



UNIVERSITÀ  
DEGLI STUDI  
FIRENZE

Da un secolo, oltre.



HR EXCELLENCE IN RESEARCH

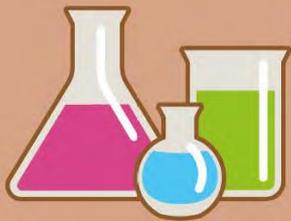
# I segreti delle proteine svelati dall'intelligenza artificiale

La soluzione a un problema cinquantennale

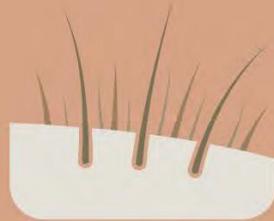
**Antonio Rosato**

antonio.rosato@unifi.it

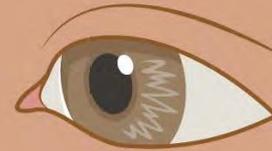
# Le proteine sono le molecole della vita



Enzymes



Structural  
proteins



Receptors



Transporter  
proteins



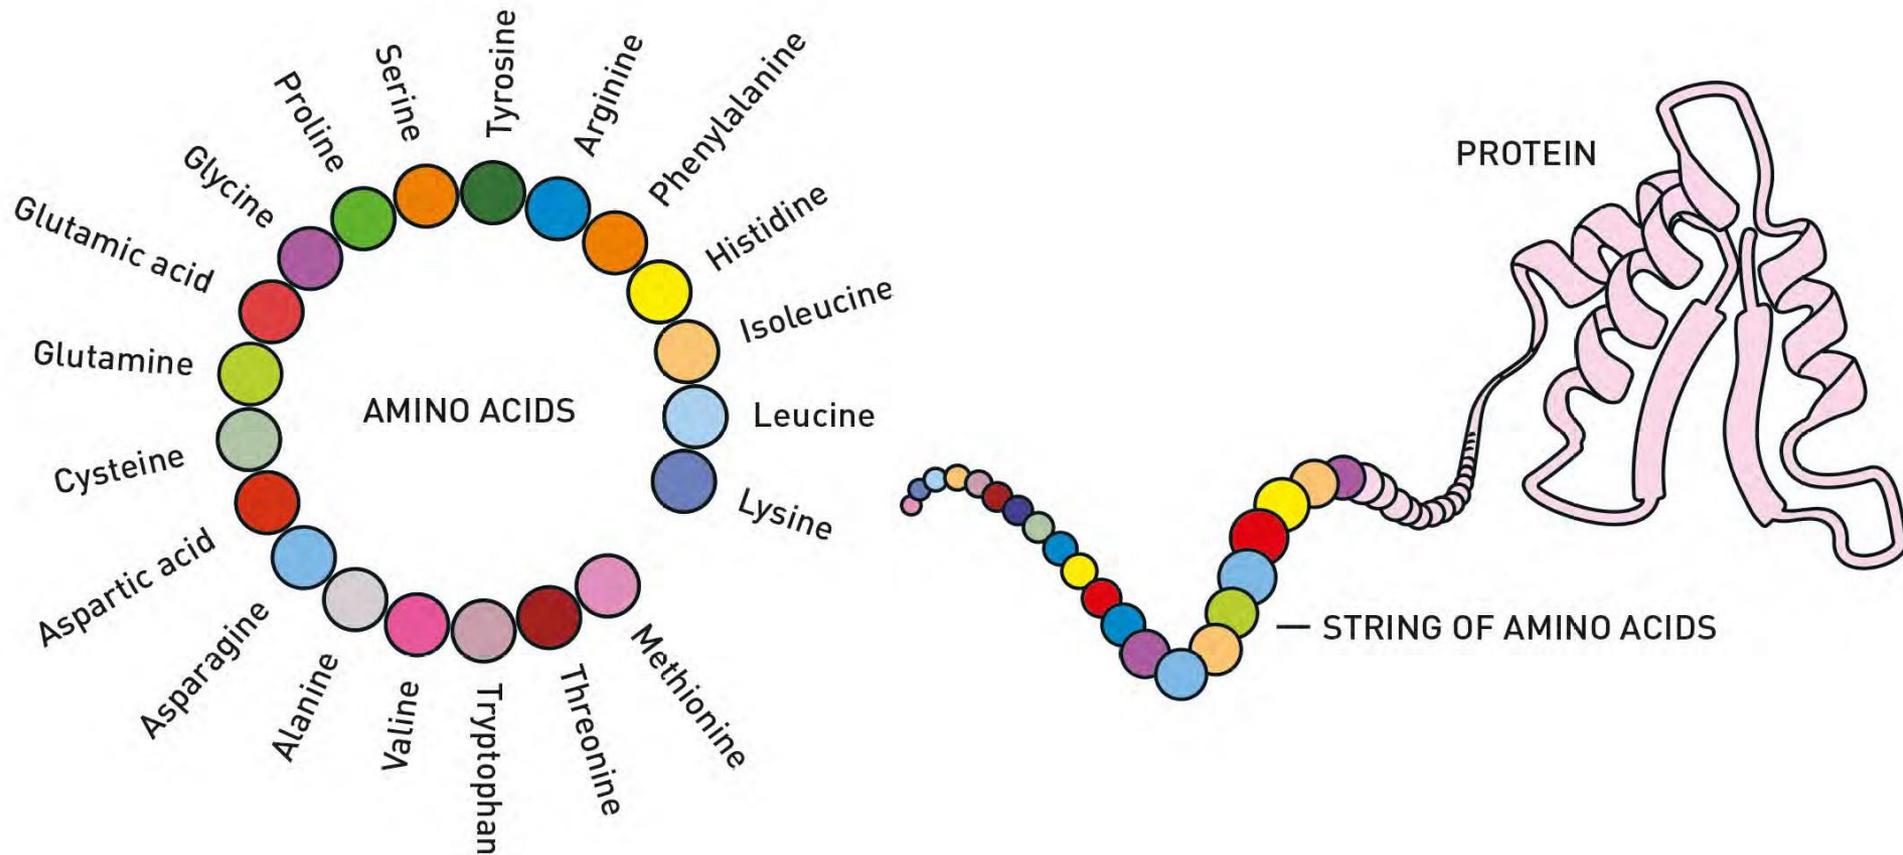
Gene regulatory  
proteins



Signaling  
proteins

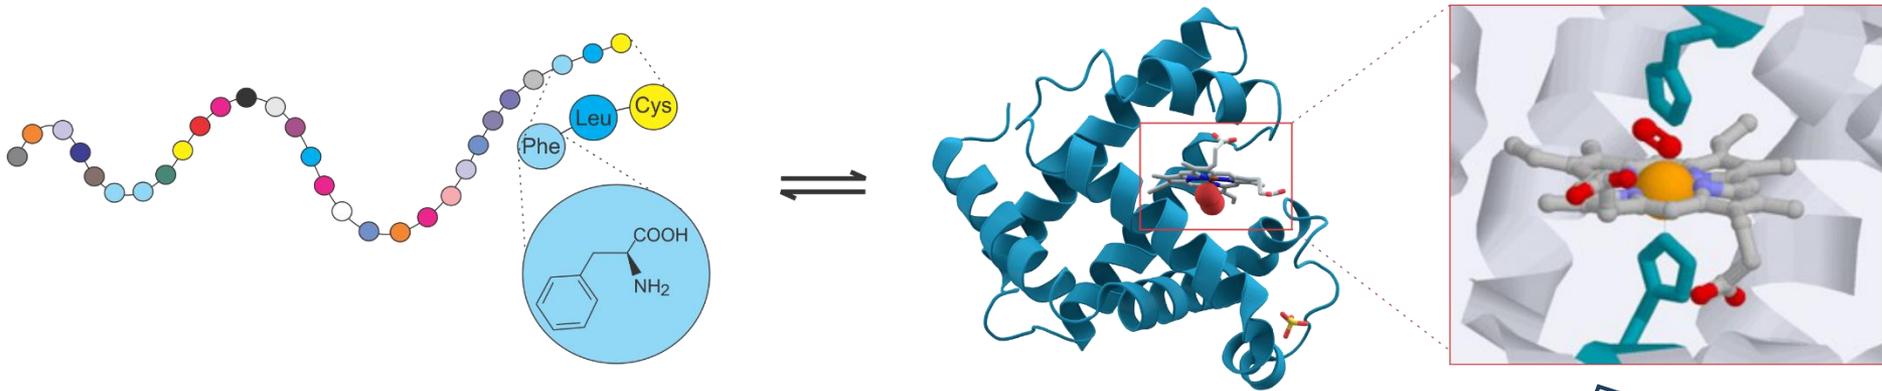
Le proteine si trovano in tutti gli esseri viventi, inclusi i virus, e svolgono un grande numero di funzioni diverse

# Le proteine sono costituite da aminoacidi



Le proteine sono formate combinando i 20 aminoacidi in catene contenenti varie centinaia di questi blocchi chimici

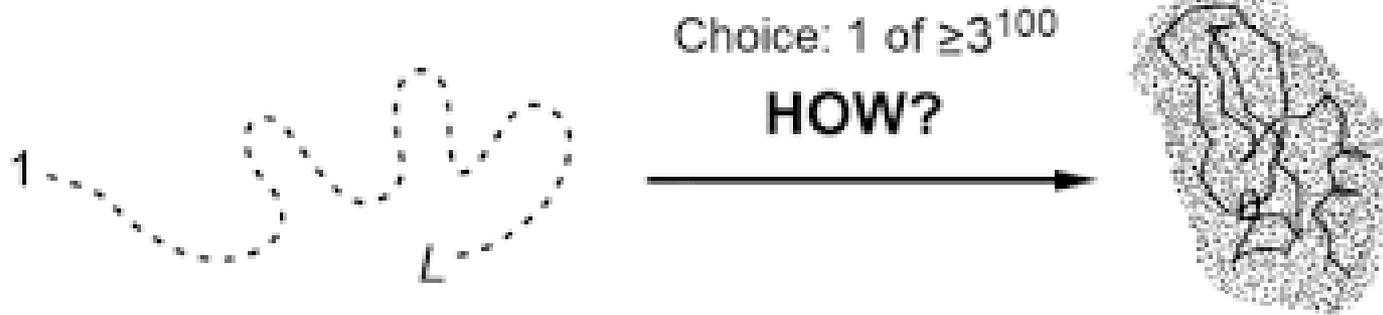
# Il paradigma sequenza-struttura-funzione



La catena degli aminoacidi si avvolge (**struttura 3D**) in una maniera unicamente determinata dalla sua sequenza.

La struttura 3D determina la reattività (bio)chimica della proteina, p.es. formando **siti di legame** per altre molecole.

# Il paradosso di Levinthal

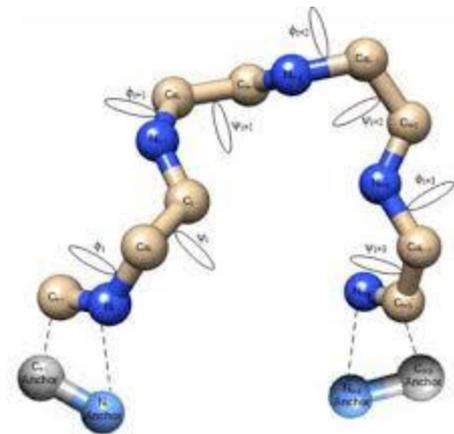


Unfolded protein chain:  $\geq 3^{100}$  conformations  
for a chain of  $L=100$  amino acid residues

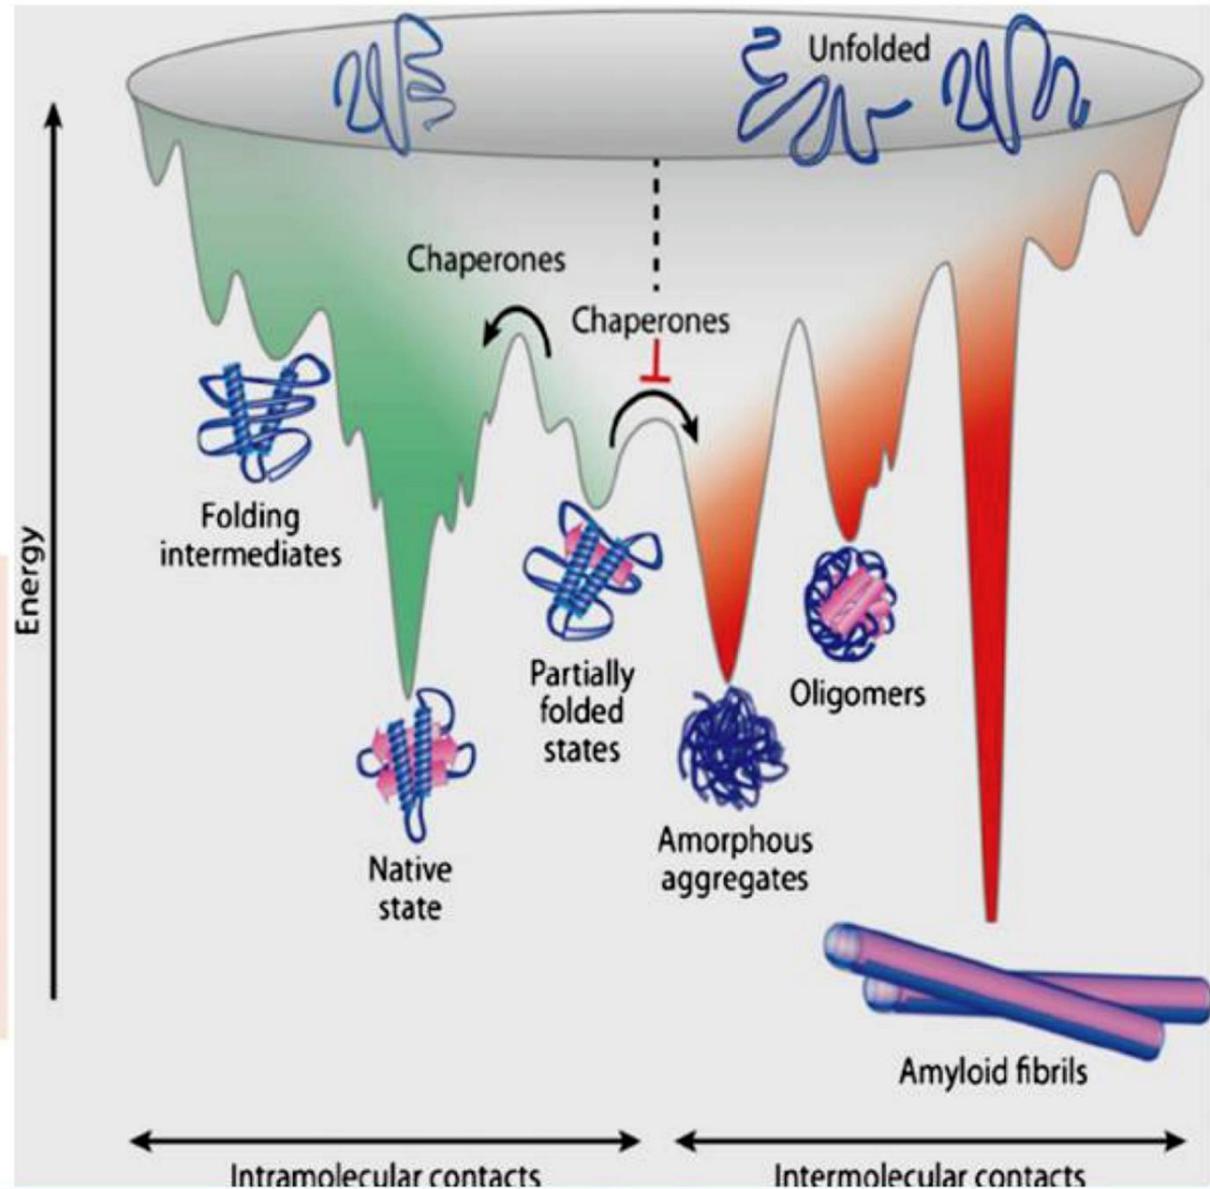
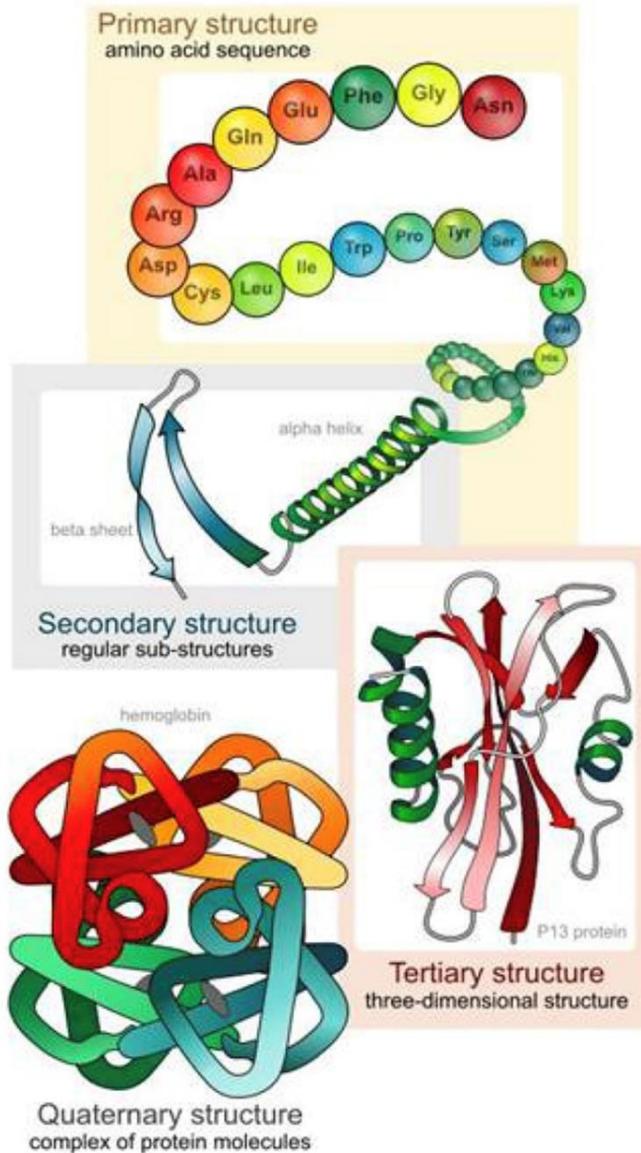
Native protein structure:  
1 conformation

Tenendo conto dei gradi di libertà disponibili, una proteina di 100 aminoacidi può assumere  $5 \cdot 10^{47}$  conformazioni. Se dovesse campionarle tutte per trovare la sua conformazione nativa, anche alla velocità di una ogni attosecondo, impiegherebbe  $10^{22}$  anni per avvolgersi.

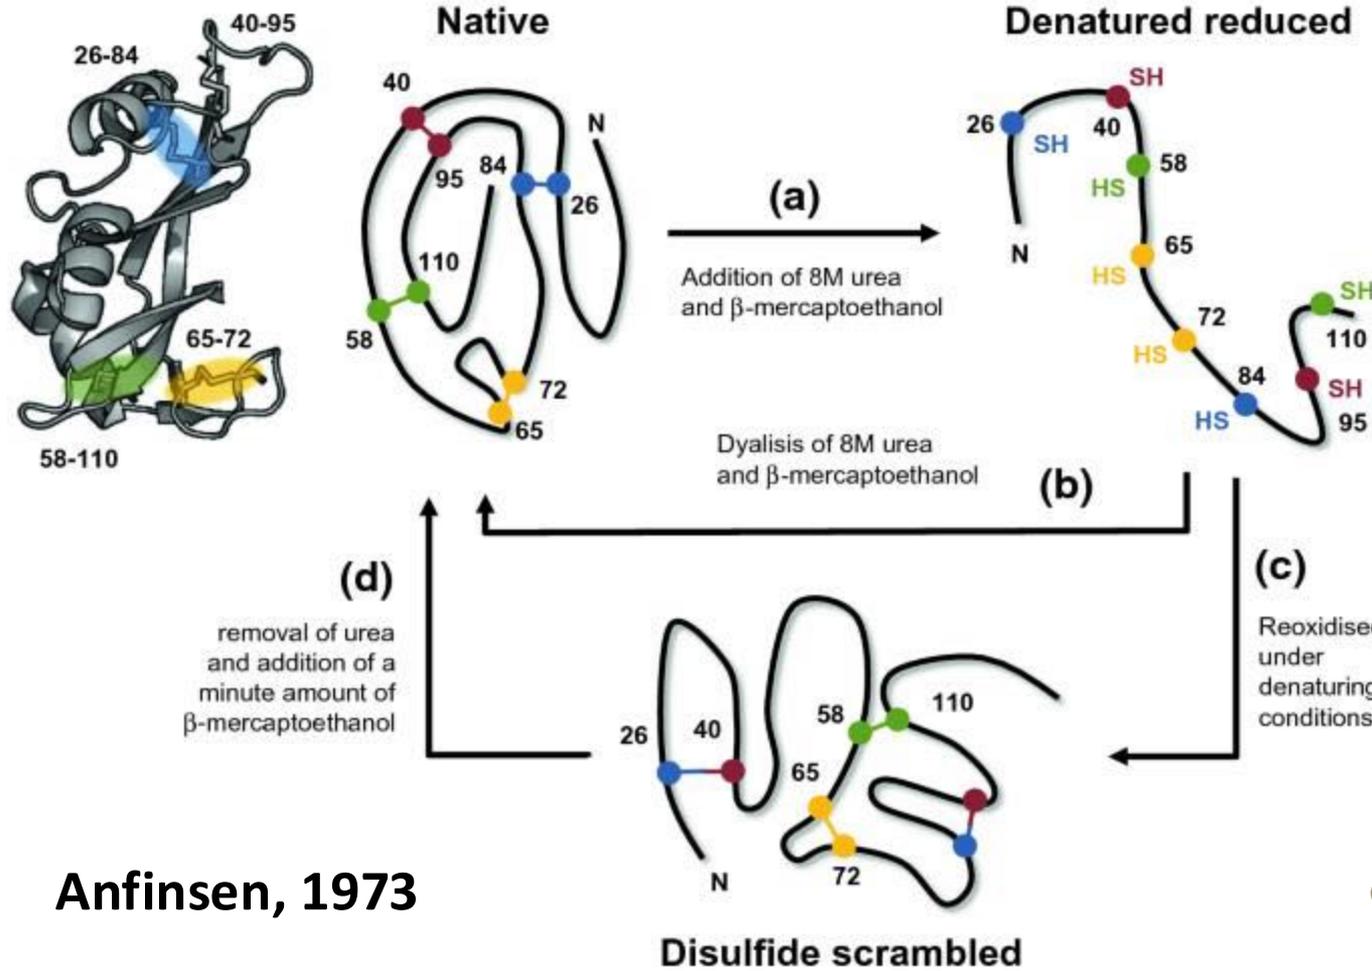
Per contro, una cellula di *E. coli* impiega alcune decine di minuti per replicarsi.



# The dynamics of protein folding and misfolding

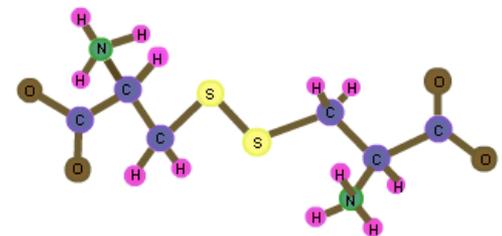


# La sequenza determina la struttura



- a) +8M urea + $\beta$ ME
- b) -urea - $\beta$ ME
- c) +8M urea - $\beta$ ME
- d) -urea + $\beta$ ME (in minima quantità)

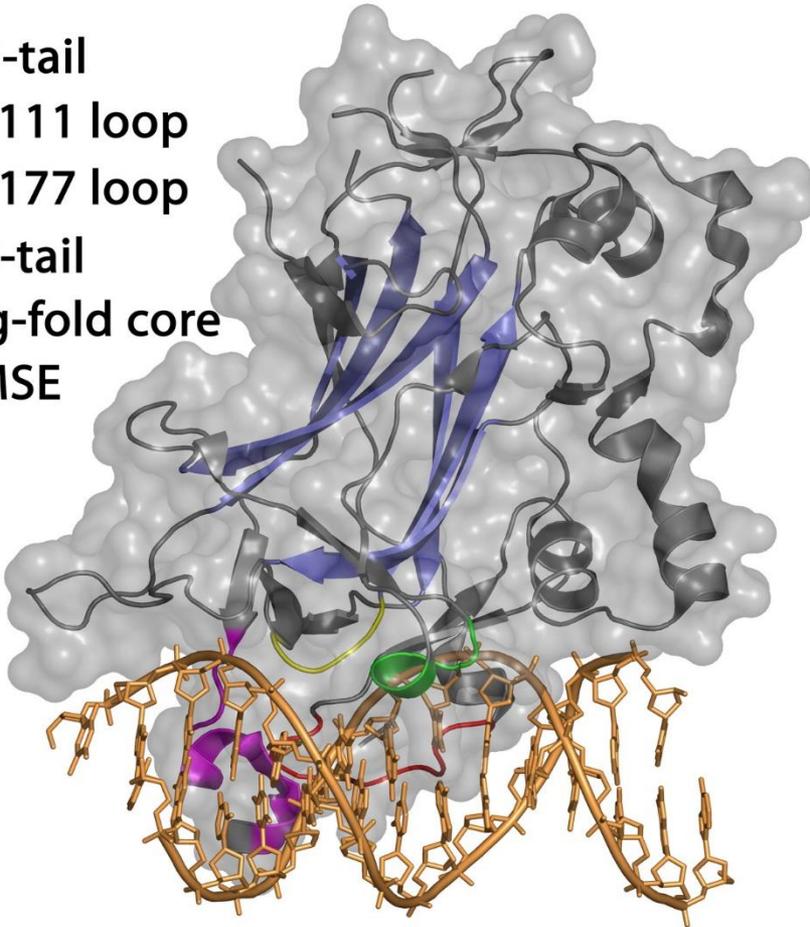
Anfinsen, 1973



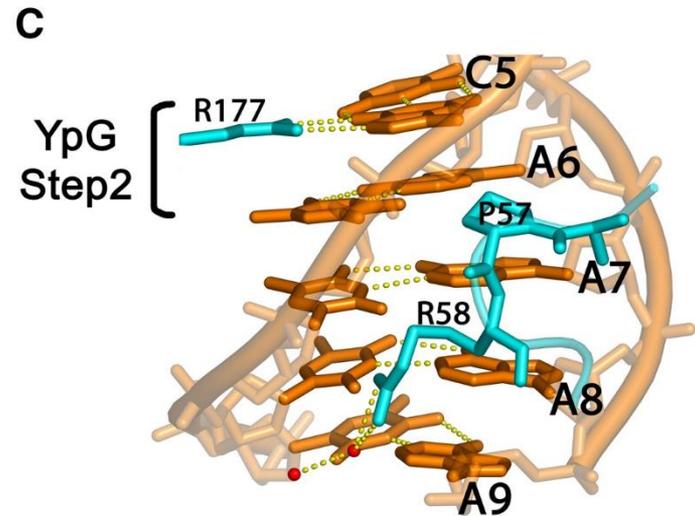
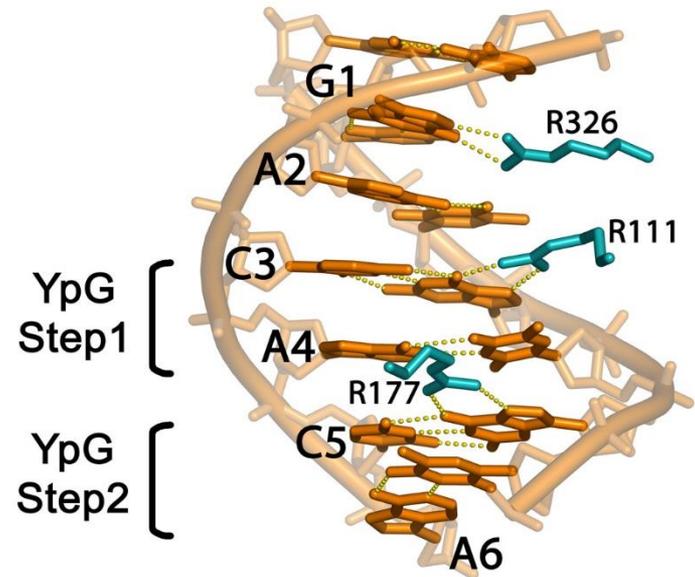
# La struttura determina la funzione

Da un secolo, oltre.

- N-tail
- R111 loop
- R177 loop
- C-tail
- Ig-fold core
- MSE



-3 -2 -1 1 2 3 4 5 6 7 8 9 10 11  
 5' TGCGACACAAAAC 3'  
 3' CGCTGTGTTTTTGA 5'  
 -2' -1' 1' 2' 3' 4' 5' 6' 7' 8' 9' 10' 11' 12'



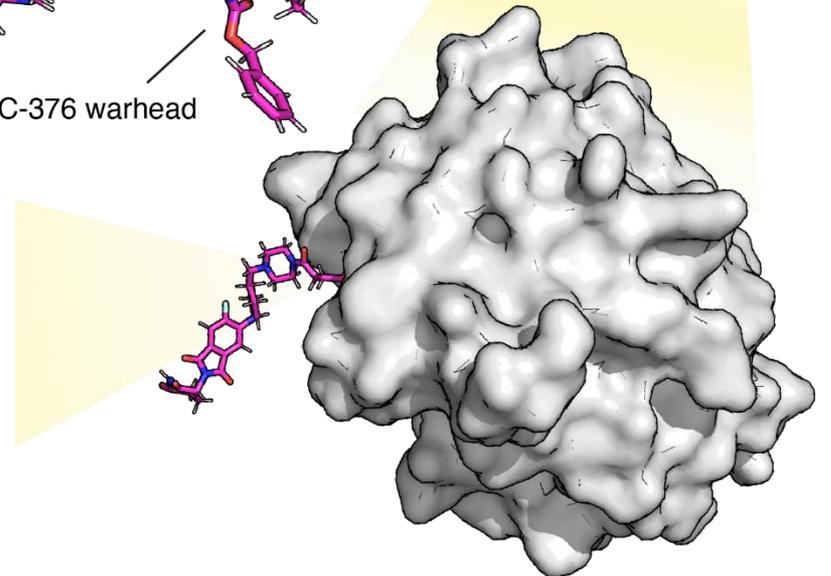
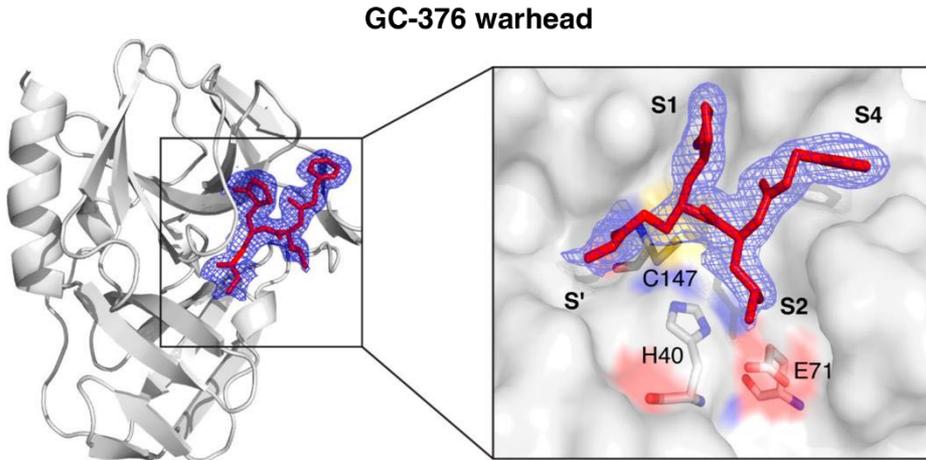
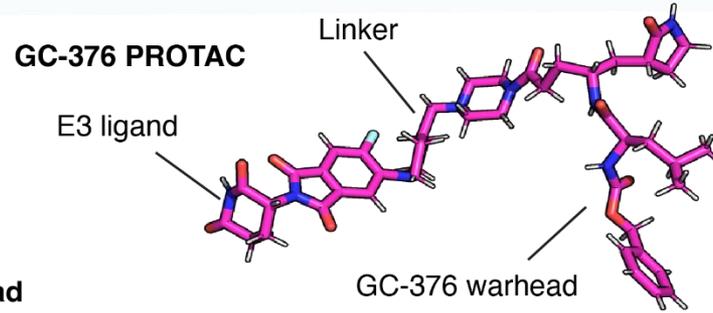
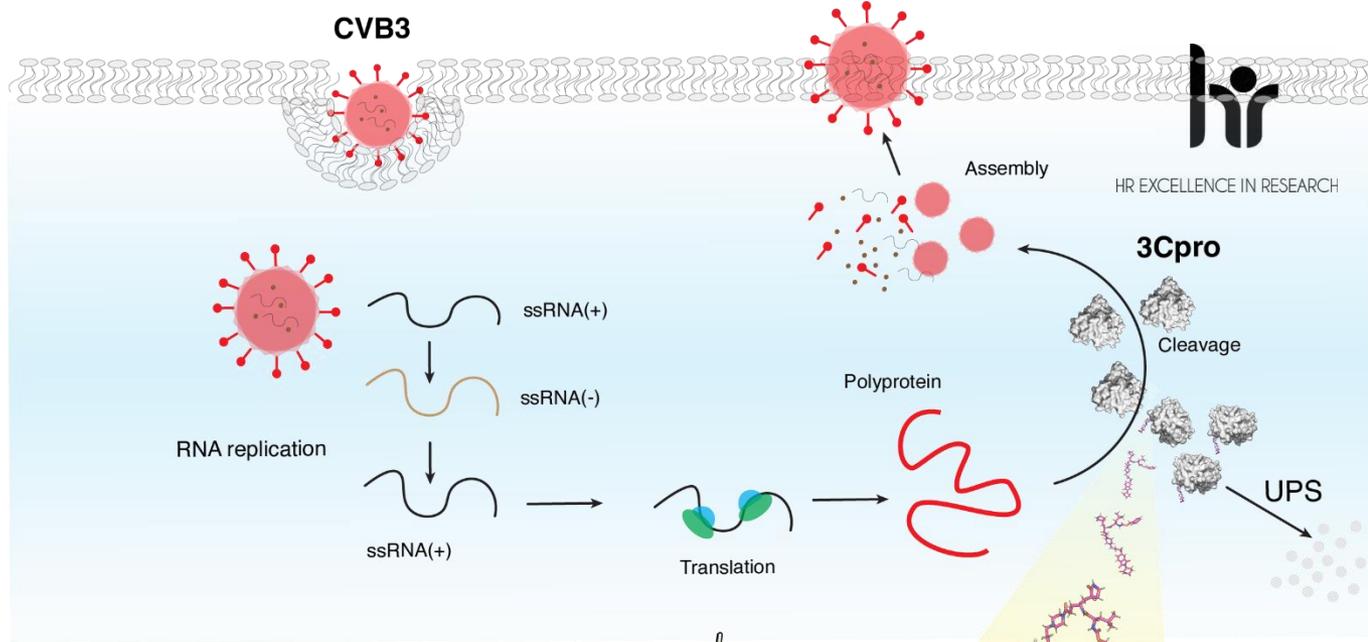


UNIVERSITÀ  
DEGLI STUDI  
FIRENZE

Da un secolo, oltre.

# Conoscere la struttura è utile

Image courtesy of Andrea Orsetti



De Santis et al., *Biomolecules*, 2024



## Riassumendo ...

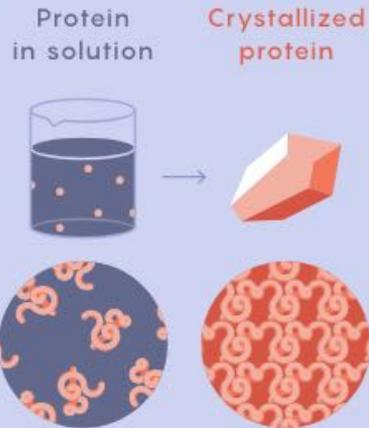
- Per capire pienamente il ruolo biologico di una proteina bisogna conoscerne sia la sequenza sia la struttura 3D
  - Ogni proteina (globulare) raggiunge una conformazione 3D stabile in un tempo relativamente breve, attraverso un meccanismo di progressiva stabilizzazione energetica
  - La conformazione 3D stabile dipende solo dalla sequenza aminoacidica (dimostrato nel 1973)
- ✓ Pertanto, nota la sequenza aminoacidica p.es. tramite sequenziamento genico, dovrebbe essere possibile predirne la struttura 3D sulla base di calcoli di energia e imparare qualcosa sulla funzione della proteina

# Determinare sperimentalmente la struttura 3D di una proteina richiede tempo e investimenti

## How X-Ray Crystallography Works

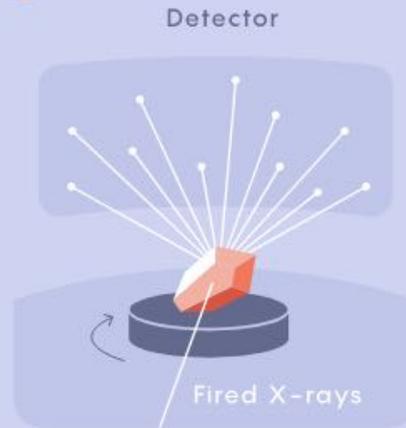
For decades, structural biologists primarily used X-ray crystallography to deduce protein structures. This technique reconstructs the shape of a protein from how its crystallized form scatters X-rays.

1



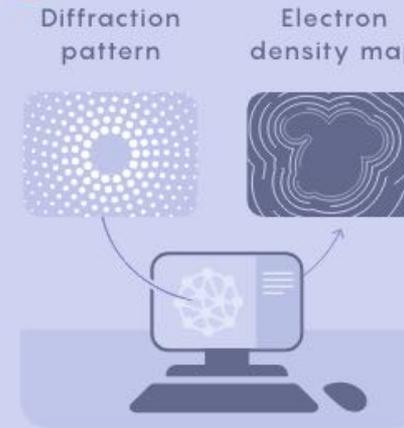
Purified proteins in solution are grown into a crystal, locking the structures into a fixed pattern. Because not all proteins crystallize easily, this step can take years of trial and error.

2



The protein crystal is bombarded with X-rays from many angles. The X-rays bounce off the atoms' electrons and scatter in different directions. A detector determines the "diffraction pattern" of scattering.

3



A computer processes the diffraction patterns to build an electron density map that shows where electrons congregate in the crystal.

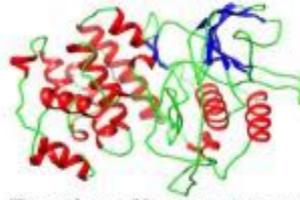
4



The electron density map is used to build a model of the protein. Where electrons congregate, an atom is likely to be present.

MAARLCCQLDPARDVLCRLPVGAE  
SRGRPFSGSLGTLSSPSPSAVPTDHG  
AHLRLRGLPVCFAFSSAGPCALRFTS

Target sequence: Unknown structure



Template: Known structure

BLASTp-PDB

Target-template alignment and  
alignment correction



Backbone generation

Loop modeling

Side-chain modeling

Model optimization

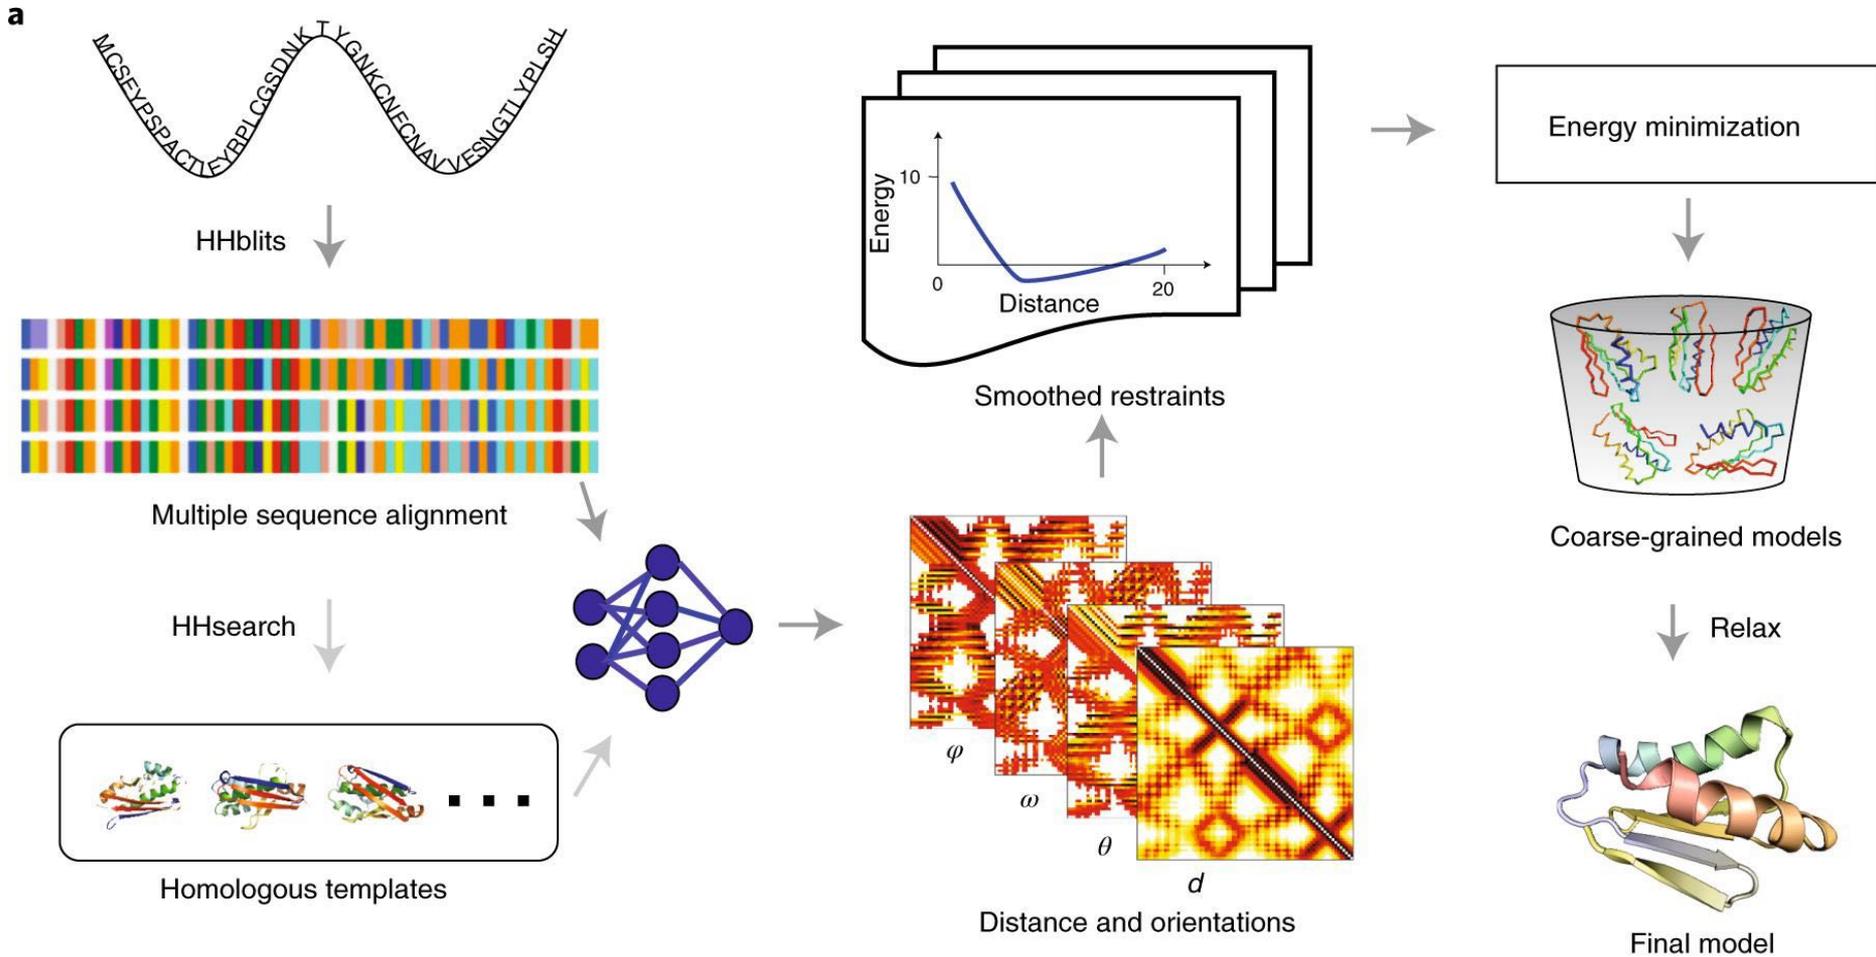
Model validation



- Predire la struttura 3D di una proteina sulla base del calcolo dell'energia delle diverse conformazioni è troppo lungo e costoso
- Si è fatto quindi ricorso a metodi alternativi, quali il **modeling per omologia**, basato sul riconoscere somiglianze fra la mia proteina d'interesse e una già caratterizzata

# Il programma trRosetta di David Baker & Co.

Da un secolo, oltre.





# Una competizione internazionale per la predizione strutturale delle proteine

Critical assessment of structure prediction (CASP) is a biennial community experiment to advance methods of computing three-dimensional protein structure from amino acid sequence

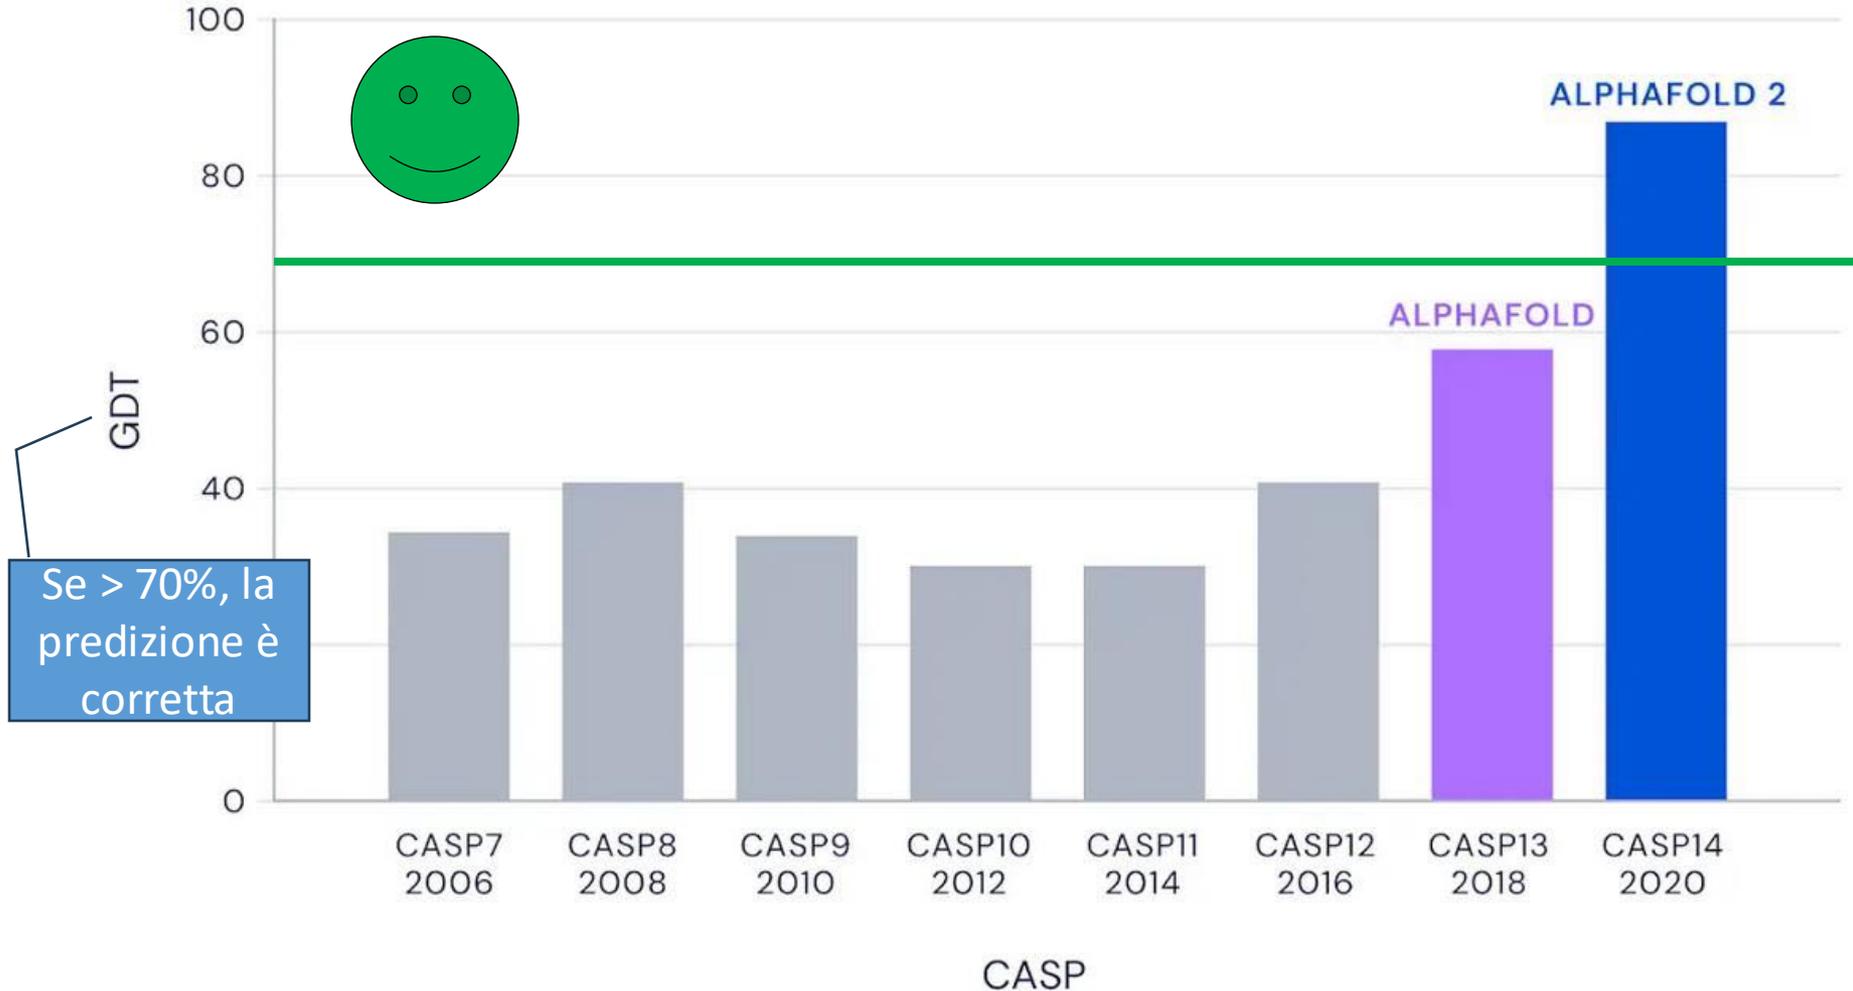
Gli organizzatori di CASP raccolgono decine di nuove strutture 3D di proteine determinate da ricercatori in tutto il mondo e ne sottopongono la sequenza aminoacidica ai partecipanti alla competizione **prima** che le strutture sperimentali siano rese pubbliche

Ogni due anni si effettua un confronto sistematico fra predizioni e strutture sperimentali

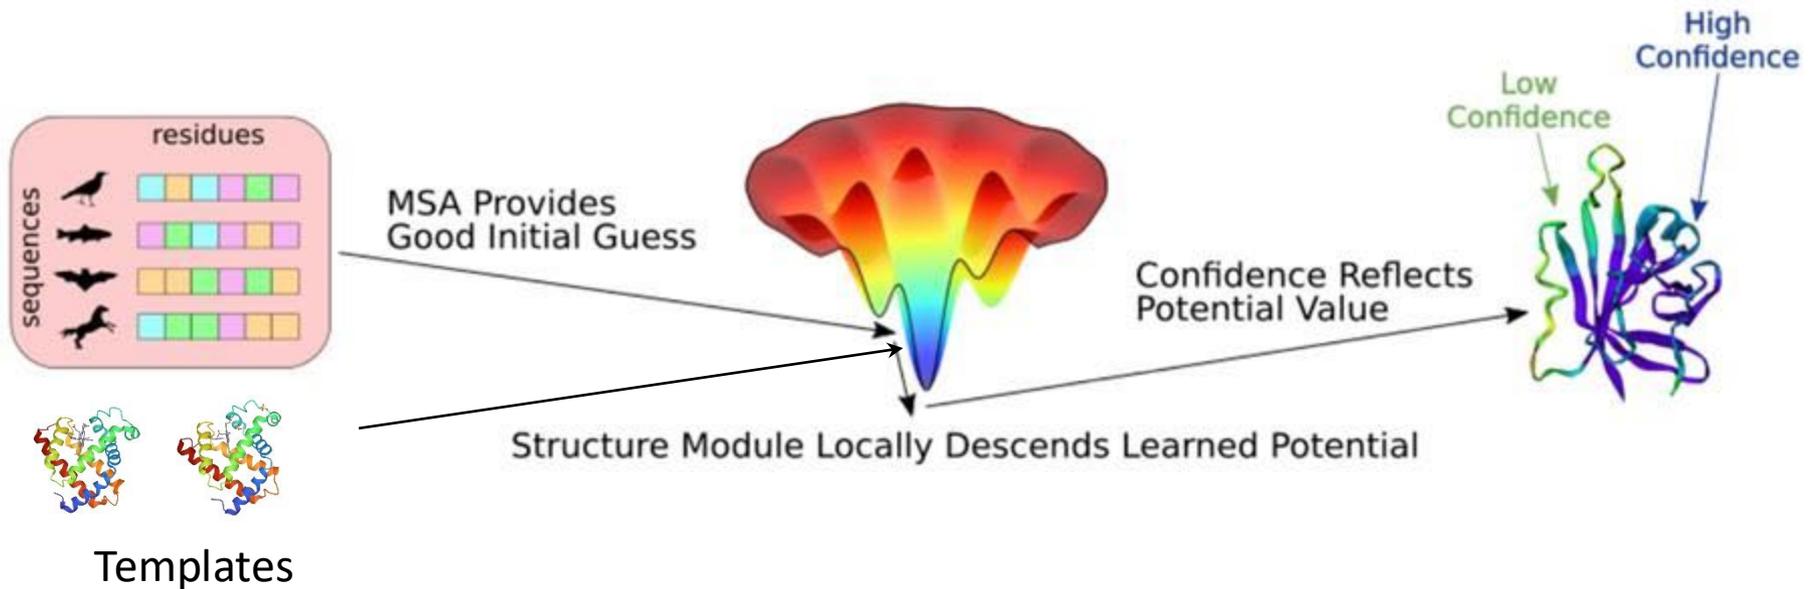
Prima edizione nel 1994, tuttora attivo

# Nel 2020 AlphaFold 2 vince

**Prestazione media** su tutte le predizioni effettuate dal migliore programma in ogni edizione



Dall'analisi statistica dei database di strutture di proteine (Protein Data Bank), AlphaFold ha imparato a capire se l'energia di un possibile avvolgimento della catena polipeptidica è **soddisfacente** oppure **no**



AlphaFold è composto da due parti: **la prima stima una conformazione iniziale**, la seconda ne valuta l'energia e la ottimizza



# A partire dal 2020, le predizioni di AlphaFold sono in media corrette

## One of biology's biggest mysteries 'largely solved' by AI

By Helen Briggs  
BBC science correspondent

NEWS | 30 November 2020

## 'It will change everything': DeepMind's AI makes gigantic leap in solving protein structures

Google's deep-learning program for determining the 3D shapes of proteins stands to transform biology, say scientists.

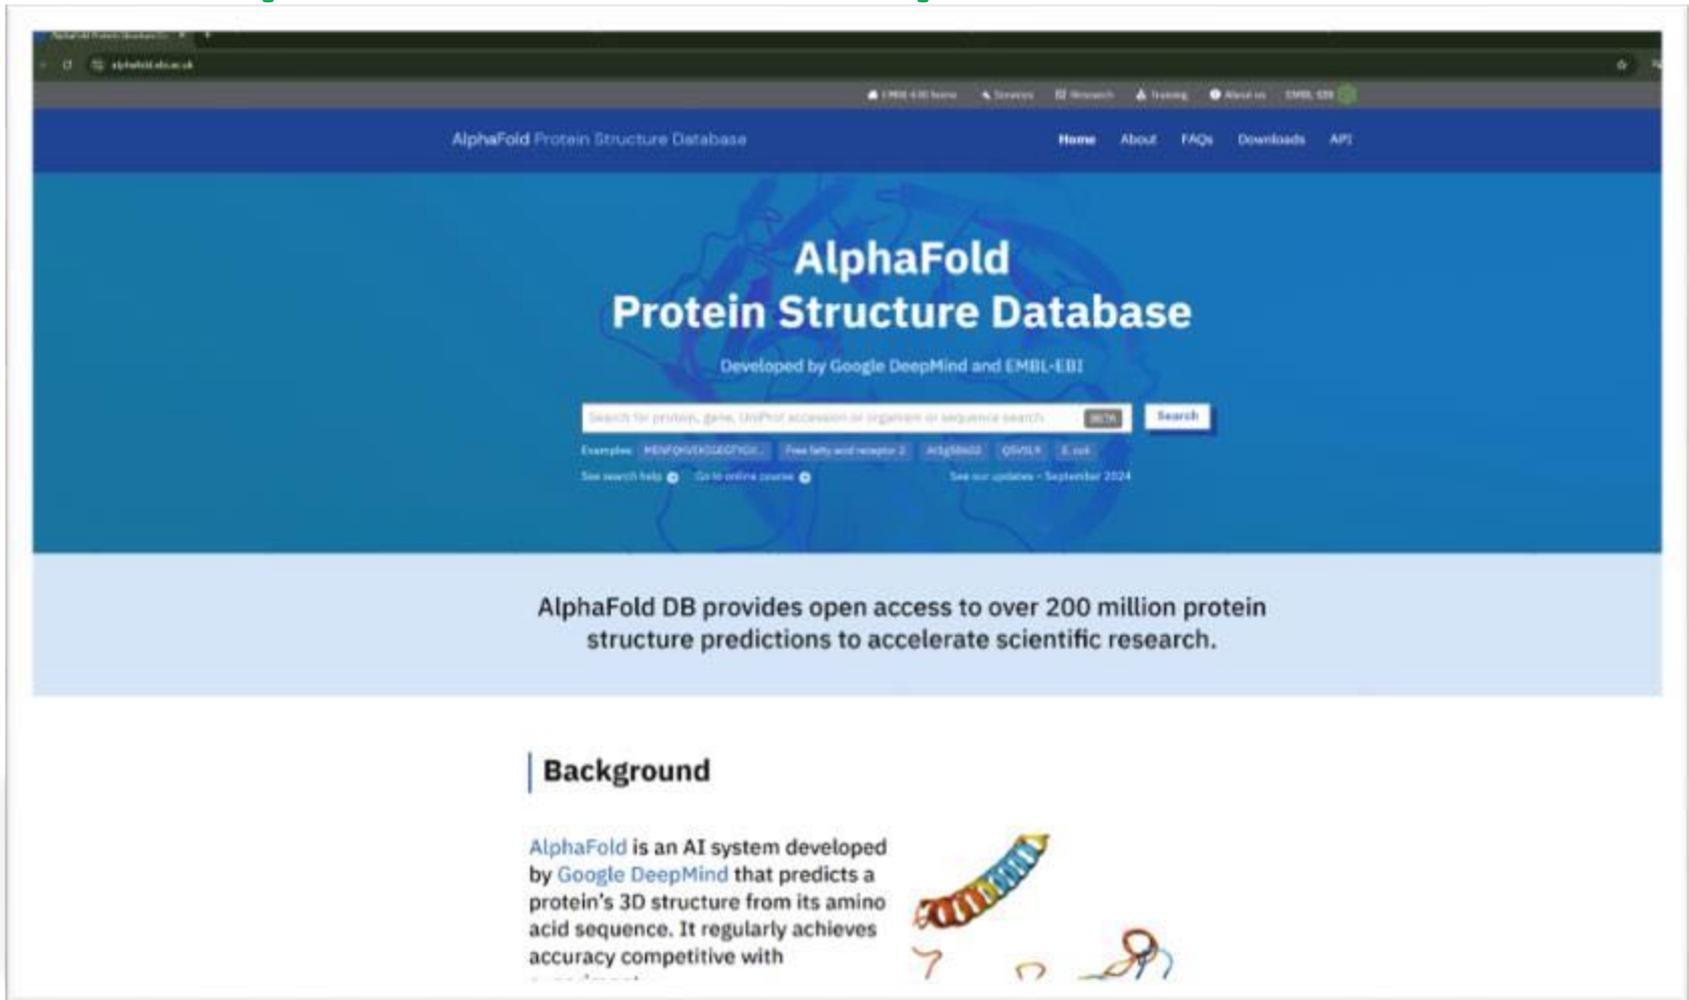
### *A.I. Predicts the Shapes of Molecules to Come*

DeepMind has given 3-D structure to 350,000 proteins, including every one made by humans, promising a boon for medicine and drug design.

*La sede di  
DeepMind a  
Londra*



# Le predizioni di AlphaFold sono pubblicamente disponibili



The screenshot shows the homepage of the AlphaFold Protein Structure Database. The page features a blue header with navigation links: Home, About, FAQs, Downloads, and API. The main content area has a dark blue background with the text "AlphaFold Protein Structure Database" and "Developed by Google DeepMind and EMBL-EBI". Below this is a search bar with a "Search" button and a "beta" label. There are also links for "See search help" and "Go to online course". A light blue banner below the search bar states: "AlphaFold DB provides open access to over 200 million protein structure predictions to accelerate scientific research." The "Background" section describes AlphaFold as an AI system developed by Google DeepMind that predicts a protein's 3D structure from its amino acid sequence. To the right of the text are three small 3D protein structure models.

Varadi, M et al. AlphaFold Protein Structure Database in 2024: providing structure coverage for over 214 million protein sequences. *Nucleic Acids Research* (2024).



## The 2024 chemistry laureates

David Baker is awarded "*for computational protein design*" and Demis Hassabis and John Jumper "*for protein structure prediction*".



David Baker  
Born: 1962, USA



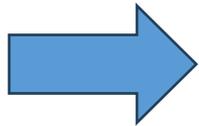
Demis Hassabis  
Born: 1976, UK



John Jumper  
Born: 1985, USA

## In parallelo...

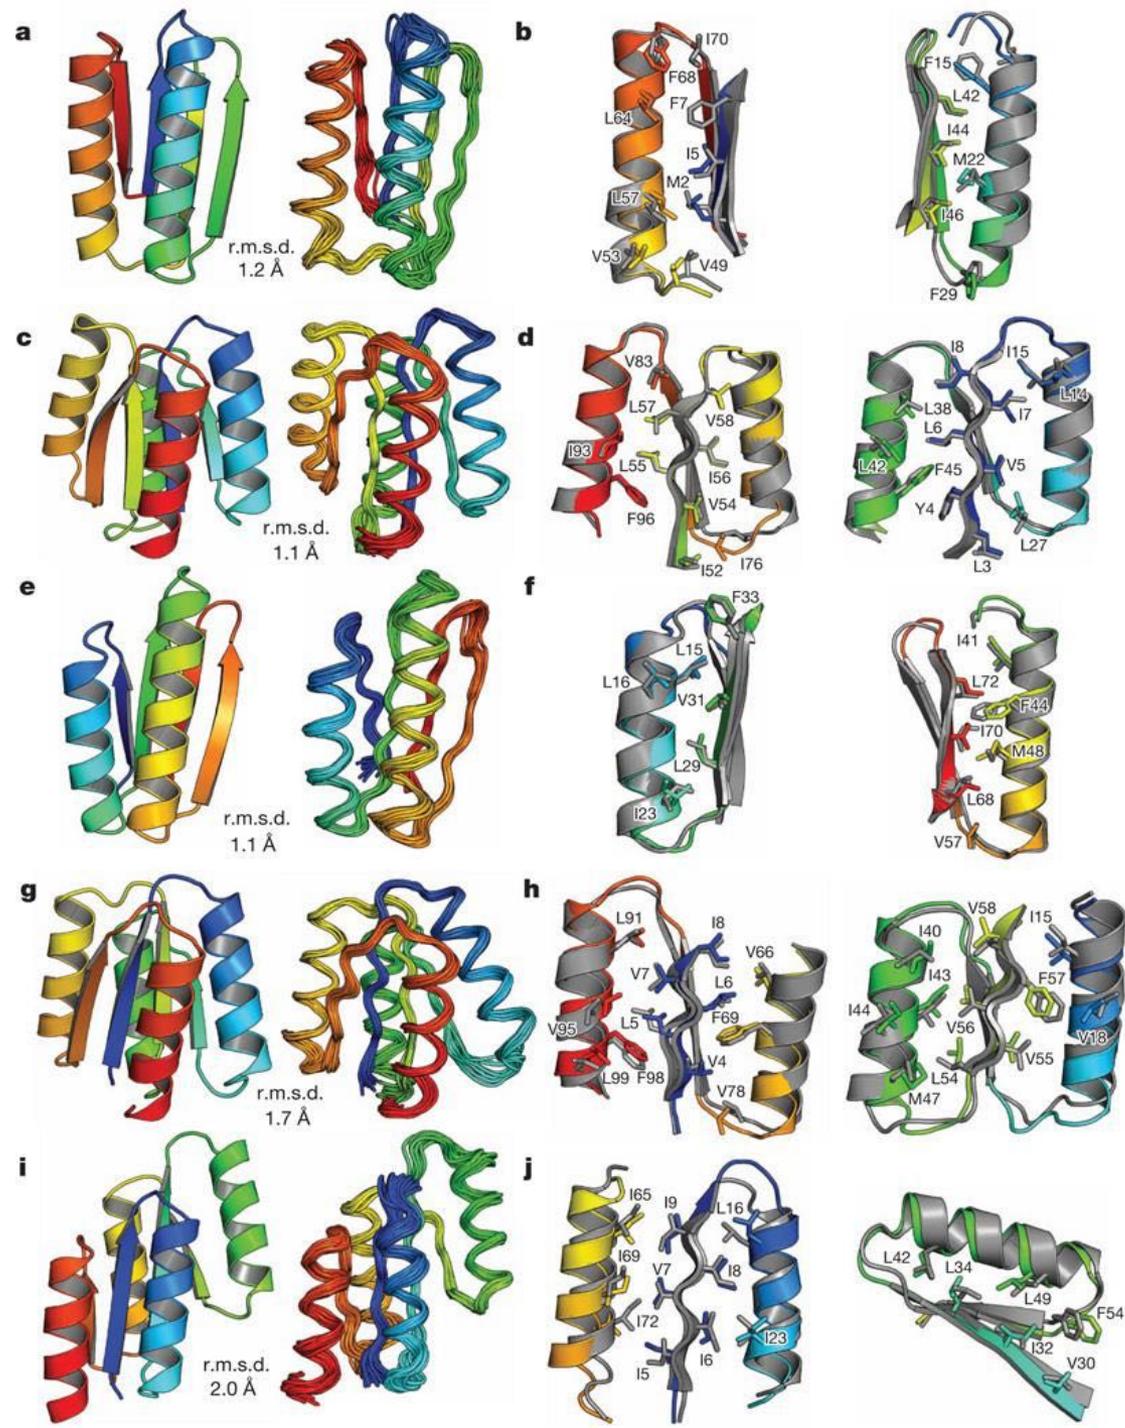
David Baker oltre ad aver lavorato intensamente sul problema della predizione strutturale (il suo algoritmo Rosetta è stato fra i vincitori più frequenti prima di AlphaFold), ha cercato di sfruttare quello che imparava da queste applicazioni per poter disegnare nuove proteine, mai esplorate dalla selezione naturale, che avessero forme e/o funzioni scelte *a priori*



## PROTEIN DESIGN

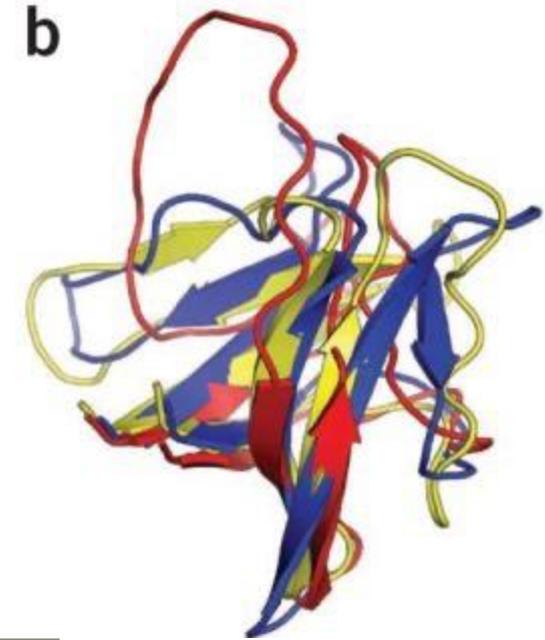
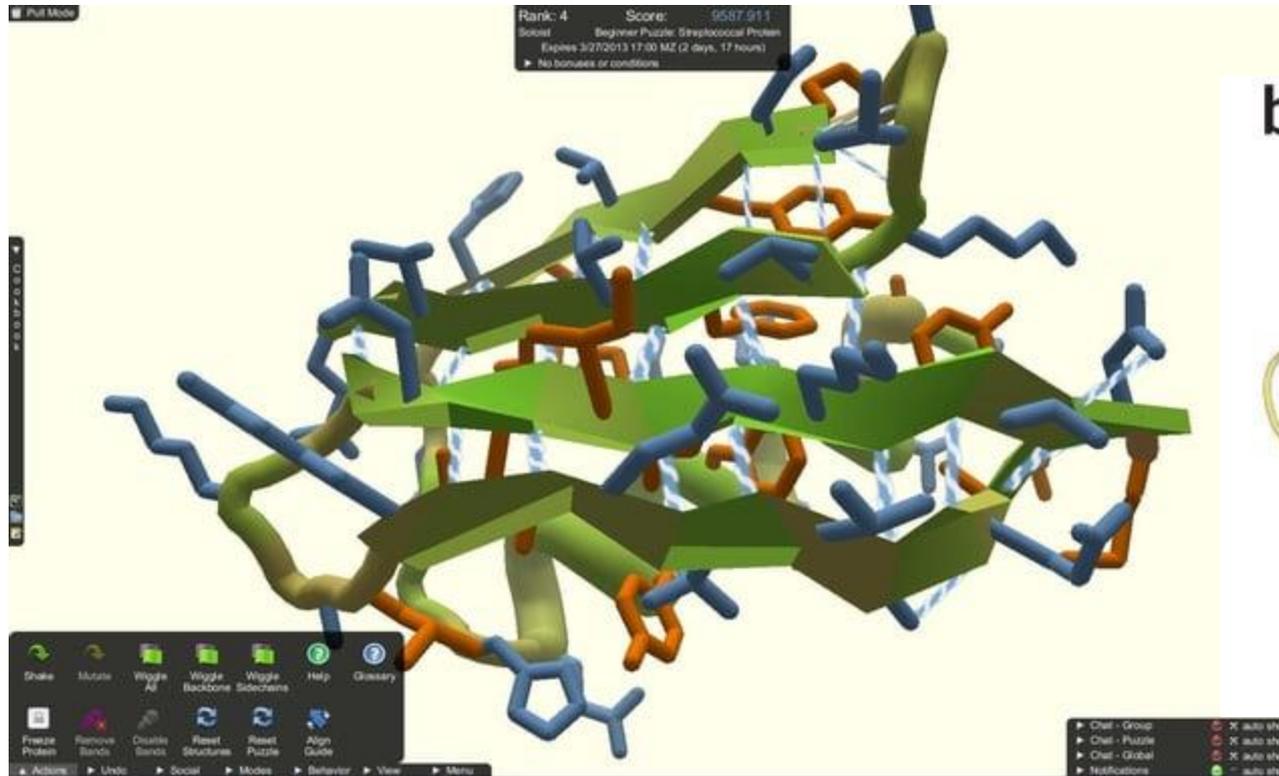
Per esempio, stimando l'energia nel modo che usa AlphaFold (o simile) si può prevedere se la nuova proteina disegnata sarà **stabile** quando prodotta realmente e quindi **se sarà possibile usarla in laboratorio**

Proteine disegnate con topologie complesse sono state prodotte e la loro struttura determinata sperimentalmente. Il disegno riesce a definire anche i principali contatti fra catene laterali.



Nature 491:222–227  
(2012)

# Foldit, un gioco online per la predizione strutturale e il protein design



**High-resolution structure of a retroviral protease folded as a monomer**

Nature Struct Mol Biol 2011

Acta Crystallogr D Biol Crystallogr. 2011

**Struttura predetta automaticamente**

**Struttura predetta dai giocatori**

Struttura sperimentale, risolta successivamente



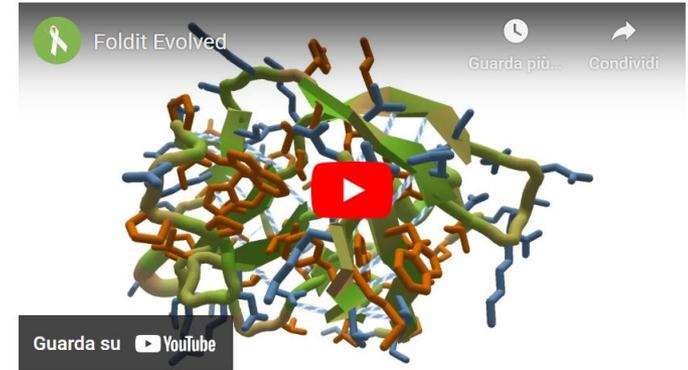
Fra le alter cose, Foldit è usato anche per il disegno di nuovi inibitori/candidati farmaci

<https://fold.it/>

Foldit is a revolutionary crowdsourcing computer game enabling you to contribute to scientific research. Learn the science behind Foldit and how your playing can help.

About Foldit

Start Playing



## Latest News

**November 11, 2024**

"How AI Cracked the Protein Folding Code and Won a Nobel Prize" video mentions Foldit

**October 10, 2024**

Congrats to the 3 Nobel Prize in Chemistry winners, and their connections to Foldit!

**September 10, 2024**

Foldit does well at CACHE!

**August 21, 2024**

New Release (2024-08-21)

**August 12, 2024**

Developer Preview Release (2024-08-12)

**July 26, 2024**

New Release (2024-07-26)

**July 26, 2024**

Develop Preview Release (2024-07-25)

**July 24, 2024**

New Release (2024-07-23)

**July 20, 2024**

Office Hour 7/26

**July 17, 2024**

Developer Preview Release (2024-07-17)

[→ See all news](#)

## See Who's Leading

### Soloists Groups

	1. LociOiling <b>Lv 1</b>	6,132
	2. gmn <b>Lv 1</b>	4,620
	3. Bruno Kestemont <b>Lv 1</b>	4,439
	4. Galaxie <b>Lv 1</b>	4,071
	5. christioanchauvin <b>Lv 1</b>	3,911

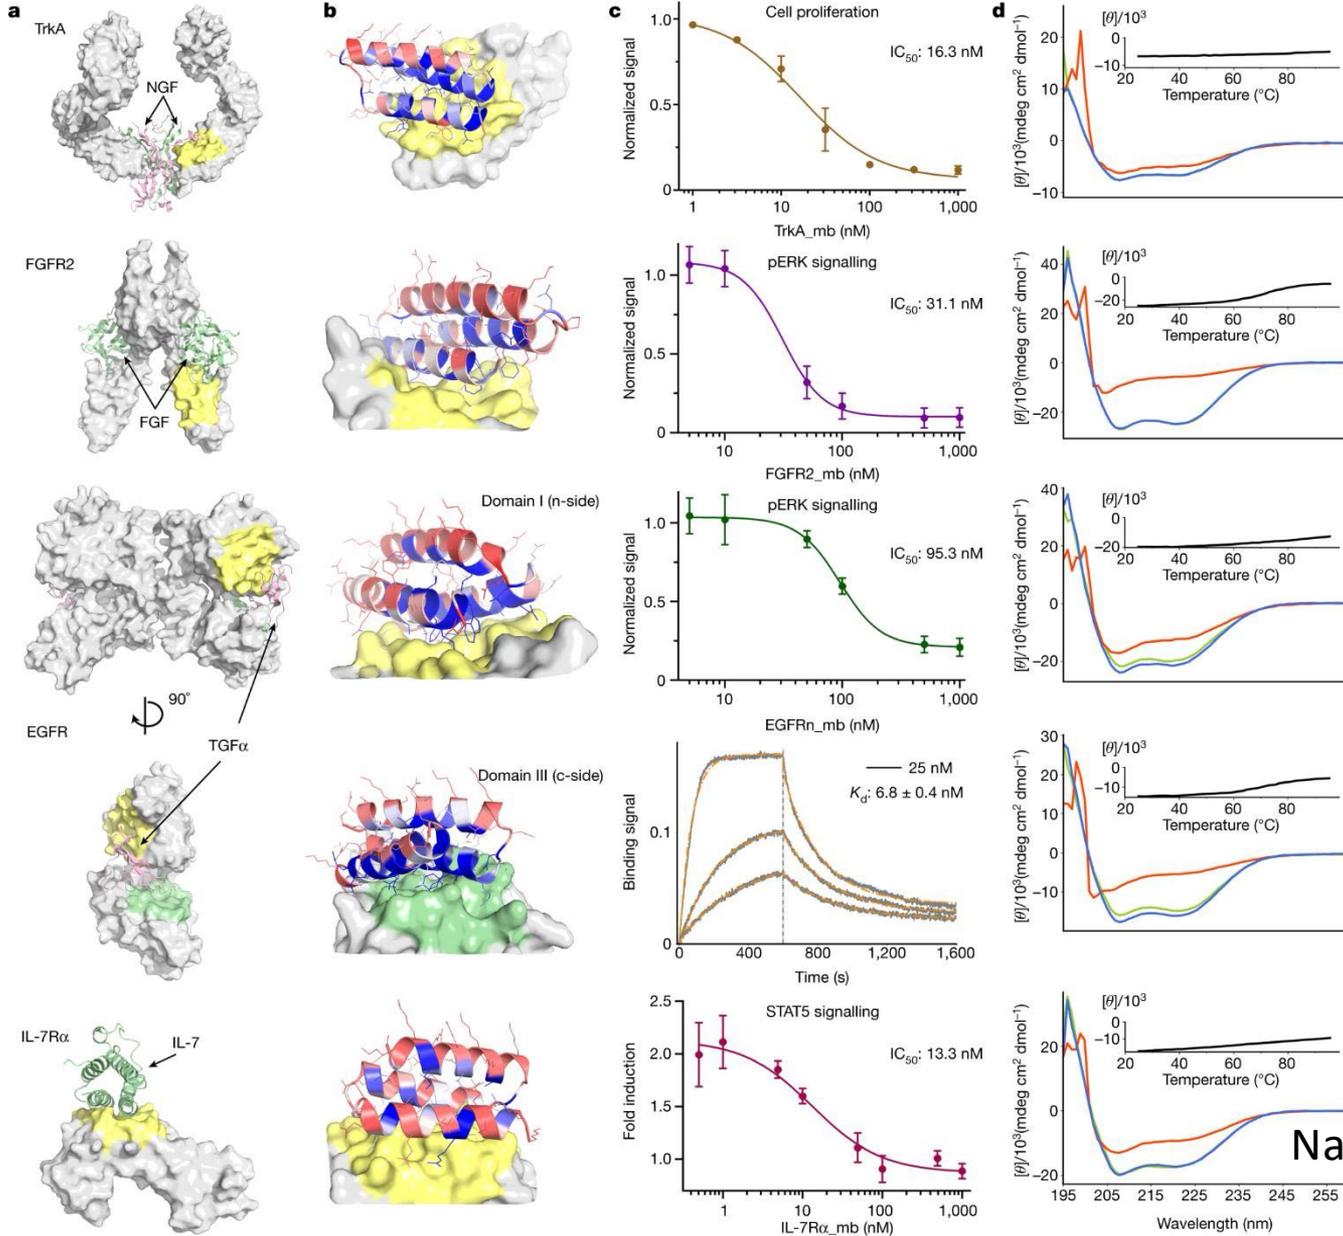
[→ View all leaderboards](#)

### Top New Players

	1. lancetime <b>Lv 1</b>	27
	2. EmelendezTAMUCT <b>Lv 1</b>	22
	3. Tenlocket <b>Lv 1</b>	9

Da un secolo, oltre.

## Dati su colture cellulari



Proteine diseguate  
per interagire con  
specifici recettori  
(minibinders, mb)  
inducono effetti  
misurabili *in vivo*

Nature 605:551–560 (2022)

## In conclusione

- La struttura 3D di proteine semplici è ora prevedibile computazionalmente con ottima affidabilità – **il paradosso di Levinthal è risolto**
- **Cosa resta da studiare:** interazioni fra macromolecole (proteine, acidi nucleici) e con piccoli ligandi (inibitori, cofattori, ...); proteine multi-dominio e proteine altamente flessibili
- Il disegno di proteine permette di **generare forme e architetture desiderate**, con un buon controllo anche sulle proprietà biologiche (ma la necessità di verifica sperimentale resta!)
- **Cosa resta da studiare:** nuovi catalizzatori enzimatici per processi biochimici mirati (biotecnologie e chimica verde); sistemi reattivi agli stimoli



UNIVERSITÀ  
DEGLI STUDI  
FIRENZE

Da un secolo, oltre.



HR EXCELLENCE IN RESEARCH

**Grazie per l'attenzione!**

We used MetalPDB stats MFSs  
to derive parameters for a  
**non-bonded** MD force field

Macchiagodena M, Pagliai M, Andreini C,  
Rosato A, Procacci P.  
*J. Chem. Inf. Model.* 2019; *ACS Omega* 2020

An atomistic view of structural  
changes in bacterial and human  
YiiP upon zinc(II) binding

D. Sala, A. Giachetti and A. Rosato  
*Biochim. Biophys. Acta - General Subjects* (2019)  
*J. Chem. Inf. Model.* 2021

