Sviluppo di modelli QSAR predittivi mediante tecniche di Machine Learning: applicazione sugli inibitori di HDAC4

Tesi Sperimentale in
Chimica Farmaceutica

SAPIENZA
UNIVERSITÀ DI ROMA

FACOLTÀ DI FARMACIA E MEDICINA

DIPARTIMENTO DI CHIMICA E TECNOLOGIA DEL FARMACO

CORSO DI LAUREA MAGISTRALE IN
CHIMICA E TECNOLOGIA FARMACEUTICHE

LAUREANDA:
Fantera Giulia

RELATORE:
Prof. Rino Ragno

Obiettivo della ricerca e strumenti impiegati

Target biologico di interesse: HDAC4

CLASSE	PROTEINA
I	HDAC1 HDAC2 HDAC3 HDAC8
IIa	HDAC4 HDAC5 HDAC7 HDAC9
IIb	HDAC6 HDAC10
III	SIRTUINE
IV	HDAC11

Inibitori di HDAC4

Rome Center for Molecular Design

Tasquinimod

- fase I e III
- antitumorale

TMP-269

- fase preclinica
- neuroprotezione

Metodologia Sperimentale

Rome Center for Molecular Design

Generazione training set

Rome Center for Molecular Design

Costruzione dei modelli per classificazione e regressione

```
est.fit(x_train, y_train)
y_pred = est.predict(x_test)
y_fit = est.predict(x_train)
y_cvpred = make_cv(x_train,
y_train, 5, est)
```

Risultati Training Classificazione

M.C.C. Fingerprints	y_pred	y_fit	y_cvpred
SupportVectorMachine	0,726	1	0,645
RandomForest	0,545	0,887	0,645
GradientBoosting	0,656	1	0,649

M.C.C. Descrittori Molecolari	y_pred	y_fit	y_cvpred
SupportVectorMachine	0,635	0,934	0,619
RandomForest	0,585	0,989	0,599
GradientBoosting	0,618	1	0,607

Risultati Training Classificazione

FINGERPRINTS

DESCRITTORI MOLECOLARI

Risultati Training Regressione

Fingerprints	y_pred R ² pred	y_fit R ²	y_cvpred Q ²
SupportVectorMachine	0,707	0,993	0,695
RandomForest	0,666	0,921	0,654
Ridge	0,695	0,957	0,681

Descrittori Molecolari	y_pred R ² pred	y_fit R ²	y_cvpred Q ²
SupportVectorMachine	0,585	0,886	0,609
RandomForest	0,539	0,937	0,557
Ridge	0,468	0,487	0,441

Risultati Training Regressione

Desc. Molec. Scalati	y_pred R ² pred	y_fit R ²	y_cvpred Q ²
SupportVectorMachine	0,630	0,875	0,589
RandomForest	0,628	0,941	0,555
Ridge	0,415	0,599	0,339

Risultati Validazione interna Classificazione e Regressione

SVC	Fingerprints	Descrittori Molecolari
Accuracy	0,844	0,825
M.C.C.	0,687	0,652

SVR	Fingerprints	Descrittori Molecolari	Desc. Molec. Scalati
Q ²	0,729	0,655	0,651
RMSE	0,677	0,764	0,769

svr - Fingerprints

svr - Descriptors

svr - Scaled Descriptors

Validazione esterna ed analisi similarità training-test sets

Rome Center for Molecular Design

Ricerca
test set

Confronto
con *training set*

Generazione
features e labels

58 molecole:
37 attive, 21 inattive

Max similarity: 0,48

Risultati validazione esterna

CLASSIFICAZIONE	DESCRITTORI MOLECOLARI	FINGERPRINTS
Accuracy	0,689	0,551
F1 score	0,769	0,566
Confusion Matrix	10-11 7-30	15-6 20-17
M.C.C.	0,303	0,171

REGRESSIONE	DESC. MOLEC.	DESC. MOLEC. SCALATI	FINGERPRINTS
M.A.E.	0,642	0,789	0,669

Analisi Selettività: costruzione modelli

```
selectivity = []  
for i in df_hdac4_1['RATIO_HDAC4_1']:  
    if i>=0.5:selectivity.append(1)  
    if i<=-0.5:selectivity.append(0)  
    if i>-0.5 and i<0.5:selectivity.append(-1)
```

545 molecole:
185 HDAC4 selettive,
144 HDAC1 selettive,
216 non selettive

Risultati Training Classificazione e Regressione Selettività

Rome Center for Molecular Design

M.C.C.	FINGERPRINTS	DESC. MOLEC.
SupportVectorMachine	0,900	0,883
RandomForest	0,838	0,875
GradientBoosting	0,905	0,878

R ² pred	FINGERPRINTS	DESC. MOLEC.	DESC. MOLEC. SCAL.
SupportVectorMachine	0,854	0,814	0,810
RandomForest	0,808	0,818	0,820
Ridge	0,827	0,636	0,833

Virtual Screening

Rome Center for Molecular Design