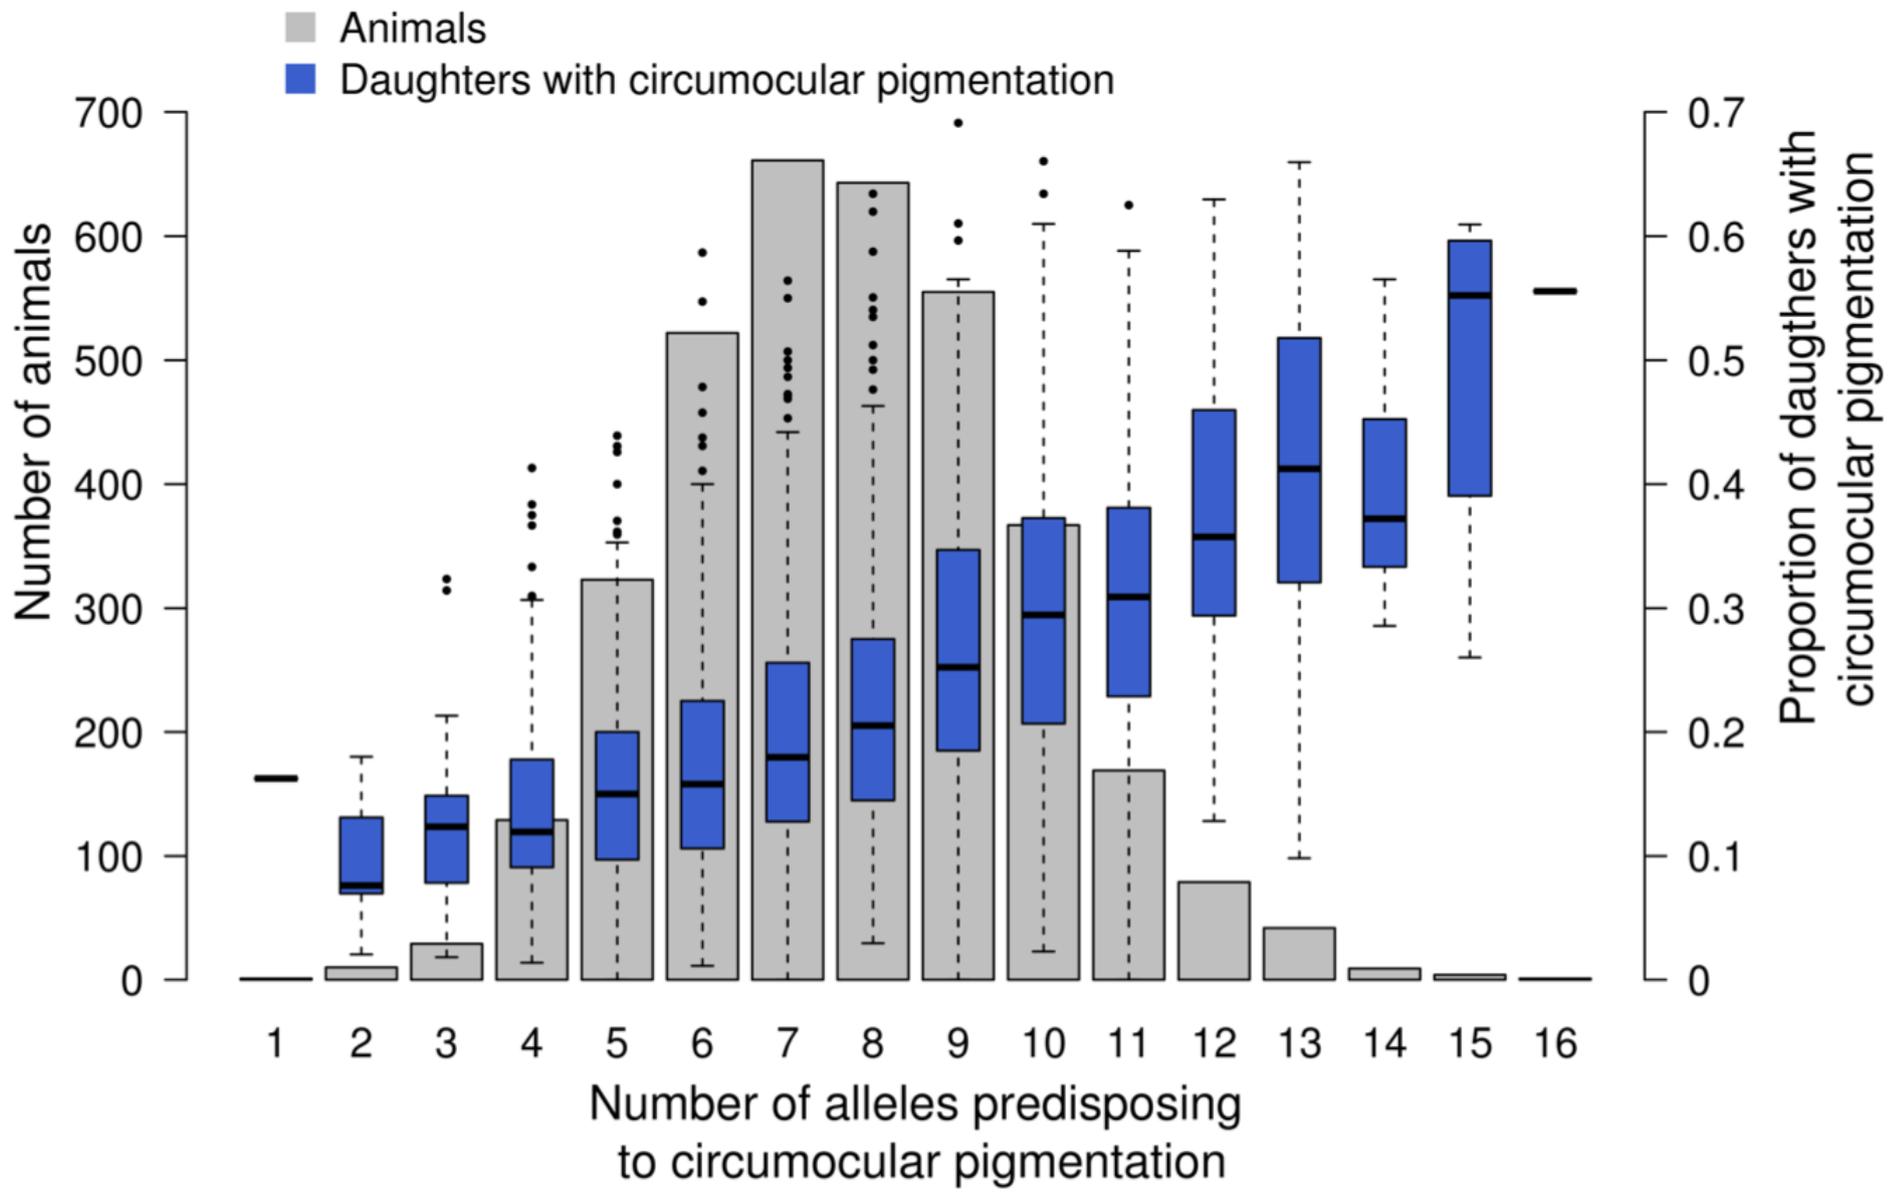
# FV: Fett-% QTL auf Chromosom 27 – 777K SNPs

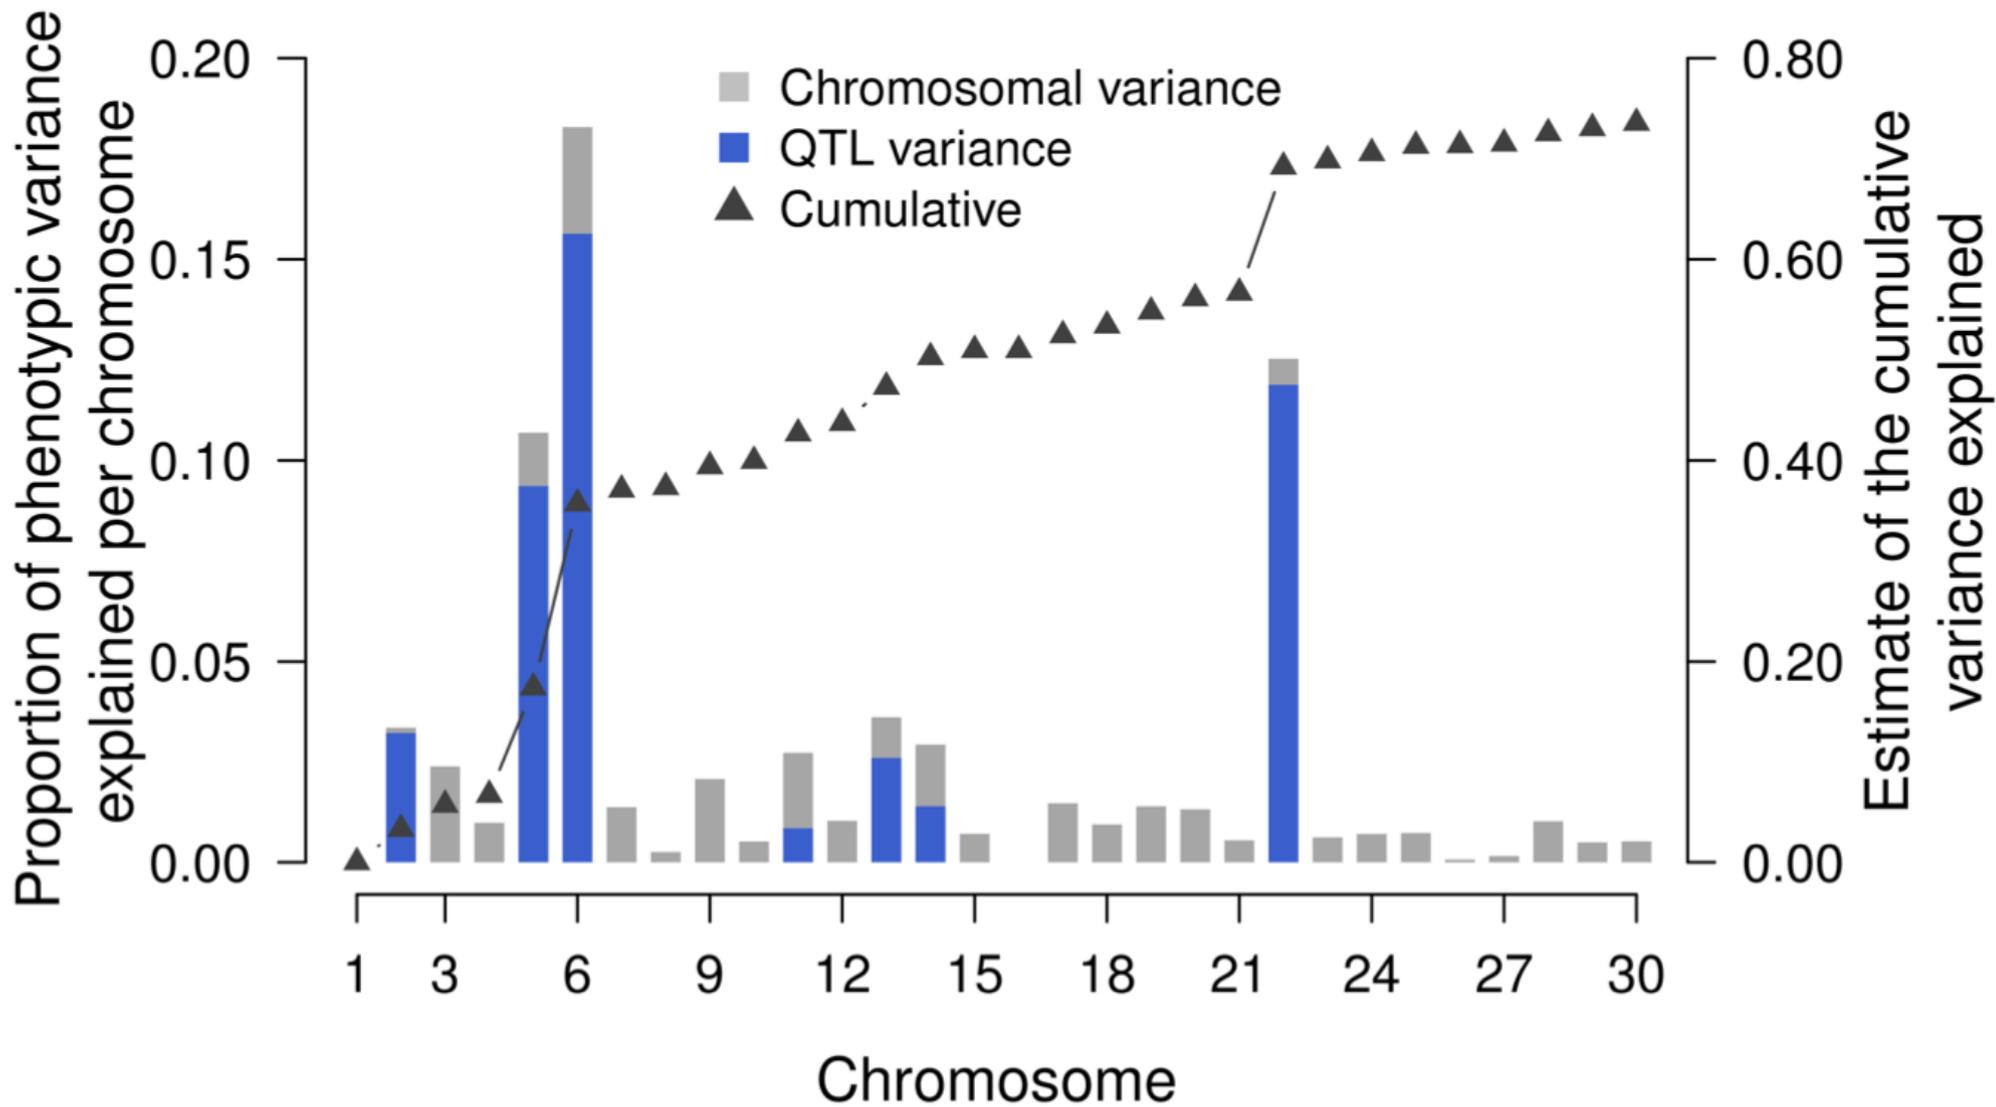


# FV: Fett-% QTL auf Chromosom 27 – 12 Mio SNPs







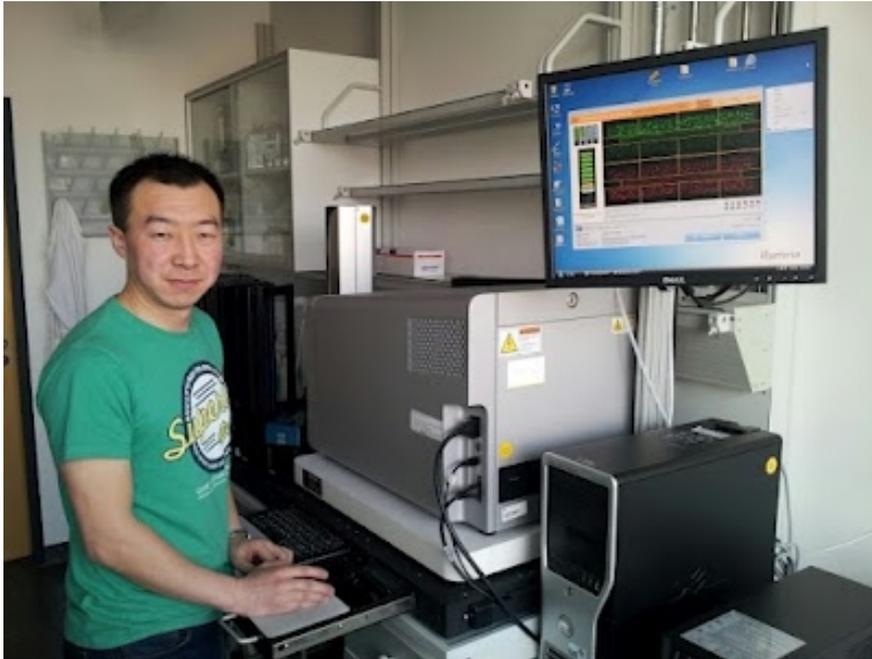




# Auf dem Weg zur GS 2.0 (2)

- Vorbereitung der flächendeckenden HD-Genotypisierung (> 600 SNPs für 30 € pro Tier)
- Entwicklung der Schätzung des genomischen Produktionswertes auf der Basis
  - der imputierten Genomsequenz,
  - der VIQ-Information und
  - der allgemeinen (“ = polygenen”) genomischen Formel

# 30 € pro Tier für HD-Genotypisierung?



illumina®  
777K



650K

# Hubert Pausch und ich danken ...

- dem **BMBF** für die Unterstützung im Rahmen von **GenoTrack** und **Synbreed**,
- Sebastian Eck, Anna Benet-Pagès, Elisabeth Graf, Thomas Wieland, Tim Strom und Thomas Meitinger vom **Lehrstuhl für Humangenetik der TUM / Institut für Humangenetik des Helmholtz-Zentrums München** für die Sequenzierung,
- Sandra Jansen, Bernhard Aigner, Xiaolong Wang, Tini Wurmser und Michal Wysocki vom **Lehrstuhl für Tierzucht** für die Organisation der DNA-Logistik, Genotypisierung und Datenanalyse.



# Steve Jobs' quote on product design applied to genomic evaluation (1)

- *“When you start looking at a problem and it seems really simply, you don't really understand the complexity of the problem.”*
  - Genomic evaluation and improvement of animals
- *“Then you get into the problem, and you see it's really complicated, and you come up with all these convoluted solutions.”*
  - Bayes A – Z, ... methods for genomic evaluation

# Steve Jobs' quote on product design applied to genomic evaluation (2)

- *“That's sort of the middle, and that's where most people stop”*
  - Genomic selection 1.0: keep genes in the “black box”
- *“But let's keep going and find the key, the underlying principle of the problem – and come up with an elegant, really beautiful solution that works.”*
  - Genomic selection 2.0: gene-based evaluation and selection