

Datenkompetenz in der Chemie und Chemischen Biologie

Prof. Dr. Paul Czodrowski



www.czodrowskilab.org



twitter.com/czodrowskipaul



www.czodrowskilab.org/music



github.com/czodrowskilab



WiSe

Statistik in den Lebenswissenschaften

SoSe

**Einführung Data Science im Bereich Chemie und
Chemische Biologie**

WiSe

***[In Planung]* Statistisches Lernen**

WiSe

Statistik in den Lebenswissenschaften

Thema	Inhalte (Thematische Unterteilung)	Schlüsselbegriffe
Was ist Statistik?	Einführung Statistik, Organisatorisches, Merkmale, Grundlagen der Mathematik	Python, Logarithmus, Wurzeln, Funktionen
Deskriptive Statistik	Beschreibung von Daten mittels der Deskriptiven Statistik	Gini-Koeffizient, Lorenzkurve, Häufigkeiten, Median, MAD (mean absolute deviation)
Deskriptive Statistik	Beschreibung von Daten mittels der Deskriptiven Statistik	Kendall's tau, Standardabweichung, Varianz, Mittelwerte, Histogramm
Korrelation und Regression	Rangkorrelation, Regression	Spearman, Scheinkorrelation, Verdeckte Korrelation
Klassierte Daten	Umgang und Interpretation von kategorialen Daten	Kontingenztafeln, chi ² , odds ratio
Sensitivität und Spezifität	Sensitivität und Spezifität, External quality assessment, hERG kapa	Sensitivität und Spezifität, kappa
Fallbeispiele	Fallbeispiel SARS-CoV2, hERG	kappa, Hypothesen-Test logP bei hERG
Fallbeispiele	hERG, Biochemie-Praktikums-Versuch	MatchedMolecularPairs & Significance, Michaelis-Menten & Error

WiSe

Statistik in den Lebenswissenschaften

Beispiel: Lineare Regression

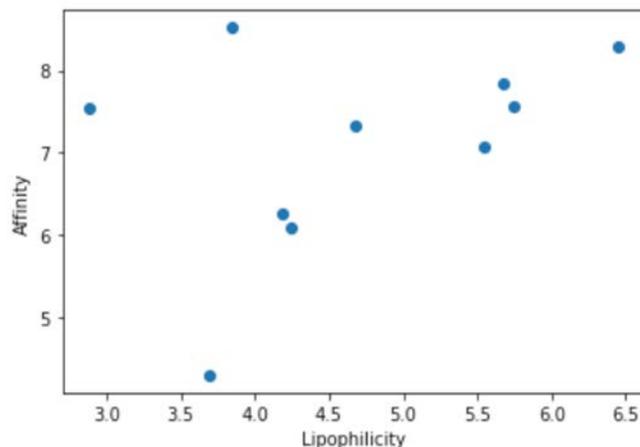
Zitat

If your experiment needs a statistician,
you need a better experiment.

Ernest Rutherford

Plausibilitätsabschätzungen

	Molekül ₁	Molekül ₂	Molekül ₃	Molekül ₄	Molekül ₅	Molekül ₆	Molekül ₇	Molekül ₈	Molekül ₉	Molekül ₁₀
Lipophilie	3,84	5,67	5,55	2,88	4,24	3,69	6,45	4,18	4,68	5,74
Affinität	8,52	7,85	7,08	7,54	6,09	4,29	8,3	6,26	7,32	7,57



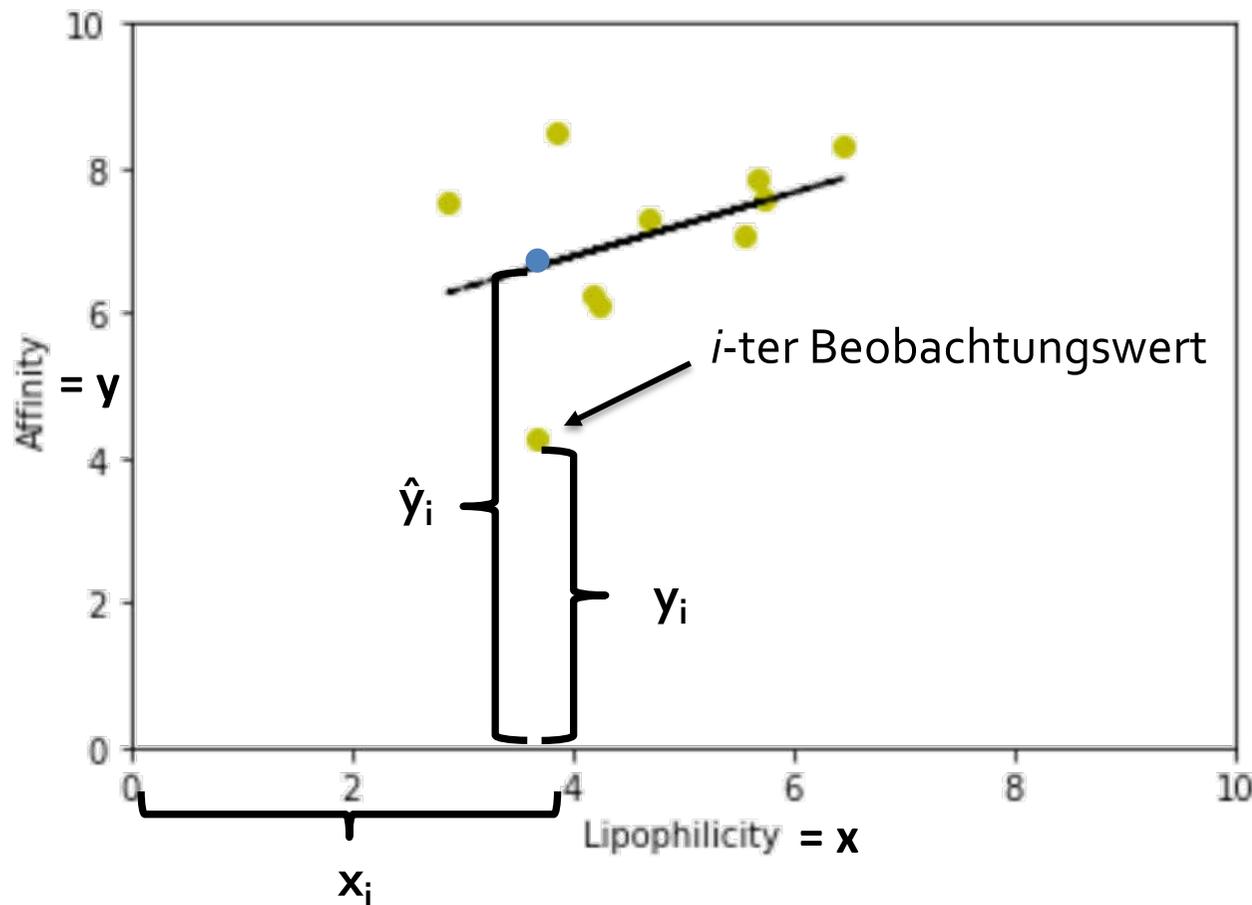
- Sie haben 10 Moleküle im Labor synthetisiert und die Affinität auf dem *Target* p38 bestimmt
- Für diese 10 Moleküle haben Sie ebenso die Lipophilie (der sogenannte logP-Wert) bestimmt
- Mittels Bravais-Pearson erhalten Sie eine Korrelation von 0,40

Lässt sich nun für ein neues Molekül (bspw. mit einem logP=5) die Affinität auf p38 abschätzen?

Anders ausgedrückt: wie hängen logP und pIC₅₀ linear miteinander zusammen?

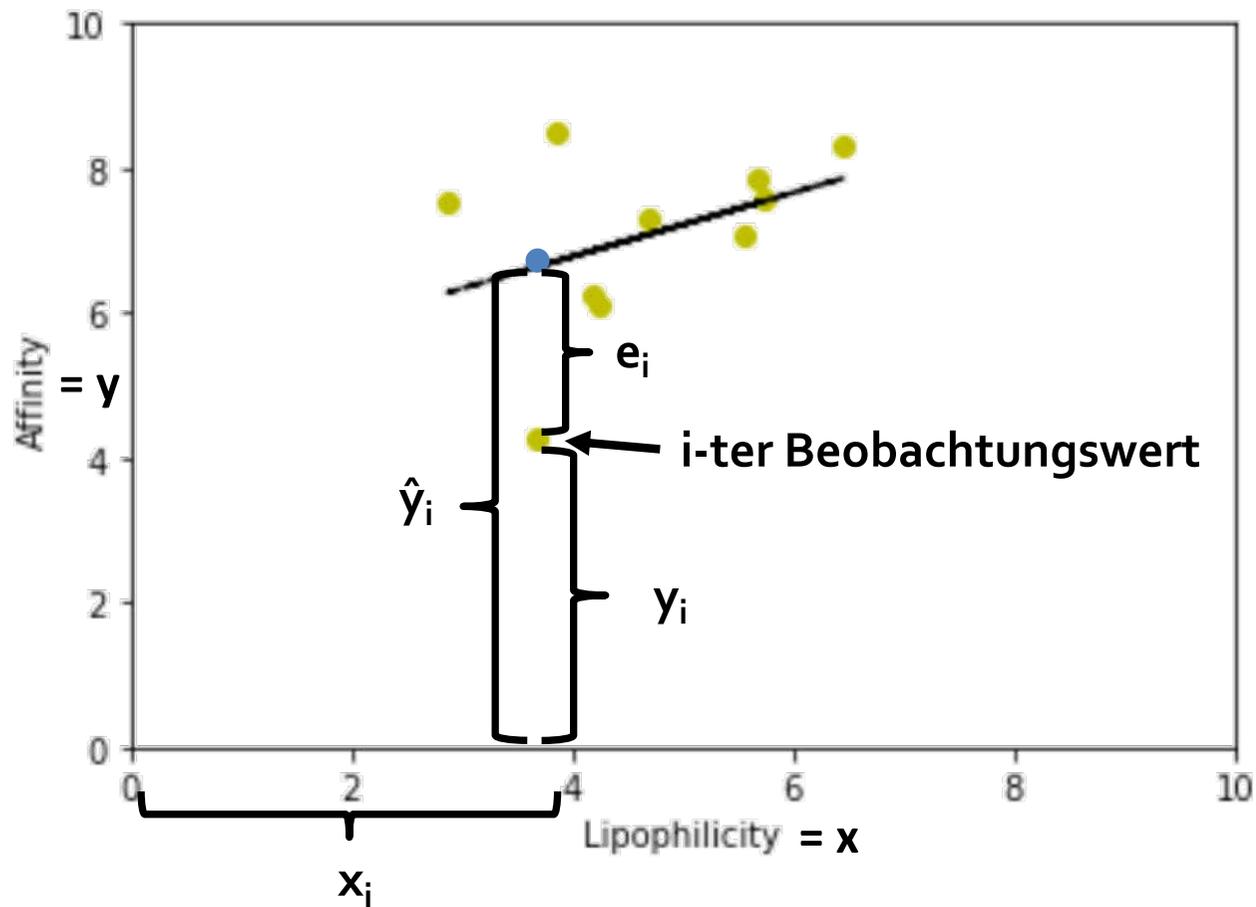
Aus Plausibilitätsbetrachtungen können Sie auf einen Zusammenhang von pIC₅₀ und logP schließen, da die Bindetasche von p38 einen stark lipophilen Charakter hat

Lineare Regression



y_i Beobachtungswert
 \hat{y}_i Gemäß der linearen Funktion geschätzter Wert

Geradengleichung



$$\hat{y}_i = a + b * x_i$$

a, b: zu schätzende Parameter
 a: y-Achsenabschnitt
 b: Steigung der linearen Funktion

Residuen und Zielfunktion

Die Abweichungen der geschätzten von den tatsächlichen Werten der abhängigen Variable y heißen **Residuen**

$$e_i = y_i - \hat{y}_i$$

Zielfunktion der linearen Regression (Methode der kleinsten Quadrate)

$$\sum_{i=1}^n e_i^2 = e_1^2 + e_2^2 + \dots + e_n^2 \rightarrow \min_{a,b}$$

n : Anzahl der Beobachtungen

Quadriert weil:

- Residuen können positiv oder negativ sein
- Größere Residuen werden stärker gewichtet

Ermittlung der zu schätzenden Parameter

Die Schätzung der Regressionsparameter a und b erfolgt mittels der Methode der kleinsten Quadrate, so dass die Summe der quadrierten Residuen minimal wird.

Lösung des Optimierungsproblems

y-Achsenabschnitt (a)

$$a = \bar{y} - b\bar{x}$$

Steigung (b)

Kovarianz

Korrelationskoeffizient nach Bravais-Pearson

$$b = \frac{S_{XY}}{S_X^2} = \frac{S_{XY} \cdot S_Y}{S_X^2 \cdot S_Y} = r \cdot \frac{S_Y}{S_X}$$

Varianz

Einfache, lineare Regression: Rechenbeispiel

	Molekül1	Molekül2	Molekül3	Molekül4	Molekül5	Molekül6	Molekül7	Molekül8	Molekül9	Molekül10
Lipophilie	3,84	5,67	5,55	2,88	4,24	3,69	6,45	4,18	4,68	5,74
Affinität	8,52	7,85	7,08	7,54	6,09	4,29	8,3	6,26	7,32	7,57

$$a = \bar{y} - b\bar{x}$$

$$b = \frac{S_{XY}}{S_X^2} = \frac{S_{XY} \cdot S_Y}{S_X^2 \cdot S_Y} = r \cdot \frac{S_Y}{S_X}$$

Was benötigen wir?

- 1) Arithmetisches Mittel von X: \bar{x}
- 2) Arithmetisches Mittel von Y: \bar{y}
- 3) Kovarianz von X und Y: S_{XY}
- 4) Varianz von X: S_X^2

$$(3) \quad s_{XY} = \frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y}) = \frac{1}{n} \cdot \left(\sum_{i=1}^n x_i \cdot y_i \right) - \bar{x} \cdot \bar{y}$$

$$(4) \quad s_X^2 = \frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \cdot \left(\sum_{i=1}^n x_i^2 \right) - \bar{x}^2$$

Hinweis \tilde{S}_{XY} und S_{XY} (sowie \tilde{S}_X und S_X etc.) bedeuten dasselbe

Lineare Regression in Python

```
x_mean = np.mean(Lipophilicity)
```

```
y_mean = np.mean(Affinity)
```

```
np.cov(Lipophilicity,Affinity)  
array([[1.26237333, 0.55677333],  
       [0.55677333, 1.56675111]])
```

```
S_XY = np.cov(Lipophilicity,Affinity,bias=True)[0,1]  
S_XY
```

```
0.50109600000000002
```

```
S_x2 = np.var(Lipophilicity)  
S_x2
```

```
1.136136
```

```
b = S_XY / S_x2  
b
```

```
0.44105283170324694
```

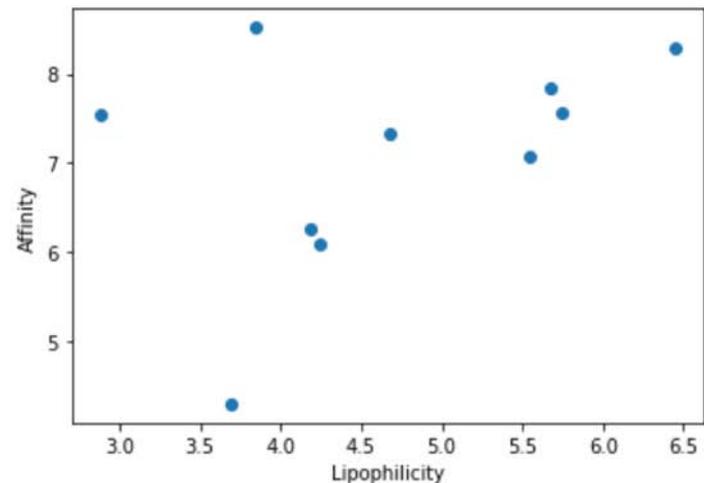
```
yachsenabschnitt = y_mean - b*x_mean  
yachsenabschnitt
```

```
5.012580113648364
```

Lineare Regression in Python

```
Lipophilicity = [3.84, 5.67, 5.55, 2.88, 4.24, 3.69, 6.45, 4.18, 4.68, 5.74]  
Affinity = [8.52, 7.85, 7.08, 7.54, 6.09, 4.29, 8.3, 6.26, 7.32, 7.57]
```

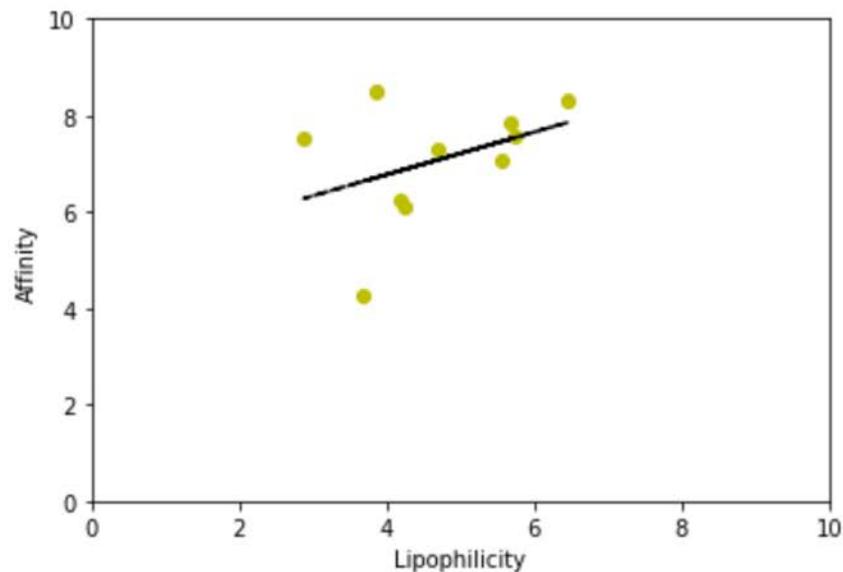
```
plt.scatter( Lipophilicity, Affinity)  
plt.xlabel("Lipophilicity")  
plt.ylabel("Affinity")  
plt.show()
```



Lineare Regression in Python

```
coef = np.polyfit(Lipophilicity,Affinity,1)  
polyld_fn = np.polyld(coef)
```

```
plt.plot(Lipophilicity,Affinity, 'yo', Lipophilicity, polyld_fn(Lipophilicity), '--k')  
plt.xlabel("Lipophilicity")  
plt.ylabel("Affinity")  
plt.xlim(0,10)  
plt.ylim(0,10)  
plt.show()
```



Lineare Regression in Python

```
slope, intercept, r_value, p_value, std_err = linregress(Lipophilicity, Affinity)
```

```
print("Steigung:           %1.2f" % slope)  
print("y-Achsenabschnitt: %1.2f" % intercept)  
print("Korrelation:       %1.2f" % r_value)
```

```
Steigung:           0.44  
y-Achsenabschnitt: 5.01  
Korrelation:       0.40
```

Kurze Zwischenfrage: Was bedeuten y-Achsenabschnitt und Steigung anschaulich?

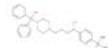
SoSe

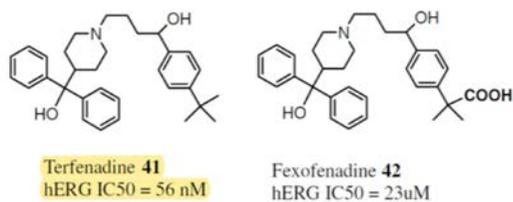
**Einführung Data Science im Bereich Chemie und
Chemische Biologie**

Data curation

Sources of errors: Data Extraction

Unit inconsistencies is very common during data digitization

<input type="checkbox"/>		41, Terfenadine	IC50	=	56000	nM	No Data	No Data	CHEMBL907269	Inhibition of human ERG potassium channel in HEK293 cells by patch clamp assay	cell-based format	Homo sapiens
<input type="checkbox"/>		Terfenadine	IC50	=	56	nM	7.25	No Data	CHEMBL768686	Inhibitory activity against Potassium channel HERG	single protein format	Homo sapiens



Zhu et al. *Bioorg. Med. Chem. Lett.* **2006**, *16*, 5507

Table 1. Comparison of the HERG Channel Affinity to That of the Intended Pharmacological Target for Several Drugs

drug	target affinity	HERG IC ₅₀	comment
terfenadine	58 nM (histamine H1 K _i)	56 nM	withdrawn
astemizole	3 nM (histamine H1 K _i)	0.9 nM	withdrawn
cisapride	29 nM (serotonin 5HT ₄ K _i)	47 nM	withdrawn
sertindole	0.6 nM (serotonin 5HT _{2A} K _i)	3 nM	withdrawn
thioridazine	27 nM (dopamine D ₂ K _i)	191 nM	black box ^a
pimozide	12 nM (dopamine D ₂ K _i)	18 nM	TDP ^b
grepafloxacin	up to 2.4 µM (bacterial MIC ^c)	50 µM	withdrawn

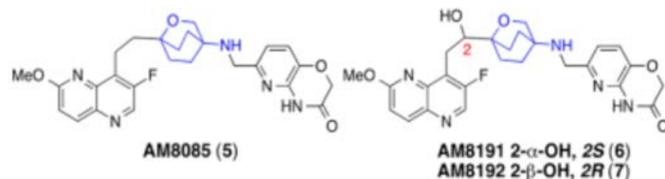
Pearlstein et al. *J. Med. Chem.* **2003**, *46*, 2017

Automation procedure: nM switched to µM

Courtesy: Pankaj Daga (Simulations Plus)

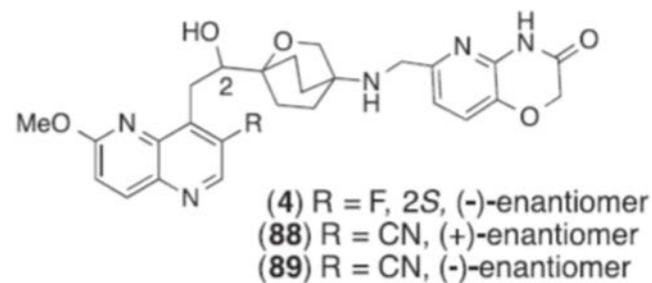
Sources of errors: Original Research Articles

Singh et al, ACS Med. Chem. Lett. **2014**, 5, 609



agents. We evaluated hERG activity in a functional automated patch clamp assay (see Supporting Information for Methods). In this assay, AM8085 showed an IC_{50} of $0.6 \mu M$. The 2S-hydroxy group of AM8191 improved the polarity and attenuated the hERG activity ($IC_{50} = 18 \mu M$). However, more than an order of magnitude attenuation of hERG activity may be required for a clinical development compound.

Singh et al, Bioorg. Med. Chem. Lett. **2015**, 25, 2409



List	R	SaS	SaMR	Sp	Ef	Ec	Ab	Pa	hERG binding (IC_{50} , nM)	PX hERG (IC_{50} , nM)	clog $D_{7,4}$
4	F	0.02	.06	.05	0.5	2	0.5	8	26.00	18.00	1.9
88	CN	0.031	0.031	0.25	1	4	0.5	8	2.13	2.00	1.3
89	CN	0.063	0.031	0.25	2	4	1	16	2.58	NT	1.3

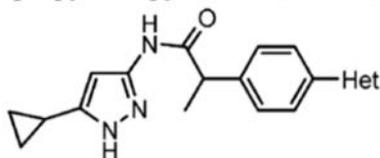
The original author made a mistake

Courtesy: Pankaj Daga (Simulations Plus)

Sources of errors: Image processing

Original publication

Table 3. SAR of 3-(4-Heterocycl-1-yl)phenyl-acetamido-5-cyclopropyl-1H-pyrazoles (**21–32**)



Entry	Het	α -methyl configuration	CDK2/cyclin A (IC ₅₀ ; nM) ^a	A2780 (IC ₅₀ ; nM) ^b	Caco-2 Permeability	Solubility (μ M; buffer pH 7)	Plasma Protein Binding (%)
21		R,S	77	>10,000	Moderate	220	48
22		R,S	12	2,250	Moderate	224	74
23		R	455	13,200	Moderate	220	74
24		S	2	1,270	Moderate	>225	74
25		R,S	17	4,540	Low	201	67
16		R,S	150	6,400		222	67

Pevarello et al, *J. Med. Chem.* **2005**, 48, 2944

The Compound **21** shows extracellular double bond in original article



Transcribed likewise in the database

But here an oxygen becomes lost!

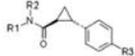
Waldman et al, *J Comput Aided Mol Des*, **2015**, 29, 897

Wrong initial sketch leads to wrong structure

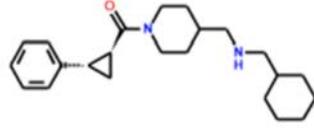
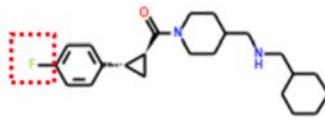
Courtesy: Pankaj Daga (Simulations Plus)

Sources of errors: Image processing

Table 1 SAR and key *in vitro* properties of phenylcyclopropylcarboxamide analogs



Compound	R_1	R_2	R3	σ_1 p <i>K_i</i> ^d	σ_2 p <i>K_i</i> ^b	Off-targets profiling	log <i>D</i> [ACD_log <i>D</i>] ^e	LLE [cLLE] ^d	p <i>K_a</i> [ACD_p <i>K_a</i>] ^e	Cl _{int} (rat) ^f
(±)-1			H	6.7 ± 0.38	nt	Ca ²⁺ , 5HT2a, α1 ^e	1.3	5.4	10.1	nt
						[...]				
14			H	7.1 ± 0.22	50% inhib. at 10 μM	H3, Ca ²⁺ ^h	1.1	6.0	9.3	32
15			F	7.0 ± 0.27	61% inhib. at 10 μM	Clean ^h	[1.4]	[5.6]	[9.3]	nt
16			H	7.1 ± 0.38	nt	Na ⁺ , muscarinic, 5HT1a ^h	[0.5]	[6.6]	[10.6]	17

Structure	Identifier	Previous Structure
<p>Correct Structure</p> 	Cmpd A	<p>ChEMBL Structure</p> 

Valade et al, *Med Chem Commun*, 2011, 2, 655

The different R-Groups were combined in the wrong way