

# APLICANDO REDES NEURAIS E ESTIMATIVA ANÁLOGA PARA DETERMINAR O ORÇAMENTO DO PROJETO

## *Publicações*

PMI Global Congress 2015 - América do Norte

Orlando – Flórida – EUA – 2015

## Resumo

### Podcasts Relacionados

🎵 Importância da Estrutura Analítica (EAP) no Gerenciamento de Custos do Projeto  
<http://rvarg.as/93>

🎵 Estimativas de Custos – Parte 1 de 3  
<http://rvarg.as/ct>

🎵 Estimativas de Custos – Parte 2 de 3  
<http://rvarg.as/cz>

🎵 Estimativas de Custos – Parte 3 de 3  
<http://rvarg.as/d1>

🎵 Aplicando Redes Neurais e Estimativa Análoga para Determinar o Orçamento do Projeto  
<http://rvarg.as/ev>

Este artigo procura discutir o uso de Redes Neuras Artificiais (RNAs) para modelar aspectos do orçamento do projeto em casos em que os algoritmos tradicionais e fórmulas não estão disponíveis ou não são de fácil aplicação. Redes neurais usam um processo análogo ao cérebro humano, onde um componente de treinamento é feito a partir de dados existentes e, subseqüentemente, têm-se uma rede neural treinada “especialista” na categoria de informação analisada. Esse “especialista” pode, então, ser utilizado para fazer projeções a partir de novas situações baseadas numa aprendizagem adaptativa (STERGIOU & CIGANOS, 1996).

O artigo também apresenta um exemplo fictício que ilustra o uso de redes neurais para determinar o custo das atividades de gerenciamento do projeto de acordo com a complexidade, localização, orçamento, duração e número de stakeholders considerados relevantes. O exemplo baseia-se em dados de 500 projetos e é usado para prever o custo do gerenciamento de um novo projeto.

## Redes Neurais Artificiais (RNA)

Algumas categorias de problemas e desafios enfrentados em ambientes de projetos podem depender de vários fatores sutis de tal maneira que um algoritmo computacional não pode ser criado para calcular seu resultado (KRIESEL, 2005). Redes Neurais Artificiais (RNAs) são uma família de modelos estatísticos de aprendizagem cujo funcionamento é inspirado na maneira com que sistemas nervosos biológicos, como o cérebro, processam informação. Eles processam registros um por vez, e “aprendem” comparando os resultados obtidos com os resultados reais previamente conhecidos.

Os erros da classificação inicial do primeiro registro são retroalimentados à rede e são usados para modificar os algoritmos da mesma para a segunda iteração, e assim por diante continua, para um grande número de repetições, num processo de aprendizagem cujo o objetivo é prever resultados confiáveis a partir de dados complicados ou imprecisos (STERGIOU & CIGANOS, 1996) (Figura 01).

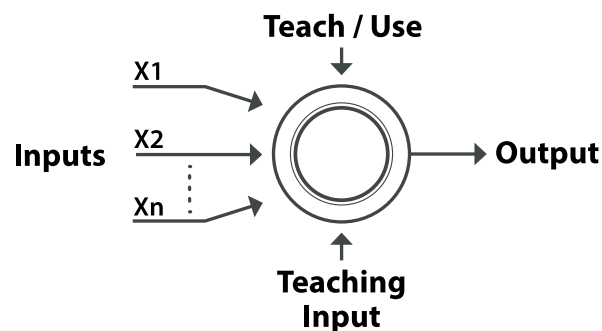


Figura 01 - Arquiteturas de Redes Neurais Artificiais (adaptado de MCKIM, 1993, e STERGIOU & CIGANOS, 1996)

Algumas aplicações típicas das RNAs são:

- *Reconhecimento de escrita;*
- *Previsões no mercado de ações;*
- *Compressão de imagens;*
- *Gerenciamento de riscos;*
- *Previsão de vendas;*
- *Controle de processos industriais.*

O processo matemático que fundamenta os cálculos usa diferentes configurações de redes neurais para um melhor ajuste para as previsões. Os tipos mais comuns de redes são descritos a seguir.

**Redes Neurais Probabilísticas (RNP)** – Algoritmos estatísticos onde as operações são organizadas em redes multicamadas sem realimentação (“feedforward”). É composta por quatro camadas (entrada, padrão, somas e saída). É treinada mais rapidamente mas possui uma execução mais lenta e requer muita memória. Tam-

bém não é tão geral quanto as outras redes sem realimentação (CHEUNG & CANNONS, 2002).

**Redes Multicamadas sem Realimentação (RMSR)** – RMSR, treinadas com algoritmos de aprendizagem com retropropagação (Figura 02). São os modelos mais populares de redes neurais (SVOZIL, KVASNIČKA & POSPÍČHAL, 1997).

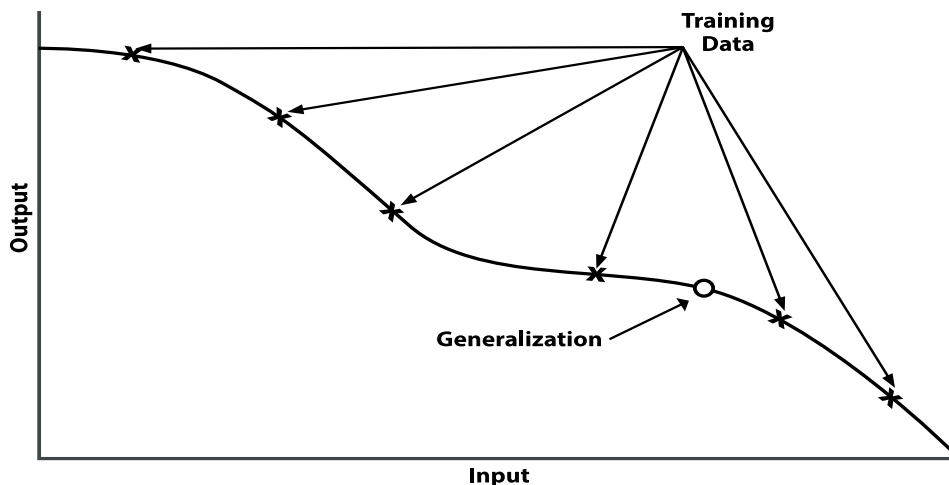


Figura 02 - Dados de treinamento do modelo e generalização em Redes Multicamadas sem Realimentação SVOZIL, D, KVASNIČKA, V. & POSPÍČHAL, J., 1997)

**Redes Neurais com Regressão Generalizada (RNRR)** – Semelhante às RNP, é uma rede “baseada em memória” (registros prévios) que fornece estimativas para variáveis contínuas. O algoritmo pode ser utilizado para qualquer problema de regressão onde a premissa de linearidade não é justificada (SPECHT, 2002).

## Processo de Analogia e Conjunto de Dados

Um dos pontos principais das Redes Neurais é o conjunto de dados usados para o processo de aprendizagem. Se o conjunto não for consistente, os resultados obtidos a partir dos cálculos também não serão. O uso de Redes Neurais Artificiais pode ser considerado um tipo de analogia (BAILER-JONES & BAILER-JONES, 2002).

A analogia é uma comparação entre dois ou mais elementos, tipicamente com o propósito de explicação ou esclarecimento (Figura 03). Um dos mais relevantes usos da analogia é previsão de resultados futuros baseados em resultados similares obtidos em condições similares (BARTHA, 2013). O desafio é entender o que é uma condição similar. Projetos no passado podem ser utilizados como referência para projetos futuros se as condições subjacentes anteriores persistem no cenário atual.



Figura 03 - Exemplo de uma simples analogia: “meias são para os pés e luvas são para as mãos” (Adaptada de Spitzig, 2013)

Um dos aspectos mais relevantes da analogia está relacionada com um processo simples de estimativas baseado em fatos e eventos semelhantes. Esse processo reduz a granularidade de todos os cálculos, onde os custos finais do projeto podem ser determinados por uma série de variáveis fixas e finitas.

### Conjunto de Dados, Categorias Dependentes e Independentes e Variáveis Numéricas

O primeiro passo para desenvolver uma Rede Neural Artificial é preparar um conjunto básico de dados que será utilizada como referência no “processo de treinamento” da rede neural. É importante salientar que construir um conjunto correto de dados para o processo é usualmente caro e consome tempo (INGRASSIA & MORLINI, 2005). Esse conjunto de dados é composto por uma série de variáveis que formatam a referência do treinamento. Cada composição de variáveis agrupada é chamada de caso (Figura 04).

		VARIABLES					DEPENDENT VARIABLE (OUTPUT)
		INDEPENDENT VARIABLES					
		V1	V2	V3	.....	Vn	
CASES	Case 1						V'1
	Case 2						
	Case 3						
	⋮						
	Case n						

Figura 04 - Estrutura de um conjunto de dados básico

Os tipos de variáveis mais comuns são:

**Dependente Categórica** – variável dependente ou saída cujos valores são pertencentes a uma categoria qualquer; por exemplo: Sim ou Não, ou Vermelho, Verde ou Azul;

**Dependente Numérica** – variável dependente ou saída cujos valores possíveis são numéricos;

**Independente Categórica** – uma variável independente cujos valores possíveis são pertencentes a uma categoria qualquer; por exemplo: Sim ou Não, ou Vermelho, Verde ou Azul;

**Independente Numérica** – uma variável independente cujos valores possíveis são numéricos;

Em ambientes de projetos, muitas variáveis podem ser usadas para calcular o orçamento do projeto. Alguns exemplos comuns são:

**Complexidade** – Nível de complexidade do projeto (Baixa, Média e Alta). Geralmente é de categoria independente;

**Local** – Local onde o trabalho do projeto irá acontecer. Associada à complexidade do trabalho e da logística do projeto. É, quase sempre, uma de categoria independente.

**Orçamento** – Orçamento planejado para o projeto. É um valor numérico que pode ser independente e dependente (saída);

**Custo Atual** – Aquilo que já foi gasto até o presente no projeto. É, quase sempre, uma variável numérica independente;

**Variância do Custo** – A diferença entre o valor planejado e o custo atual. É uma variável numérica que pode ser independente ou dependente (saída);

**Duração da Linha de Base** – Duração do projeto. Variável numérica independente;

**Duração Atual** – Duração atual do projeto. Usualmente, uma variável numérica independente;

**Variância da Duração** – A diferença entre a duração da linha de base e a duração atual;

**Tipo de Contrato** – variável categórica independente que define o tipo do contrato usado no trabalho do projeto (por exemplo: Preço Fixo, Preço Unitário, Taxa de Administração, etc.);

**Número de Grupos de Stakeholders Relevantes** – Variável numérica independente que reflete o número de grupos de stakeholders relevantes no projeto.

Alguns exemplos de variáveis de entrada são apresentados nas Figuras 05, 06 e 07.

INPUT VARIABLES	DESCRIPTION	UNIT	RANGE
PWA	Predominant Work Activity	Category	New Construction Asphalt or Concrete
WD	Work Duration	month	14–30
PW	Pavement Width	m	7–14
SW	Shoulder Width	m	0–2
GRF	Ground Rise Fall	nillan	2–7
ACG	Average Site Clear/Grub	m <sup>2</sup> /kin	12605–30297
EWV	Earthwork Volume	m <sup>3</sup> /kin	13134–31941
SURFCLASS	Surface Class	Category	Asphalt or Concrete
BASEMATE	Base Material	Category	Crushed Stone or Cement Stab.
OUTPUT VARIABLE			
USDPERKM	Unit Cost of New Construction Project	US Dollars (2000)	572.501.64-4.006.103.95

Figura 05 – Exemplos de Variáveis em Construção de Rodovias (SODIKOV, 2005)

DESCRIPTION	RANGE
Ground floor	100–3668 m <sup>2</sup>
Area of the typical floor	0–2597 m <sup>2</sup>
No. of storeys	1–8
No. of columns	10–156
Type of foundation	1 – isolated
	2 – isolated and combined
	3 – raft or piles
No. of elevators	0–3
No. of rooms	2–38
Cost of structural skeleton	6,282469,680 USD

Figura 06 – Exemplos de Variáveis Importantes para Edifícios (ARAFA & ALQEDRA, 2011)

PROJECT CHARACTERISTICS	UNIT	TYPE OF INFORMATION	DESCRIPTORS
Gross Floor Area (GFA)	m <sup>2</sup>	Quantitative	n.a
Principal structural material	No unit	Categorical	1 – steel 2 – concrete
Procurement route	No unit	Categorical	1 – traditional 2 – design and construct
Type of work	No unit	Categorical	1 – residential 2 – commercial 3 – office
Location	No unit	Categorical	1 – central business district 2 – metropolitan 3 – regional
Sector	No unit	Categorical	1 – private sector 2 – public sector
Estimating method	No unit	Categorical	1 – superficial method 2 – approximate quantities
Number of storey	No unit	Categorical	1 – one to two storey(s) 2 – three to seven storeys 3 – eight storeys and above
Estimated Sum	Cost/m <sup>2</sup>	Quantitative	n.a

Figura 07 – Exemplos de Variáveis para Construção de Edifícios (AIBINU, DASSANAYAKE & THIEN, 2011)

## Treinando Redes Neurais Artificiais

Quando o conjunto de dados está pronto o treinamento da rede pode ser iniciado. Duas abordagens podem ser usadas para o processo de aprendizagem: supervisionada ou treinamento adaptativo.

No treinamento supervisionado, ambas entradas e saídas são fornecidas e a rede compara os resultados fornecido pelo modelo com as saídas fornecidas. Isso permite o monitoramento da qualidade da convergência dos resultados da rede neural artificial com os valores históricos e sua habilidade de prever a resposta correta.

No treinamento adaptativo, apenas as entradas são fornecidas ao modelo. Usando mecanismos auto organizáveis, a rede neural beneficia-se da aprendizagem contínua no intuito de se adaptar a novas situações e ambientes. Esse tipo de rede é comumente chamada Mapa Auto Organizável (MAO) e foi desenvolvido por Teuvo Kohonen (KOHONEN, 2014).

Um dos maiores desafios dos métodos de treinamento é decidir que tipo de rede deve-se utilizar e o tempo de execução do modelo em computadores. Algumas



redes podem ser treinadas em segundos, mas em aplicações mais complexas, em que são utilizadas várias variáveis e casos, podem ser necessárias várias horas.

Os resultados do processo de treinamento são fórmulas complexas que relacionam as entradas (ou variáveis independentes) com as saídas (variáveis dependentes), como no gráfico apresentado na Figura 02.


A maioria dos pacotes comerciais comumente testam os resultados do treinamento com alguns pontos do conjunto de dados para avaliar a qualidade do treinamento. Cerca de 10 a 20% das amostras são utilizadas com o propósito de treinamento (Figura 08).

Person	Gender	Age	Income	Alcohol	Exercise	Smoke	Blood pressure	Tag	Used	Prediction	Good/Bad	Residual
1	Female	52	84800	75	7	49	53		train			
	Female	43	118570	75	70	49						
2	Female	28	172600	7	70	0	27		test	24,01	Good	2,99
3	Male	64	274500	31	19	24	78		test	81,80	Good	-3,80
4	Male	57	103600	50	0	78	94		train			
5	Female	37	107400	31	25	42	41		train			
6	Male	58	108500	57	0	62	72		train			
7	Male	54	156700	42	31	24	41		test	42,14	Good	-1,14
8	Male	26	71300	0	40	14	17		train			
9	Female	44	101300	54	24	56	49		train			
10	Male	31	100200	13	35	27	36		train			
11	Male	46	113100	39	5	75	67		train			
12	Male	65	122500	77	0	89	92		train			
13	Female	52	118900	62	21	67	60		test	63,75	Good	-3,75
14	Male	30	192600	78	83	65	71		test	82,75	Good	-11,75
15	Male	58	150600	52	1	61	65		train			
16	Male	42	66400	67	13	62	48		train			
17	Male	60	149600	63	13	69	70		test	72,05	Good	-2,05
18	Female	46	176100	39	60	46	54		train			

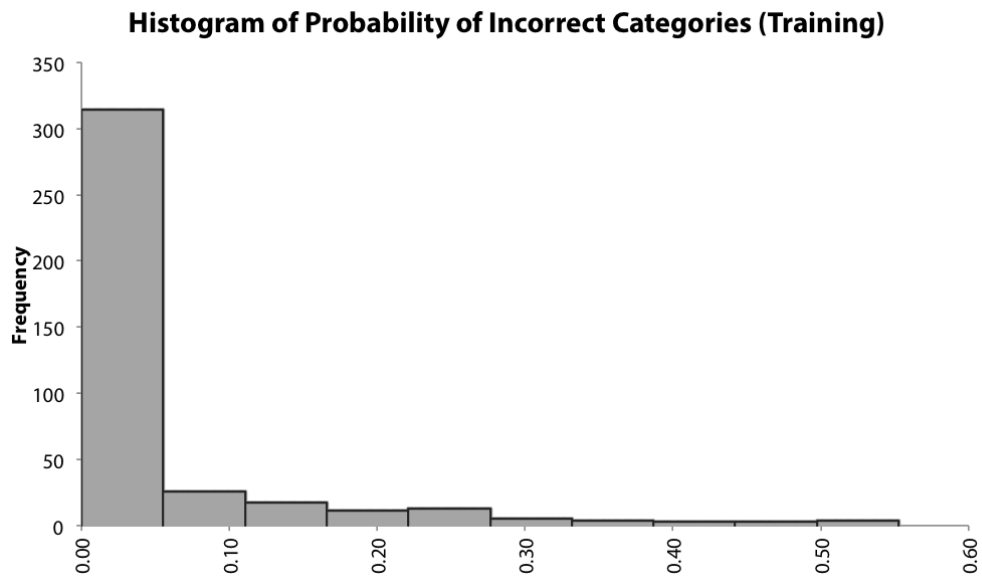
**Figura 08** – Exemplos de resultados de treinamento para previsão da pressão sanguínea onde alguns dados são utilizados para testar as saídas do modelo (o software utilizado: Palisade Neural Tools)

## Resultados da Previsão

Depois do treinamento, o modelo está pronto para a predição de resultados. A informação mais relevante que deve ser foco de investigação é a contribuição individual de cada variável para os resultados previstos (Figura 09) e a confiança do modelo (Figura 10).



**Figura 09** - Exemplo de impacto relativo das variáveis, demonstrando que a variável Salário é responsável por mais de 50% do impacto na variável dependente (software usado: Palisade Neural Tools)



**Figura 10** – Exemplo de histograma de Probabilidade de Categorias Incorretas evidenciando uma chance de 30% que 5% da previsões podem estar erradas (software usado: Palisade Neural Tools)

É importante enfatizar que uma rede treinada que falha em obter um resultado confiável em 30% dos casos é muito menos confiável que outro que falha em apenas 1% dos casos.

## Exemplo de Modelagem de Custos usando Redes Neurais Artificiais

A título de exemplo do processo, um caso fictício foi desenvolvido para prever o custo de gerenciamento do projeto a partir de dados históricos de 500 casos<sup>1</sup>. As variáveis utilizadas estão apresentadas na Figura 11.

O perfil dos casos usados para o treinamento está apresentado nas Figuras 12, 13, 14, 15 e 16 e o conjunto de dados está apresentado integralmente no Apêndice.



Figura 12 – Distribuição dos casos por Local

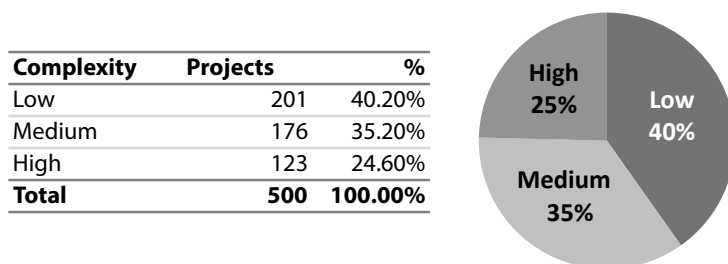


Figura 13 – Distribuição de casos por Complexidade




Figura 14 – Distribuição de casos por Orçamento do projeto

<sup>1</sup> O exemplo foi desenvolvido apenas para demonstração do uso das redes artificiais e não foi contruído a partir de dados reais. Todos os dados são fictícios e devem ser encarados apenas como exemplo.

Duration Range	Projects	%
12-17	145	29.00%
18-23	189	37.80%
24-29	96	19.20%
30-36	70	14.00%
<b>Total</b>	<b>500</b>	<b>100.00%</b>




Figura 15 – Distribuição de casos por Duração do Projeto

Stakeholder Groups	Projects	%
3	238	47.60%
4	158	31.60%
5	104	20.80%
<b>Total</b>	<b>500</b>	<b>100.00%</b>




Figura 16 – Distribuição dos casos por Grupos de Stakeholders Relevantes

O treinamento e os testes foram executados usando o software Palisade Neural Tools. O teste foi executado com 20% da amostra e com um modelo de previsões numéricas baseado em Redes Neurais com Regressão Generalizada. O resumo do treinamento da RNA está apresentado na Figura 17.

NET INFORMATION		PREDICTION	
Name	Net Trained on Project Data	Number of Cases	1
Configuration	GRNN Numeric Predictor	Live Prediction Enabled	YES
Location	This Workbook	<b>TESTING</b>	
Independent Category Variables	3 (Location, Complexity, Relevant Stakeholder Groups)	Number of Cases	100
Independent Numeric Variables	2 (Budget, Duration)	% Bad Predictions (30% Tolerance)	0.0000%
Dependent Variable	Numeric Var. (PM Cost)	Root Mean Square Error	1,508.66
<b>TRAINING</b>		Mean Absolute Error	1,170.24
Number of Cases	400	Std. Deviation of Abs. Error	952.16
Training Time	00:00:38	<b>DATA SET</b>	
Number of Trials	75	Name	Project Data
Reason Stopped	Auto-Stopped	Number of Rows	501
% Bad Predictions (30% Tolerance)	0.0000%	Manual Case Tags	NO
Root Mean Square Error	944.70	<b>VARIABLE IMPACT ANALYSIS</b>	
Mean Absolute Error	706.47	Budget	54.3124%
Std. Deviation of Abs. Error	627.18	Duration	25.4821%
		Location	8.2800%
		Complexity	7.0677%
		Relevant Stakeholder Groups	4.8578%

Figura 17 – Tabela de Resumo do Palisade Neural Tools

O impacto relativo das cinco variáveis independentes está descrito na Figura 18, demonstrando que, no exemplo apresentado, mais de 50% do impacto do custo de gerenciamento do projeto está relacionado com a variável Orçamento.

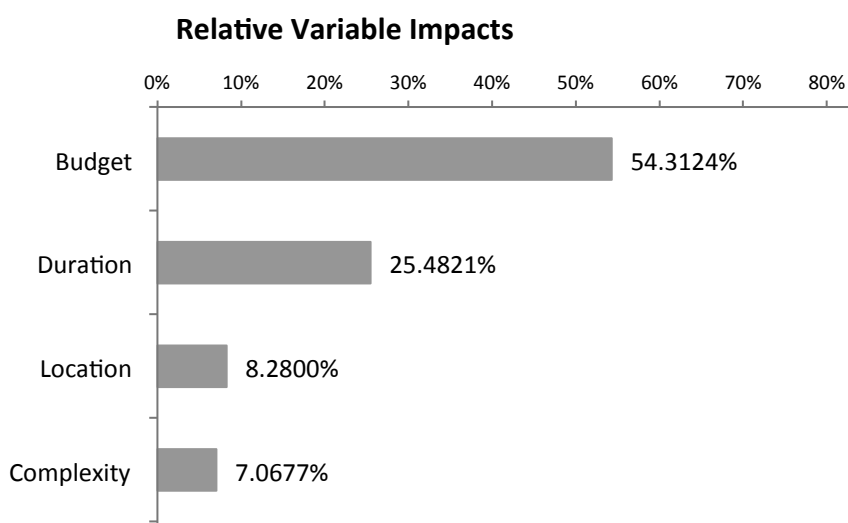


Figura 18 – Impacto Relativo das Variáveis

O treinamento e os testes foram então usados para prever o custo de gerenciamento de um projeto fictício com as seguintes características.

Após a execução da simulação, a previsão do custo de gerenciamento do projeto, baseando-se nos padrões do conjunto de dados, é \$ 24.334,75, aproximadamente 3% do orçamento do projeto.

## Conclusão

O uso de Redes Neurais Artificiais pode ser uma ferramenta útil para determinar aspectos do orçamento do projeto como o custo do gerenciamento do projeto, a estimativa do valor de uma proposta de um fornecedor ou o custo de um seguro de um equipamento. A Rede Neural permite a tomada de decisão com considerável precisão sem o emprego de um processo baseado em fórmulas ou algoritmos.

Com o recente desenvolvimento de ferramentas computacionais, o cálculo tende a ser muito simples e franco. Todavia, o grande desafio para obter resultados confiáveis está na qualidade das informações presentes. O processo por completo é baseado em dados históricos, e muitas vezes é exatamente essa a parte mais laboriosa e cara: conseguir um conjunto de dados confiáveis para o treinamento e teste do modelo.

## Bibliografia

AIBINU, A. A., DASSANAYAKE, D. & THIEN, V. C. (2011). *Use of Artificial Intelligence to Predict the Accuracy of Pretender Building Cost Estimate*. Amsterdam: Management and Innovation for a Sustainable Built Environment.

ARAFI, M. & ALQEDRA, M. (2011). *Early Stage Cost Estimation of Buildings Construction Projects using Artificial Neural Networks*. Faisalabad: Journal of Artificial Intelligence.

BAILER-JONES, D & BAILER-JONES, C. (2002). *Modeling data: Analogies in neural networks, simulated annealing and genetic algorithms*. New York: Model-Based Reasoning: Science, Technology, Values/Kluwer Academic/Plenum Publishers.

BARTHA, P (2013). *Analogy and Analogical Reasoning*. Palo Alto: Stanford Center for the Study of Language and Information.

CHEUNG, V. & CANNONS, K. (2002). *An Introduction to Neural Networks*. Winnipeg, University of Manitoba.

INGRASSIA, S & MORLINI, I (2005). *Neural Network Modeling for Small Datasets In Technometrics: Vol 47, n 3*. Alexandria: American Statistical Association and the

American Society for Quality

KOHONEN, T. (2014). *MATLAB Implementations and Applications of the Self-Organizing Map*. Helsinki: Aalto University, School of Science.

KRIESEL, D. (2005). *A Brief Introduction to Neural Networks*. Downloaded on 07/01/2015 at [http://www.dkriesel.com/\\_media/science/neuronalenetze-en-zeta2-2col-dkrieselcom.pdf](http://www.dkriesel.com/_media/science/neuronalenetze-en-zeta2-2col-dkrieselcom.pdf)

MCKIM, R. A. (1993). *Neural Network Applications for Project Management*. Newtown Square: Project Management Journal.

SODIKOV, J. (2005). *Cost Estimation of Highway Projects in Developing Countries: Artificial Neural Network Approach*. Tokyo: Journal of the Eastern Asia Society for Transportation Studies, Vol. 6.

SPECHT, D. F. (2002). *A General Regression Neural Network*. New York, IEEE Transactions on Neural Networks, Vol 2, Issue 6.

SPITZIG, S. (2013). *Analogy in Literature: Definition & Examples in SAT Prep: Help and Review*. Link accessed on 06/30/2015: <http://study.com/academy/lesson/analogy-in-literature-definition-examples-quiz.html>

STERGIOUS, C & CIGANOS, D. (1996). *Neural Networks in Surprise Journal Vol 4, n 11*. London, Imperial College London.

SVOZIL, D, KVASNIČKA, V. & POSPÍČHAL, J. (1997). *Introduction to multi-layer feed-forward neural networks In Chemometrics and Intelligent Laboratory Systems, Vol 39*. Amsterdam, Elsevier Journals.

## Apêndice – Conjunto de Dados do Exemplo

LOCATION	COMPLEXITY	BUDGET	DURATION	RELEVANT STAKEHOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Remote	Medium	703,998.33	17	3	21,547.87	3.06%	train				
Remote	High	902,327.29	17	5	33,934.58	3.76%	test	33,275.83	Good	658.75	1.94%
Local	Low	904,824.77	27	3	14,789.98	1.63%	train				
Local	Low	640,833.02	17	3	15,128.69	2.36%	train				
Local	Low	683,992.89	16	3	16,985.82	2.48%	test	17,240.60	Good	-254.78	-1.50%
Remote	High	1,467,802.93	20	5	49,416.03	3.37%	train				
Remote	High	569,532.07	26	4	16,983.74	2.98%	train				
Remote	Low	1,235,140.98	12	4	47,896.02	3.88%	train				
Remote	Low	1,254,182.69	13	4	45,954.54	3.66%	test	43,510.55	Good	2,443.99	5.32%
Local	Low	634,127.64	16	3	15,747.50	2.48%	test	16,691.89	Good	-944.38	-6.00%
Remote	High	1,310,397.18	25	3	34,507.13	2.63%	train				
Local	High	1,045,689.31	15	3	31,603.05	3.02%	test	29,729.94	Good	1,873.11	5.93%
Local	Medium	1,070,909.21	20	5	27,486.67	2.57%	train				
Remote	High	1,069,089.15	25	4	31,359.95	2.93%	train				
Remote	Low	600,174.43	14	4	21,491.96	3.58%	train				
Remote	Low	1,274,790.04	17	4	39,018.57	3.06%	test	37,604.96	Good	1,413.61	3.62%
Remote	Low	1,333,972.58	13	5	50,212.10	3.76%	train				
Remote	High	1,600,399.26	16	4	58,948.04	3.68%	train				
Remote	High	1,208,443.26	32	3	28,297.71	2.34%	train				
Local	Low	1,618,395.90	12	3	49,810.63	3.08%	test	43,252.94	Good	6,557.69	13.17%
Remote	Low	580,524.22	15	3	18,125.26	3.12%	test	18,178.96	Good	-53.70	-0.30%
Remote	Low	1,277,669.74	26	4	30,434.75	2.38%	train				
Local	High	1,465,538.27	27	5	35,679.52	2.43%	test	36,732.46	Good	-1,052.93	-2.95%
Local	High	534,389.92	19	5	16,322.33	3.05%	test	16,106.84	Good	215.49	1.32%
Local	Low	1,110,809.34	19	4	26,152.74	2.35%	test	24,588.71	Good	1,564.03	5.98%
Remote	Low	938,755.52	14	4	33,616.39	3.58%	train				
Remote	Medium	573,363.07	22	5	17,287.77	3.02%	train				
Remote	High	1,030,776.33	24	3	27,716.43	2.69%	train				
Remote	High	961,099.65	13	5	41,943.37	4.36%	train				
Local	Medium	765,884.98	16	3	20,551.25	2.68%	train				
Remote	High	1,074,273.06	15	3	37,838.28	3.52%	train				
Local	Low	762,219.86	16	3	18,928.46	2.48%	train				
Local	Low	964,410.00	20	3	19,931.14	2.07%	train				
Remote	Low	911,404.26	24	4	23,595.24	2.59%	test	22,578.66	Good	1,016.59	4.31%
Remote	High	1,930,468.28	20	3	57,270.56	2.97%	train				
Remote	High	981,611.00	23	5	31,895.24	3.25%	train				
Local	Low	1,126,200.40	21	3	21,254.80	1.89%	test	22,151.95	Good	-897.15	-4.22%
Local	High	708,383.15	21	3	17,619.63	2.49%	train				
Local	Low	852,403.45	17	4	22,680.62	2.66%	train				
Remote	Low	816,178.39	16	3	24,349.32	2.98%	train				



LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Remote	Low	1,151,686.39	22	5	31,270.03	2.72%	train				
Remote	High	624,255.72	13	3	24,746.14	3.96%	train				
Remote	High	531,076.00	25	3	14,516.08	2.73%	train				
Local	Low	1,219,803.85	21	5	27,900.59	2.29%	train				
Remote	Low	1,359,202.77	17	4	41,602.27	3.06%	train				
Local	Low	693,228.75	15	3	18,178.00	2.62%	train				
Local	High	801,510.16	28	3	16,755.38	2.09%	train				
Local	High	511,096.39	26	5	13,196.77	2.58%	train				
Local	Low	590,242.71	15	5	17,838.45	3.02%	train				
Remote	Low	1,116,386.68	17	4	34,170.19	3.06%	train				
Remote	Medium	1,123,846.83	23	4	30,897.64	2.75%	test	31,578.29	Good	-680.64	-2.20%
Remote	High	547,802.19	23	5	17,799.60	3.25%	train				
Remote	High	966,086.13	15	4	37,892.04	3.92%	train				
Local	Medium	1,273,716.73	22	3	25,667.32	2.02%	train				
Local	High	778,993.21	20	4	22,331.14	2.87%	test	22,044.71	Good	286.43	1.28%
Local	Low	894,732.93	19	3	19,276.00	2.15%	train				
Remote	Low	1,171,008.92	19	4	33,425.11	2.85%	train				
Remote	Low	551,582.86	21	4	15,374.28	2.79%	train				
Remote	High	546,599.66	29	4	15,574.95	2.85%	train				
Remote	High	1,789,071.54	28	4	49,923.62	2.79%	train				
Local	Low	1,323,310.37	28	3	19,723.63	1.49%	train				
Remote	Low	845,707.18	20	3	21,706.48	2.57%	train				
Local	Medium	782,095.09	21	5	20,235.16	2.59%	train				
Local	Medium	512,318.31	18	4	14,098.24	2.75%	train				
Remote	High	1,056,680.60	23	4	32,221.10	3.05%	train				
Local	Low	1,399,151.60	12	4	47,260.23	3.38%	train				
Remote	Low	1,629,835.05	19	4	46,521.78	2.85%	train				
Local	Low	1,747,728.47	19	5	42,896.00	2.45%	train				
Local	High	584,824.62	24	4	15,140.46	2.59%	train				
Remote	High	1,522,611.48	36	4	38,460.04	2.53%	train				
Remote	Low	1,234,685.15	19	4	35,242.68	2.85%	train				
Local	Low	982,920.06	21	3	19,533.59	1.99%	train				
Local	Medium	1,788,200.40	12	4	63,977.84	3.58%	train				
Local	High	1,082,133.01	21	4	29,080.18	2.69%	test	28,236.53	Good	843.65	2.90%
Remote	High	1,035,386.38	25	4	30,371.33	2.93%	test	31,220.71	Good	-849.38	-2.80%
Remote	Medium	1,264,034.73	14	3	42,736.41	3.38%	train				
Remote	High	1,367,409.84	19	4	45,868.20	3.35%	train				
Remote	Low	1,002,553.31	13	5	37,737.13	3.76%	train				
Local	Low	1,420,828.51	19	3	29,189.30	2.05%	train				
Local	Low	1,709,337.52	15	4	48,241.30	2.82%	train				
Local	High	609,335.11	28	4	14,566.01	2.39%	test	14,651.91	Good	-85.90	-0.59%
Remote	High	833,883.05	30	4	23,441.38	2.81%	train				

LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Remote	Low	1,297,801.29	23	3	29,191.12	2.25%	train				
Remote	Low	1,119,369.76	14	3	35,606.62	3.18%	train				
Local	Low	925,628.02	19	4	22,718.48	2.45%	train				
Local	High	667,414.59	24	3	15,276.38	2.29%	train				
Remote	High	1,722,870.56	19	5	59,514.60	3.45%	train				
Local	Low	951,195.05	23	5	21,395.00	2.25%	test	20,650.89	Good	744.11	3.48%
Local	Low	1,363,830.91	18	5	34,802.94	2.55%	train				
Remote	Medium	1,151,990.74	24	4	30,975.75	2.69%	train				
Local	High	1,125,818.31	30	5	26,018.91	2.31%	train				
Remote	High	1,279,302.89	28	3	31,860.73	2.49%	train				
Local	Medium	555,745.83	16	3	14,912.51	2.68%	test	17,164.08	Good	-2,251.57	-15.10%
Local	High	1,437,619.16	15	5	49,198.52	3.42%	train				
Remote	Low	512,839.97	15	3	16,012.00	3.12%	train				
Remote	Low	1,108,388.88	18	3	29,392.83	2.65%	train				
Local	Low	1,491,757.71	14	4	44,468.59	2.98%	train				
Local	High	573,367.88	25	4	14,525.32	2.53%	train				
Local	High	577,732.27	28	5	14,388.28	2.49%	test	13,498.17	Good	890.11	6.19%
Remote	Low	1,340,923.44	30	3	25,626.54	1.91%	train				
Local	Medium	1,218,034.19	30	3	19,623.88	1.61%	train				
Remote	Medium	982,929.62	15	4	35,603.90	3.62%	train				
Remote	Low	918,511.12	15	3	28,677.96	3.12%	train				
Remote	High	799,134.56	34	3	19,022.54	2.38%	train				
Local	Medium	1,699,228.84	14	4	54,051.66	3.18%	train				
Local	Medium	557,737.83	20	4	14,315.27	2.57%	train				
Local	Medium	1,308,696.78	25	4	27,918.86	2.13%	train				
Local	Low	823,502.63	21	3	16,365.48	1.99%	train				
Local	Low	1,277,239.09	22	5	28,292.78	2.22%	train				
Remote	High	951,405.82	17	3	31,974.70	3.36%	train				
Remote	Low	615,510.45	19	5	18,800.06	3.05%	train				
Local	Low	852,551.98	24	3	15,251.21	1.79%	test	16,513.71	Good	-1,262.50	-8.28%
Local	Low	514,229.05	22	5	11,905.18	2.32%	train				
Local	Medium	831,541.04	19	4	22,072.31	2.65%	train				
Local	Medium	1,035,118.41	21	4	24,711.40	2.39%	train				
Remote	High	813,527.00	16	4	30,778.44	3.78%	test	31,776.14	Good	-997.71	-3.24%
Local	Low	534,936.99	27	5	10,883.66	2.03%	test	11,947.44	Good	-1,063.79	-9.77%
Remote	High	839,992.75	27	3	22,130.18	2.63%	test	21,463.60	Good	666.58	3.01%
Local	High	968,941.49	20	4	27,776.32	2.87%	train				
Local	High	1,455,430.69	23	3	32,736.64	2.25%	train				
Remote	Low	553,402.62	20	4	15,864.21	2.87%	train				
Remote	Low	1,550,217.54	15	3	46,851.02	3.02%	train				
Remote	Medium	1,571,769.84	20	3	41,913.86	2.67%	train				
Local	Low	958,266.50	21	4	21,918.44	2.29%	train				

LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Remote	High	1,203,129.39	12	5	53,873.46	4.48%	train				
Local	Medium	512,774.70	19	4	13,611.02	2.65%	train				
Remote	Low	1,572,775.22	24	3	34,426.30	2.19%	train				
Local	High	928,720.44	21	3	23,100.08	2.49%	test	22,313.20	Good	786.88	3.41%
Local	Low	1,286,047.40	13	5	41,977.91	3.26%	test	43,382.91	Good	-1,405.01	-3.35%
Local	Medium	897,200.07	21	3	19,624.47	2.19%	train				
Local	Medium	506,773.64	28	3	9,073.66	1.79%	test	10,009.00	Good	-935.33	-10.31%
Remote	Medium	1,561,191.51	16	5	54,381.50	3.48%	test	53,120.34	Good	1,261.17	2.32%
Local	High	903,316.02	20	4	25,895.06	2.87%	train				
Remote	Medium	580,211.77	20	3	16,052.53	2.77%	test	17,675.50	Good	-1,622.97	-10.11%
Remote	Low	595,520.47	15	5	20,975.55	3.52%	train				
Local	Low	1,001,793.43	19	4	23,586.08	2.35%	test	21,799.23	Good	1,786.85	7.58%
Local	Low	655,421.89	16	5	18,898.00	2.88%	train				
Local	High	897,256.60	20	4	25,721.36	2.87%	train				
Remote	Low	604,357.31	19	3	16,041.98	2.65%	train				
Remote	High	868,980.86	18	4	30,864.91	3.55%	train				
Local	Medium	1,054,258.00	16	3	27,235.00	2.58%	train				
Local	Low	504,023.79	19	3	10,858.62	2.15%	train				
Remote	Medium	984,726.14	26	3	23,456.68	2.38%	train				
Remote	Low	914,671.35	20	3	23,476.56	2.57%	test	23,342.33	Good	134.24	0.57%
Local	Low	816,984.05	33	3	11,520.30	1.41%	train				
Local	Medium	1,102,518.04	15	5	34,423.06	3.12%	test	32,270.39	Good	2,152.67	6.25%
Local	Medium	1,568,418.96	18	3	36,886.89	2.35%	train				
Local	Low	866,386.50	27	4	16,760.84	1.93%	train				
Remote	Low	945,814.91	19	3	25,105.58	2.65%	train				
Remote	Medium	1,352,496.54	25	4	35,615.74	2.63%	train				
Remote	Low	1,007,543.31	21	3	24,053.10	2.39%	train				
Local	Medium	1,585,230.00	17	4	43,764.78	2.76%	train				
Remote	High	599,627.37	28	3	15,533.20	2.59%	test	15,007.94	Good	525.27	3.38%
Local	Medium	1,063,937.52	33	3	16,066.53	1.51%	test	19,098.46	Good	-3,031.93	-18.87%
Remote	Low	1,316,509.72	17	3	36,345.99	2.76%	train				
Local	Low	819,992.37	36	5	14,152.46	1.73%	train				
Remote	Medium	1,059,271.62	15	3	34,132.09	3.22%	test	34,598.62	Good	-466.54	-1.37%
Remote	High	661,598.27	36	3	15,388.29	2.33%	train				
Local	Low	556,860.84	22	3	10,664.73	1.92%	train				
Remote	High	1,629,259.58	20	4	53,222.48	3.27%	train				
Local	Medium	560,885.36	27	5	12,533.36	2.23%	train				
Remote	Low	1,128,949.92	36	3	19,484.84	1.73%	train				
Remote	Low	1,140,022.19	16	3	32,870.64	2.88%	train				
Local	Medium	1,277,998.06	23	5	30,023.69	2.35%	test	29,794.51	Good	229.18	0.76%
Local	Low	1,370,381.07	13	4	43,360.26	3.16%	train				
Remote	Medium	622,821.80	20	3	17,231.40	2.77%	train				

LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Local	Low	606,852.57	26	5	12,634.98	2.08%	train				
Remote	Low	951,616.00	12	5	38,804.79	4.08%	train				
Remote	Medium	617,490.46	35	3	12,673.26	2.05%	train				
Local	Low	704,413.02	34	3	9,723.66	1.38%	test	9,729.60	Good	-5.94	-0.06%
Remote	Low	580,202.08	32	3	11,265.59	1.94%	train				
Local	Low	1,283,482.92	30	5	23,245.30	1.81%	train				
Remote	Low	1,615,066.28	23	4	41,172.49	2.55%	test	38,529.89	Good	2,642.60	6.42%
Remote	Medium	1,221,684.39	25	3	28,505.97	2.33%	train				
Local	Low	1,554,072.32	21	4	33,992.25	2.19%	test	32,400.12	Good	1,592.13	4.68%
Local	Medium	1,147,660.40	21	3	23,955.13	2.09%	test	25,670.99	Good	-1,715.86	-7.16%
Remote	Low	1,226,103.02	27	3	24,945.90	2.03%	train				
Remote	Low	514,184.61	22	3	12,418.34	2.42%	train				
Remote	Medium	1,559,320.98	22	3	39,219.29	2.52%	train				
Remote	Medium	904,655.73	18	3	26,704.10	2.95%	train				
Remote	Low	1,304,661.29	22	4	34,118.87	2.62%	test	32,420.45	Good	1,698.42	4.98%
Remote	Medium	573,409.51	16	4	19,973.76	3.48%	train				
Remote	High	545,633.58	21	3	16,299.72	2.99%	train				
Remote	High	503,090.27	33	4	13,634.25	2.71%	train				
Local	Medium	525,195.05	30	5	11,087.45	2.11%	train				
Local	Low	894,012.12	17	5	24,681.75	2.76%	train				
Local	Medium	833,563.20	22	3	17,631.12	2.12%	train				
Local	Low	535,711.70	22	4	11,866.83	2.22%	train				
Local	Medium	1,325,009.13	24	4	29,002.98	2.19%	train				
Remote	Medium	590,318.95	22	5	17,799.01	3.02%	train				
Local	High	1,770,395.16	22	3	40,987.33	2.32%	train				
Local	High	1,405,512.56	16	3	40,525.61	2.88%	train				
Local	Medium	1,286,163.78	17	3	31,649.72	2.46%	train				
Local	Low	1,103,463.05	15	3	27,831.79	2.52%	train				
Remote	Medium	885,202.32	20	4	27,146.20	3.07%	test	25,689.17	Good	1,457.04	5.37%
Local	Low	1,220,977.54	27	4	22,399.66	1.83%	train				
Remote	High	679,641.98	31	3	16,822.97	2.48%	train				
Local	Medium	1,158,479.42	20	5	29,734.31	2.57%	train				
Remote	High	1,297,008.10	16	3	43,882.11	3.38%	train				
Local	Medium	595,980.69	31	3	9,984.28	1.68%	train				
Remote	Low	812,827.47	19	3	21,575.58	2.65%	train				
Remote	Low	800,720.74	20	4	22,953.99	2.87%	train				
Local	Low	1,360,528.32	31	4	22,792.51	1.68%	test	22,768.65	Good	23.86	0.10%
Remote	Medium	622,078.94	25	3	15,137.25	2.43%	train				
Local	Medium	1,048,802.19	22	4	24,281.36	2.32%	test	25,044.15	Good	-762.79	-3.14%
Local	High	964,150.49	20	4	27,638.98	2.87%	train				
Remote	Low	1,270,776.17	21	4	34,149.59	2.69%	train				
Local	Medium	1,236,912.47	26	5	26,990.06	2.18%	test	27,084.03	Good	-93.96	-0.35%

LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Local	Medium	828,706.86	16	4	24,723.09	2.98%	train				
Remote	High	946,925.63	15	3	34,299.75	3.62%	train				
Local	Medium	826,666.64	20	5	22,044.44	2.67%	train				
Local	Medium	744,008.05	22	4	17,968.92	2.42%	train				
Local	Medium	1,335,476.56	18	3	31,408.43	2.35%	train				
Remote	Low	540,059.74	12	3	19,862.20	3.68%	train				
Remote	Medium	1,937,816.91	19	3	53,374.96	2.75%	train				
Remote	Medium	769,785.60	17	3	23,561.48	3.06%	train				
Local	Medium	1,094,632.16	20	4	27,000.93	2.47%	train				
Remote	High	1,280,061.70	22	3	36,035.68	2.82%	train				
Remote	High	896,347.09	36	4	23,537.41	2.63%	train				
Local	Low	704,793.42	16	3	17,502.37	2.48%	train				
Remote	High	849,940.50	21	4	27,940.11	3.29%	train				
Local	Low	1,325,031.76	28	4	23,724.38	1.79%	train				
Remote	Medium	1,493,825.11	21	5	44,625.06	2.99%	train				
Remote	Low	640,849.31	33	3	12,240.87	1.91%	test	11,703.26	Good	537.61	4.39%
Remote	Medium	536,908.21	19	3	15,325.43	2.85%	train				
Remote	Low	1,167,617.40	16	4	37,169.15	3.18%	train				
Local	High	1,192,348.18	26	3	24,825.30	2.08%	train				
Remote	Low	531,703.85	15	3	16,600.98	3.12%	test	17,783.95	Good	-1,182.98	-7.13%
Remote	Medium	1,510,277.92	19	3	41,598.88	2.75%	train				
Local	Medium	1,438,409.49	35	3	20,891.19	1.45%	test	19,508.51	Good	1,382.68	6.62%
Remote	Medium	866,217.66	17	5	29,977.92	3.46%	train				
Local	High	1,830,390.71	28	4	37,189.23	2.03%	train				
Remote	Medium	993,322.40	12	4	41,498.80	4.18%	train				
Local	Low	948,143.98	15	3	24,862.44	2.62%	train				
Local	Medium	1,379,684.09	21	4	32,937.22	2.39%	train				
Remote	Low	1,120,685.21	14	5	40,131.20	3.58%	test	38,958.02	Good	1,173.18	2.92%
Local	Medium	1,163,330.12	19	4	29,715.94	2.55%	train				
Local	Medium	1,028,805.86	21	3	21,474.28	2.09%	train				
Local	Medium	698,116.99	19	3	16,436.37	2.35%	train				
Local	Medium	520,721.77	21	3	11,389.76	2.19%	train				
Remote	Medium	1,761,126.50	20	5	54,007.88	3.07%	train				
Remote	High	1,657,808.50	31	4	44,350.83	2.68%	test	46,338.40	Good	-1,987.57	-4.48%
Local	Medium	1,458,640.17	25	4	31,117.66	2.13%	train				
Remote	High	1,143,918.74	19	3	34,939.69	3.05%	train				
Remote	Low	539,042.04	24	5	14,494.24	2.69%	test	16,519.13	Good	-2,024.88	-13.97%
Local	Medium	809,443.86	15	5	26,082.08	3.22%	train				
Local	High	1,767,884.50	25	3	37,714.87	2.13%	train				
Local	High	771,280.77	21	3	19,184.08	2.49%	train				
Remote	Low	625,360.95	26	5	16,147.14	2.58%	train				
Remote	Low	599,119.11	15	5	21,102.31	3.52%	train				

LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Local	High	854,967.79	22	3	20,648.77	2.42%	train				
Local	Low	614,910.44	18	4	15,691.60	2.55%	train				
Local	High	1,010,812.89	16	3	29,145.11	2.88%	train				
Local	Low	1,605,359.49	15	3	40,490.73	2.52%	train				
Local	Low	909,185.58	25	5	19,395.96	2.13%	train				
Remote	Medium	559,258.89	15	3	18,579.82	3.32%	train				
Remote	High	575,367.10	20	4	19,370.69	3.37%	test	18,927.68	Good	443.01	2.29%
Remote	Medium	565,256.88	30	5	14,759.49	2.61%	train				
Local	Medium	868,794.53	20	3	19,692.68	2.27%	test	19,750.18	Good	-57.50	-0.29%
Local	Medium	513,426.44	24	3	10,211.48	1.99%	train				
Local	Medium	565,225.63	33	3	9,100.70	1.61%	train				
Remote	Low	1,750,698.16	16	5	57,481.26	3.28%	train				
Remote	Low	777,901.92	18	3	21,406.71	2.75%	train				
Local	Low	1,485,078.05	32	4	24,380.03	1.64%	test	25,014.55	Good	-634.52	-2.60%
Local	High	785,613.65	34	3	14,772.62	1.88%	train				
Local	Low	706,311.75	19	3	15,216.68	2.15%	train				
Remote	Low	739,540.41	21	5	21,352.76	2.89%	train				
Remote	High	1,342,549.88	20	3	39,828.98	2.97%	train				
Local	High	1,201,962.84	21	3	28,694.48	2.39%	train				
Remote	High	735,242.88	17	3	24,709.93	3.36%	test	24,688.38	Good	21.55	0.09%
Remote	High	1,712,608.43	16	3	57,943.25	3.38%	train				
Local	High	1,050,306.81	16	4	33,434.77	3.18%	train				
Remote	Medium	538,418.45	28	4	13,947.60	2.59%	train				
Local	Medium	606,669.12	32	5	12,386.16	2.04%	train				
Local	Low	888,601.69	20	3	18,364.43	2.07%	train				
Local	High	602,631.37	25	3	13,458.77	2.23%	train				
Local	Medium	528,769.94	28	5	11,582.58	2.19%	train				
Remote	Medium	733,381.20	24	5	21,186.57	2.89%	test	19,471.21	Good	1,715.35	8.10%
Remote	Low	615,606.68	31	5	14,622.31	2.38%	train				
Local	Low	1,038,350.37	30	3	14,652.28	1.41%	train				
Remote	Low	1,008,605.83	15	3	30,482.31	3.02%	train				
Remote	Medium	1,537,920.89	23	4	42,281.68	2.75%	train				
Remote	Medium	1,246,255.59	14	4	45,874.07	3.68%	train				
Remote	Medium	563,905.89	21	4	16,845.57	2.99%	train				
Local	High	1,033,174.25	18	4	30,497.77	2.95%	test	28,677.64	Good	1,820.13	5.97%
Remote	Low	658,752.67	20	3	16,907.99	2.57%	train				
Remote	Medium	829,602.26	20	3	22,952.33	2.77%	train				
Local	Medium	1,771,365.49	16	5	52,845.74	2.98%	train				
Remote	Medium	511,380.29	22	4	14,907.51	2.92%	test	17,273.01	Good	-2,365.50	-15.87%
Local	Medium	1,543,534.66	20	3	33,443.25	2.17%	train				
Remote	Medium	629,687.82	27	3	14,700.49	2.33%	train				
Remote	Medium	895,421.00	25	4	24,474.84	2.73%	train				

LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Remote	Low	556,260.00	14	4	19,919.41	3.58%	test	20,022.91	Good	-103.50	-0.52%
Local	Medium	1,817,837.94	27	3	31,531.63	1.73%	train				
Local	Medium	1,622,698.23	20	4	40,026.56	2.47%	test	38,438.01	Good	1,588.54	3.97%
Remote	Medium	846,257.51	27	3	19,756.46	2.33%	train				
Local	Medium	1,611,292.85	16	3	41,625.07	2.58%	train				
Remote	Low	1,262,421.26	18	5	38,527.23	3.05%	test	37,941.67	Good	585.56	1.52%
Remote	Medium	612,061.28	36	3	12,399.91	2.03%	train				
Remote	High	1,129,246.13	12	3	46,048.15	4.08%	train				
Local	Low	537,807.95	25	4	10,935.43	2.03%	train				
Local	Low	955,684.84	26	3	16,075.11	1.68%	train				
Remote	High	1,134,051.12	25	4	33,265.50	2.93%	train				
Remote	Medium	600,240.51	19	4	18,933.90	3.15%	train				
Remote	Low	995,130.04	27	3	21,241.73	2.13%	train				
Remote	Low	1,141,834.26	19	3	29,166.85	2.55%	train				
Remote	Medium	950,139.68	16	3	30,246.11	3.18%	train				
Remote	High	1,236,433.40	12	3	50,419.01	4.08%	train				
Local	Low	1,149,263.50	28	5	21,726.55	1.89%	test	22,898.96	Good	-1,172.40	-5.40%
Local	High	697,640.20	21	3	17,352.42	2.49%	train				
Remote	Medium	584,742.74	26	3	13,928.87	2.38%	train				
Local	High	1,439,365.41	15	3	43,500.82	3.02%	train				
Local	High	644,115.39	35	5	14,507.93	2.25%	train				
Remote	Low	875,107.31	19	3	23,228.73	2.65%	train				
Local	Low	1,471,608.90	30	5	26,652.47	1.81%	train				
Local	Medium	630,681.97	21	5	16,317.64	2.59%	train				
Local	Low	1,134,830.22	15	3	28,622.94	2.52%	test	27,401.45	Good	1,221.49	4.27%
Local	Low	1,515,009.77	24	3	25,586.83	1.69%	train				
Local	Medium	503,379.10	24	4	11,521.79	2.29%	train				
Local	Medium	1,289,329.63	13	5	44,663.70	3.46%	train				
Remote	Low	540,092.44	20	3	13,862.37	2.57%	train				
Remote	Medium	1,506,018.23	27	3	33,653.00	2.23%	test	36,646.12	Good	-2,993.12	-8.89%
Local	Low	1,223,357.49	20	3	24,059.36	1.97%	train				
Remote	Low	1,177,260.33	22	3	27,255.36	2.32%	train				
Remote	Low	567,631.63	20	3	14,569.21	2.57%	train				
Remote	Low	1,059,977.22	30	3	20,257.34	1.91%	train				
Remote	High	1,426,212.38	33	3	32,946.95	2.31%	train				
Remote	Low	1,078,018.55	34	5	23,505.03	2.18%	test	20,705.97	Good	2,799.07	11.91%
Local	Medium	1,642,148.81	23	4	36,936.45	2.25%	train				
Remote	Medium	568,875.01	27	3	13,280.77	2.33%	train				
Local	Medium	1,323,716.42	12	5	48,683.35	3.68%	test	45,392.41	Good	3,290.94	6.76%
Remote	Low	1,242,074.92	22	3	28,755.92	2.32%	train				
Remote	Low	533,466.84	19	5	16,294.14	3.05%	train				
Remote	High	1,341,511.76	20	5	45,164.23	3.37%	train				

LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Remote	Medium	1,190,106.86	17	3	35,236.50	2.96%	train				
Remote	Medium	1,639,194.71	12	4	66,842.72	4.08%	train				
Local	High	557,365.65	17	4	17,617.13	3.16%	train				
Remote	Low	840,319.07	15	4	28,757.59	3.42%	test	29,966.92	Good	-1,209.33	-4.21%
Local	Low	575,092.91	30	3	8,690.29	1.51%	train				
Local	Medium	865,197.22	19	3	20,370.08	2.35%	train				
Local	Low	1,283,649.31	21	4	28,077.28	2.19%	train				
Local	High	1,127,308.76	21	4	30,294.19	2.69%	train				
Remote	Low	863,172.40	15	5	30,402.85	3.52%	train				
Local	Medium	822,039.76	24	4	18,815.58	2.29%	train				
Remote	Low	562,812.48	15	4	19,260.69	3.42%	train				
Local	Low	502,502.19	24	4	10,496.71	2.09%	test	11,330.66	Good	-833.95	-7.94%
Remote	Low	518,239.43	34	5	11,817.89	2.28%	train				
Local	High	1,282,007.44	15	4	42,591.14	3.32%	train				
Remote	Medium	774,354.55	35	3	15,892.71	2.05%	train				
Remote	Low	589,499.15	21	4	16,431.12	2.79%	test	16,242.83	Good	188.28	1.15%
Remote	Medium	1,682,541.00	24	3	40,194.04	2.39%	train				
Local	Medium	838,064.15	24	3	16,668.16	1.99%	test	18,249.56	Good	-1,581.39	-9.49%
Remote	Medium	1,197,097.75	15	3	38,573.15	3.22%	train				
Local	Low	673,022.37	15	3	17,648.14	2.62%	train				
Local	Medium	989,563.79	14	4	32,467.12	3.28%	train				
Local	Low	1,314,990.27	26	3	20,803.82	1.58%	test	21,387.48	Good	-583.66	-2.81%
Local	High	1,768,637.41	33	5	39,088.67	2.21%	train				
Remote	Medium	902,133.76	34	3	18,767.92	2.08%	train				
Remote	Medium	768,791.62	21	4	22,966.12	2.99%	train				
Local	Medium	834,143.17	21	3	18,245.23	2.19%	train				
Local	Low	1,721,279.85	20	3	33,851.84	1.97%	train				
Remote	Medium	649,359.38	28	4	16,821.50	2.59%	test	14,796.02	Good	2,025.48	12.04%
Remote	Medium	1,292,141.59	30	5	32,447.11	2.51%	train				
Local	Medium	1,162,828.90	31	3	18,317.68	1.58%	test	19,475.00	Good	-1,157.31	-6.32%
Remote	Low	522,425.32	24	3	11,957.74	2.29%	test	13,711.25	Good	-1,753.51	-14.66%
Remote	Low	1,259,321.65	18	5	38,432.63	3.05%	train				
Local	High	753,129.64	34	3	14,161.79	1.88%	test	14,469.25	Good	-307.46	-2.17%
Local	High	1,591,469.31	13	4	58,313.07	3.66%	train				
Local	High	1,815,026.04	15	5	62,114.22	3.42%	train				
Remote	Medium	539,535.55	16	4	18,793.82	3.48%	test	19,527.43	Good	-733.61	-3.90%
Remote	Medium	1,012,917.15	17	3	29,990.29	2.96%	train				
Local	Low	1,191,074.21	24	3	20,115.92	1.69%	train				
Remote	Medium	1,242,927.66	25	3	29,001.65	2.33%	train				
Local	Low	866,382.17	26	3	14,572.99	1.68%	train				
Remote	High	1,809,778.83	14	3	66,617.10	3.68%	train				
Local	Low	1,200,895.52	19	4	28,273.72	2.35%	train				



LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Remote	High	664,897.90	21	3	19,862.51	2.99%	train				
Remote	Low	838,060.77	19	3	22,245.37	2.65%	test	22,111.30	Good	134.06	0.60%
Local	High	708,604.12	15	3	22,124.20	3.12%	train				
Remote	High	721,495.49	21	5	24,439.23	3.39%	test	22,337.15	Good	2,102.08	8.60%
Local	Medium	1,455,977.09	15	3	39,634.93	2.72%	train				
Local	Low	1,111,810.02	27	3	17,061.48	1.53%	test	17,956.39	Good	-894.91	-5.25%
Remote	Low	1,587,492.55	16	5	52,122.67	3.28%	train				
Local	Low	879,426.14	20	3	18,174.81	2.07%	train				
Remote	Low	814,569.24	24	3	18,644.58	2.29%	train				
Remote	Low	550,677.71	29	3	11,285.73	2.05%	train				
Remote	Low	654,244.47	28	3	13,676.82	2.09%	train				
Local	Medium	1,142,844.15	19	5	30,335.49	2.65%	train				
Local	Medium	873,476.34	21	3	19,105.56	2.19%	train				
Remote	Medium	554,435.96	13	3	20,315.10	3.66%	train				
Local	Medium	825,566.09	15	4	25,776.01	3.12%	train				
Remote	Low	633,649.59	26	3	13,826.56	2.18%	train				
Remote	High	587,307.33	20	4	19,772.68	3.37%	train				
Remote	Low	641,383.96	35	3	11,880.87	1.85%	train				
Remote	Medium	1,481,728.02	17	3	43,870.77	2.96%	test	42,949.19	Good	921.58	2.10%
Local	Medium	1,007,413.35	34	5	18,943.32	1.88%	train				
Local	Medium	643,538.40	26	5	14,685.88	2.28%	train				
Remote	Low	1,827,161.32	16	3	52,683.15	2.88%	train				
Remote	Low	964,830.02	15	4	33,018.63	3.42%	train				
Local	Low	632,906.70	22	3	12,121.12	1.92%	train				
Local	Low	526,027.21	34	3	7,261.24	1.38%	train				
Remote	Medium	731,439.19	20	3	20,236.48	2.77%	train				
Local	Low	886,535.29	20	3	18,321.73	2.07%	train				
Remote	Medium	1,055,346.94	20	4	31,308.63	2.97%	test	31,889.28	Good	-580.66	-1.85%
Local	Low	1,248,941.20	33	3	16,362.39	1.31%	train				
Local	High	618,518.54	21	3	15,384.42	2.49%	train				
Local	Low	530,522.61	15	3	13,911.48	2.62%	train				
Local	Low	1,009,146.22	22	4	21,344.97	2.12%	train				
Local	High	1,021,674.63	27	3	20,786.66	2.03%	train				
Remote	Low	1,121,376.46	22	5	30,447.07	2.72%	train				
Local	Low	638,464.57	31	4	11,334.46	1.78%	train				
Remote	Medium	1,256,833.06	34	3	24,890.22	1.98%	train				
Remote	High	546,298.17	30	4	15,357.05	2.81%	train				
Local	Medium	987,396.42	15	3	27,866.52	2.82%	test	26,778.88	Good	1,087.64	3.90%
Remote	Medium	1,046,307.06	21	5	31,256.35	2.99%	train				
Local	High	694,023.76	29	4	16,305.57	2.35%	train				
Local	Medium	1,234,868.04	27	5	26,359.10	2.13%	train				
Local	Medium	632,587.31	24	3	12,581.46	1.99%	train				

LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Remote	High	1,366,884.27	21	4	43,566.72	3.19%	train				
Remote	Medium	869,516.65	12	3	33,717.92	3.88%	test	34,888.20	Good	-1,170.28	-3.47%
Remote	High	924,774.23	20	4	31,134.07	3.37%	train				
Remote	High	1,729,408.45	21	3	49,933.24	2.89%	train				
Local	Low	1,633,982.66	35	4	25,365.64	1.55%	train				
Local	Medium	814,029.10	15	4	25,415.80	3.12%	train				
Local	High	994,502.93	21	3	24,736.29	2.49%	test	24,108.59	Good	627.70	2.54%
Remote	Low	573,443.71	23	3	13,471.77	2.35%	train				
Local	Medium	586,644.29	30	5	12,384.71	2.11%	test	12,332.61	Good	52.10	0.42%
Local	Low	1,194,191.56	20	3	23,485.77	1.97%	train				
Local	Low	640,851.46	29	4	11,852.07	1.85%	train				
Local	High	653,026.72	15	3	20,388.95	3.12%	train				
Remote	Low	1,123,457.64	30	3	21,470.52	1.91%	train				
Remote	Medium	807,182.36	23	3	20,577.30	2.55%	train				
Remote	Low	1,367,692.12	17	4	41,862.11	3.06%	train				
Local	Low	573,685.93	27	4	11,098.34	1.93%	train				
Local	Medium	567,217.09	20	3	12,856.92	2.27%	train				
Remote	Medium	1,188,181.44	21	4	34,306.38	2.89%	train				
Local	Medium	552,218.25	12	3	18,652.71	3.38%	train				
Local	Medium	575,508.83	19	5	15,851.73	2.75%	train				
Local	Low	1,022,032.17	16	3	24,358.43	2.38%	test	24,273.38	Good	85.06	0.35%
Remote	High	1,245,112.01	17	3	40,600.42	3.26%	train				
Local	Medium	764,762.97	35	3	11,872.03	1.55%	test	12,294.49	Good	-422.46	-3.56%
Remote	High	534,546.78	16	4	20,223.69	3.78%	train				
Local	Medium	934,959.92	19	5	25,752.40	2.75%	train				
Local	High	1,680,626.26	17	5	53,120.97	3.16%	train				
Local	Medium	1,072,671.58	24	4	23,479.59	2.19%	train				
Remote	High	1,556,942.09	17	3	50,768.52	3.26%	test	52,653.72	Good	-1,885.20	-3.71%
Local	Low	1,368,257.92	16	4	36,714.92	2.68%	train				
Remote	Low	551,086.24	20	3	14,144.55	2.57%	train				
Local	Medium	860,268.78	25	5	20,072.94	2.33%	train				
Local	High	584,003.61	16	4	19,174.79	3.28%	train				
Remote	Low	625,248.12	18	3	17,205.90	2.75%	train				
Local	Low	1,689,416.73	30	4	28,907.80	1.71%	test	26,945.85	Good	1,961.94	6.79%
Remote	Medium	1,069,349.15	15	5	38,734.20	3.62%	train				
Remote	Low	627,751.93	15	4	21,483.07	3.42%	test	20,197.79	Good	1,285.28	5.98%
Local	High	1,268,675.38	20	4	35,100.02	2.77%	train				
Local	High	1,547,340.00	27	5	37,671.04	2.43%	train				
Local	Medium	1,294,799.07	20	4	31,938.38	2.47%	train				
Remote	High	1,185,245.00	32	4	31,310.22	2.64%	test	28,602.72	Good	2,707.50	8.65%
Local	Low	524,430.06	33	3	7,394.99	1.41%	train				
Local	Medium	663,249.69	28	5	14,528.33	2.19%	train				

LOCA-TION	COMPLE-XITY	BUDGET	DURA-TION	RELE-VANT STAKE-HOLDER GROUPS	PM COST	% PM COST	TAG USED	TEST	GOOD OR BAD	RESIDUAL	%
Local	Medium	1,653,133.09	15	4	49,961.36	3.02%	train				
Local	Medium	528,820.61	20	4	13,573.06	2.57%	train				
Local	Medium	519,719.13	30	3	8,892.97	1.71%	train				
Remote	Medium	743,037.32	33	5	18,650.99	2.51%	train				
Remote	Medium	856,258.79	24	3	21,311.33	2.49%	test	21,521.34	Good	-210.01	-0.99%
Local	High	620,702.06	31	4	14,122.64	2.28%	train				
Remote	Medium	1,284,054.66	24	4	34,526.80	2.69%	test	33,189.13	Good	1,337.68	3.87%
Remote	Low	1,221,724.86	15	5	41,810.14	3.42%	train				
Local	Low	1,713,664.43	16	4	45,983.33	2.68%	train				
Remote	Medium	1,277,241.72	36	3	24,598.73	1.93%	test	25,616.68	Good	-1,017.95	-4.14%
Remote	Medium	1,376,535.12	15	3	44,355.02	3.22%	train				
Local	Medium	1,201,960.23	30	3	19,364.91	1.61%	train				
Local	Medium	1,048,096.64	16	4	30,220.12	2.88%	train				
Local	Medium	781,372.88	16	3	20,966.84	2.68%	train				
Local	Low	889,253.80	16	4	24,750.90	2.78%	test	22,245.27	Good	2,505.62	10.12%
Remote	Low	635,992.33	32	5	14,892.82	2.34%	test	13,943.56	Good	949.26	6.37%
Local	Low	510,489.36	31	4	9,062.56	1.78%	train				
Local	Medium	880,766.98	15	3	24,857.20	2.82%	train				
Remote	Medium	843,268.82	20	3	23,330.44	2.77%	test	23,204.29	Good	126.15	0.54%
Local	High	1,296,821.96	23	5	34,356.38	2.65%	train				
Local	Medium	1,484,991.68	14	5	48,721.87	3.28%	train				
Local	Medium	1,273,825.30	24	3	24,061.14	1.89%	train				
Local	Low	1,066,325.50	20	3	20,971.07	1.97%	train				
Remote	Low	941,441.39	16	5	31,852.10	3.38%	train				
Local	Low	546,951.49	23	3	10,114.64	1.85%	train				
Remote	Low	661,069.81	20	4	18,950.67	2.87%	train				
Local	Medium	568,661.89	20	4	14,595.66	2.57%	train				
Remote	Low	1,240,392.01	16	3	35,764.64	2.88%	train				
Remote	Medium	1,474,071.34	34	4	33,614.61	2.28%	train				
Remote	High	504,448.03	31	3	12,486.44	2.48%	train				
Remote	Low	869,608.71	23	4	23,038.33	2.65%	train				
Remote	Medium	1,484,723.62	20	4	44,046.80	2.97%	train				
Remote	Low	568,098.78	22	3	13,720.45	2.42%	train				
Remote	High	809,584.87	21	5	27,423.08	3.39%	test	28,005.36	Good	-582.28	-2.12%
Remote	Medium	1,283,825.59	19	5	40,496.81	3.15%	train				
Remote	Low	568,442.98	34	3	10,688.96	1.88%	test	11,691.38	Good	-1,002.42	-9.38%
Local	Medium	543,071.16	17	5	16,079.17	2.96%	train				
Remote	Medium	1,206,922.14	20	3	32,184.59	2.67%	train				
Local	Low	1,565,873.75	23	5	33,654.94	2.15%	train				
Remote	Low	686,957.91	19	3	18,234.51	2.65%	train				