

# Modelli generativi per sequenze:

## “Recurrent Temporal Restricted Boltzmann Machines”



CCNL

Alberto Testolin

*Computational Cognitive Neuroscience Lab*

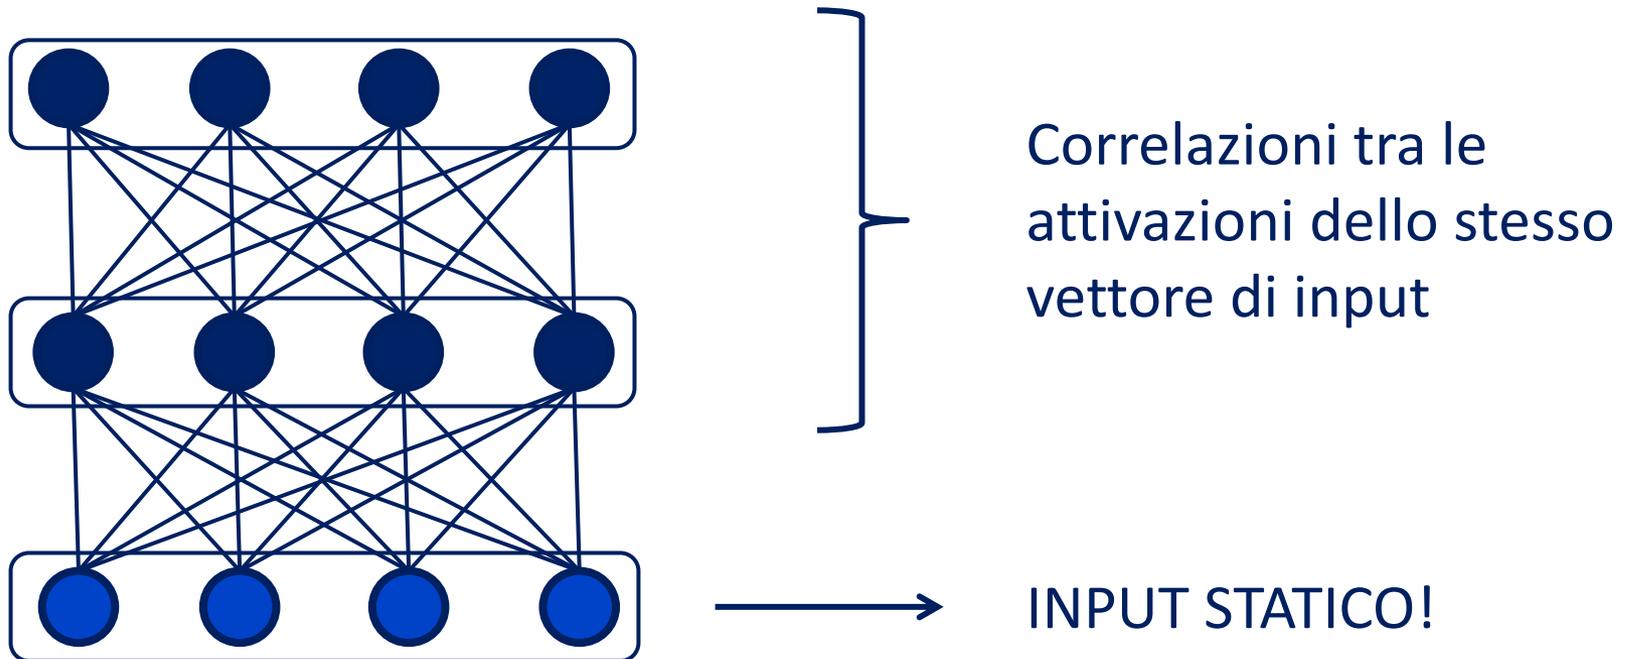
Dipartimento di Psicologia Generale

Università degli studi di Padova

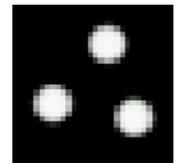
31.01.2013



# Standard (deep) RBM

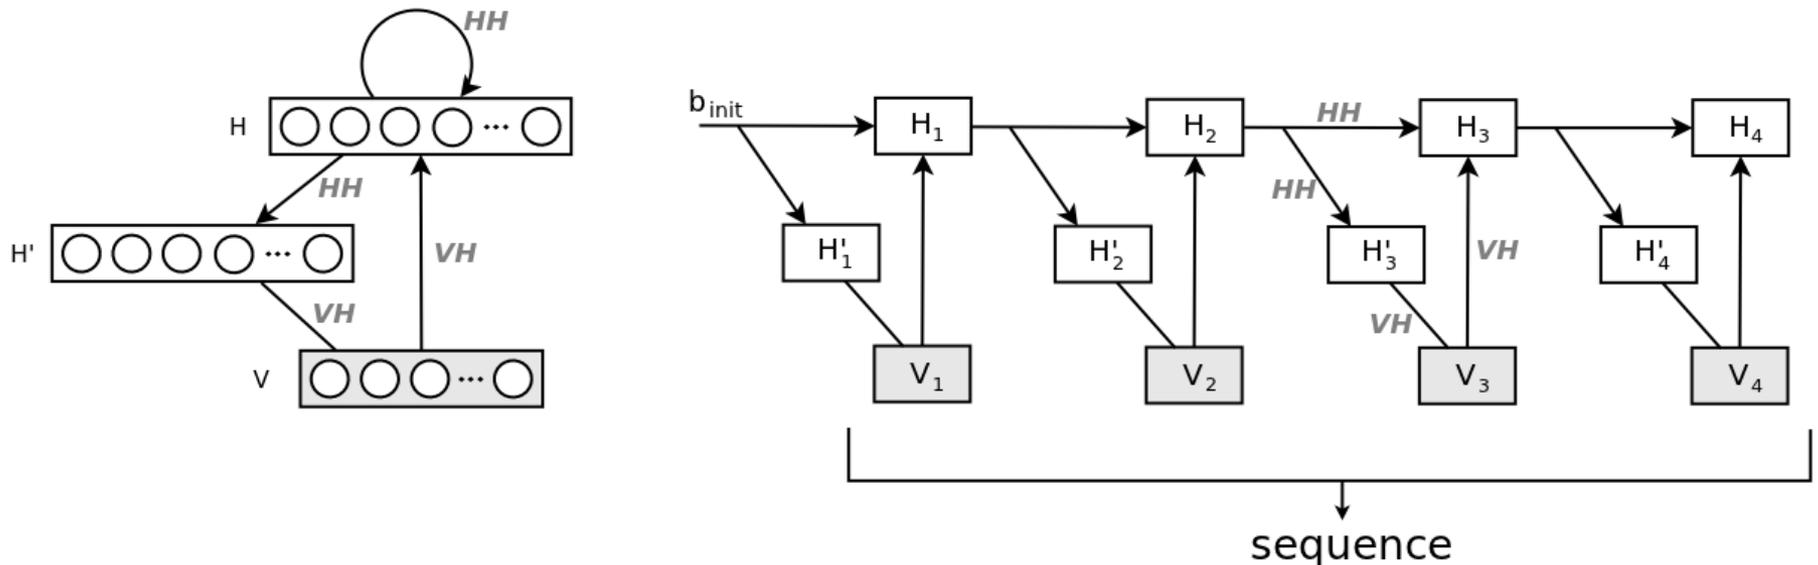


E' possibile estendere questo tipo di reti per consentire la modellazione della ***dinamica temporale*** dei dati di input?



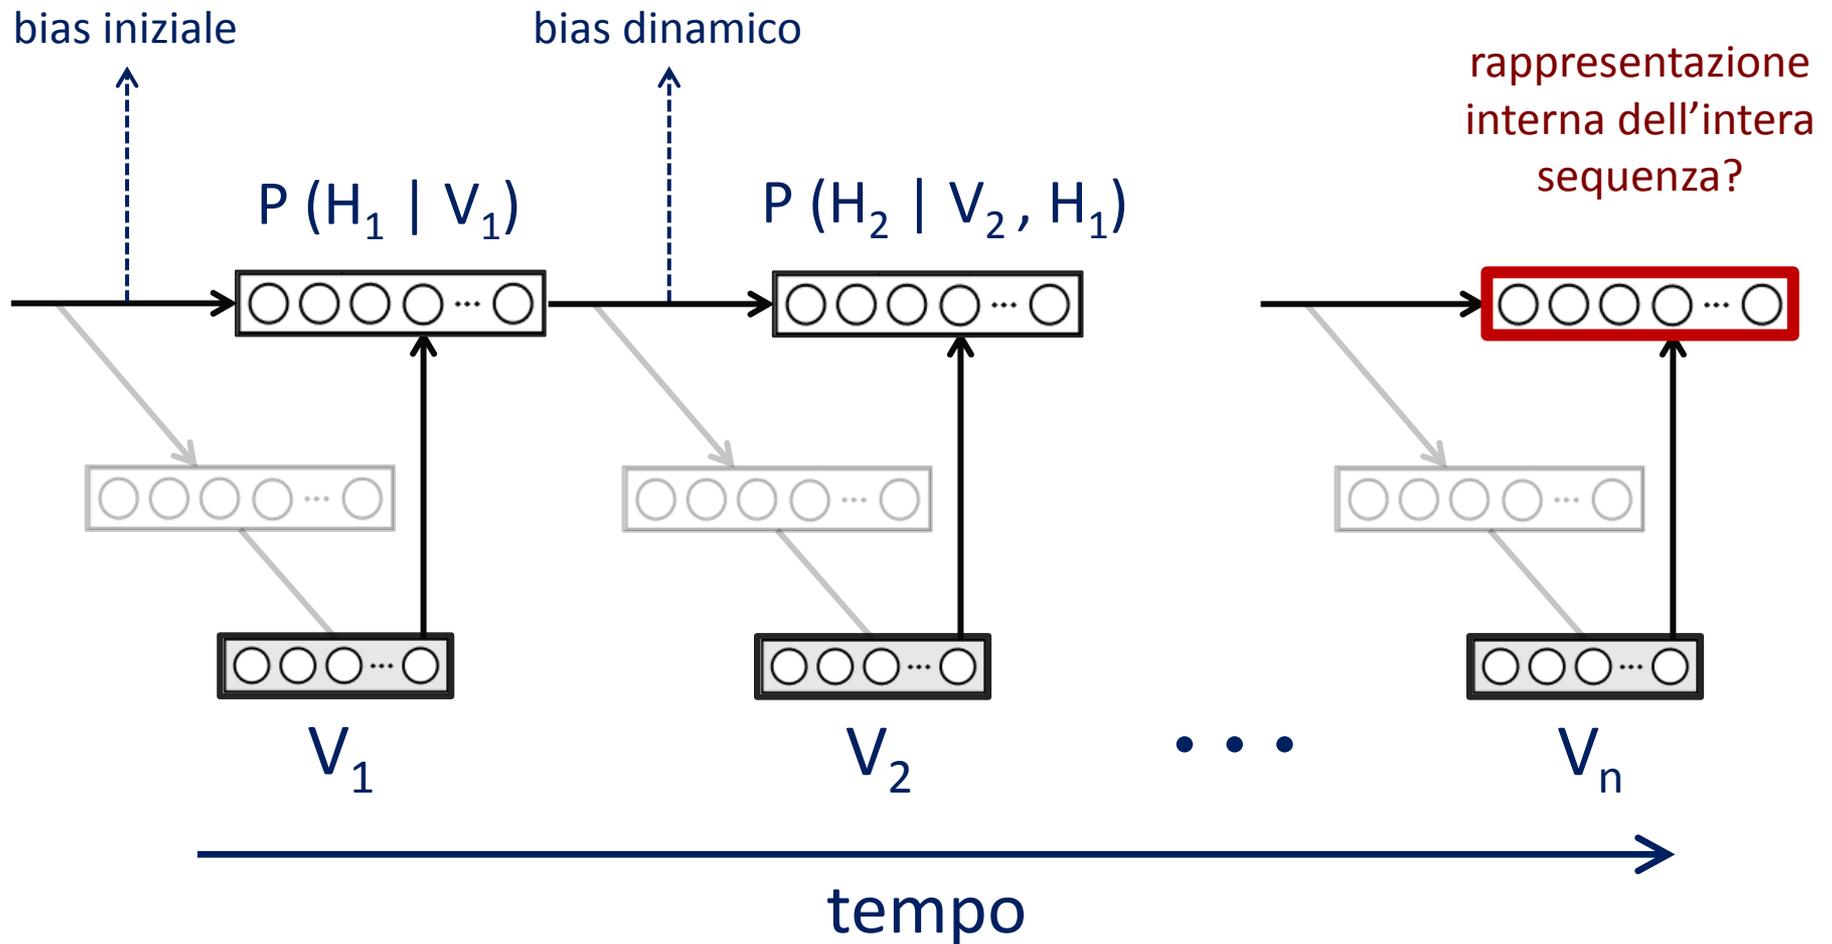
# Recurrent Temporal RBM (RTRBM)

Idea di base: dotare la rete di **connessioni ricorrenti** nello strato nascosto in modo da poter tener traccia degli stati passati

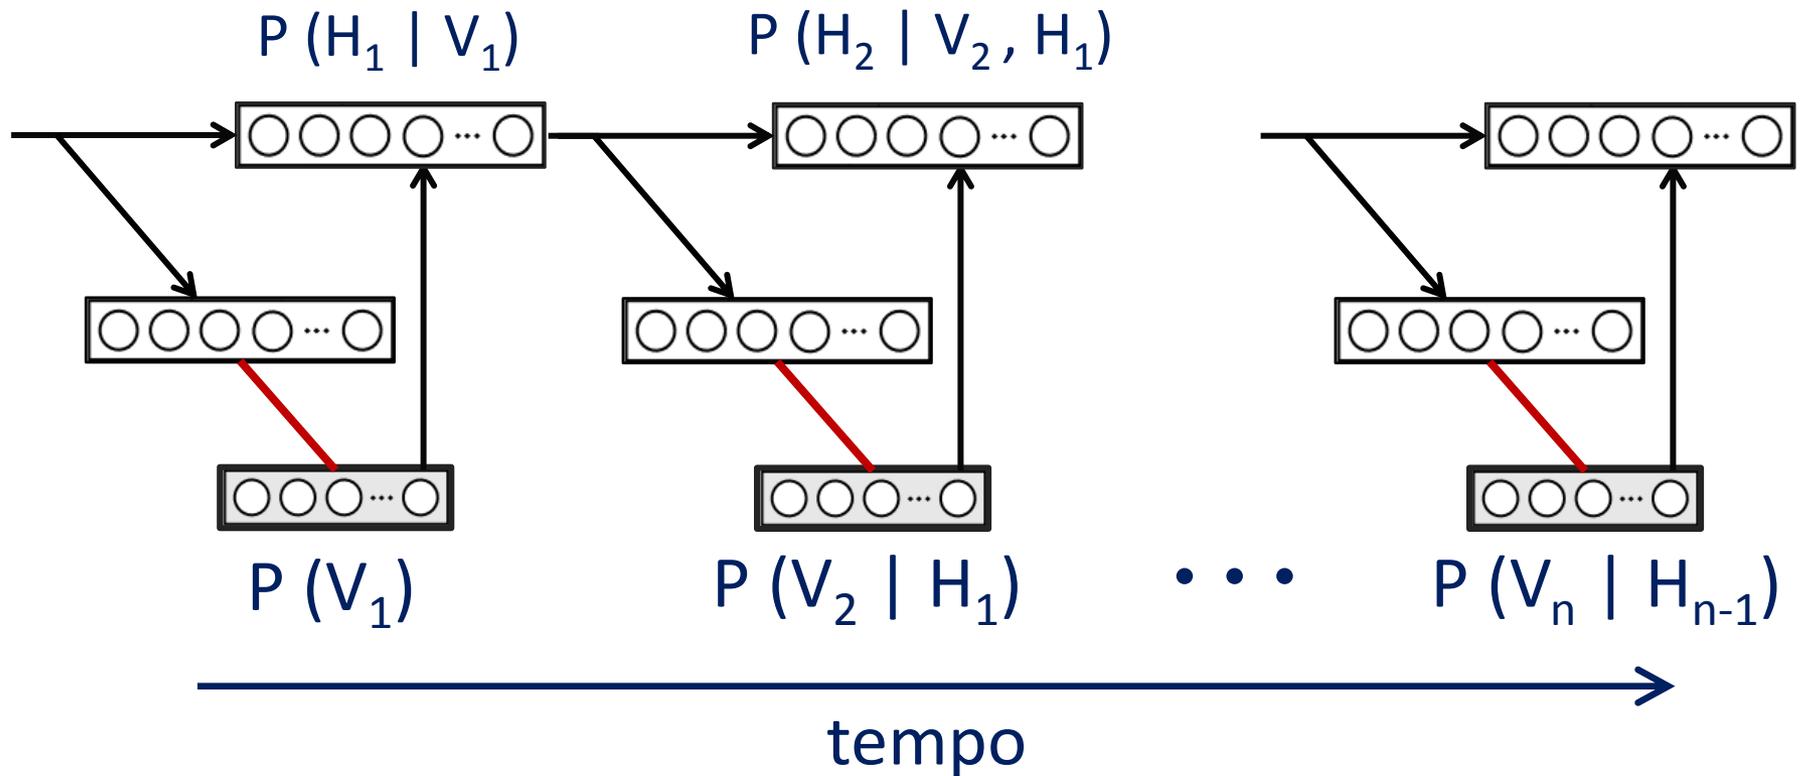


Apprendimento con **backpropagation through time**, ma **unsupervised**: il gradiente dell'errore viene approssimato con CD

# Dinamica del modello (inferenza)

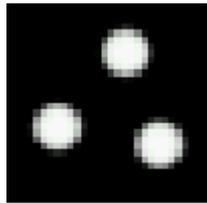


# Dinamica del modello (generazione)

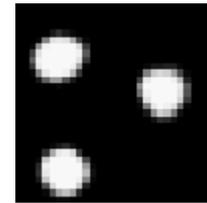


# RTRBM e sequenze video

- Sutskever, Hinton, Taylor (2008):  
modellazione di «bouncing balls» e motion capture  
→ dinamica *smooth*



sequenza di training

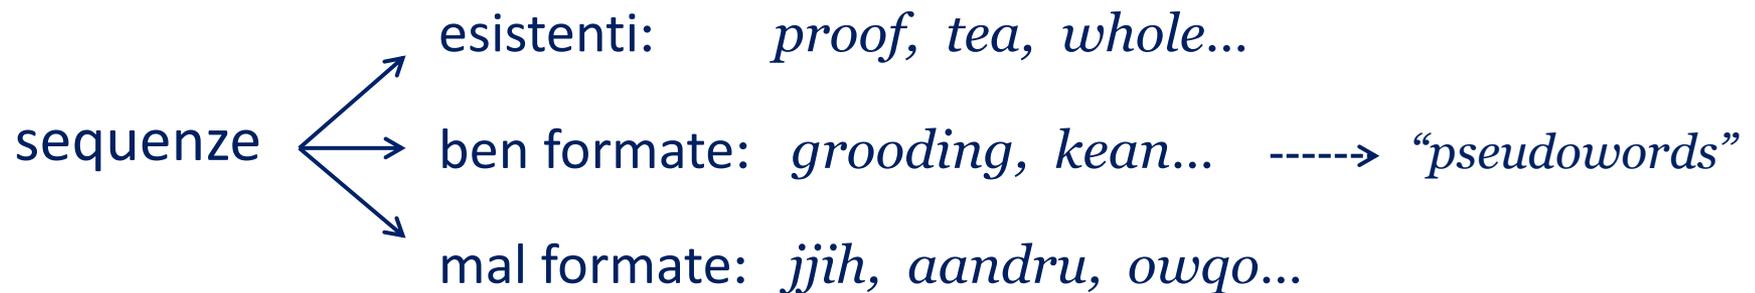


generazione del modello

- Quali sono le capacità del modello in un compito **simbolico**?  
→ dinamica *discreta*

# RTRBM e linguaggio

- Abilità linguistiche → elaborazione sequenziale
- Parole = sequenze di lettere, disposte secondo regole di composizione (*language-specific*)



- Regole di composizione apprese implicitamente (apprendimento statistico) durante l’acquisizione del linguaggio parlato (regole fonotattiche) e scritto (regole grafotattiche)

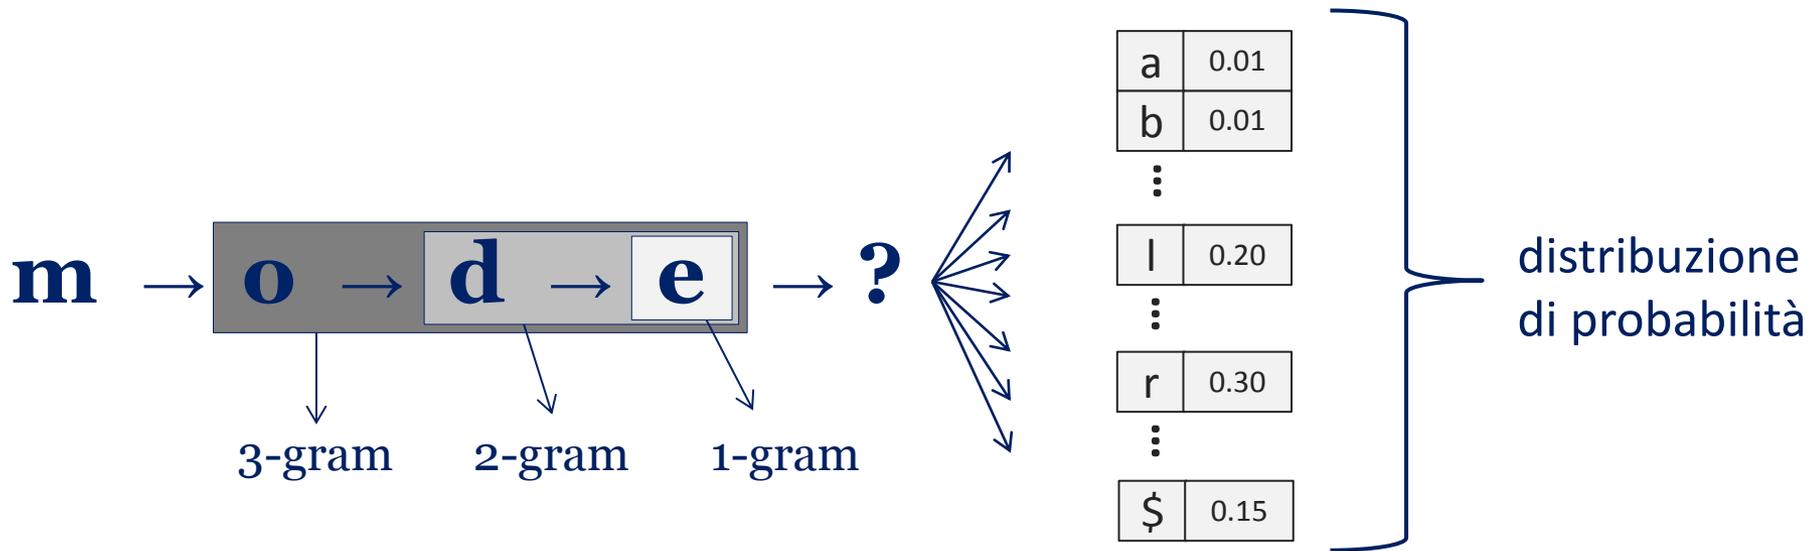
# Metodo e dettagli

- Dataset: lista di monosillabi inglesi (da 3 a 7 lettere)
  - Training set: 5300 parole
  - Test set: 1370 parole
- Lettere presentate alla rete una alla volta
  - Codifica simbolica: 27 neuroni binari (a..z + \$)
  - Dimensione dello strato nascosto: 200 neuroni
- Apprendimento «mini-batch» e parallelizzazione su processori grafici (GPU) per ridurre i tempi di calcolo
  - Speed-up: 25x

# Risultati principali (1)

La rete è in grado di estrarre regole di transizione tra gli elementi di una sequenza

→ analisi dell'accuratezza di predizione del modello e confronto con altri modelli sequenziali (*n*-grams e *Hidden Markov Models*)



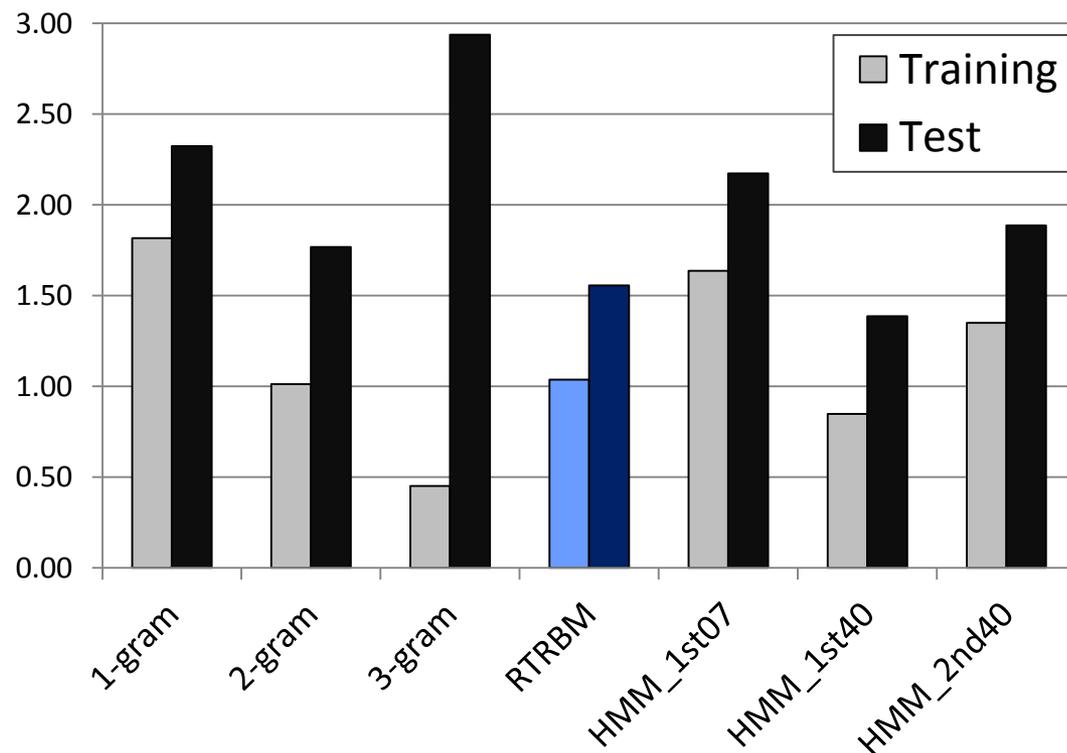
# Risultati principali (1)

Divergenza di Kullback-Leibler tra la distribuzione del successore predetta dal modello e quella empirica (ricavata dalle parole del dataset)

$$D_{KL}(P||Q) = \sum_i \log \frac{P(i)}{Q(i)} P(i)$$



calcolata su tutti i possibili contesti (i.e., prefissi)



# Risultati principali (2)

La rete è in grado di generare autonomamente nuove sequenze

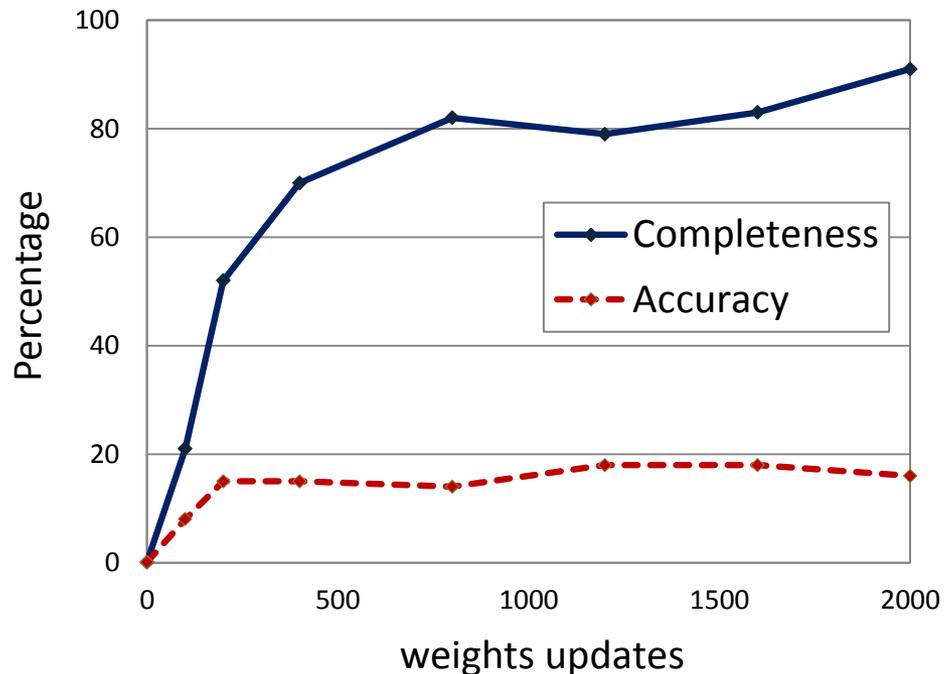
→ analisi della completezza e dell'accuratezza della generazione

Pseudowords:

*craged – fooped – reaved – thinked –  
dramped – dritch – peares...*

Sequenze mal formate:

*suffft – rivbt – prexked – mumlse –  
taat ...*

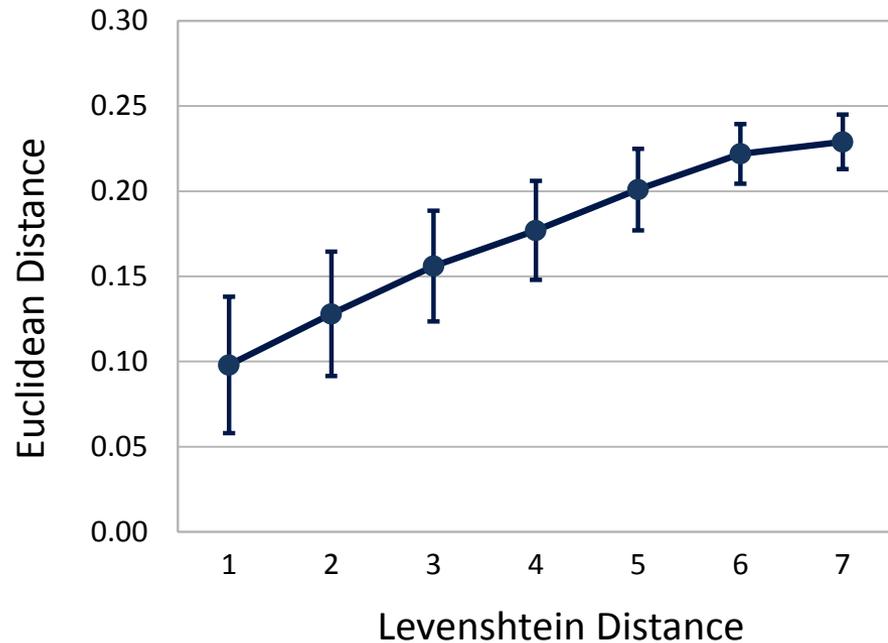


# Risultati principali (3)

La rete è in grado di creare una rappresentazione distribuita «olistica» di un'intera sequenza?

→ sembra di no

più le parole sono simili,  
più le rappresentazioni  
diventano indistinguibili



# Riassumendo...

- Modelli associativi basati su macchine di Boltzmann possono essere estesi per manipolare informazione temporale
- Buone prestazioni in predizione
- Capacità di generare sequenze autonomamente
- Apprendimento non supervisionato e locale, biologicamente più plausibile rispetto a reti neurali tradizionali
- Formulazione nel contesto dei modelli grafici probabilistici

## LIMITI:

- Backpropagation Through Time
- Compressione (con perdita) dell'informazione
- Modello non gerarchico (i.e., non deep)

[...FINE]