

PALESTRA



Promoção:



IBAPE NACIONAL
Instituto Brasileiro de Avaliações
e Perícias de Engenharia

Realização:



IBAPE BAHIA
Instituto Brasileiro de
Avaliações e Perícias de
Engenharia da Bahia

REGRESSÃO POLINOMIAL E REDES NEURAIS ARTIFICIAIS

Norberto Hochheim

- Engenheiro Civil (UFSC)
- Mestre em Engenharia de Produção (UFSC)
- Doutor pela *Université de Nancy I* (França)
- Professor Titular da UFSC
- Coordenador do Programa de Pós-Graduação em Engenharia de Transportes e Gestão Territorial (PPGTG)
- Coordenador do Grupo de Pesquisa em Engenharia de Avaliações e Perícias (GEAP)


REGRESSÃO POLINOMIAL E REDES NEURAIS ARTIFICIAIS

Objetivos:

- **Discorrer** sobre **regressão polinomial (RP)** e **redes neurais (RNs)**
 - Diferenças
 - Similaridades
- Apresentar **estudo de caso**



REDES NEURAIS ARTIFICIAIS




$$v_k = \sum_{j=1}^n w_{kj} \cdot x_j + b_k$$

$$y_k = \varphi(v_k)$$

REDES NEURAIS ARTIFICIAIS

Função de ativação (φ): limita o intervalo permissível de amplitude do sinal de saída (y_k)



(a) degrau

(b) linear

(c) logística

(d) tanh

Fonte: Fiorin *et al* (2011)




APRENDIZAGEM DE UMA REDE NEURAL

RNs **aprendem por** intermédio de **exemplos** e analisam os seus resultados, **melhorando** gradativamente o seu **desempenho**

- Para a aprendizagem, as RNs usam um **algoritmo** cuja tarefa é **ajustar os pesos** de suas conexões
- **Overfitting**: a rede ‘decora’ os dados, ao invés de aprender os seus padrões (perde capacidade de generalização)





Entrada: $X_1 X_2 X_3$

Saída: Y

Modelo: $Y = f(X_1 X_2 X_3)$

$$0.2 = 0.5 * 1 - 0.1 * (-1) - 0.2 * 2$$

$$f(x) = e^x / (1 + e^x)$$

$$f(0.2) = e^{0.2} / (1 + e^{0.2}) = 0.55$$


Y previsto = 0.478

Se $Y = 2$
então

$$\text{Erro} = (2 - 0.478) = 1.522$$



RNA: Treinamento do modelo



$$E = \sum (Y_i - V_i)^2$$

- **Inicie** com um conjunto de pesos aleatórios
- Passe a **primeira observação** (Y_1) pela rede
Valor estimado: V_1 Erro = $(Y_1 - V_1)$
- **Ajuste de pesos** de maneira a reduzir este erro
(modelo faz um bom ajuste para a primeira observação)
- Passe a **segunda observação** (Y_2) pela rede
(**Ajuste de pesos** para um bom ajuste da segunda observação)
- **Repita** a observação até a última observação (Y_n)
- **Fim** do primeiro ciclo de treinamento
- **Repita** os ciclos de teinamento até que o **erro do modelo (E)** seja pequeno para todo o conjunto de dados

RNA: Treinamento do modelo – Critério de Convergência

Dividir os dados em **2 conjuntos**:


- de **treinamento**: para construir o modelo
- de **validação**: para testar a performance do modelo

Ao longo dos **ciclos** de treinamento:

- ✓ Erro no conjunto de **treinamento diminui**
- ✓ Erro no conjunto de **validação primeiro cai e depois aumenta** (overfitting)



RNA: Treinamento do modelo - Critério de Convergência



- **Termine** o treinamento quando o **erro** no conjunto de **validação** **aumenta**

Regressão Polinomial (RP)

RLS

$$y = f(x_1) = \beta_0 + \beta_1 x_1 + e$$

RLM

$$y = f(x_1, x_2, \dots, x_m) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_m x_m + e$$

RP

$$y = f(x_1) = \beta_0 + \beta_1 x_1 + \beta_2 x_1^2 + \dots + \beta_m x_1^m + e$$

RP

$$y = f(x_1, x_2) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_1^2 + \beta_4 x_2^2 + \beta_5 x_1 x_2 + e$$

Redes Neurais (RN) **são** Regressões Polinomiais (RP)

Matloff et al. (2018)

1º Caso: Redes Neurais (RN) com

Funções de Ativação polinomiais

O argumento básico: Considere o caso com $p = 2$. Sejam as variáveis u and v . As entradas para a primeira camada oculta, incluindo o nó “1”, serão da forma:

$$a00 + a01u + a02v \quad \text{e} \quad a03 + a04u + a05v$$

Exemplo: função de ativação $a(t) = t^2$

- Saídas da **primeira** camada serão **funções quadráticas** de u e v
- **Segunda** camada produzirá polinômios de **grau 4**
- **Depois**, de **grau 8** e assim por diante
- Funciona da mesma maneira para qualquer função de ativação polinomial
- Assim, para uma função de ativação polinomial, **treinar uma rede neural é a mesma coisa que uma regressão polinomial**



Redes Neurais (RN) **são** Regressões Polinomiais (RP)

Matloff et al. (2018)

2º Caso: Redes Neurais (NN) com Funções de Ativação Transcendentais

Considerando agora funções de ativação mais realistas, como funções transcendentais do tipo ***tanh()***

Implementação computacional frequentemente usa **séries de Taylor**

Nestes casos, a situação é a mesma da anterior, e RNs são novamente RP



Redes Neurais (RN) **são** Regressões Polinomiais (RP)

Matloff et al. (2018)

3º Caso: Redes Neurais (NN) com Funções de Ativação Genéricas

Funções de ativação genéricas e implementações **são próximas de um polinômio**, de acordo com o **Teorema de Stone-Weierstrass**, que estabelece que **qualquer função** contínua de um conjunto delimitado pode ser **aproximado por polinômios**

Em qualquer situação, para **objetivos práticos**, a maioria das funções de ativação podem ser aproximadas por um polinômio



REGRESSÃO POLINOMIAL E REDES NEURAIS ARTIFICIAIS

Resumindo (Matloff et al., 2018):

- **redes neurais são** uma forma de **regressões polinomiais**
- para **cada camada** oculta de uma rede neural, há **um modelo** de regressão polinomial equivalente
- O **grau** da aproximação polinomial **aumenta** de **camada para camada** da rede neural



Por que existem problemas de convergência nas Redes Neurais?

- Modelos de **RP** tendem a produzir **multicolinearidade** quando em **graus maiores**
- Ver **RNs** como um **tipo de regressão polinomial** sugere que elas também sofrem de **problemas de colinearidade**
- Esta colinearidade **aumenta** de uma **camada para outra**, pois ela tende a aumentar com o grau do polinômio
- Assim, RNs podem sofrer de um **problema de colinearidade** oculto
- Isto pode resultar em **problemas de convergências** nas RNs



O que fazer para evitar problemas de convergência em RNs?

- Seria interessante **incluir** nos softwares de RNs **checagem para multicolinearidade**, camada por camada
- Caso a camada produza um alto grau de colinearidade, pode-se considerar **diminuir o número de neurônios** dela, ou mesmo **eliminar** esta **camada** por completo
- Assim, camadas posteriores podem ter menos neurônios do que camadas anteriores



Limitações da RP:

Memória, tempo de processamento e multicolinearidade

- **Redução da dimensão** via Análise de Componentes Principais (**ACP**) pode remediar problemas de memória, tempo de processamento e multicolinearidade
- Outra possibilidade: aplicar **ACP para a matriz** dos termos polinomiais, ao invés dos termos originais
- Multicolinearidade também pode ser tratada com **Regressão Ridge** ou **LASSO** (Least Absolute Shrinkage and Selection Operator)
- Multicolinearidade também pode ocorrer em RNs
- Multicolinearidade pode provocar **overfitting** em **RNs ou RP**



RP como alternativa à RN

- Matloff *et. al.* (2018) aplicaram RP e RNs através de várias implementações (Keras, DeepNet, NeuralNet) a vários conjuntos de dados
- Em todos os casos, **RPs** tiveram performance **similar ou superior** às **RNs**
- Exemplo: Resistência à compressão do concreto
1030 dados, 8 variáveis

Método	Correlação (Previsto vs. Observados)
NeuralNet	0,608
Keras Formula	0,546
PR, grau 2	0,869



ESTUDO DE CASO: Aptos Florianópolis




Dados coletados em
Abril/2015




ESTUDO DE CASO: Aptos Florianópolis

Ident	VT	Área Total	nº Quartos	nº Suítes	nº Garagens	Dist B Mar	Padrão	Coord E	Coord N
AP_01	1.060.000,00	350,00	3	1	2	720	2	741.617	6.945.437
AP_02	510.000,00	136,56	3	1	1	665	2	741.470	6.945.464
AP_03	780.000,00	164,77	3	1	2	415	2	741.562	6.945.757
AP_04	550.000,00	174,58	3	1	1	320	2	741.049	6.945.701
AP_05	850.000,00	123,01	3	1	3	895	3	741.859	6.945.340
AP_06	300.000,00	89,83	2	0	1	645	1	741.180	6.945.388
AP_07	750.000,00	174,00	2	1	2	860	3	741.989	6.945.407
AP_08	650.000,00	123,00	3	1	1	745	3	741.053	6.945.154
AP_09	620.000,00	121,00	3	1	1	745	3	741.009	6.945.298
AP_10	740.000,00	109,00	3	1	1	300	2	741.019	6.945.704
...	...	...	...	...	...	...	...	...	...
AP_49	1.650.000,00	246,00	3	3	3	307	3	742.188	6.946.149
AP_50	650.000,00	159,72	3	1	1	120	2	740.940	6.945.889
Aval	???	205,00	3	1	2	250	2	741.506	6.945.904

Regressão Linear Múltipla




Estatísticas (Resíduos)	
RLM	
Desvio médio Abs	118.431,60
Desvio médio Rel	11,4%
RMSE	179.634,41
Valor Estimado:	962.663,91



Estatísticas (Resíduos)	
RLM (Saneado)	
Desvio médio Abs	93.855,89
Desvio médio Rel	10,3%
RMSE	126.250,22
Valor Estimado:	961.660,64



Rede Neural - Software NN: Angshuman Saha



Amostra:

50 dados, 6 variáveis explicativas


Modelo:

Camada oculta: 1


Parâmetro de aprendizado: 0,4

Momentum: 0,4


Partição: 10% dos dados para validação
(seleção aleatória)




Amostra original



Validação: 14,95%
Treinamento: 9,49%




Amostra saneada




Validação: 13,21%
Treinamento: 7,48%



Rede Neural



Estatísticas (Resíduos)	
RN	
Desvio médio Abs	119.446,67
Desvio médio Rel	14,1%
RMSE	172.314,90
Valor Estimado:	1.013.207,17




Estatísticas (Resíduos)	
RN (Saneado)	
Desvio médio Abs	102.400,66
Desvio médio Rel	12,8%
RMSE	141.013,49
Valor Estimado:	965.886,27



Regressão Polinomial

Número grande de variáveis:


redução dimensional via Análise de Componentes Principais (ACP)




Fonte:
Software
IpeaGEO

IDENT	VT	Area_Total	N_Quartos	N_Suites	N_Garagens	Dist_BMar	Padrao	Comp_1	Comp_2
AP_01	1.060.000,00	350	3	1	2	720	2	156,314	180,391
AP_02	510.000,00	136,56	3	1	1	665	2	124,148	-37,659
AP_03	780.000,00	164,77	3	1	2	415	2	-127,433	-35,989
AP_04	550.000,00	174,58	3	1	1	320	2	-222,937	-36,268
AP_05	850.000,00	123,01	3	1	3	895	3	354,291	-26,841

Regressão Polinomial - Grau 2



Estatísticas (Resíduos)	
RP grau 2	
Desvio médio Abs	175.638,70
Desvio médio Rel	19,3%
RMSE	243.755,04
Valor Estimado:	1.153.131,16



Estatísticas (Resíduos)	
RP grau 2 (Saneado)	
Desvio médio Abs	81.700,91
Desvio médio Rel	13,0%
RMSE	101.644,68
Valor Estimado:	1.129.864,05



Regressão Polinomial - Grau 2

Fator de Inflação da Variância (FIV)


Variance Inflation Factor (VIF)

Valor limite: 10


Variável:	CP1	CP2	CP1^2	CP2^2	CP1*CP2
RP grau 2	1,43	2,51	1,17	2,65	1,55
RP grau 2 (Saneado)	1,63	1,78	1,24	1,65	1,50



Regressão Polinomial - Grau 3



Estatísticas (Resíduos)	
RP grau 3	
Desvio médio Abs	166.747,98
Desvio médio Rel	22,0%
RMSE	214.007,94
Valor Estimado:	1.186.470,30



Estatísticas (Resíduos)	
RP grau 3 (Saneado)	
Desvio médio Abs	64.202,57
Desvio médio Rel	11,0%
RMSE	76.362,30
Valor Estimado:	1.052.612,58



Regressão Polinomial - Grau 3

Fator de Inflação da Variância (FIV)

Variance Inflation Factor (VIF)


Valor limite: 10

Variável:	CP1	CP2	CP1^2	CP2^2	CP1*CP2	CP1^3	CP2^3	CP1*CP2^2	CP2*CP1^2
RP grau 3	5,07	7,01	5,66	17,92	3,69	11,80	28,76	5,87	5,68


Variável:	CP1	CP2	CP1*CP2	CP2^3	CP1*CP2^2
RP grau 3 (Saneado)	1,59	5,70	1,74	6,71	2,01



Melhor Rede Neural X Melhor Regressão Polinomial



Estatísticas (Resíduos)	
Rede Neural (Saneado)	
Desvio médio Abs	102.400,66
Desvio médio Rel	12,8%
RMSE	141.013,49
Valor Estimado:	965.886,27



Estatísticas (Resíduos)	
RP grau 3 (Saneado)	
Desvio médio Abs	64.202,57
Desvio médio Rel	11,0%
RMSE	76.362,30
Valor Estimado:	1.052.612,58



Rede Neural X Regressão Polinomial

Zilli, Droubi e Hochheim (2018), usando os mesmos dados realizaram os seguintes procedimentos:

1. Para uma determinada porcentagem **porc**, inicialmente de 20% do número de dados disponíveis n , foram criadas duas partições, uma partição de **treinamento**, com $\text{porc} \times n = 10$ dados e uma partição de **testes**, com $(1 - \text{porc}) \times n = 40$ dados, em que os dados das partições foram escolhidos randomicamente
2. Com as partições de treinamento assim obtidas, foram ajustados **100 modelos de regressão polinomial de grau 2**, ou de **redes neurais artificiais com 1 camada oculta**
3. Com os modelos obtidos no passo anterior, foram realizadas estimativas sobre os dados da **partição de testes** com respectivo cálculo da **RMSE**

Rede Neural X Regressão Polinomial

Zilli, Droubi e Hochheim (2018) - usando os mesmos dados realizaram os seguintes procedimentos:

4. Iterativamente aumentou-se, de **2 em 2 pontos percentuais** o tamanho da partição de **treinamento**, calculando-se o valor da **RMSE** para a **partição de teste**
5. Finalmente, comparou-se o comportamento dos **valores medianos do RMSE** com o aumento do número de dados da partição de testes para os dois métodos, assim como a **distribuição final do RMSE** com a utilização de **90% dos dados na partição de treinamento**

Software R:


RN → Neuralnet

RP → Polyreg

Redução Dimensional
→ MACP


Rede Neural: Resultados

Variação do RMSE
com o tamanho da partição de treinamento




Rede Neural: Resultados

Diagrama de Caixa do RMSE
partição de treinamento com 45 dados




Regressão Polinomial: Resultados




Regressão Polinomial: Resultados

Diagrama de Caixa do RMSE
partição de treinamento com 45 dados



com o tamanho da partição de treinamento



com o tamanho da partição de treinamento



Diagrama de Caixa do RMSE
partição de treinamento com 45 dados





Diagrama de Caixa do RMSE
partição de treinamento com 45 dados




Considerações Finais: Uma 'parceria' de sucesso:


$RLM + RP(coord\ X, coord\ Y) = ST\ (Superfície\ de\ Tendência)$

Fonte: GLANERT (2019)


ST (grau 1)




ST (grau 2)



ST (grau 3)




ST (grau 4)




Considerações Finais: Uma 'parceria' de sucesso:

$RLM + RP(coord\ X, coord\ Y) = ST\ (Superfície\ de\ Tendência)$



RLM



ST (grau 3)

Considerações Finais

- ✓ Resultados da raiz do erro médio quadrático (RMSE) para modelos de **regressão polinomial** foram **menores** e com menor dispersão quando comparados com os obtidos por **redes neurais artificiais**
- ✓ **Realizar mais estudos** relacionados ao uso da **regressão polinomial** na Engenharia de Avaliações
 - **Regressão polinomial** é um **caso particular de regressão linear**
 - **Método e aplicação** são conhecidos e estão **normalizados** pela NBR 14.653-02



FIORIN, D. V.; MARTINS, F. R.; SCHUCH, N. J.; PEREIRA, E. B. **Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares.** Revista Brasileira Ensino de Física. São Paulo, v. 33, n 11, mar. 2011.

GLANERT, A. **Diagnóstico e incorporação de efeitos espaciais aplicados à planta de valores genéricos no município de Nova Erechim-SC.** Monografia de especialização. Unochapecó, 2019.

GUARNIERI, Ricardo André. **Emprego de redes neurais artificiais e regressão linear múltipla no refinamento das previsões de radiação solar do modelo ETA.** Dissertação (Mestrado em Meteorologia) - Programa de Pós-Graduação em Meteorologia, IMPE, São José dos Campos, 2006.

HAYKIN, Simon. **Redes neurais: princípios e prática.** 2. ed. Porto Alegre: Bookman, 2001.

MATLOFF, Norman; CHENG, Xi; KHOMTCHOUK, Bohdan; MOHANTY, Pete. **Polynomial regression as an alternative to neural nets.** 2018. Disponível em: < <https://arxiv.org/abs/1806.06850>>. Acesso em outubro 2018.

SAHA, Angshuman. **Introduction to Artificial Neural Network Models.** Disponível em: <www.geocities.com/adotsaha/NNinExcel.html>. Acesso em agosto 2003.

ZILLI, C. A.; DROUBI, L. F. P.; HOCHHEIM, N. **Regressão polinomial e redes neurais artificiais: um estudo de caso.** Anais VIII Simpósio da Sociedade Brasileira de Engenharia de Avaliações (SOBREA), João Pessoa (PB), 2018.

Agradecimentos



**UNIVERSIDADE FEDERAL DE SANTA CATARINA
(UFSC)**

**PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE TRANSPORTES E GESTÃO
TERRITORIAL (PPGTG)**



IBAPE-SC

Instituto Catarinense de Engenharia
de Avaliações e Perícias



OBRIGADO !

hochheim@gmail.com

norberto.nochheim@ufsc.br

UFSC - Universidade Federal de Santa Catarina
IBAPE-SC

