



O Projeto Estatístico das Redes Neurais

Validação guiada por hipóteses para a modelagem de dinâmicas caóticas


Baseado na pesquisa de G. B. do Vale, L. S. Garcia, W. S. Ting, e M. K. Madrid (UNICAMP).

O Problema: Convenção em Vez de Evidência


Decisão Arquitetural	O Hábito Cego	A Alternativa Estatística
 Topologia	Sempre usar LSTM para séries temporais 	Teste de Markovianidade (MLP vs LSTM) 
 Ativação	O padrão da indústria é ReLU 	Teste de Paridade RESET para simetria (tanh) 
 Função de Perda	MSE (Erro Quadrático Médio) por padrão $\text{MSE} = \frac{1}{n} \sum (y_i - \hat{y}_i)^2$	Ajuste t-Student para caudas pesadas (Huber) $\mathcal{L}_{\text{Huber}}(a) = \dots$ 

As redes neurais são tratadas como caixas pretas. Este estudo prova que escolhas arquiteturais podem ser respondidas matematicamente antes do treinamento e validadas depois.

O Framework de Validação em Malha Fechada



O Ambiente de Teste: Pêndulo Invertido Duplo



Dataset

50.000 amostras
(Geradas via MuJoCo).
Divididas em 5
episódios isolados.

Vetor de Estado (Input)

$\mathbf{x}(t) = [\sin(\theta_1),$
 $\cos(\theta_1), \sin(\theta_2),$
 $\cos(\theta_2), \cos(\theta_2),$
 $\omega_1, \omega_2, \tau_1, \tau_2]$


Alvo (Output)

Acelerações
angulares futuras
 $[\alpha_1, \alpha_2]$.

Protocolo

Validação rigorosa.
Divisão treino/teste
estritamente por
episódios para evitar
vazamento temporal.

O Projeto Mestre: As 5 Hipóteses



Hipótese	Teste Estatístico	Decisão	Experimento (Validação)
H1 - Acoplamento	Teste F-parcial	Input 8-D	Ablação de θ_1
H2 - Acoplamento	Teste F-parcial	Input 8-D	Ablação de θ_2
H3 - Markovianidade	Teste de Permutação	Feedforward MLP	LSTM vs MLP
H4 - Paridade Não-Linear	Teste RESET	Ativação tanh	tanh vs ReLU
H5 - Perda Robusta	Ajuste t-Student	Perda Huber	Huber vs MSE


H2: Validação Direta de Relevância

O Teste F-parcial previu que o ângulo θ_2 contribui enormemente (+26.50% de ΔR^2) para prever α_1 .

O que acontece se removermos θ_2 da rede neural treinada?

-3.69%↓

Queda real de ΔR^2 na rede neural. R-quadrado colapsa de 0.9999 para 0.9629.



A rede altamente não-linear sofre degradação consistente com a previsão estatística linear. Hipótese validada.

H1: O Paradoxo da Redundância Não-Linear

The Paradox

O teste linear prova que θ_1 é causalmente relevante.

Mas ao remover θ_1 da rede neural, a predição de α_2

MELHORA.

(RMSE cai de 0.919 para 0.683).

Stat Card Focus


MELHORA↑

Intervalo de Confiança inteiramente negativo $[-0.010\%, -0.002\%]$.

Remoção de θ_1 **aumenta generalização.**

The Revelation

A Revelação: A MLP recupera a contribuição de θ_1 através de combinações não-lineares das outras variáveis. Incluir θ_1 explicitamente gera uma redundância que prejudica a rede.




H3: A Ilusão da Memória Temporal

LSTM


80.802 parâmetros.
Recebe sequência
de 10 passos.

MLP

26.050 parâmetros.
Recebe apenas o
estado atual $x(t)$.



**IC 95% inteiramente menor
que 0 → MLP Vence.**




O teste previu que o sistema
era apenas "**marginalmente
não-Markoviano**" (Paradoxo
do tamanho da amostra).

A rede neural confirmou e
amplificou isso: a topologia
Feedforward (MLP) superou
a Recorrente (LSTM) usando
3x menos parâmetros.


H4: A Mecânica da Ativação (Teste RESET)

ReLU: Falha Mecânica




ReLU falha. Fronteira linear não possui simetria ímpar.

tanh: Validação Mecânica




tanh validada. Absorve perfeitamente a não-linearidade ímpar do pêndulo.

Dados e Conclusão: Teste RESET



Stat Card
IC 95% inteiramente > 0
 $R^2_{\text{tanh}} = 0.99986$
 $R^2_{\text{ReLU}} = 0.99699$
 $\Delta R^2 = +0.287\%$
→ **tanh VALIDADA (H4)**





Stat Card
IC 95% inteiramente > 0
 $R^2_{\text{tanh}} = 0.99987$
 $R^2_{\text{ReLU}} = 0.99834$
 $\Delta R^2 = +0.153\%$
→ **tanh VALIDADA (H4)**

tanh VALIDADA


O teste de paridade RESET nos resíduos é a prova mecânica: a ReLU deixa estrutura ímpar não explicada (rejeita H_0 , $p < 0.05$). A tanh captura a dinâmica por completo (não rejeita H_0).

H5: Sobrevivendo às Caudas Pesadas

Heavy-Tail Funnel



Huber demonstra uma vantagem drástica no RMSE dos 5% de amostras extremas.



Huber iguala ou supera MSE no R-quadrado geral, mas sobrevive à massa residual concentrada nas caudas pesadas.

Os Três Níveis de Validação

O Paradoxo Não-Linear (H1)

O momento "Aha!". Uma feature estatisticamente relevante no mundo linear se torna uma redundância nociva em uma rede não-linear, prejudicando a generalização.

O Paradoxo Não-Linear (H1)

Confirmação Amplificada (H3 e H5)

A rede se comporta exatamente como o teste estatístico linear previu (direção e magnitude). Substituir a ativação ou fazer ablação gera o impacto esperado.

Confirmação Amplificada (H3 e H5)

O teste sugere uma vantagem sutil, e a capacidade não-linear da rede a amplifica (A simplicidade da MLP destruindo a LSTM; Huber dominando em amostras extremas).

Confirmação Direta (H2 e H4)

A rede se comporta exatamente como o teste estatístico linear previu (direção e magnitude). Substituir a ativação ou fazer ablação gera o impacto esperado.

Teste de hipótese não serve apenas para "escolher camadas". É um instrumento para interpretar como classes de funções não-lineares aprendem a realidade.

O Fim da "Caixa Preta" Arquitetural

A Estatística Substitui a Convenção.

Ferramentas estatísticas clássicas (F-parcial, RESET, t-Student) são guias **definitivos** para design de redes neurais em sistemas físicos.

Validação Pós-Treino.

Testes prévios devem ser **empiricamente validados** por distribuições block-bootstrap de ΔR^2 , unindo a predição estatística ao comportamento real.

Correspondência Direcional.

Efeitos projetados por testes lineares são **direcionalmente reproduzidos** por redes treinadas, fornecendo **explicabilidade mecanicista** ao deep learning.

**Arquiteturas não devem ser adivinhadas.
Elas devem ser deduzidas, testadas e provadas.**