

# **Αναδίπλωση πρωτεϊνών : Υπολογιστικές προσεγγίσεις**

# Το πρόβλημα της αναδίπλωσης των πρωτεΐνών

---

Με μοναδικό δεδομένο την πρωτοταγή αλληλουχία μιας πρωτεΐνης πως μπορούμε να προσδιορίσουμε την τρισδιάστατη δομή της ;

Ισοδύναμα : πως η αλληλουχία μιας πρωτεΐνης καθορίζει την τρισδιάστατη δομή της ;

Πριν ασχοληθούμε με το πως η πρωτοταγής δομή μιας πρωτεΐνης καθορίζει την τριτοταγή της δομή, θα πρέπει να γνωρίζουμε ότι η πρωτοταγής δομή όντως αρκεί για να καθορίσει την τριτοταγή δομή.

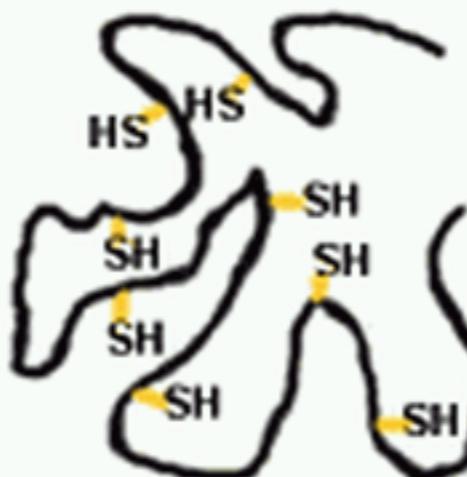
# Τα πειράματα tou Anfinsen

## The Observation:



Native  
(100% active)

1. Reduce  
2. 8 M urea



Denatured  
(inactive)

1. Remove urea  
2. Oxidize



Native  
(>90% active)

## The Control:



Native

1. Reduce  
2. 8 M urea



Denatured

1. Oxidize  
2. Remove urea



"Scrambled"  
(1-2% active)

# Τα πειράματα του Anfinsen

---

Αυτά τα πειράματα έδειξαν ότι (i) η τρισδιάστατη δομή των πρωτεΐνων καθορίζεται από την πρωτοταγή δομή τους, και, (ii) ότι η διαδικασία αναδίπλωσης είναι αυθόρυμη, δηλ. ότι η θερμοδυναμικά σταθερότερη κατάσταση είναι αυτή της αναδιπλωμένης πρωτεΐνης. Το (ii) επίσης υπονοεί ότι η φυσική δομή της πρωτεΐνης αντιστοιχεί στο ολικό (ή σε πλησίον του ολικού) ελάχιστο της ελεύθερης ενέργειας του συστήματος. Άρα το πρόβλημα της αναδίπλωσης των πρωτεΐνων μπορεί να διατυπωθεί και ως εξής : με δεδομένη την πρωτοταγή δομή μιας πρωτεΐνης, ποιά τριτοταγή της δομή αντιστοιχεί στο ολικό ενεργειακό ελάχιστο;

# Το παράδοξο του Levinthal

---

Υποθέστε ότι για κάθε κατάλοιπο υπάρχουν μόνο 10 ενεργειακά αποδεκτοί συνδυασμοί των φ,ψ γωνιών. Τότε, ο ολικός αριθμός πιθανών δομών για μια αλυσίδα 40 αμινοξέων είναι  $10^{40}$ . Ακόμα και εάν μια πρωτεΐνη μπορούσε να περάσει από  $10^{14}$  (100 τρις) δομές ανά δευτερόλεπτο, πάλι θα χρειάζονταν  $\sim 67$  εκατομμύρια φορές την ηλικία του σύμπαντος για να διπλωθεί. Ευτυχώς, τους παίρνει πολύ λιγότερο από αυτό : από χιλιοστά του δευτερολέπτου έως λεπτά.

Διάκριση θερμοδυναμικής-κινητικής της αναδίπλωσης

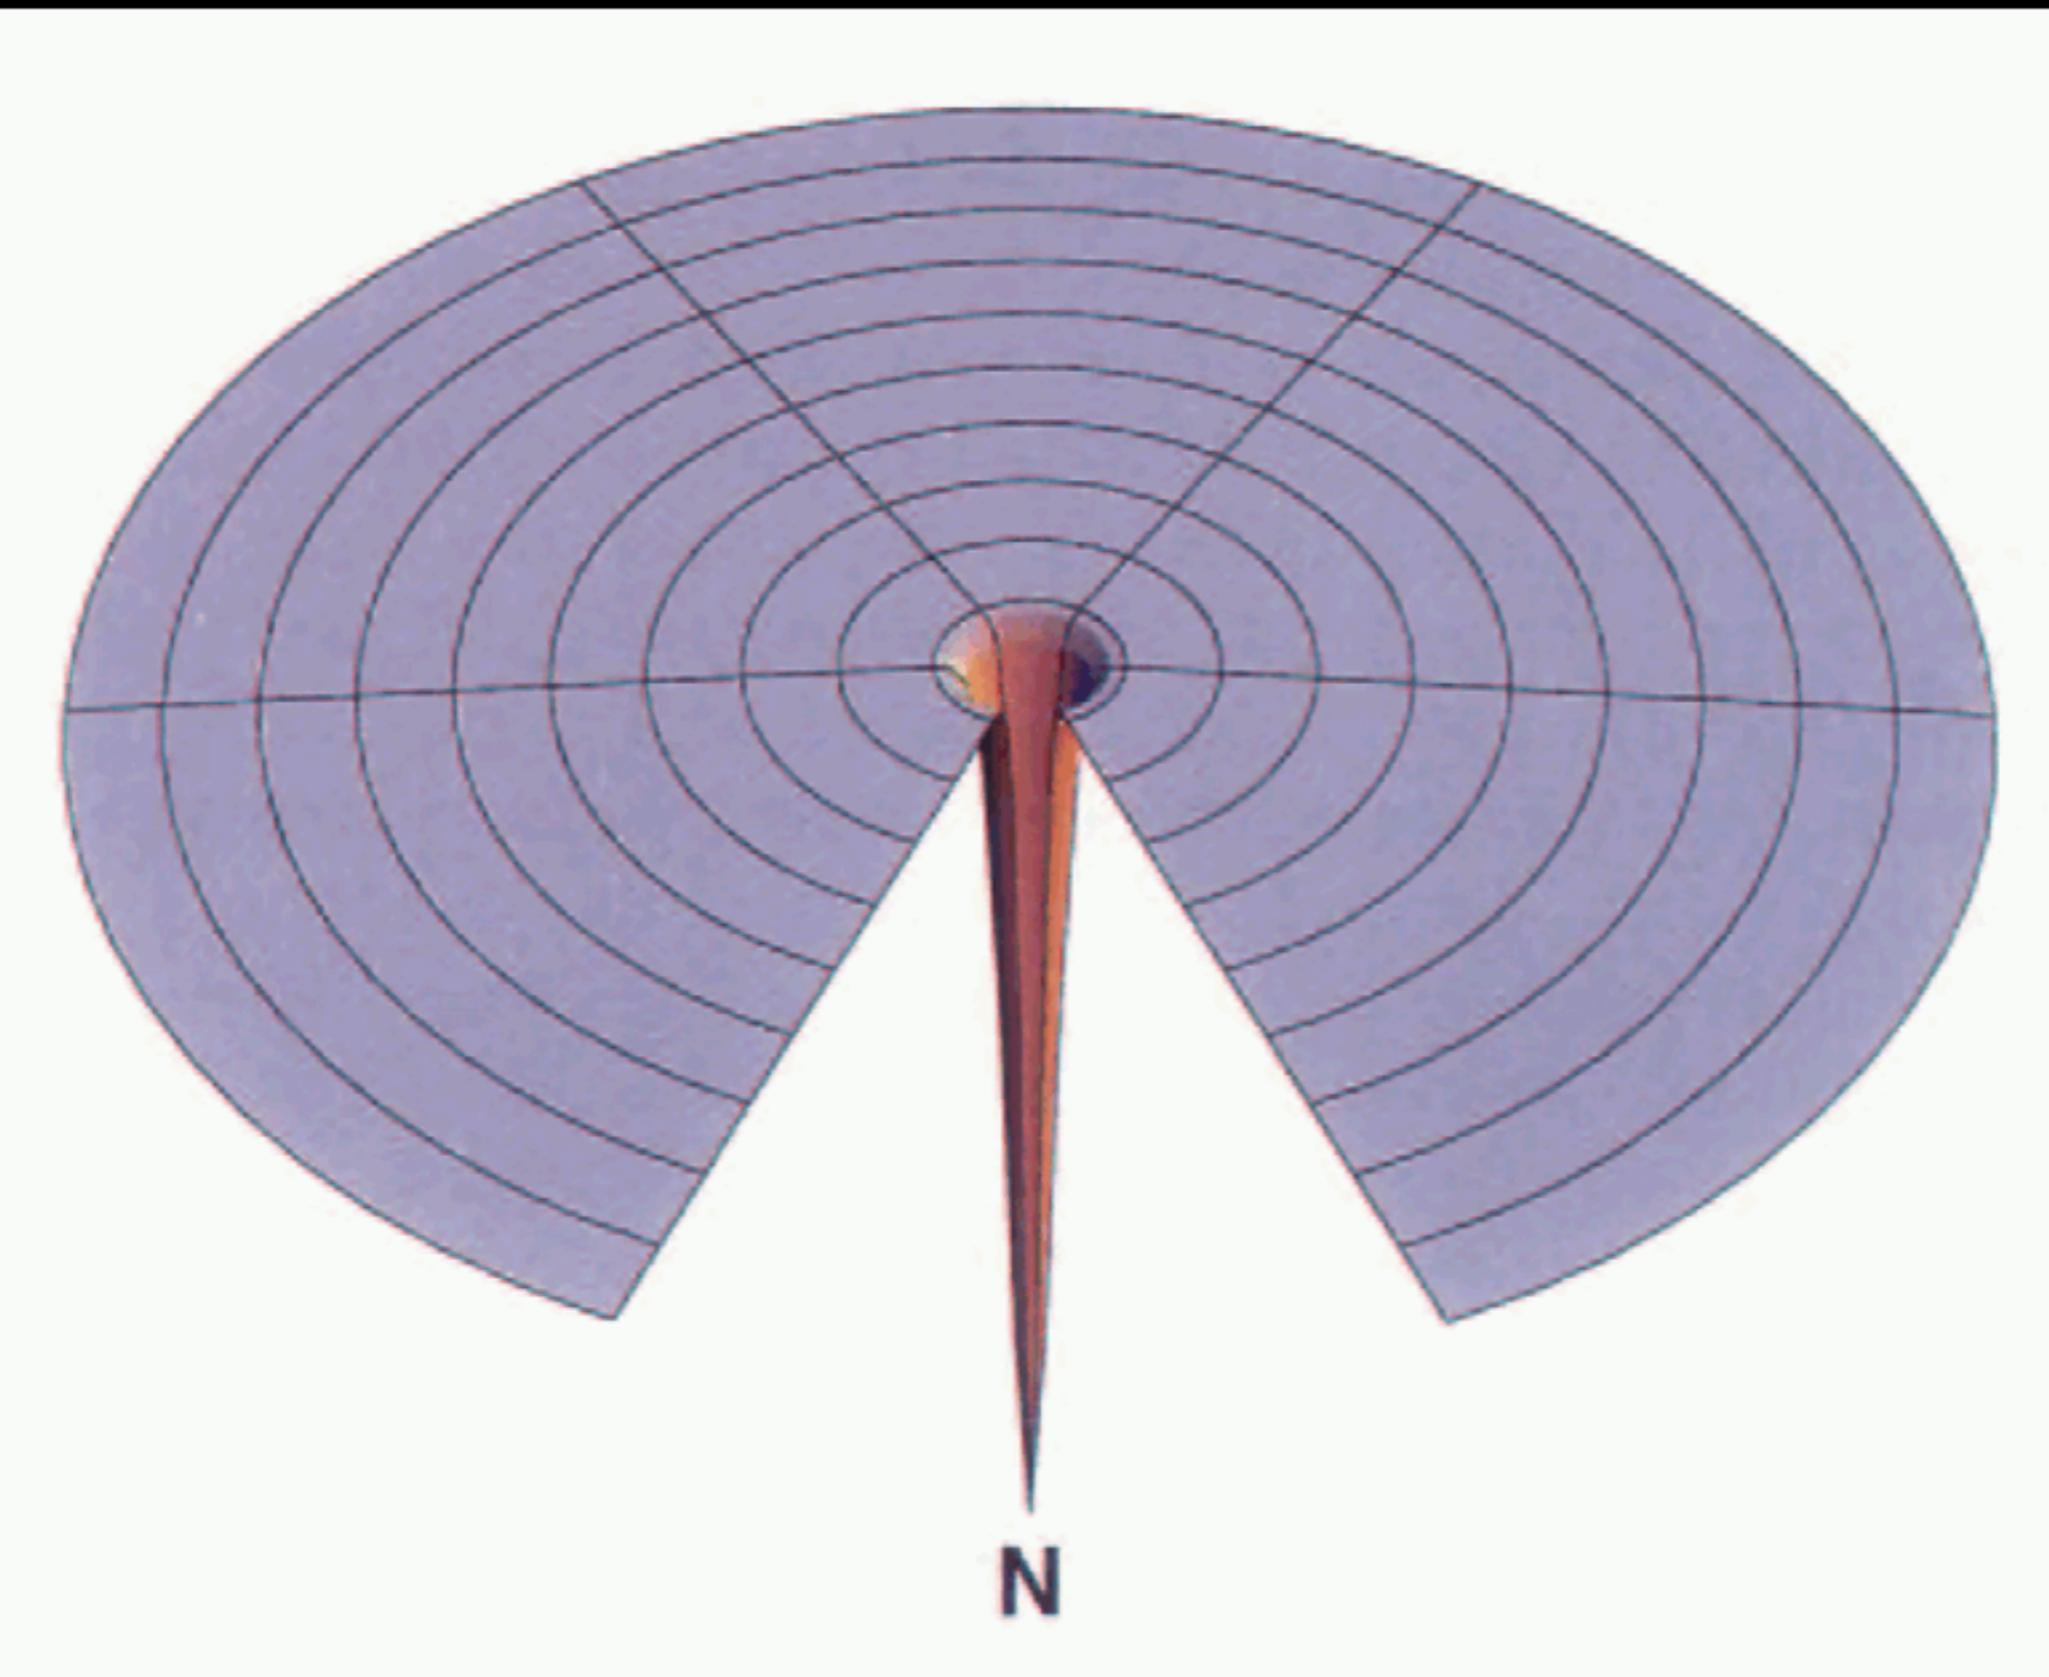
# Το πρόβλημα της αναδίπλωσης των πρωτεΐνων

---

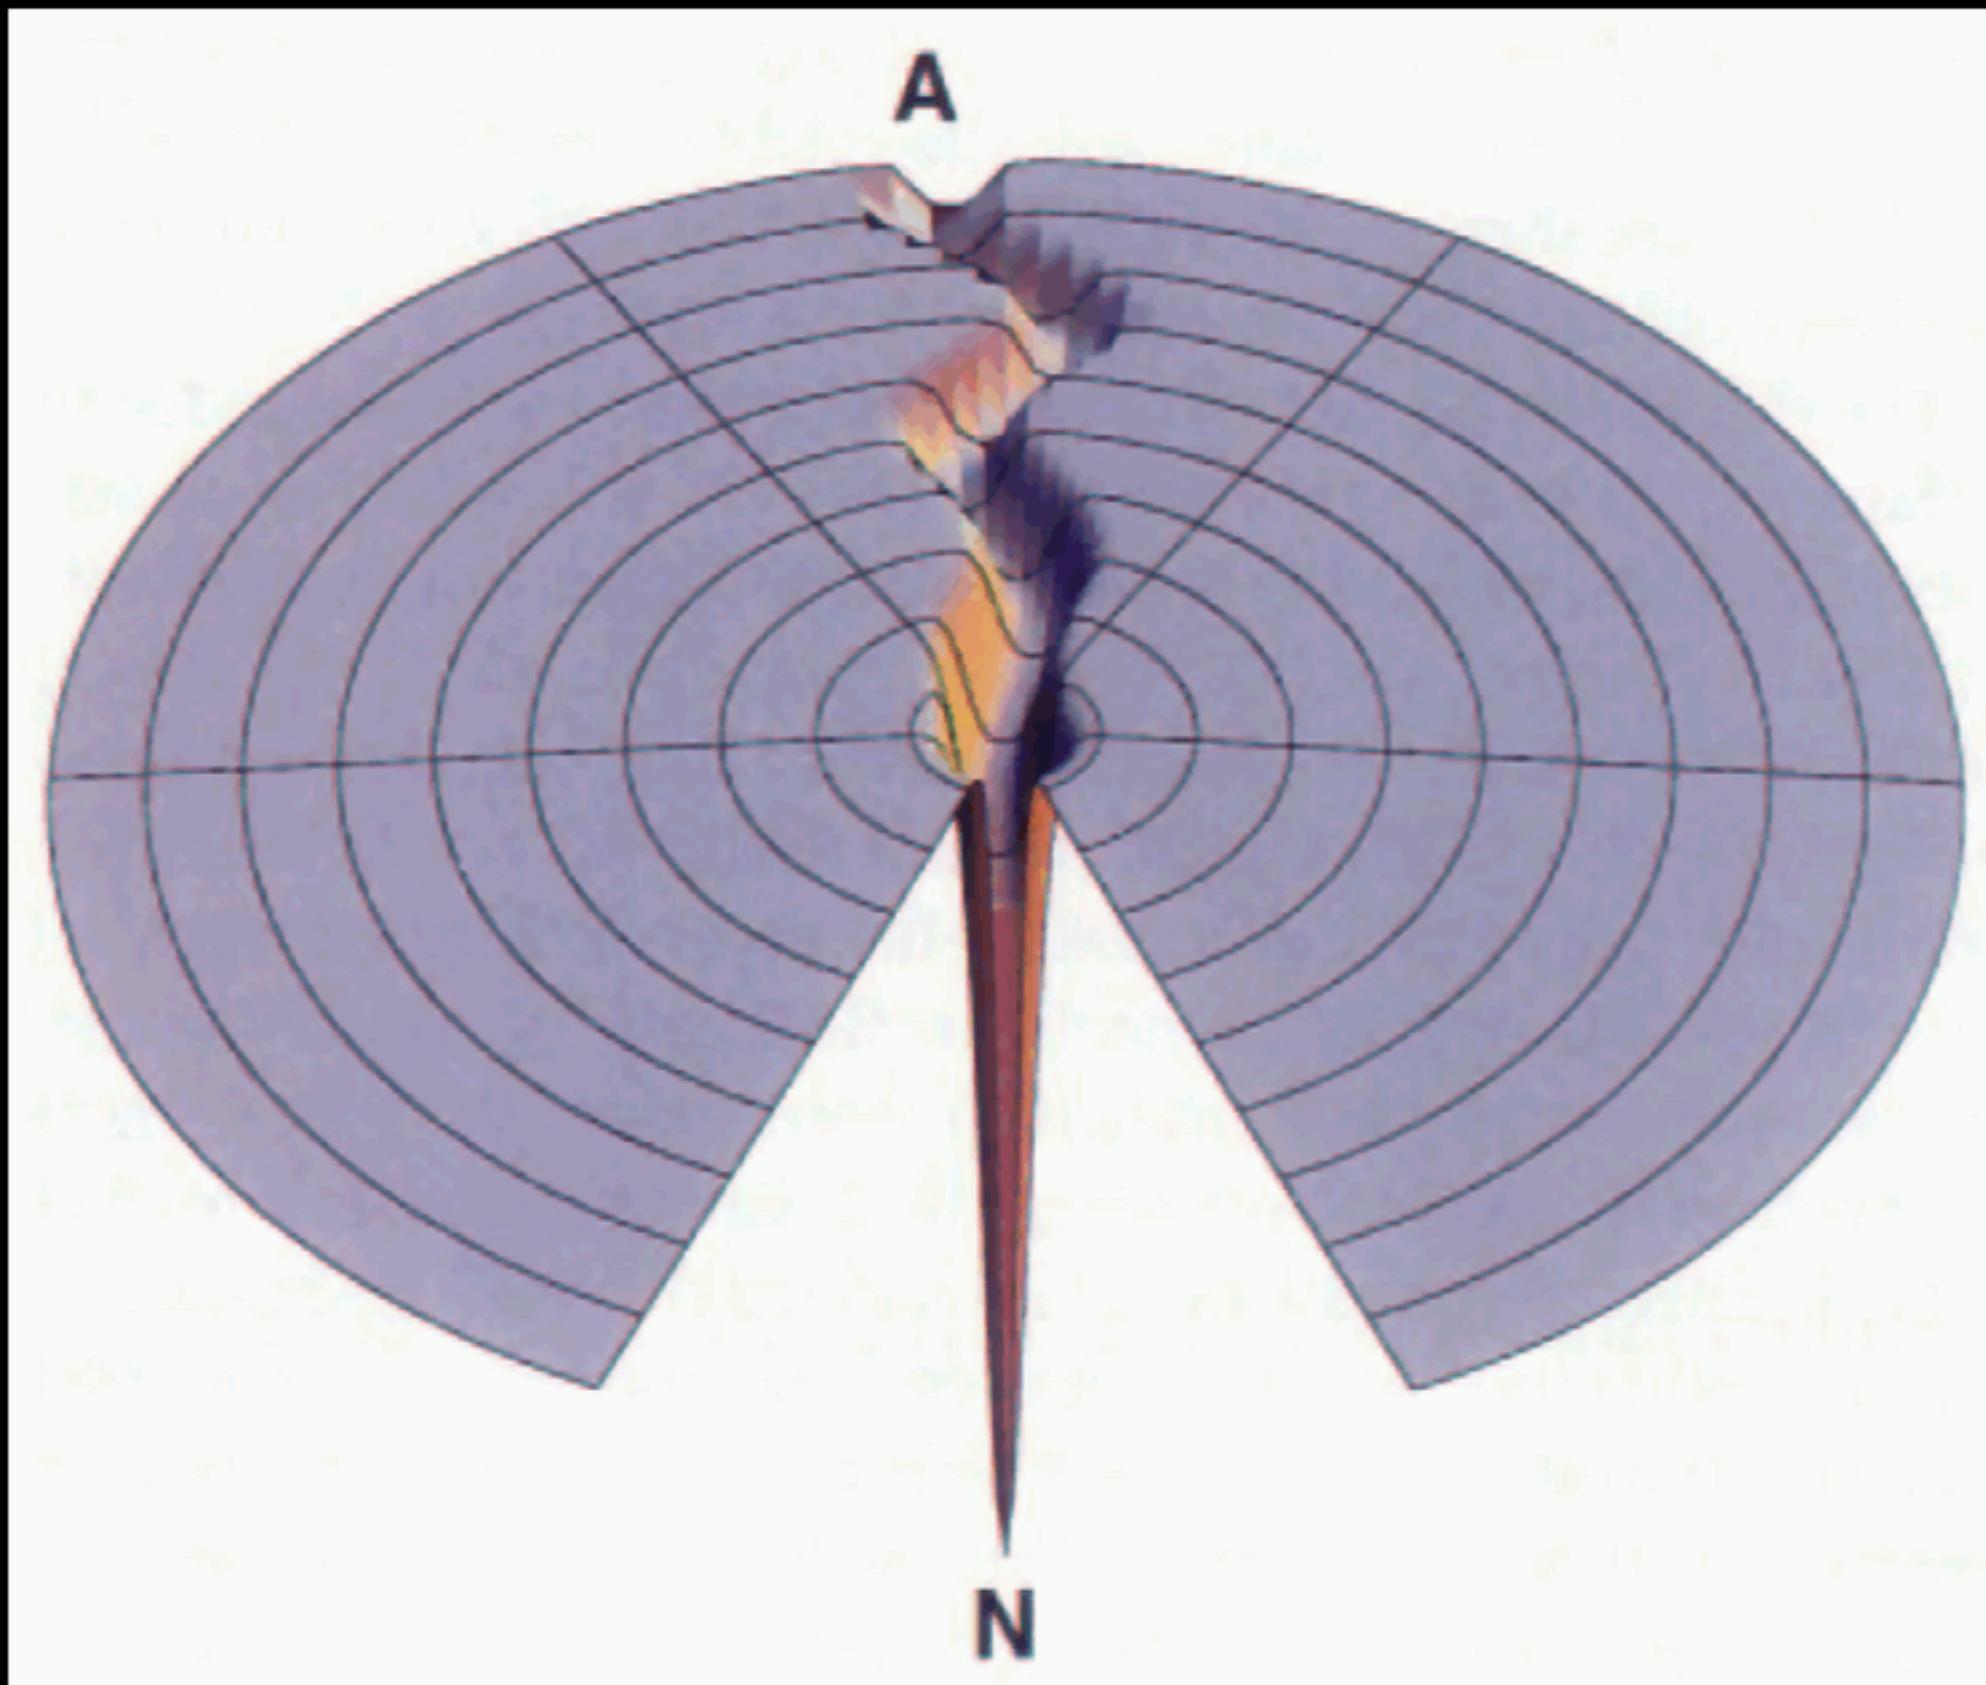
Μετά από 30 χρόνια εντατικής ερευνητικής προσπάθειας, το πρόβλημα της αναδίπλωσης των πρωτεΐνων παραμένει αμετακίνητο στην κορυφή των βασικών άλυτων προβλημάτων της Μοριακής Βιολογίας.

Μία περίοδος αισιοδοξίας στις αρχές της δεκαετίας του '90 έχει αντικατασταθεί από τη σχεδόν πλήρη αποδοχή της απιθανότητας να λυθεί το πρόβλημα στο άμεσο μέλλον. Κυρίαρχο ρόλο στην αναγνώριση της πολυπλοκότητας του προβλήματος έπαιξε η ανάπτυξη της Θεωρίας του τοπίου ενέργειας (energy landscape theory of protein folding) :

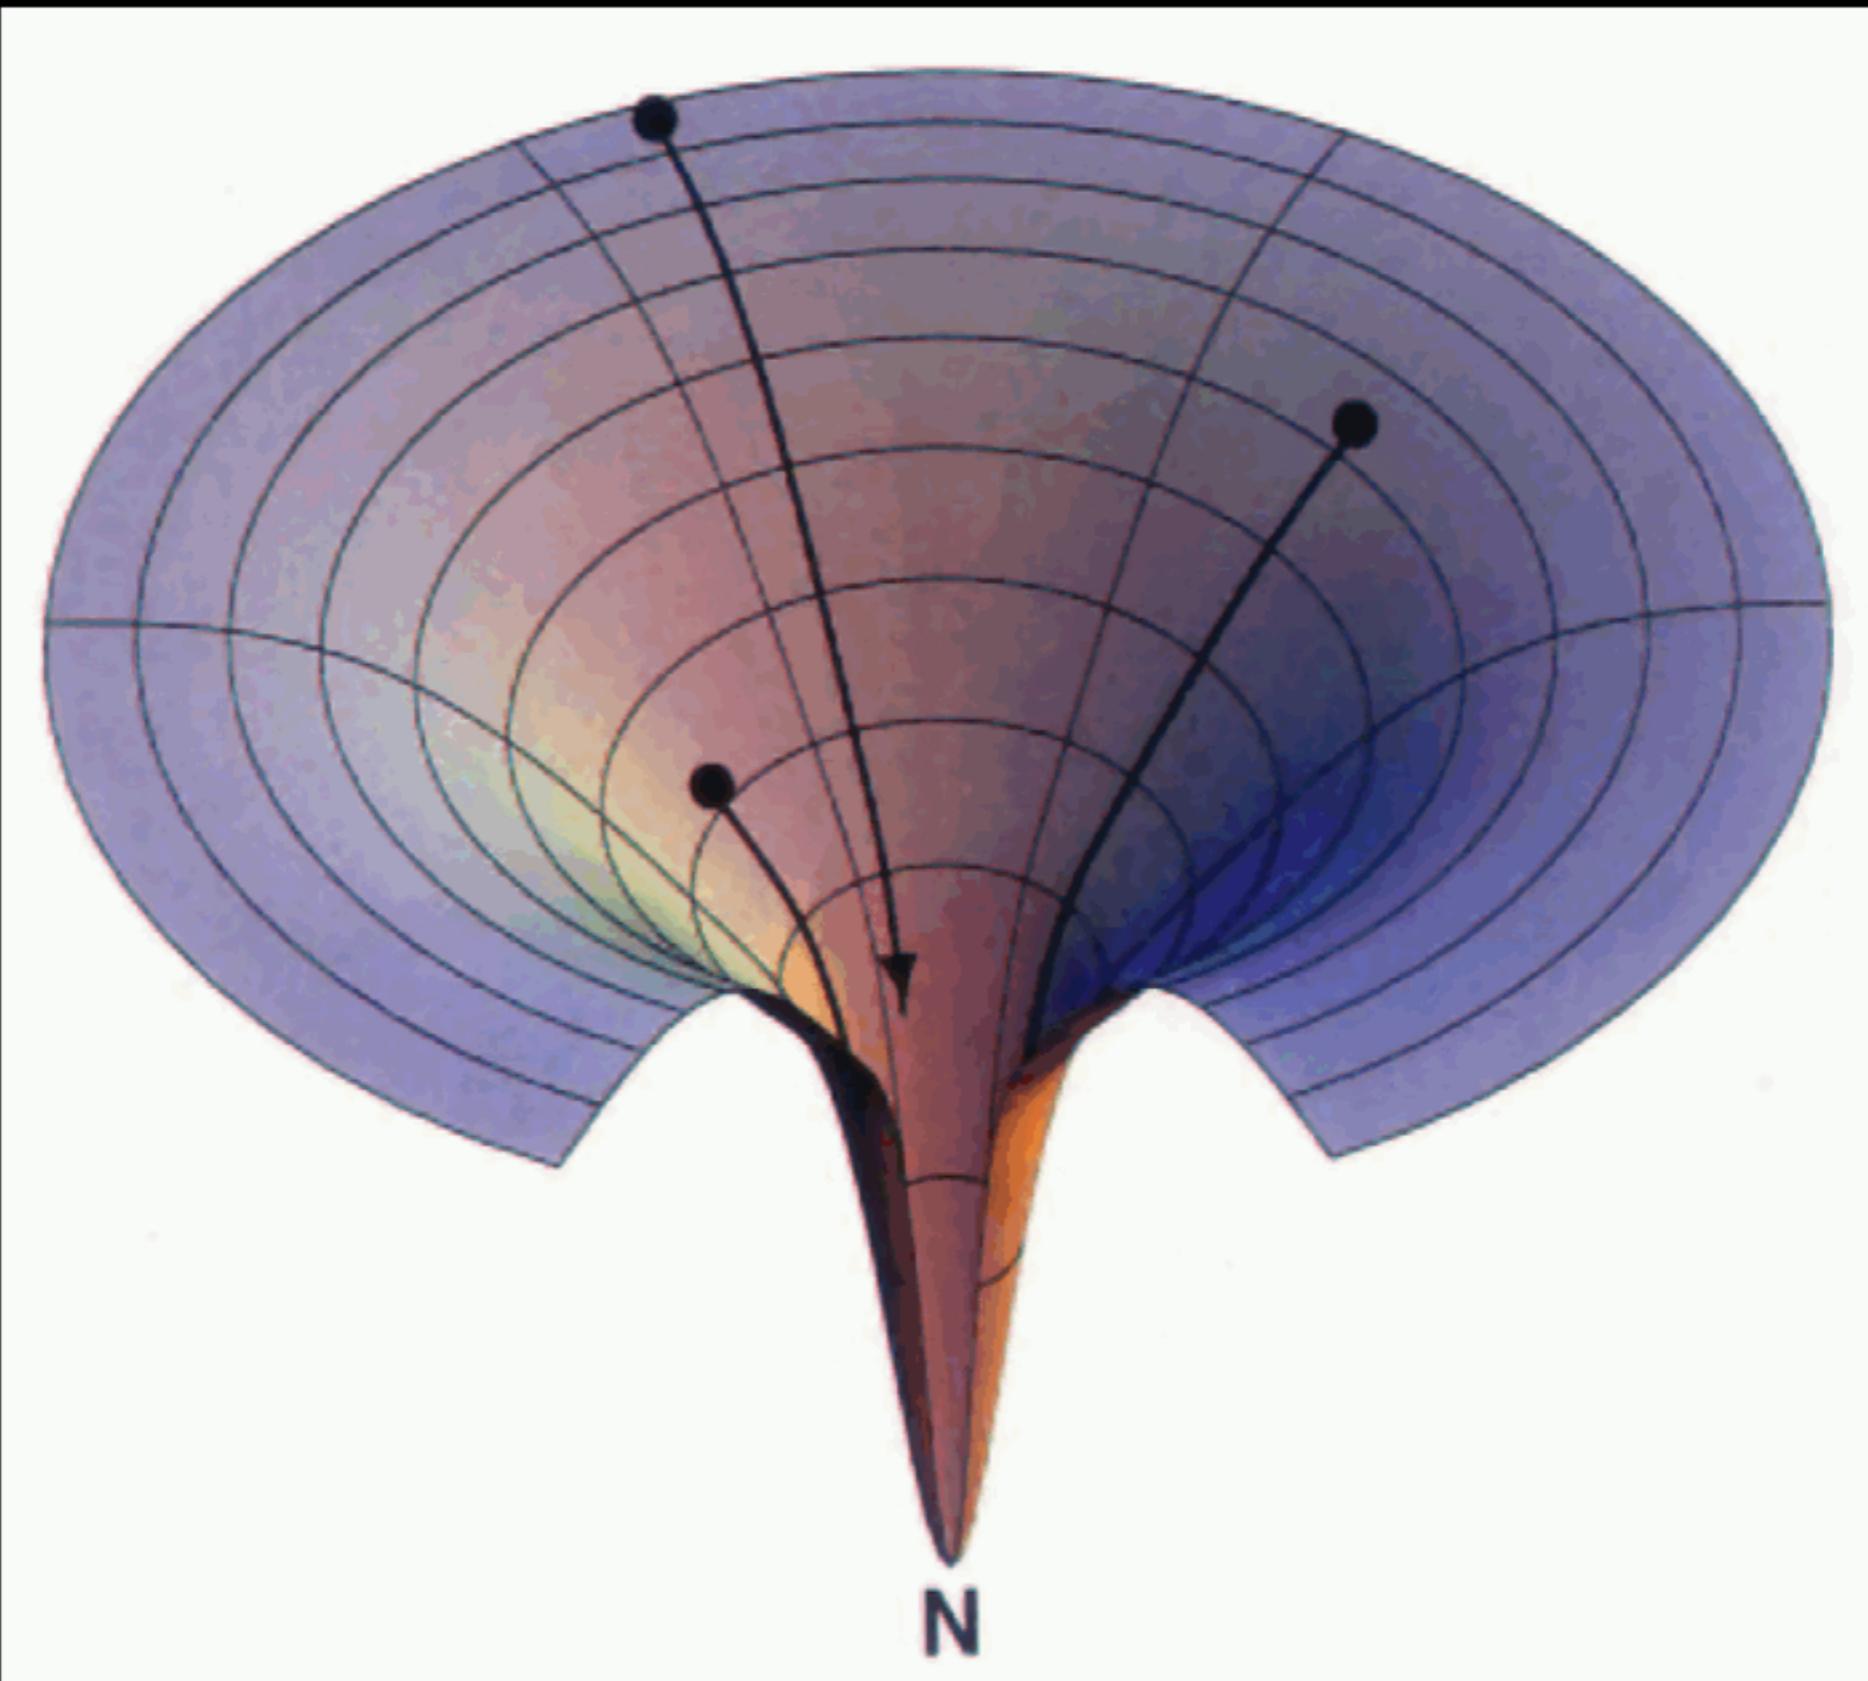
# Energy landscape : Levinthal



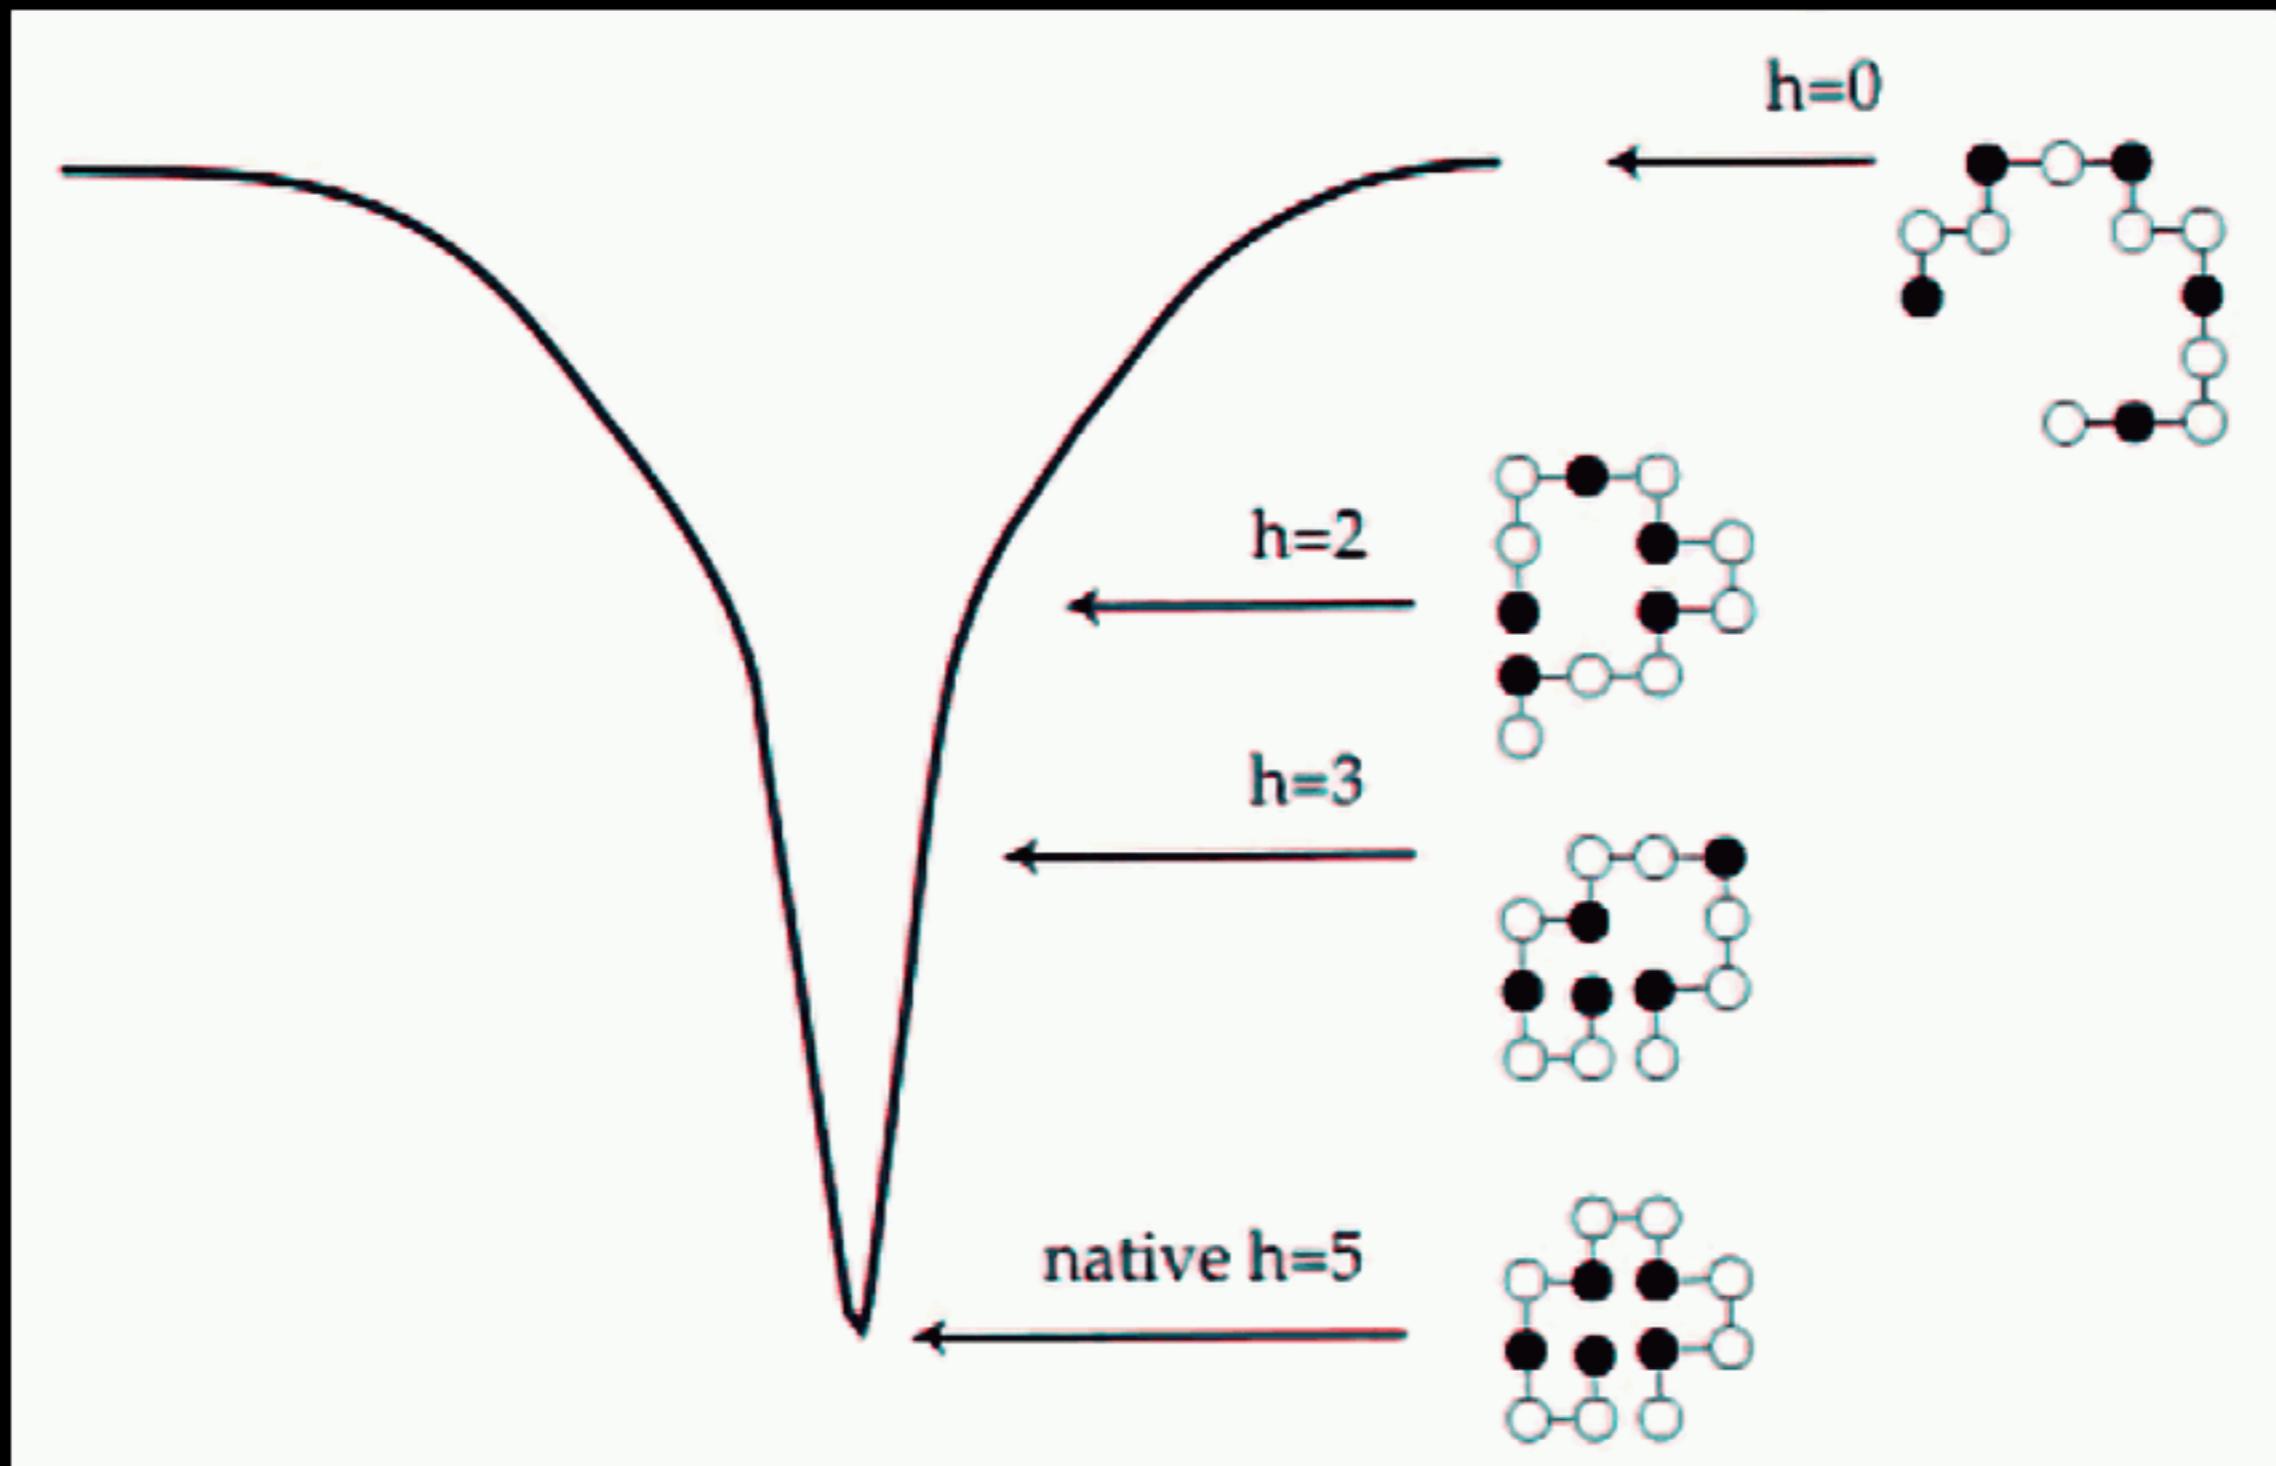
# Energy landscape : pathways



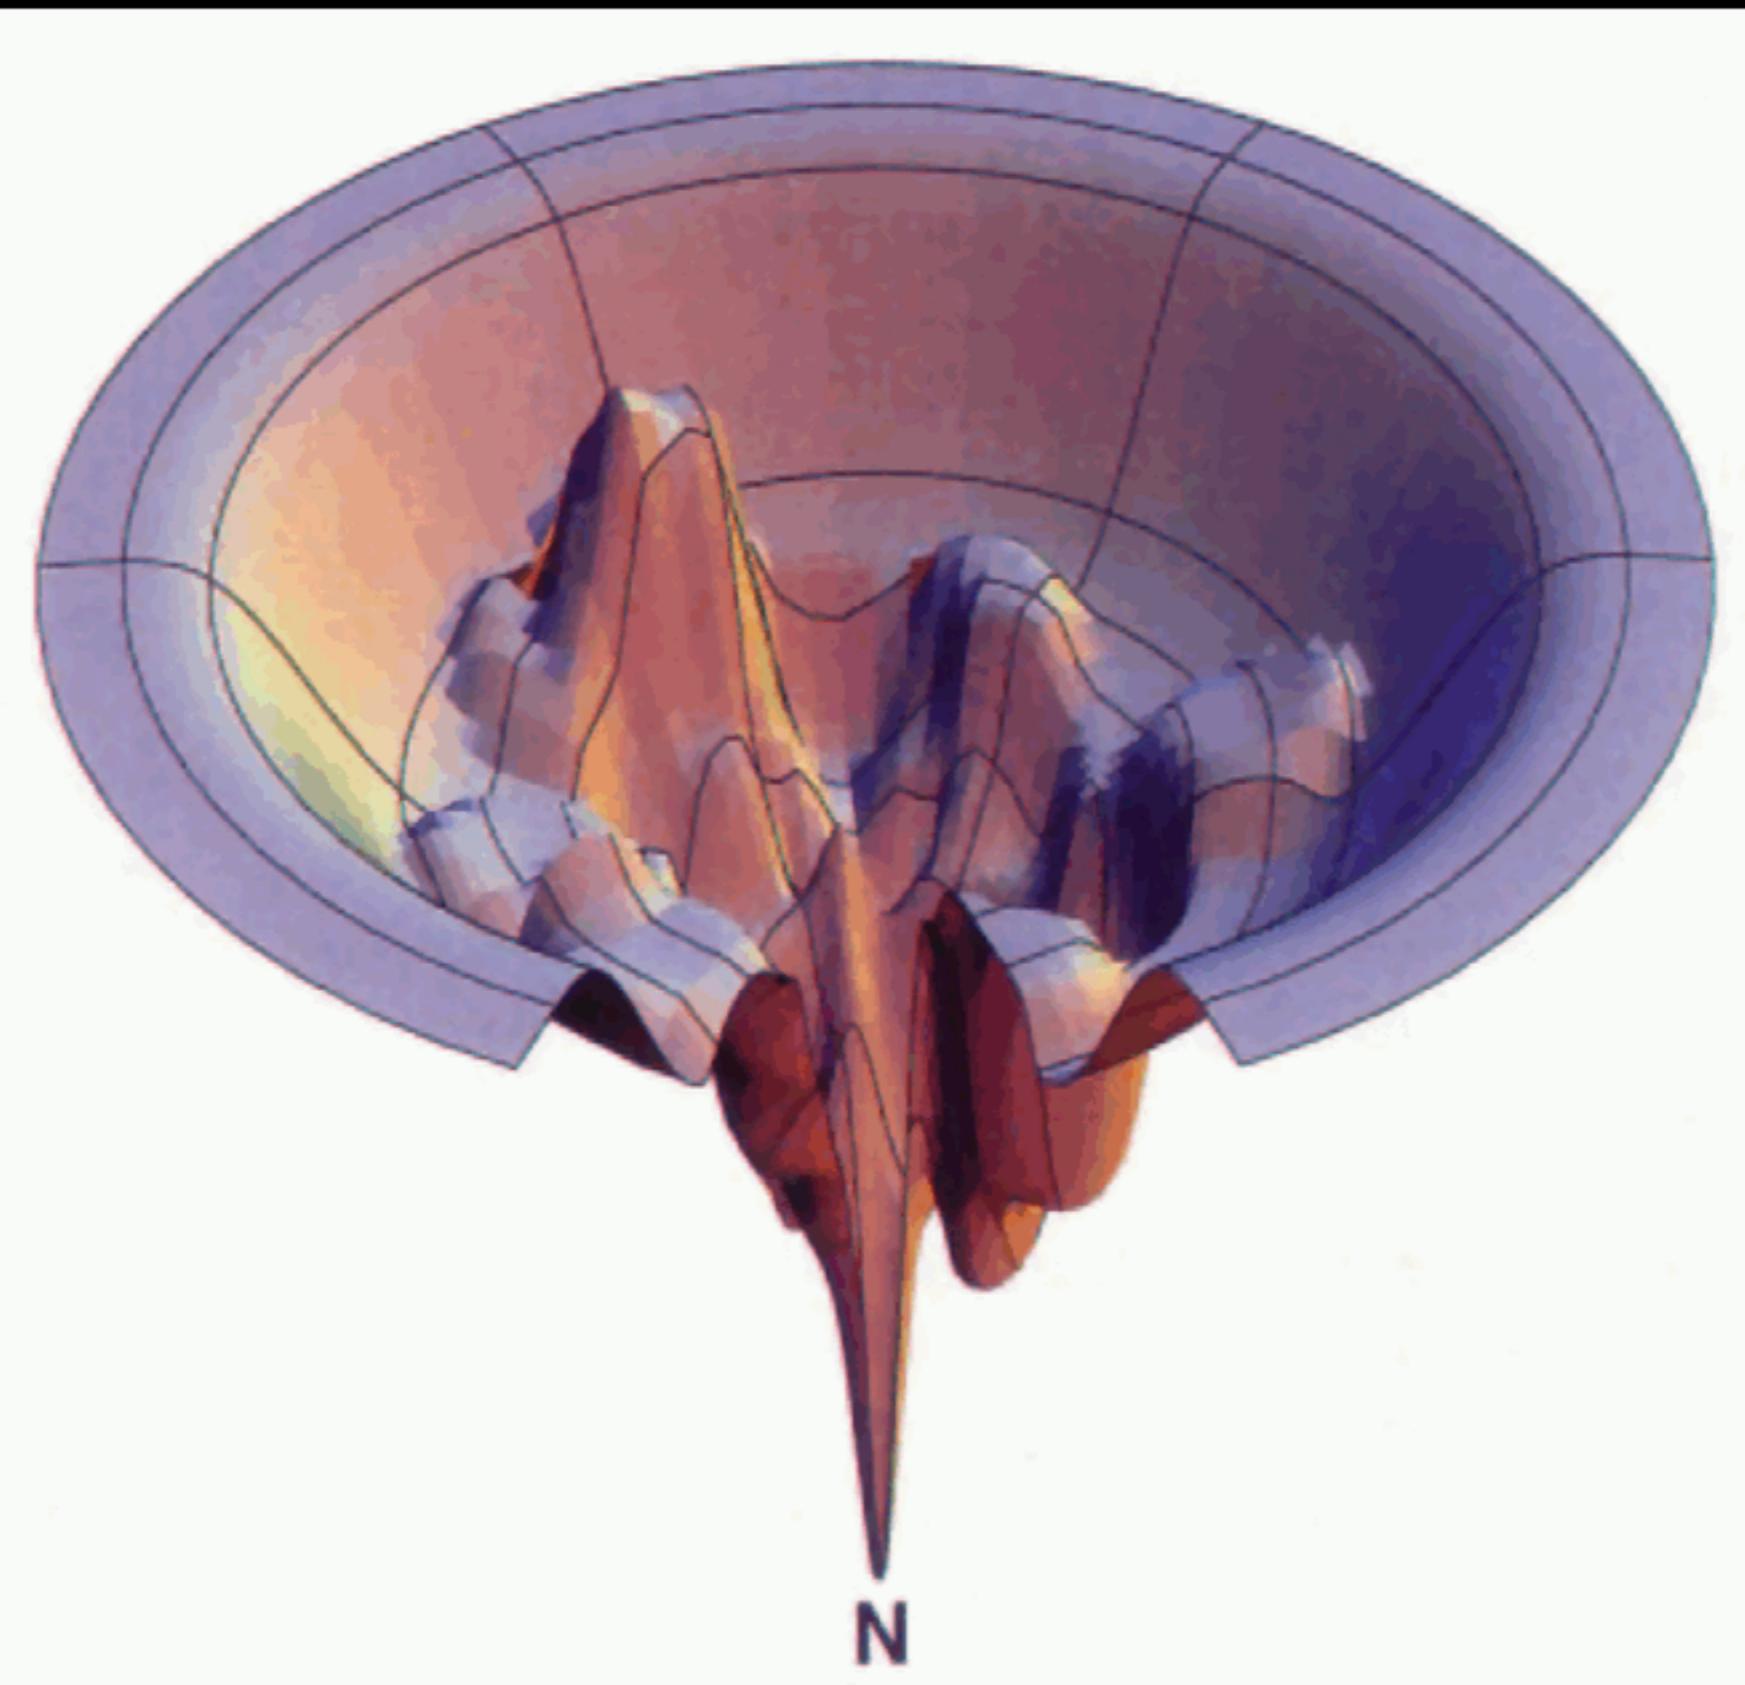
# Energy landscape : the funnel



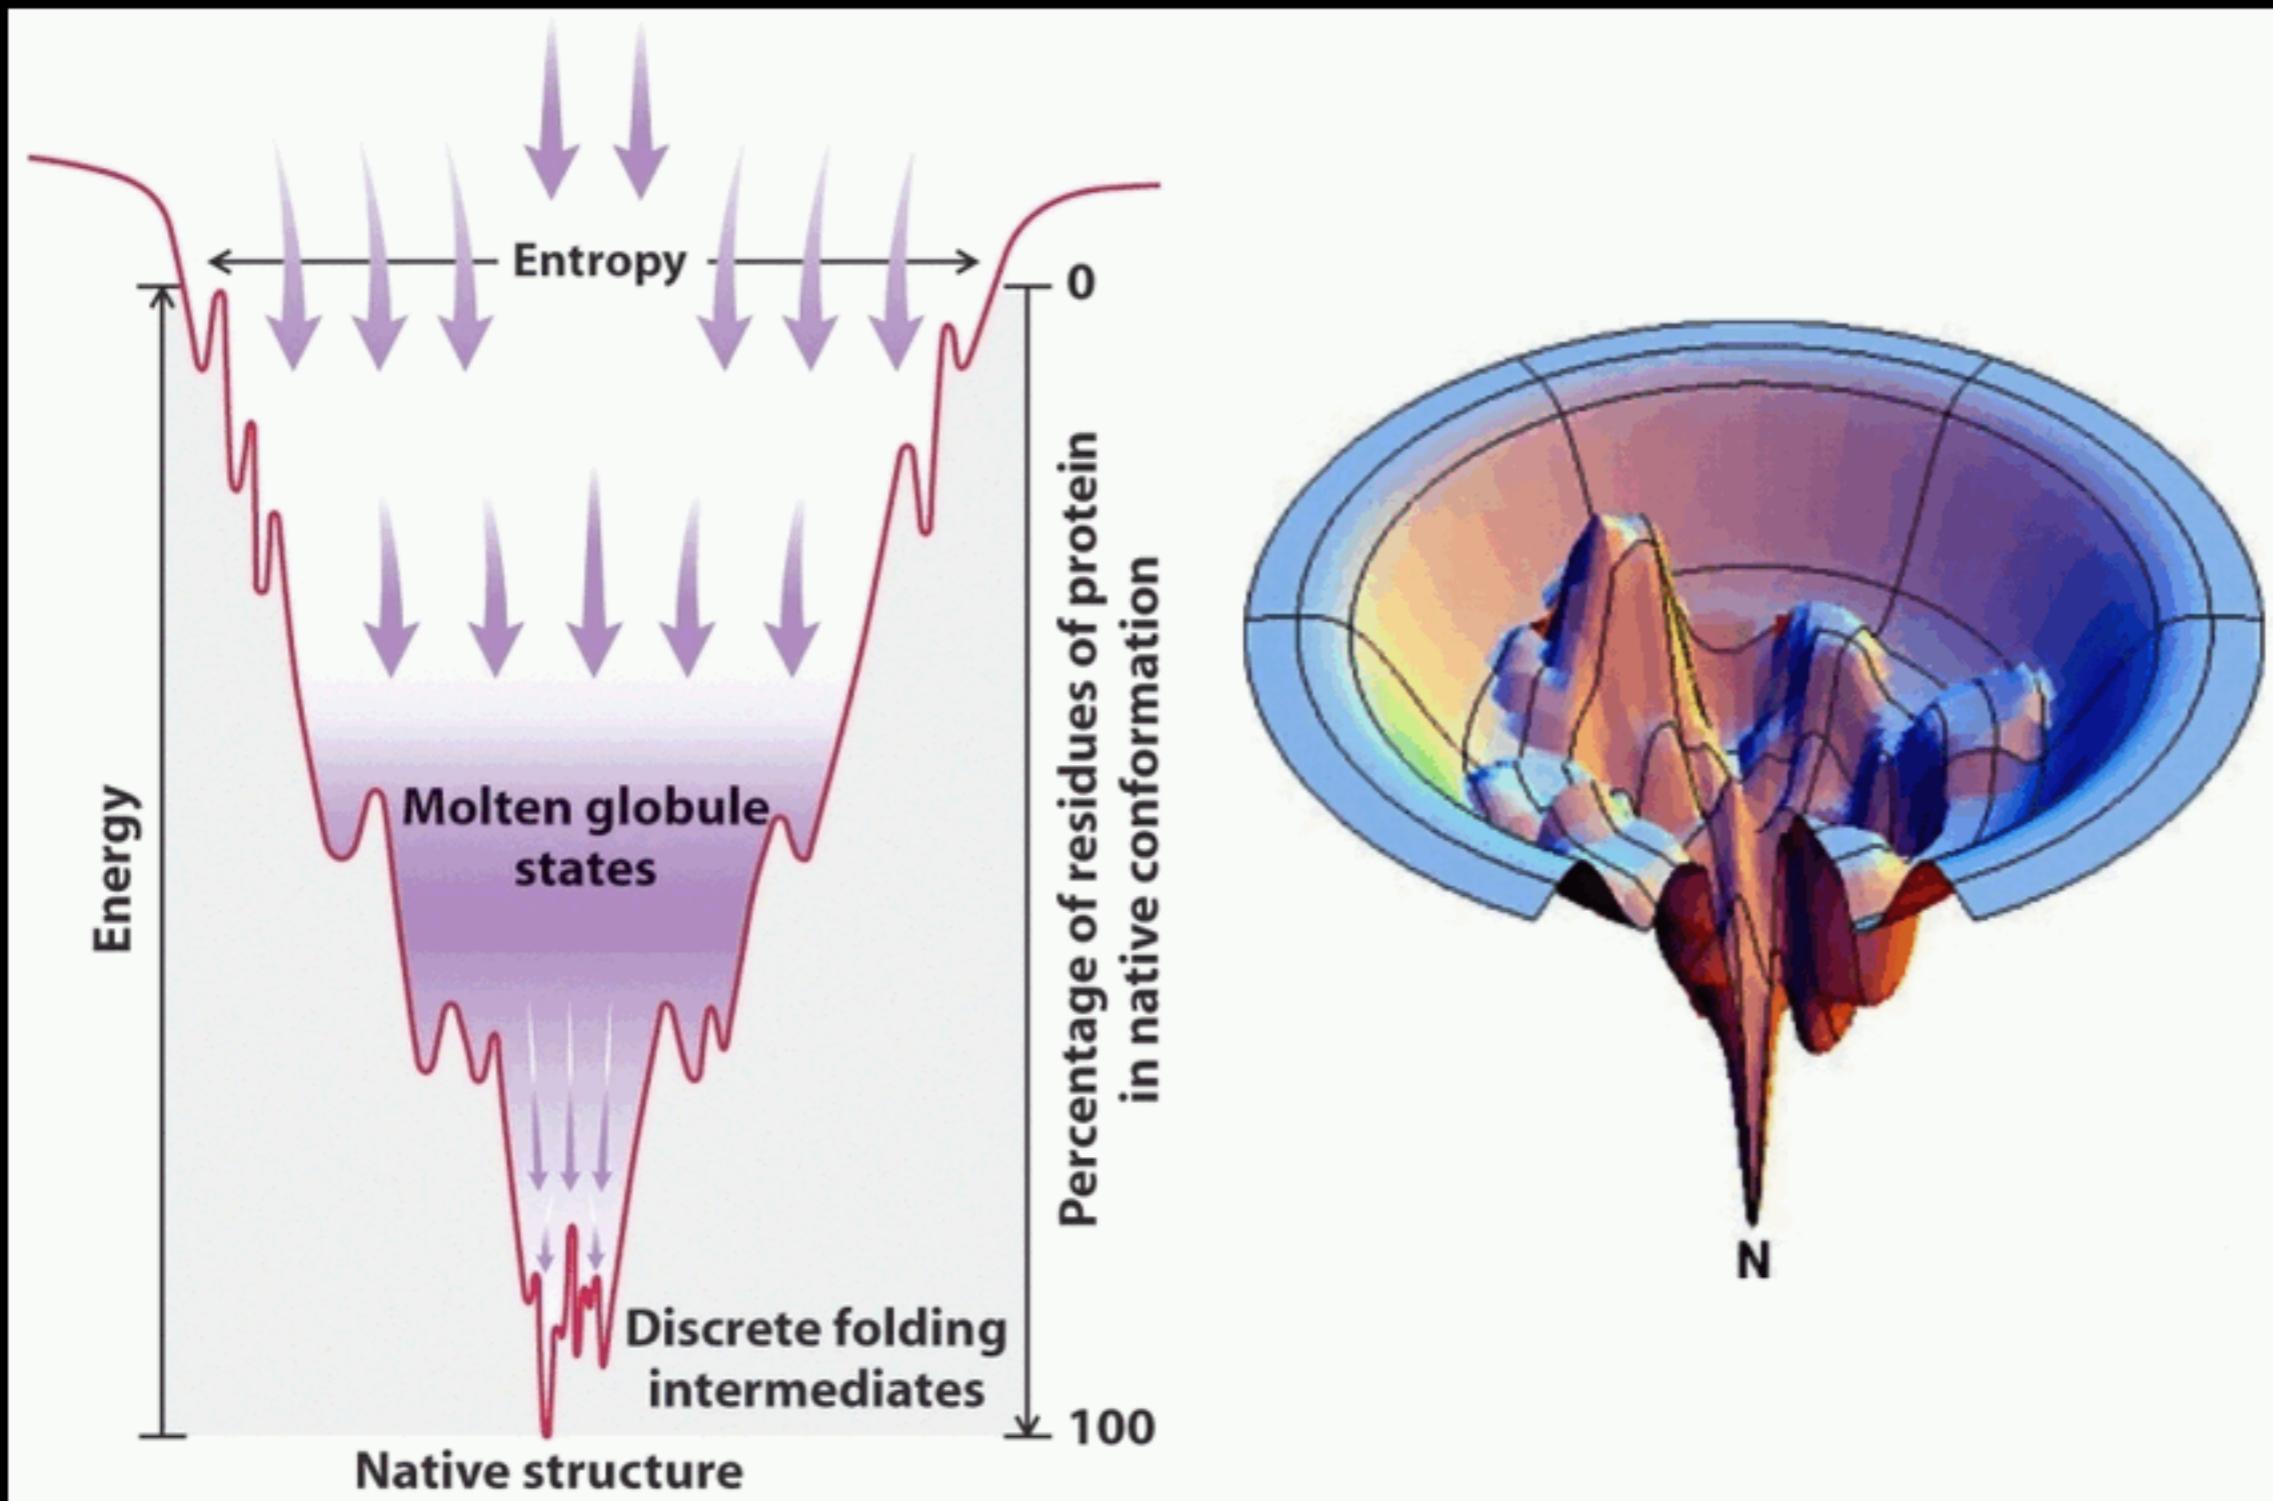
# Energy landscape : The connection with evolution



# The energy landscape



# The energy landscape



# The energy landscape



# Αναδίπλωση πρωτεΐνών : The physics-based approach

---

Η βασική υπόθεση είναι : εάν μπορούμε με ακρίβεια να υπολογίσουμε την ενέργεια ενός συστήματος ατόμων ως συνάρτηση των θέσεων και ταχυτήτων τους, τότε θα μπορούσαμε να προσδιορίσουμε τη φυσική κατάσταση (native state) των πρωτεΐνών και πεπτιδίων μέσω μίας προσομοίωσης αυτού του συστήματος ατόμων ως συνάρτηση του χρόνου. Αυτή η προσέγγιση είναι γνωστή ως

Προσομοιώσεις αναδίπλωσης μοριακής δυναμικής

# Μοριακή δυναμική

---

Προκειμένου να καταστεί εφικτή η προσομοίωση (σε ατομικό επίπεδο) ενός συστήματος, θα πρέπει να μπορεί να υπολογιστεί η ενέργεια του συστήματος ως συνάρτηση των ατομικών θέσεων.

Η ενέργεια ενός συστήματος ατόμων αποτελείται από δύο όρους : την κινητική και τη δυναμική ενέργεια.

Η κινητική ενέργεια υπολογίζεται εύκολα ως συνάρτηση των μαζών και των ταχυτήτων των ατόμων. Η ουσία του προβλήματος βρίσκεται στον υπολογισμό της δυναμικής ενέργειας.

# Ενέργεια πρωτεϊνών

---

Το ζητούμενο είναι να βρεθεί η δυναμική ενέργεια των πρωτεϊνών ως συνάρτηση της δομής τους (της διαμόρφωσης τους στον τρισδιάστατο χώρο). Θεωρητικά, ότι μπορούμε να μάθουμε για το σύστημα (συμπεριλαμβανομένης και της ενέργειας του) βρίσκεται στην επίλυση της εξίσωσης του Schrodinger. Δυστυχώς, οι κβαντομηχανικοί υπολογισμοί είναι τόσο χρονοβόροι που γίνονται πρακτικά ανέφικτοι για περισσότερα από μερικές δεκάδες ή εκατοντάδες άτομα. Για το λόγο αυτό έχουν αναπτυχθεί εμπειρικές μέθοδοι προσδιορισμού της δυναμικής ενέργειας των μακρομορίων, τα λεγόμενα δυναμικά πεδία (force fields).

# Force fields

---

Τυπικά, αυτά τα δυναμικά πεδία περιγράφουν την ολική δυναμική ενέργεια του μορίου ως άθροισμα δύο όρων, ενός για τις δεσμικές (μέσω δεσμών) αλληλεπιδράσεις, και ενός για μη δεσμικές αλληλεπιδράσεις. Οι δεσμικές αλληλεπιδράσεις περιλαμβάνουν όρους για τα μήκη δεσμών, τις γωνίες δεσμών, για άτομα που πρέπει να μείνουν συνεπίπεδα (π.χ. αρωματικά), κλπ. Οι μη δεσμικές αλληλεπιδράσεις είναι το άθροισμα των ηλεκτροστατικών αλληλεπιδράσεων συν ένα Lennard-Jones δυναμικό που περιγράφει τις δυνάμεις διασποράς και την άπωση μεταξύ των ηλεκτρονιακών νεφών.

# Force fields

---

$$\mathcal{H} = \mathcal{K} + \mathcal{V}$$

$$\mathcal{V} = \mathcal{V}_{\text{bonding}} + \mathcal{V}_{\text{non-bonding}}$$

$$\mathcal{V}_{\text{bonding}} = \mathcal{V}_{\text{lengths}} + \mathcal{V}_{\text{angles}} + \mathcal{V}_{\text{dihedral}} + \mathcal{V}_{\text{improper}}$$

$$\mathcal{V}_{\text{non-bonding}} = \mathcal{V}_{\text{electr}} + \mathcal{V}_{\text{L-J}}$$

# Force fields

$$\mathcal{V}_{\text{lengths}} = \sum_{\text{bonds}} \frac{1}{2} k_b (b - b_0)^2$$

$$\mathcal{V}_{\text{angles}} = \sum_{\text{angles}} \frac{1}{2} k_\theta (\theta - \theta_0)^2$$

$$\mathcal{V}_{\text{dihedral}} = \sum_{\text{dihedrals}} \frac{1}{2} V_n (1 + \cos(n\phi - \delta))$$

# Force fields

---

$$\mathcal{V}_{\text{electr}} = \sum_{\text{all pairs}} \frac{q_i q_j}{\epsilon r_{ij}}$$

$$\mathcal{V}_{\text{L-J}} = \sum_{\text{all pairs}} \frac{A_{ij}}{r_{ij}^{12}} - \frac{B_{ij}}{r_{ij}^6}$$

# Μοριακή δυναμική

$$\mathcal{H} = \mathcal{K} + \mathcal{V}$$

$$\mathcal{K} = \frac{1}{2} \sum_{all atoms} m_i \mathbf{u}_i^2$$

$$\mathbf{F}_i = m_i \mathbf{a}_i = m_i \frac{d^2 \mathbf{r}_i}{dt^2} = -\frac{\partial \mathcal{V}}{\partial \mathbf{r}_i}$$

# Μοριακή δυναμική

Molecular motion illustrated : a short video.

www.youtube.com/watch?v=\_xF96sNWnK4

YouTube

GUIDE

▶ 0:06 / 0:22

Protein folding

euplates · 70 videos

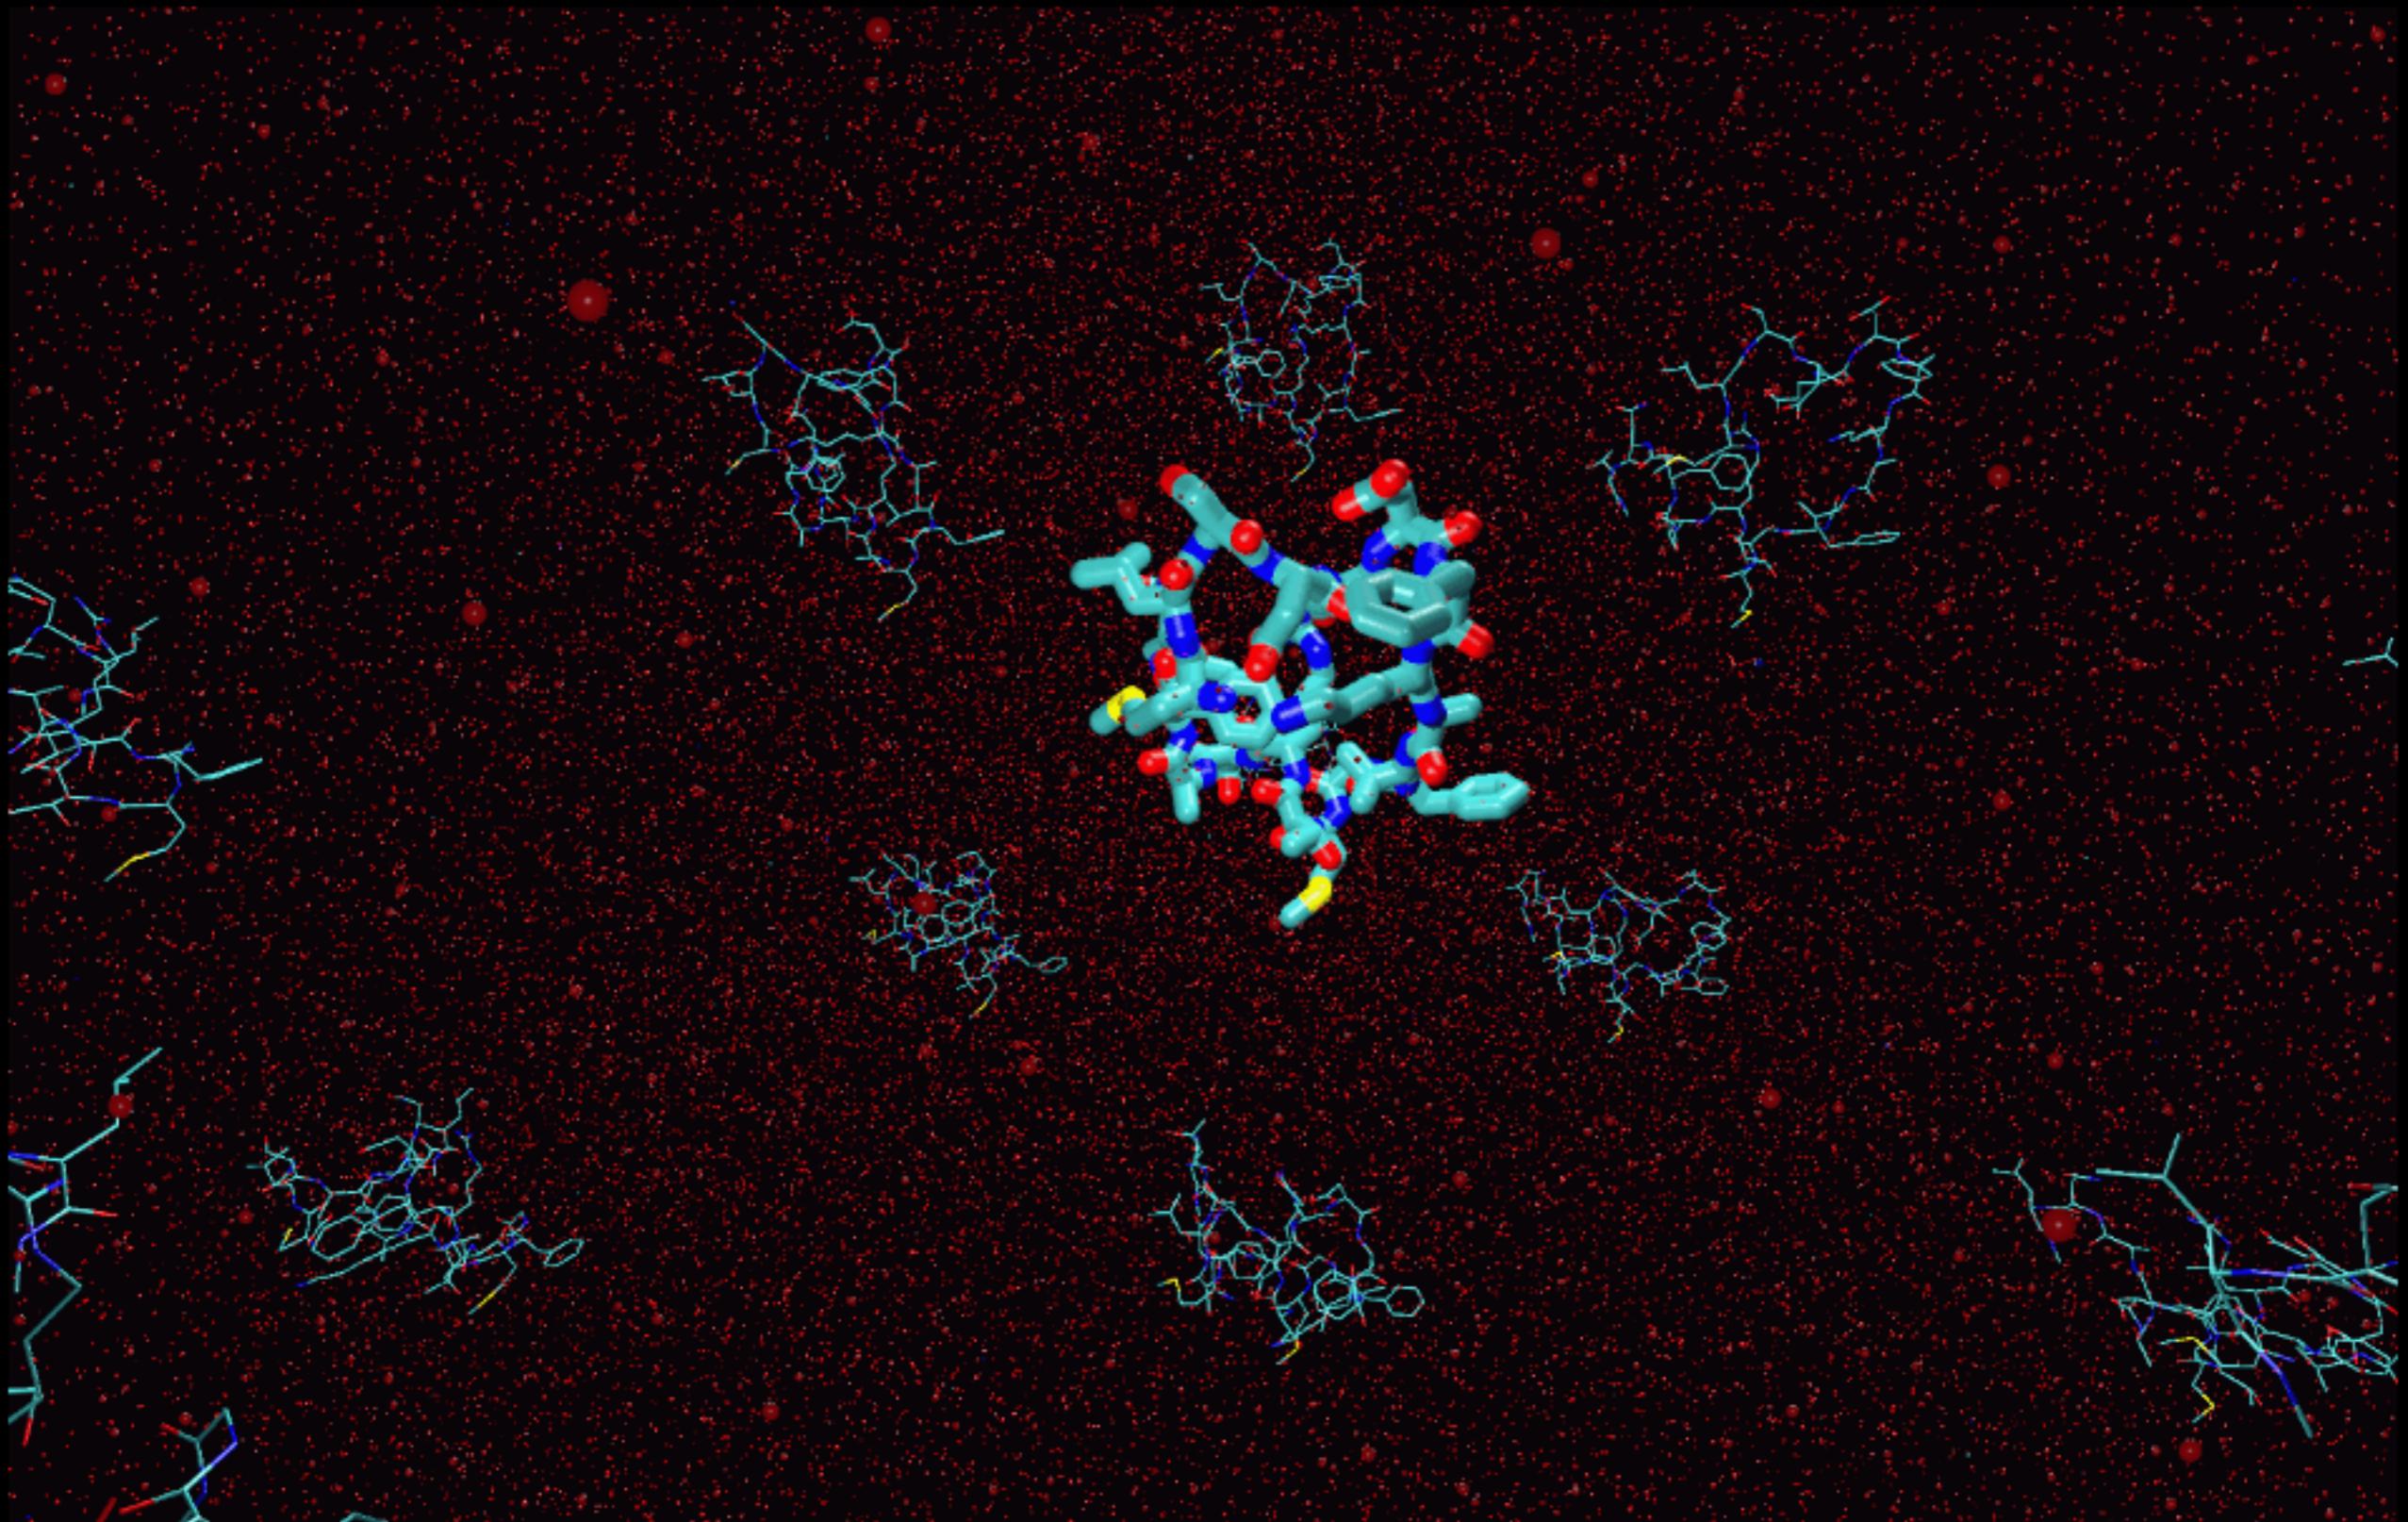
Subscribe 188

10,923

11 1

# Μοριακή δυναμική

The problem : Too many atoms, too little time



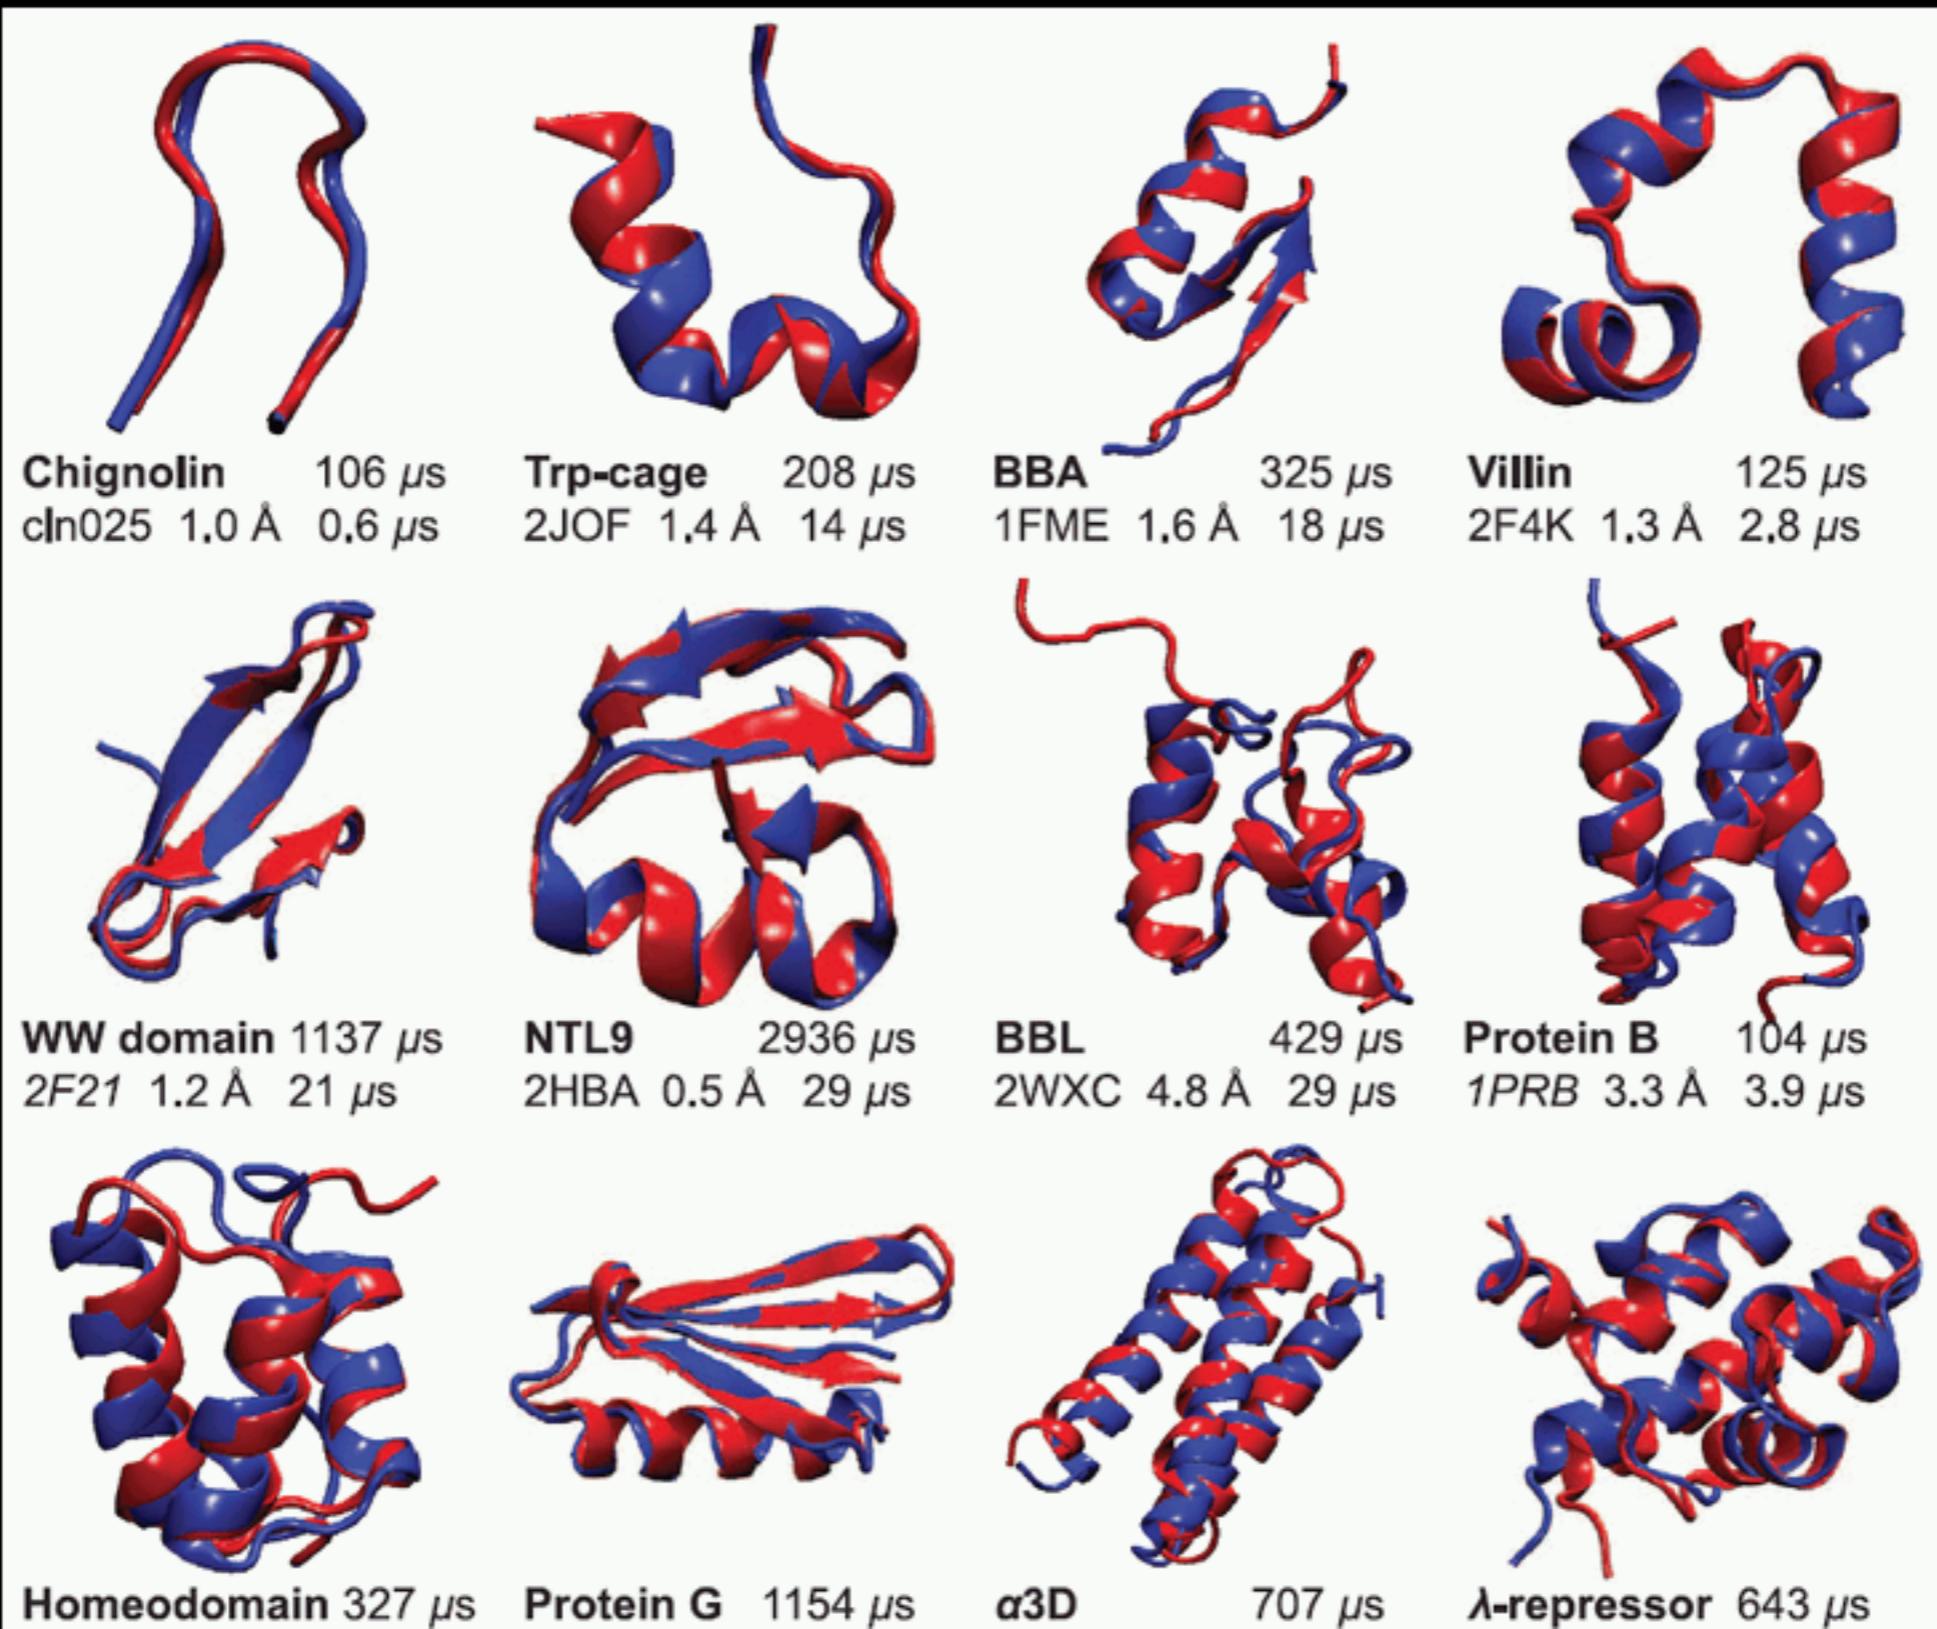
# Physics wins ?

The Anton computing machine ...



# Physics wins ?

... and its computationally folded proteins.



# Physics wins ?

## Protein folding in silico : a short video

www.youtube.com/watch?v=gFcp2Xpd29I

YouTube

GUIDE

Clean secondary structure units formed

0:47 / 2:47

▶ 🔍

Simulation of millisecond protein folding: NTL9 (from Folding@home)

Pande Lab Science · 40 videos

Subscribe 445

57,577

139 2

# Πρόβλεψη τριτοταγούς δομής

Διακρίνονται τρεις βασικές κατηγορίες αλγορίθμων

- Τεχνητά νευρωνικά (alphafold),
- Homology modeling, και,
- Ab initio structure prediction

Από αυτές, η τρίτη είναι αυτόύσιο το υπολογιστικό τμήμα του προβλήματος της αναδίπλωσης των πρωτεΐνων, η δεύτερη χρησιμοποιεί τις δομές ομόλογων πρωτεΐνων (από την PDB) για να δημιουργήσει ένα ατομικό μοντέλο για μια νέα αλληλουχία, ενώ η πρώτη χρησιμοποιεί deep neural networks και είναι η ισχυρότερη από τις υπάρχουσες μεθόδους.

# Homology modeling

---

Το πρόβλημα είναι : με δεδομένη μια στοίχιση ανάμεσα σε μια αλληλουχία άγνωστης δομής με μία ή περισσότερες αλληλουχίες γνωστής δομής, ποιά είναι η 'καλύτερη' (πλέον πιθανή) δομή για την νέα αλληλουχία ; (με βάση τη στοίχιση και τις γνωστές δομές).

Η βασική υπόθεση για την επίλυση του προβλήματος είναι ότι το μοτίβο αναδίπλωσης της νέας αλληλουχίας είναι το ίδιο με αυτό των αλληλουχιών γνωστής δομής. Τυχόν μεταβολές στις αποστάσεις μεταξύ των στοιχείων δευτεροταγούς δομής (indels) διορθώνονται με την εισαγωγή (στις δομές) βρόχων με κατάλληλο αριθμό καταλοίπων.

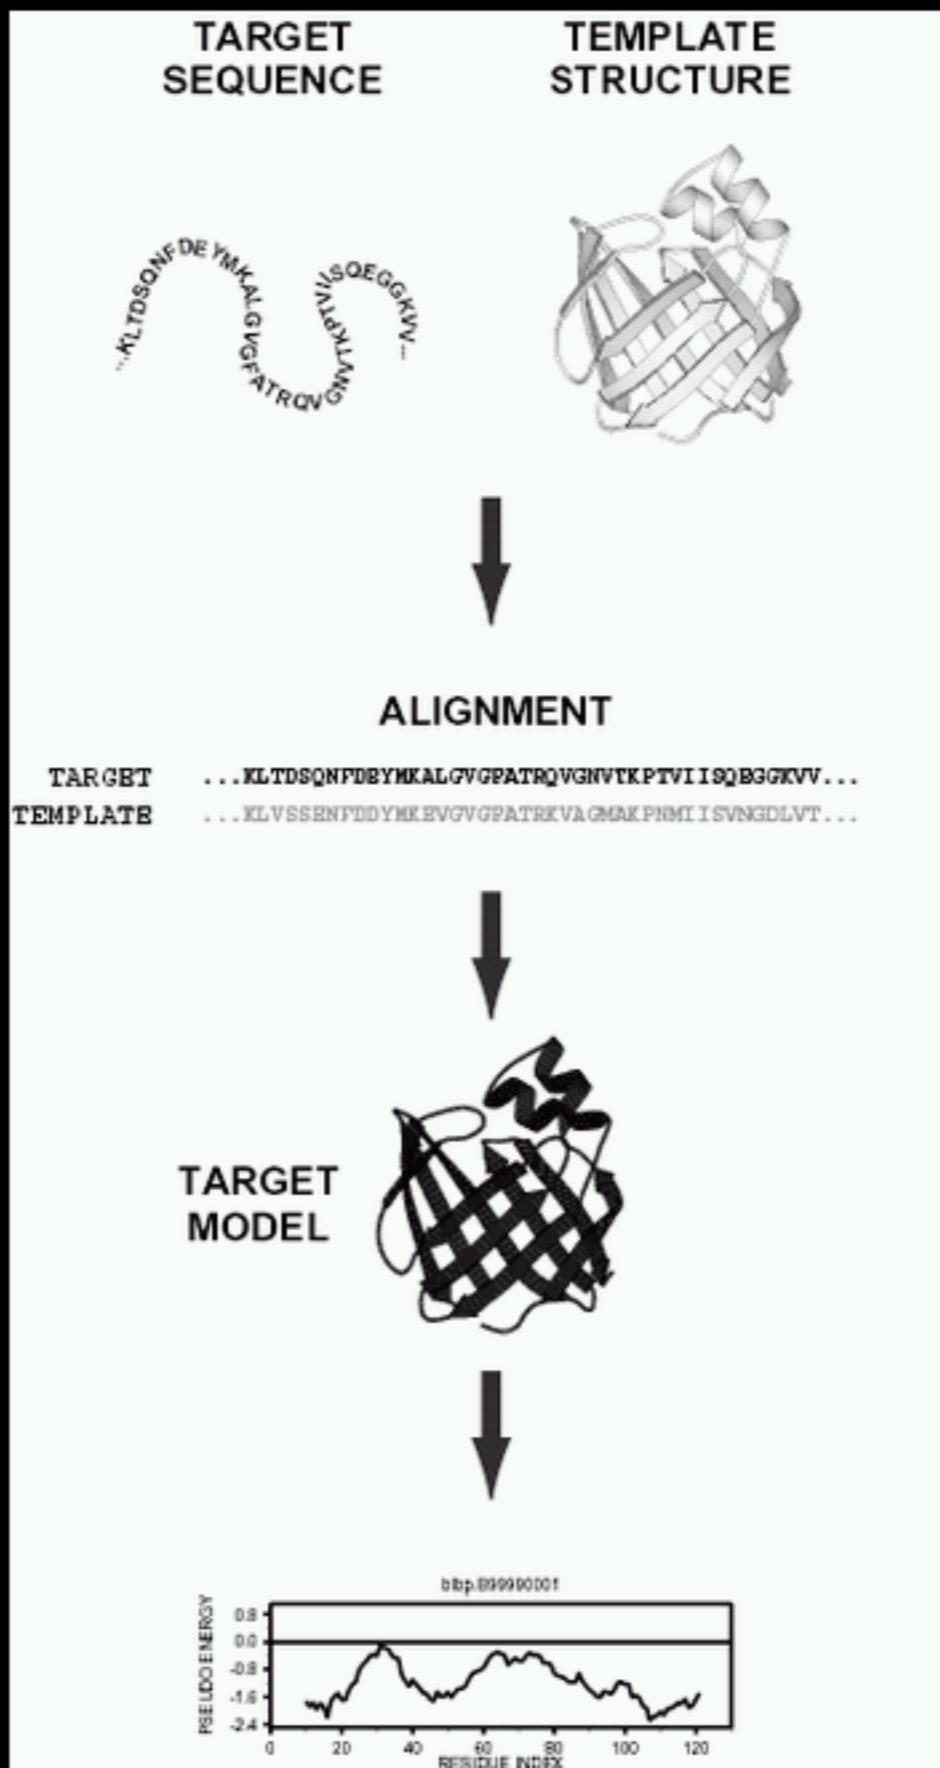
# Homology modeling

---

## Διαδικασία

1. Εύρεση ομόλογων αλληλουχιών με γνωστή δομή.
2. Στοίχιση των αλληλουχιών.
3. Δημιουργία ενός μοντέλου του πρωτεΐνικού σκελετού της νέας αλληλουχίας χρησιμοποιώντας ως μήτρα τις γνωστές δομές.
4. Στις περιοχές που υπάρχουν εισαγωγές/διαγραφές, εισαγωγή βρόχων κατάλληλου μήκους.
5. Προσθήκη πλευρικών ομάδων.
6. Βελτιστοποίηση των θέσεων των πλευρικών ομάδων.
7. Βελτιστοποίηση ολόκληρης της δομής (energy minimisation, molecular dynamics, ...).

# Homology modeling



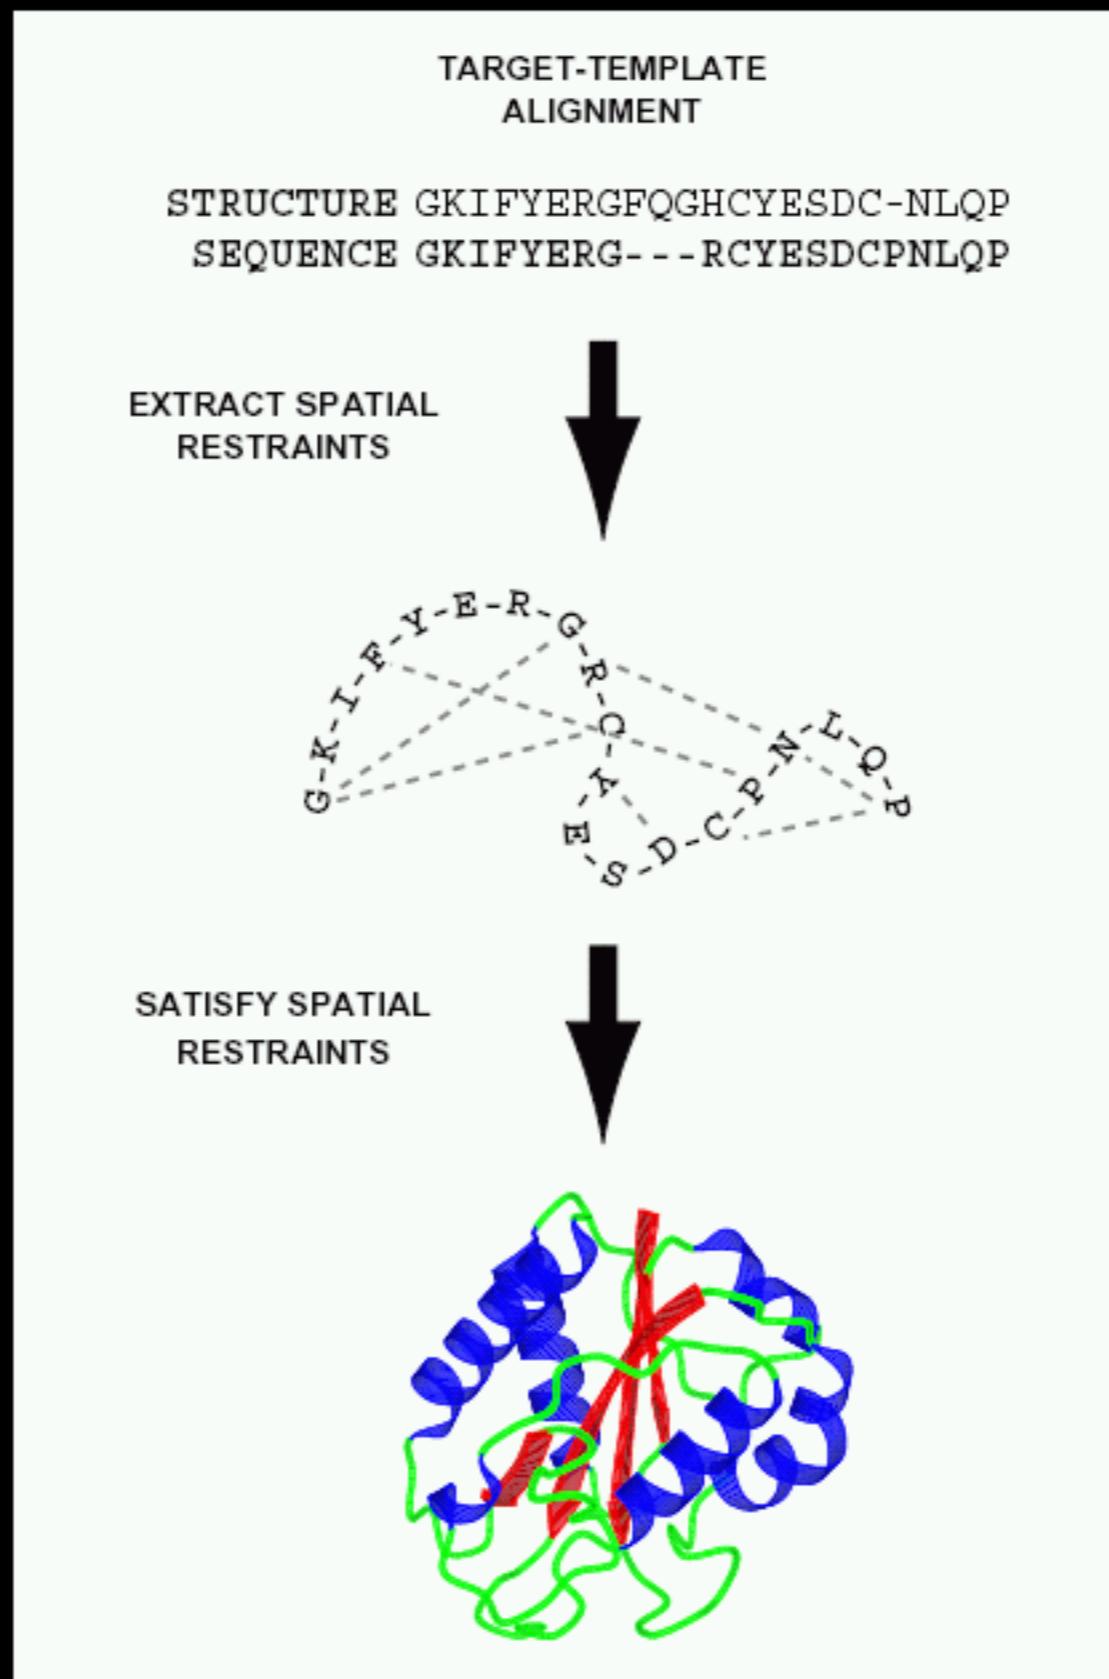
# Homology modeling

## Κατασκευή μοντέλου

Οι πλέον συνηθισμένες μέθοδοι είναι :

- Συνάθροιση στερεών σωμάτων (rigid-body assembly).
- Segment matching.
- Μέσω εκπλήρωσης χωροταξικών περιορισμών (αντίστοιχο με τον προσδιορισμό δομών με NMR). Οι περιορισμοί αναφέρονται π.χ. σε αποστάσεις μεταξύ καταλοίπων, σε τιμές δίεδρων γωνιών, σε γωνίες και αποστάσεις δεσμών, κοκ. Στόχος είναι να βρεθεί η δομή εκείνη (ή μια οικογένεια συγγενών δομών) που συμφωνεί καλύτερα με το σύνολο των περιορισμών.

# Homology modeling



# Homology modeling

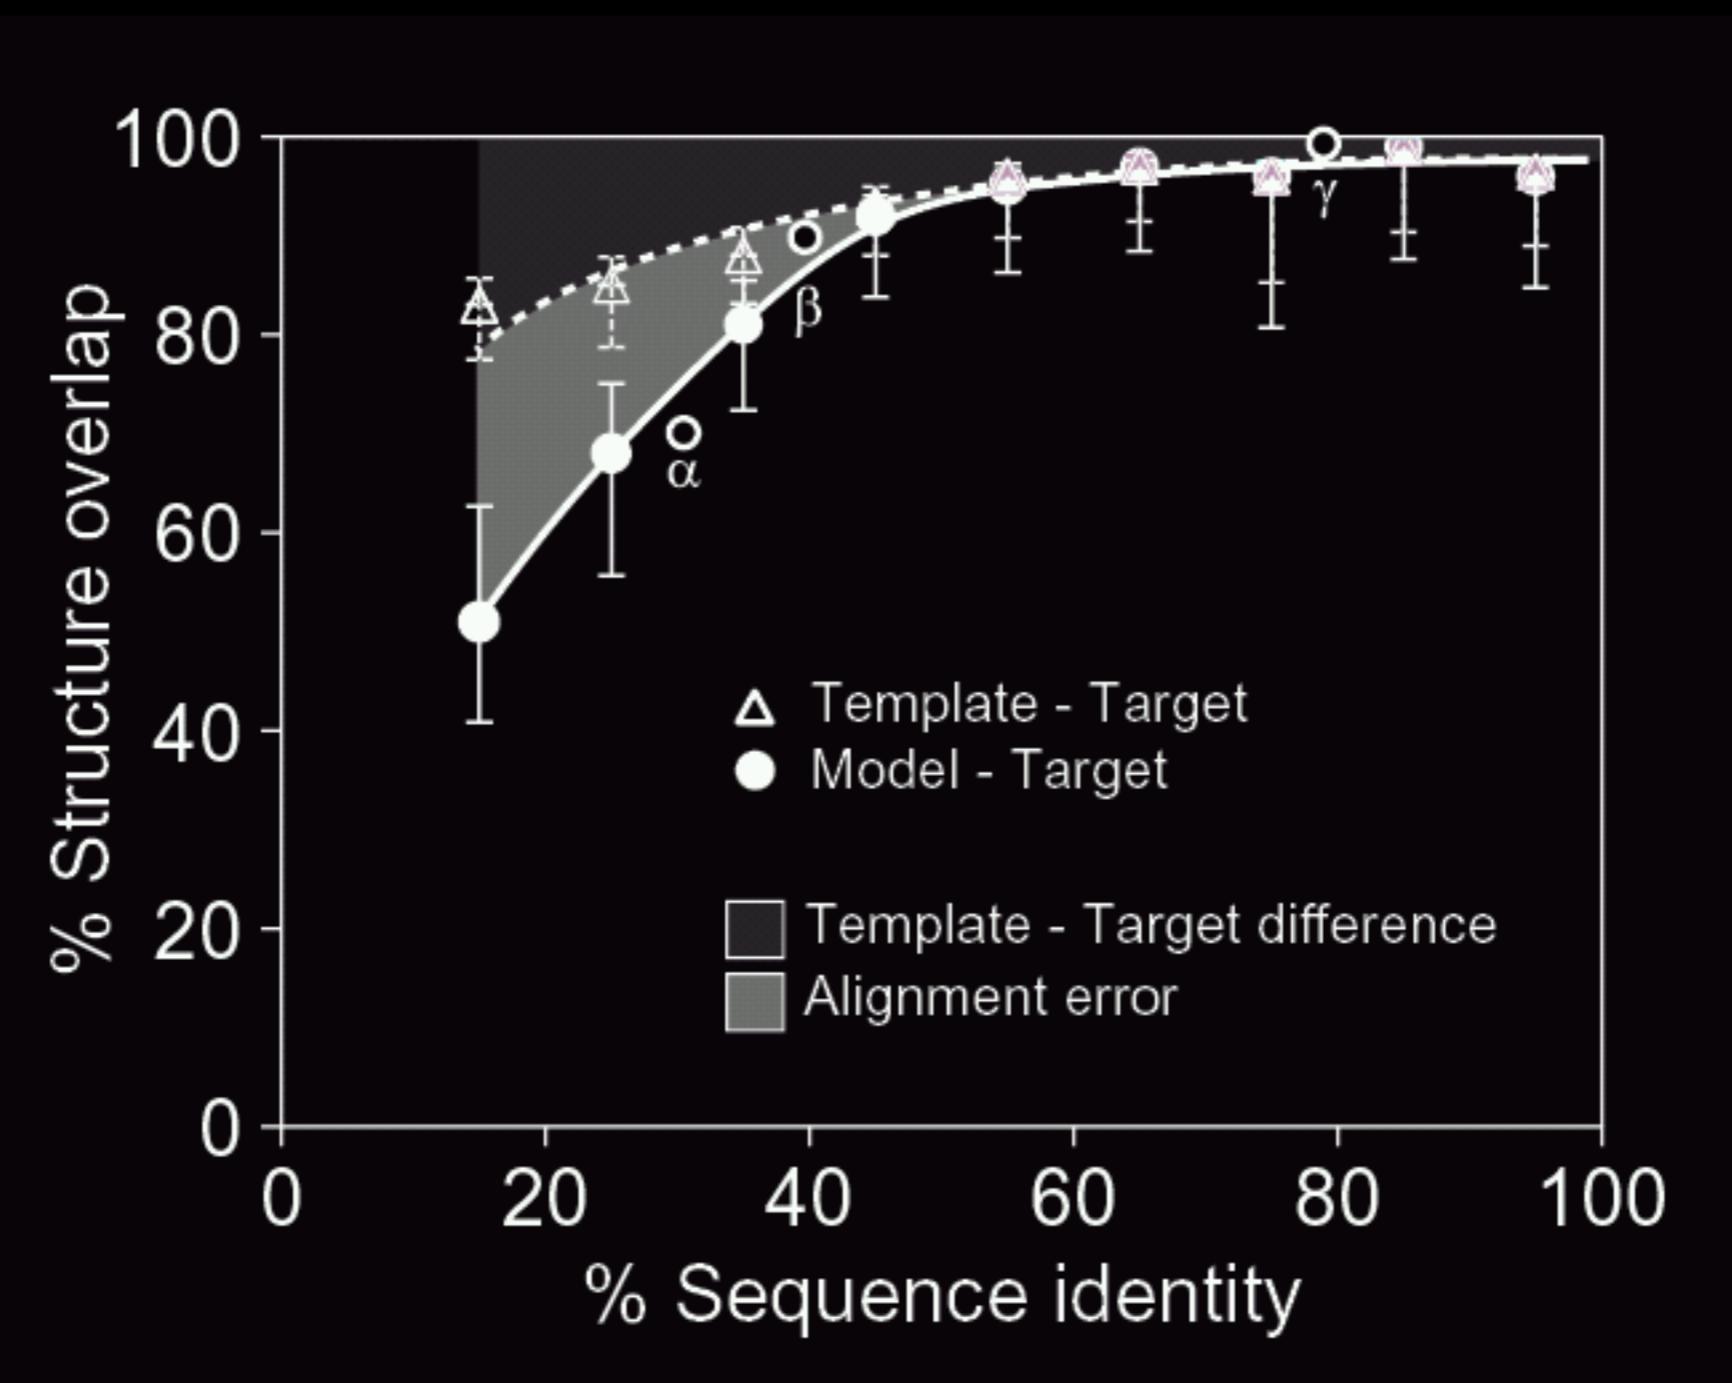
---

## Loop modelling

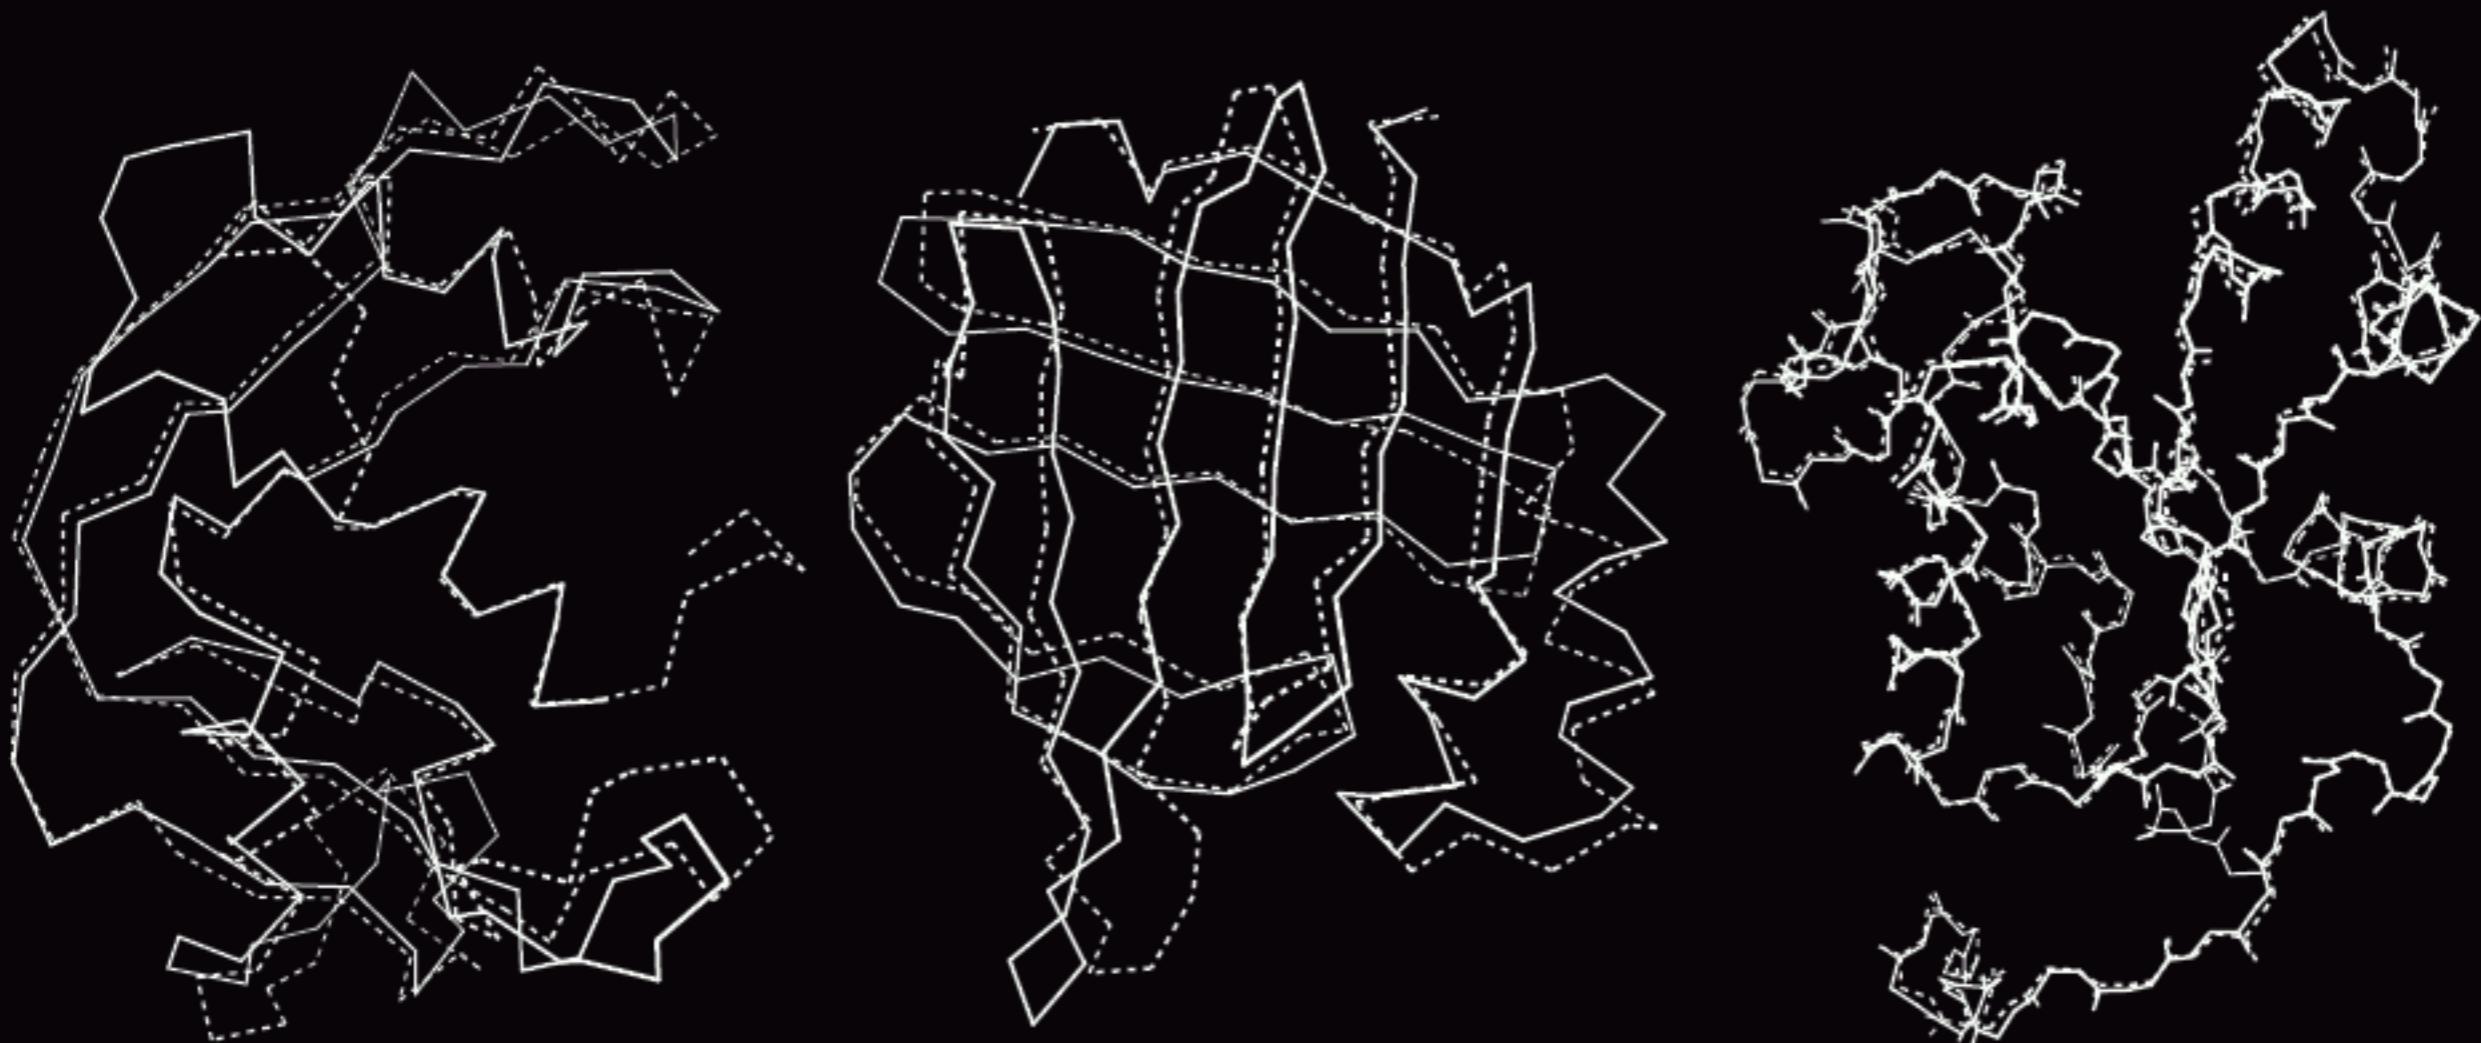
Υπάρχουν δύο βασικές προσεγγίσεις. Η πρώτη βασίζεται σε μία έρευνα της PDB για την εύρεση ενός πρωτεΐνικού τμήματος κατάλληλου μήκους (σε κατάλοιπα) και του οποίου η σχετικές θέσεις των άκρων να ταιριάζουν με το υπό κατασκευή μοντέλο. Η δεύτερη προσέγγιση χρησιμοποιεί ένα δυναμικό πέδιο για να προσδιορίσει (ab initio) πιθανές δομές βρόχων συμβατών με το υπάρχον μοντέλο και το περιβάλλον του υπό κατασκευή βρόχου. Η μέθοδος μπορεί να δώσει χρήσιμα αποτελέσματα ( $\text{Ca rmsd} < 2.0\text{\AA}$ ) ακόμα και για σχετικά μακρύς βρόχους (της τάξεως των 8 καταλοίπων).

# Homology modeling

## Ομοιότητα vs. ακρίβεια πρόβλεψης



# Homology modeling



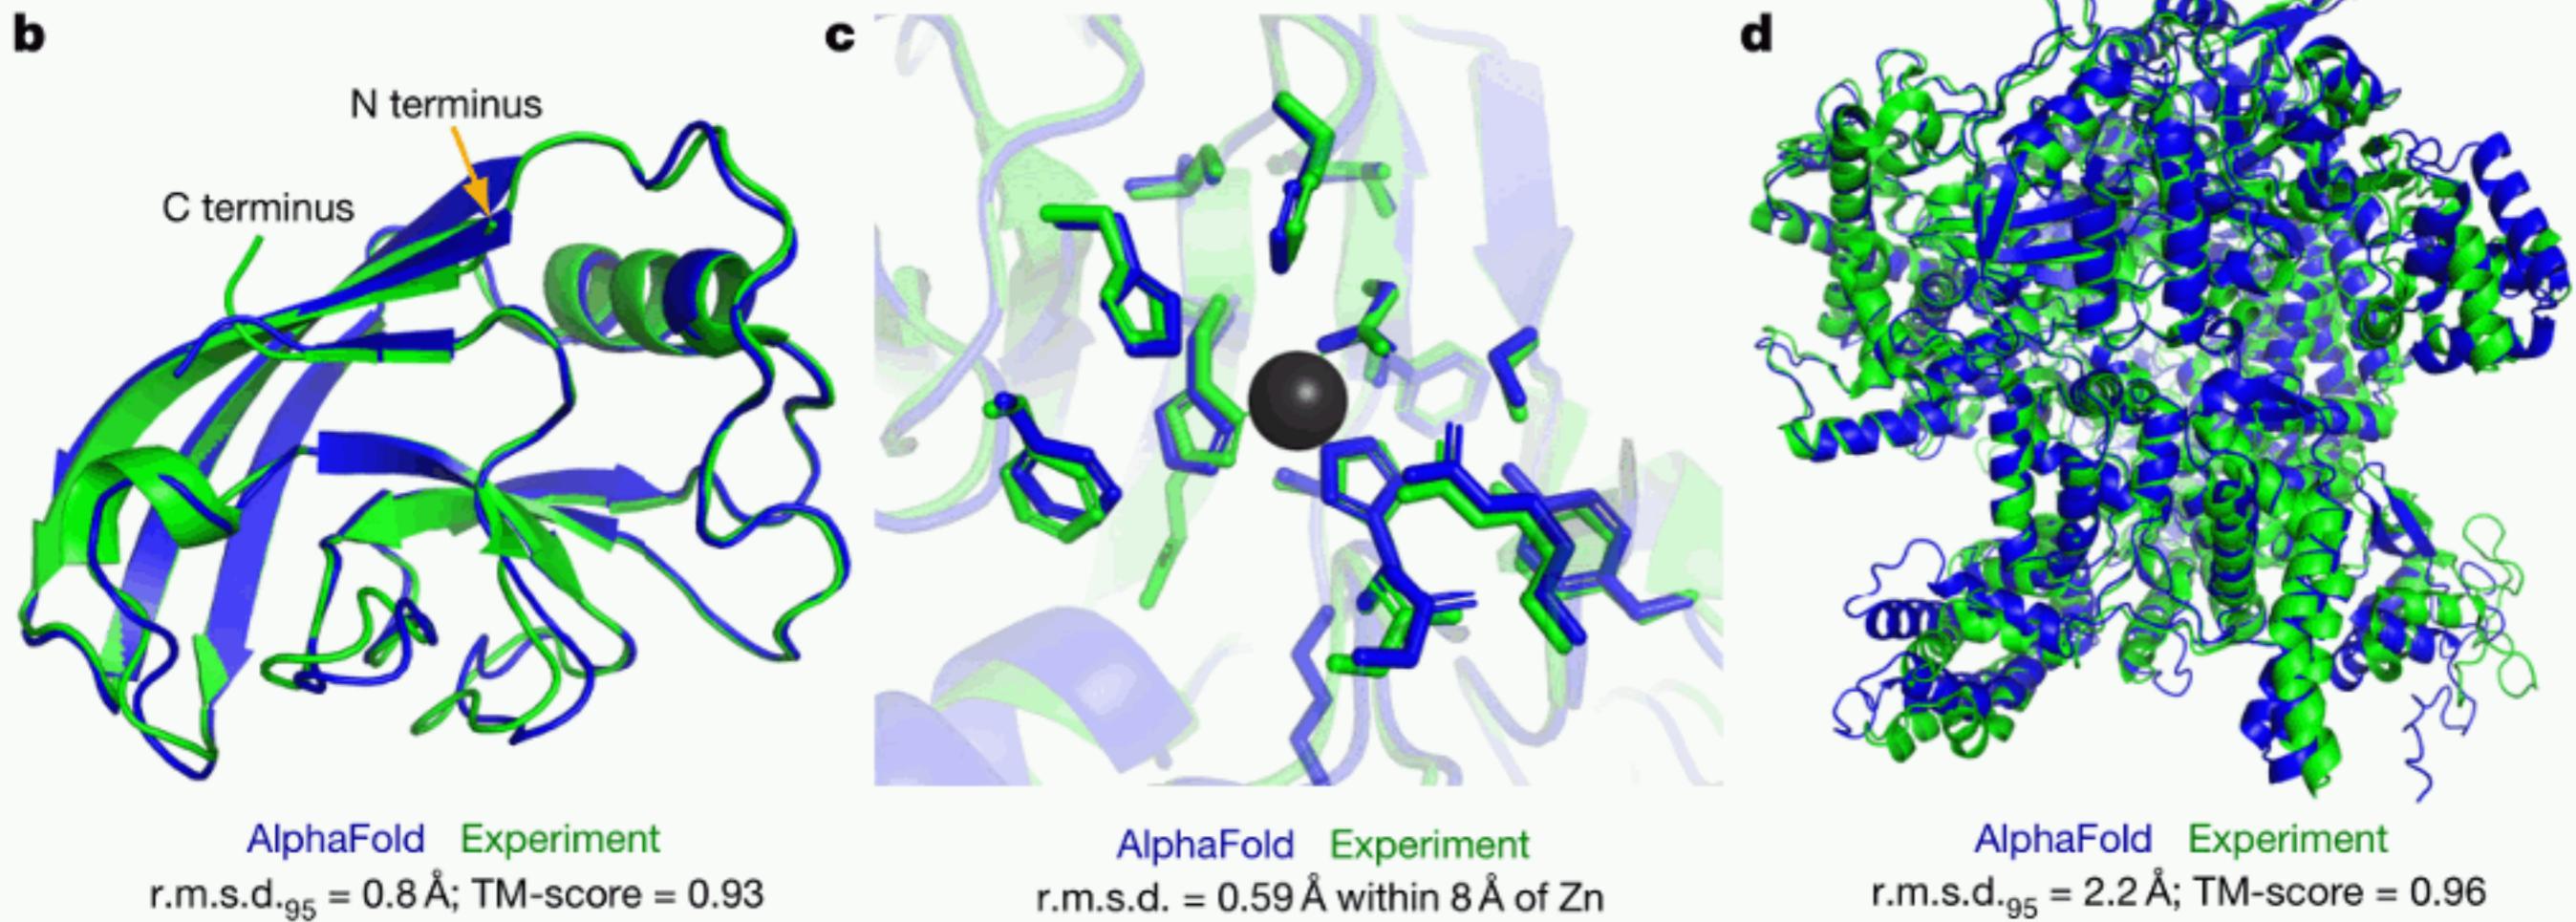
# AlphaFold

## Method of the Year 2021: Protein structure prediction

Protein structure prediction is our Method of the Year 2021, for the remarkable levels of accuracy achieved by deep learning-based methods in predicting the 3D structures of proteins and protein complexes, essentially solving this long-standing challenge.



# AlphaFold



# AlphaFold

