

# Modelli di deep learning per il progetto *de-novo* di molecole

Nicola Ancona

nicola.ancona@cnr.it

Istituto di Sistemi e Tecnologie Industriali Intelligenti per il  
Manifatturiero Avanzato - CNR

# Collaboratori

- Teresa Maria Creanza, CNR - Istituto di Sistemi e Tecnologie Industriali Intelligenti per il Manifatturiero Avanzato
- Giuseppe Felice Mangiatordi, Giuseppe Lamanna, Pietro Delre, Nicola Corriero, Michele Saviano, CNR - Istituto di Cristallografia
- Marialessandra Contino, Dipartimento di Farmacia - Scienze Farmaceutiche, Università di Bari "Aldo Moro"



# Sommario

- Contesto applicativo.
- Natura dei dati.
- Modello di linguaggio statistico.
- DeLA-Drug: Recurrent Neural Network con LSTM layers.
- Generazione di molecole: SFS e SWS.
- Valutazione *in silico* delle molecole generate.
- Conclusioni e sviluppi futuri.

# Contesto applicativo

Lo sviluppo di nuovi farmaci è un processo complesso che ha come obiettivo l'identificazione di nuove molecole con particolari proprietà chimiche per il trattamento di determinate patologie.

Tale processo ha costi estremamente elevati (miliardi di \$), coinvolge un gran numero di risorse umane ed un lungo intervallo di tempo.

Lo sviluppo di nuovi farmaci parte dalla scoperta e ottimizzazione di sostanze in forma prototipale e prevede una lunga ricerca clinica con un elevato rischio di scoprire farmaci con scarsa efficienza.

# Contesto applicativo


Il problema dell'ottimizzazione prevede la ricerca di sostanze che da un lato massimizzano alcune proprietà farmacocinetiche (solubilità e accessibilità sintetica), dall'altro siano bioattive verso determinati target.

Tale problema è estremamente sfidante in quanto la dimensione dello *spazio chimico* varia da  $10^{23}$  a  $10^{60}$  potenziali molecole, ma solo  $10^8$  sostanze sono state finora sintetizzate.

Quindi sono necessarie tecniche computazionali (*virtual screening*) per esplorare lo spazio chimico *generando* nuove molecole e identificare sostanze che si legano ad un determinato target in modo più veloce ed efficace.

# Contesto applicativo

Modelli di *deep learning* possono velocizzare la scoperta ed ottimizzazione di nuovi farmaci consentendo la generazione *data-driven* di sostanze con determinate proprietà chimico-fisiche.




AI in small-molecule drug discovery: a coming wave? M. K. P. Jayatunga, W. Xie, L. Ruder, U. Schulze and C. Meier. *Nature Reviews Drug Discovery* Feb. 2022

# DeLA-Drug: a Deep Learning Generative Model

## DeLA-Drug: A Deep Learning Algorithm for Automated Design of Druglike Analogues

Teresa Maria Creanza,<sup>1</sup> Giuseppe Lamanna,<sup>1</sup> Pietro Delre, Marialessandra Contino, Nicola Corriero, Michele Saviano, Giuseppe Felice Mangiatordi,\* and Nicola Ancona

<https://doi.org/10.1021/acs.jcim.2c00205>




CNR - Institute of Intelligent Industrial Technologies and Systems for Advanced Manufacturing

CNR – Institute of Crystallography

Department of Pharmacy - Pharmaceutical Sciences, University of Bari “Aldo Moro”

# Natura dei dati


## Differenti tipi di rappresentazioni molecolari



# Natura dei dati

Un possibile modo per rappresentare molecole è attraverso stringhe di caratteri (canonical SMILES) appartenenti ad un determinato alfabeto.

N#CCCCCCC1(Cc2ccncc2)C(=O)N(c3c1cccc3)c4ccccc4



Repository: ChEMBL28 con 1.092.285 sostanze rappresentate da SMILES con 29-75 caratteri.


Alfabeto è composto da 37 caratteri:

alcuni (H,C, N, O, F, Br, I, Cl, P, S) indicano atomi, altri (-, =, #) indicano legami.

Caratteri speciali: \$ (BoS), ~ (EoS), € (padding).

# Natura dei dati

Ogni carattere viene rappresentato da un *one-hot vector* costituito da un numero di componenti uguale al numero di caratteri dell'alfabeto.



SMILES

BrCc1c[nH]nc1

One-hot  
encoding

	Br	C	c	1	c	[	n	H	]	n	c	1
	1	0	0	0	0	0	0	0	0	0	0	0
	0	1	0	0	0	0	0	0	0	0	0	0
	0	0	0	0	0	0	0	1	0	0	0	0
	0	0	1	0	1	0	0	0	0	0	1	0
	0	0	0	0	0	0	1	0	0	1	0	0
	0	0	0	1	0	0	0	0	0	0	0	1
	0	0	0	0	0	1	0	0	0	0	0	0
	0	0	0	0	0	0	0	0	1	0	0	0

# Modello di linguaggio statistico

Un SLM è una funzione densità di probabilità congiunta  $f$  su sequenze  $(x_1, x_2, \dots, x_T)$  di caratteri in un alfabeto  $A$  di dimensione  $S$ .

Il nostro obiettivo è:

- Apprendere una stima di  $f(x_1, x_2, \dots, x_T)$  dai dati;
- Campionare  $f$  per generare nuove sequenze.

Ogni  $x_i$  è una variabile aleatoria discreta che assume uno di  $S$  valori.

Se  $T=3$  e  $A=\{a,b\}$ , dobbiamo stimare  $p_{aaa}=P\{aaa\}$ ,  $p_{aab}=P\{aab\}$ , ...,  $p_{bbb}=P\{bbb\}$ .

Poiché  $p_{aaa}+p_{aab}+\dots+p_{bbb}=1$  allora il numero di parametri liberi è  $FP=2^3-1$ .

In generale  $FP=S^T-1$ .

Per  $T=75$   $S=37$  si ha  $FP=4 \times 10^{117}$ .

# Modello di linguaggio statistico

Consideriamo sequenze di lunghezza  $T$ . La densità congiunta  $f(x_1, x_2, \dots, x_T)$  può essere espressa utilizzando la chain rule per densità condizionali:

$$f(x_1, x_2, \dots, x_T) = f(x_T | x_{T-1}, x_{T-2}, \dots, x_1) f(x_{T-1} | x_{T-2}, \dots, x_1)$$

$$f(x_1, x_2, \dots, x_T) = f(x_T | x_{T-1}, x_{T-2}, \dots, x_1) f(x_{T-1} | x_{T-2}, x_{T-3}, \dots, x_1) f(x_{T-2} | x_{T-3}, \dots, x_1)$$

In conclusione:

$$f(x_1, x_2, \dots, x_T) = f(x_T | x_{T-1}, x_{T-2}, \dots, x_1) f(x_{T-1} | x_{T-2}, x_{T-3}, \dots, x_1) \dots f(x_2 | x_1) f(x_1)$$


$$f(x_1, x_2, \dots, x_T) = \prod_{t=1}^T f(x_t | x_{t-1}, x_{t-2}, \dots, x_1)$$

# Modello di linguaggio statistico

Il nostro SLM è rappresentato da una neural network costruita e addestrata come un classificatore probabilistico che impara a predire una distribuzione di probabilità  $f(x_t / x_{t-1}, x_{t-2}, \dots, x_1)$  per tutti i simboli  $x_t \in A$ .

Abbiamo utilizzato una Recurrent Neural Network (RNN) con Long Short-Term Memory (LSTM) units per predire la distribuzione del carattere successivo della sequenza.

# DeLA-Drug



## LSTM unit

$$i = \sigma(W_i[x_t, h_{t-1}] + b_i) \text{ input gate}$$

$$f = \sigma(W_f[x_t, h_{t-1}] + b_f) \text{ forget gate}$$

$$o = \sigma(W_o[x_t, h_{t-1}] + b_o) \text{ output gate}$$

$$g = \tanh(W_g[x_t, h_{t-1}] + b_g) \text{ modulation gate}$$

$$c_t = f \odot c_{t-1} + i \odot g$$

$$h_t = o \odot \tanh(c_t)$$

# Output layer

$$z_t = W_z^t h_t + b_z^t$$

$$u_t = \text{ReLU}(z_t)$$

$$v_t = W_v^t u_t + b_v^t$$

$$y_t = s(v_t)$$

Dove  $s$  è la funzione di attivazione *softmax* .

# Training

Per determinare i pesi della rete, consideriamo la likelihood  $\mathcal{L}(X|Y)$  di osservare i dati  $\mathbf{x}_t$  date le probabilità  $\mathbf{y}_t$  assegnate dal modello:

$$\mathcal{L}(X|Y) = \prod_{t=1}^T \prod_{k=1}^S (\mathbf{y}_t^{(k)})^{\mathbf{x}_t^{(k)}}$$

Dove  $\mathbf{x}_t^{(k)}$  denota la k-th componente del vettore  $\mathbf{x}_t$ .

# Cross-Entropy Loss


$$E = -\frac{1}{T} \log \mathcal{L}(X|Y)$$

$$E = \frac{1}{T} \sum_{t=1}^T L(\mathbf{x}_t, \mathbf{y}_t)$$


$$L(\mathbf{x}_t, \mathbf{y}_t) = -\sum_{k=1}^S x_t^{(k)} \log(y_t^{(k)})$$

$L$  è la *cross-entropy* tra  $\mathbf{x}_t$  e  $\mathbf{y}_t$ .

# Sampling From Scratch



# Sampling From Scratch



# SAMPLING WITH SUBSTITUTIONS

O = C ( N C 1 C C C C C 1 ) c 1 c c c n c 1 O C c 1 c c c c 1

O = P

O = P ( N C C

O = P ( N C C 1

O = P ( N C C 1 C C N

O = P ( N C C 1 C C N C 1 ) c 1

O = P ( N C C 1 C C N C 1 ) c 1 c c c c

O = P ( N C C 1 C C N C 1 ) c 1 c c c c c 1 O

O = P ( N C C 1 C C N C 1 ) c 1 c c c c c 1 O C c 1

O = P ( N C C 1 C C N C 1 ) c 1 c c c c c 1 O C c 1 c c

O = P ( N C C 1 C C N C 1 ) c 1 c c c c c 1 O C c 1 c c c c c

O = P ( N C C 1 C C N C 1 ) c 1 c c c c c 1 O C c 1 c c c c c 1

# Valutazione in silico (SFS)


Set Name	Val (%)	Un (%)	ID (Td)	Nov (%)	QED	SA	nPAINS (%)
FSC1	85.14	85.05	0.87	99.14	0.57 ± 0.21	3.0±0.8	95.27
FSC2	83.80	87.93	0.87	99.15	0.58 ± 0.20	2.8 ± 0.7	95.32
FSC4	84.94	87.05	0.87	99.24	0.57 ± 0.21	2.9 ± 0.8	95.12
FSC6	79.43	88.51	0.87	99.29	0.58 ± 0.21	2.9 ± 0.8	94.67
FSC8	86.24	84.73	0.87	99.30	0.58 ± 0.20	3.0 ± 0.7	95.30
FSC10	83.85	88.27	0.87	99.34	0.56± 0.21	2.9 ± 0.8	95.27
FSC12	80.90	87.84	0.87	99.21	0.58± 0.21	2.8 ± 0.7	95.78

# Valutazione in silico (SWS)


Set Name	n. valid molecules	Un (%)	ID	Nov (%)	QED	SA	nPAINS (%)	QS
CB2R-DB	1,845	/	0.82	/	0.54 ± 0.19	2.90 ± 0.70	95.83	/
S5C1	108,740	60.60	0.84	99.13	0.53 ± 0.20	3.31± 0.84	95.83	0.88
S5C8	113,512	59.36	0.82	99.26	0.53 ± 0.20	3.32± 0.84	95.82	0.89
S10C1	34,426	89.35	0.87	98.83	0.54 ± 0.20	3.43 ± 0.97	96.06	0.61
S10C8	37,178	88.28	0.87	98.94	0.55 ± 0.20	3.48 ± 1.00	95.86	0.60
S15C1	11,824	96.63	0.88	98.29	0.54 ± 0.21	3.58 ± 1.00	96.04	0.40
S15C8	13,442	95.31	0.88	98.22	0.56 ± 0.21	3.67 ± 1.0	96.12	0.39

# Molecular Docking

Tecnica in silico che cerca di predire la posizione e l'orientazione di un ligando (small molecule) quando si lega ad una proteina.



# Molecular Docking



⇒ candidates selection

# Validazione Statistica del Docking

- Consideriamo 3 dataset BD1, BD2, BD3 contenenti 50 molecole attive su CB2R e 833 decoy (5.66% attive/totale).
- Ordiniamo le molecole in ciascun dataset per lo score di docking e contiamo il numero di molecole attive nel primo decile.
- Abbiamo il 13.00% in BD1 (p-value=0.0073), il 15.89% in BD2 (p-value= $1.6 \times 10^{-4}$ ), 22.80% in BD3 (p-value= $4.9 \times 10^{-9}$ ).

# Virtual Screening con Docking

Set pairs	Fisher's exact test P-values
CB2R-DB vs. randChEMBL	$3 \times 10^{-28}$
randS5C8 vs. randChEMBL	$2.7 \times 10^{-24}$
randS10C8 vs. randChEMBL	$1.3 \times 10^{-14}$
randS15C8 vs. randChEMBL	$1.16 \times 10^{-4}$



# Molecole Generate

## Query



## Generated

CHEMBL1631167

S5C8-67080



$K_i$ : 460 nM





Docking score: -6.47 kcal/mol


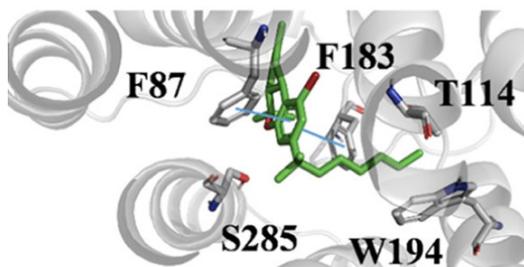
Docking score: -9.54 kcal/mol

CHEMBL1277593

S5C8-73439



$K_i$ : 34 nM



Docking score: -9.42 kcal/mol

Docking score: -11.51 kcal/mol

# DeLA-Drug web platform

<https://www.ba.ic.cnr.it/softwarec/deladrugportal/>

## Input

l'utente può:

- scrivere o disegnare una molecola query;
- scegliere il numero di caratteri da sostituire nella procedura SWB;
- vedere potenziali warning metabolici.

The screenshot displays the DeLA-Drug web platform interface. At the top, it states: "A Deep Learning Algorithm for automated Design of Drug-like Analogues. This website allows you to generate drug-like analogues of a single user-defined query. The generation is based on a Recurrent Neural Network (RNN) model able to capture the syntax of more than 1 million compounds extracted from the ChEMBL28 dataset." The interface is divided into several sections: "Draw Molecule" with a chemical drawing tool, "Generated Molecule" showing a 3D ball-and-stick model of a generated compound, "Input SMILES" with a text field containing a SMILES string and options for the number of generated compounds and substitutions, and "SMILES Results: 5" which displays a table of results.

Output SMILES	QED	SA	Similarity*	Metabolism
<chem>CC1=CC=C(C=C1)C(=O)N(C)C(=O)OCC</chem>	0.699	3.404	0.232	⚠
<chem>CC1=CC=C(C=C1)C(=O)N(C)C(=O)OCC</chem>	0.699	3.403	0.230	⚠
<chem>CC1=CC=C(C=C1)C(=O)N(C)C(=O)OCC</chem>	0.699	3.392	0.234	⚠
<chem>CC1=CC=C(C=C1)C(=O)N(C)C(=O)OCC</chem>	0.748	3.425	0.333	⚠
<chem>CC1=CC=C(C=C1)C(=O)N(C)C(=O)OCC</chem>	0.368	2.428	0.492	✓

## Output

l'utente può:

- ispezionare una molecola generata;
- scaricare i risultati in differenti formati ordinati per QED o SA.

# Sviluppi Futuri

- Transformer e Autoencoder Variazionali
- Autoencoder Variazionali Condizionati

Tali modelli saranno addestrati condizionando su dati trascrittomici al fine di progettare molecole aventi un'alta probabilità di indurre un determinato profilo trascrittomico.