

Previsão de desempenho estrutural e funcional

ABORDAGEM BASEADA EM CIÊNCIA DE DADOS


Agenda

- Motivação
- Modelos de Desempenho
- Desempenho Estrutural
 - Parâmetros de interesse
 - Técnicas convencionais
- Desempenho Funcional
 - Parâmetros de interesse
 - Técnicas convencionais
- *Machine Learning*
 - Fundamentos
 - Estudo de caso: Aplicação na previsão de desempenho de pavimento

Motivação

PREVISÃO DE DESEMPENHO

- Essencial para sistemas de gerência de pavimento;
- Pavimento: maior ativo do sistema rodoviário;
- Planejamento de atividades de manutenção e reabilitação;
- Estimativa de recursos necessários para a preservação das rodovias.



Modelos de Desempenho

ABORDAGENS MAIS COMUNS

- **Empírico:** Relacionam os materiais de pavimentação, tráfego e clima diretamente ao desempenho medido.
- **Mecanístico – Empírico:** Utiliza dados empíricos para calcular a resposta do pavimento (tensões e deformações), através de um processo mecanístico e, depois, relaciona estas respostas ao desempenho.
- **Mecanístico:** Modelos baseados em respostas estruturais (tensão e deformação)


Desempenho Estrutural

Desempenho Estrutural

- Parâmetros avaliados: Bacia de deflexão, Número Estrutural
- Equipamentos: Viga Benkelman; **Falling Weight Deflectometer (FWD)**



FWD



Bacia de Deflexão

Desempenho Estrutural

PARÂMETROS DE INTERESSE

- Tipo de estrutura: Flexível, Semirrígida, Rígida;
- Rigidez dos materiais e/ou conjunto;
- Estado da estrutura;
- Subleito (tipo e estado);

Resistência

- Tráfego;
- Clima.

Solicitação

Desempenho Estrutural

TÉCNICAS CONVENCIONAIS – DNIT

- Definem uma deflexão máxima admissível para construção/reabilitação;
- Função: estrutura, condição atual e tráfego estimado para vida útil.

DNIT PRO-11 / 79

$$\log D_{adm} = 3,01 - 0,176 * \log N$$

D_{adm} : Deflexão admissível

N: Tráfego estimado (VDM e FV)

DNIT PRO-269 / 94

$$\log D_{adm} = 3,148 - 0,188 * \log N$$

D_{adm} : Deflexão admissível

N: Tráfego estimado (VDM e FV USACE)

Desempenho Estrutural

TÉCNICAS CONVENCIONAIS – HDM-4

- Estimam a deterioração do número estrutural ao longo do tempo;
- Função: condição atual, deterioração funcional, tráfego, **geometria, qualidade da construção, drenagem e clima.**

Número Estrutural

$$SN = \sum_{i=1}^n a_i * h_i$$

SN: Número Estrutural do pavimento

n: Número de camadas

a_i : coeficiente estrutural da camada i

h_i : espessura da camada i

Número Estrutural: Simplificação

$$SNP = 3,2 * D_0^{-0,63} \text{ (base granular)}$$

$$SNP = 2,2 * D_0^{-0,63} \text{ (base cimentada)}$$

SNP: Número Estrutural Corrigido

D_0 : Deflexão Máxima

Desempenho Funcional

Desempenho Funcional

Parâmetro Avaliado	Equipamento
Trincamento	Levantamento Visual
Desgaste	Levantamento Visual
Panelas	Levantamento Visual
Deformação Permanente	Treliça, Perfilômetro Laser
Irregularidade Longitudinal	Bump Integrator, Perfilômetro Laser



International Roughness Index (IRI) [m/km]

Quociente de Irregularidade (QI) [cont/km]

$$IRI = \frac{QI}{13}$$

Desempenho Funcional

PARÂMETROS DE INTERESSE

- Tipo de estrutura: Flexível, Semirrígida, Rígida;
- Rigidez dos materiais e/ou conjunto;
- Estado da estrutura;
- Revestimento (tipo, estado e **idade**)
- Subleito (tipo e estado);
- Tráfego (VDM e Fator de Veículo);
- Drenagem;
- Clima.

Desempenho Funcional

TÉCNICAS CONVENCIONAIS – DNIT

- Previsão de Trincamento, Irregularidade, Desgaste;
- Função: condição estrutural e funcional atual, idade do pavimento e tráfego estimado anual.

DNIT PRO-159 / 85 – Trincamento

$$TR_{A'} = -18,53 + 0,0456 (B_E \times \log N_{A'}) + 0,00501 (B_E \times A' \times \log N_{A'}) + \Delta TR$$

Trincamento
Futuro

Deflexão

Tráfego

f (Deflexão, Tráfego,
Trincamento atual, Idade)

Desempenho Funcional

TÉCNICAS CONVENCIONAIS – DNIT

- Previsão de Trincamento, Irregularidade, Desgaste;
- Função: condição estrutural e funcional atual, idade do pavimento e tráfego estimado anual.

DNIT PRO-159 / 85 – QI

$$QI_{A'} = 12,63 + 0,393 \times A' + 8,66 \times \frac{\log N_{A'}}{SNC} + 7,17 \times 10^{-5} (B_E \times \log N_{A'})^2 + \Delta QI_1$$

QI Futuro

Idade

Tráfego

Deflexão

f (Deflexão, Tráfego, QI atual, Idade, SNC)


Número Estrutural

Desempenho Funcional

TÉCNICAS CONVENCIONAIS – DNIT

- Previsão de Trincamento, Irregularidade, Desgaste;
- Função: condição estrutural e funcional atual, idade do pavimento e tráfego estimado anual.

DNIT PRO-159 / 85 – Desgaste



Desempenho Funcional

TÉCNICAS CONVENCIONAIS – HDM-4

- Previsão de Trincamento, Desgaste, Irregularidade, Panelas, Deformação Permanente;
- Função: condição estrutural e funcional atual, idade do pavimento, **clima, geometria**, tráfego, fator de veículo, tipos de estrutura, revestimentos, **qualidade de construção, condição de drenagem**.
- Equações diferentes para: Momento da deterioração, Classes das variáveis acima.

Machine Learning

PREVISÃO DE DESEMPENHO DE PAVIMENTOS

ML: Fundamentos

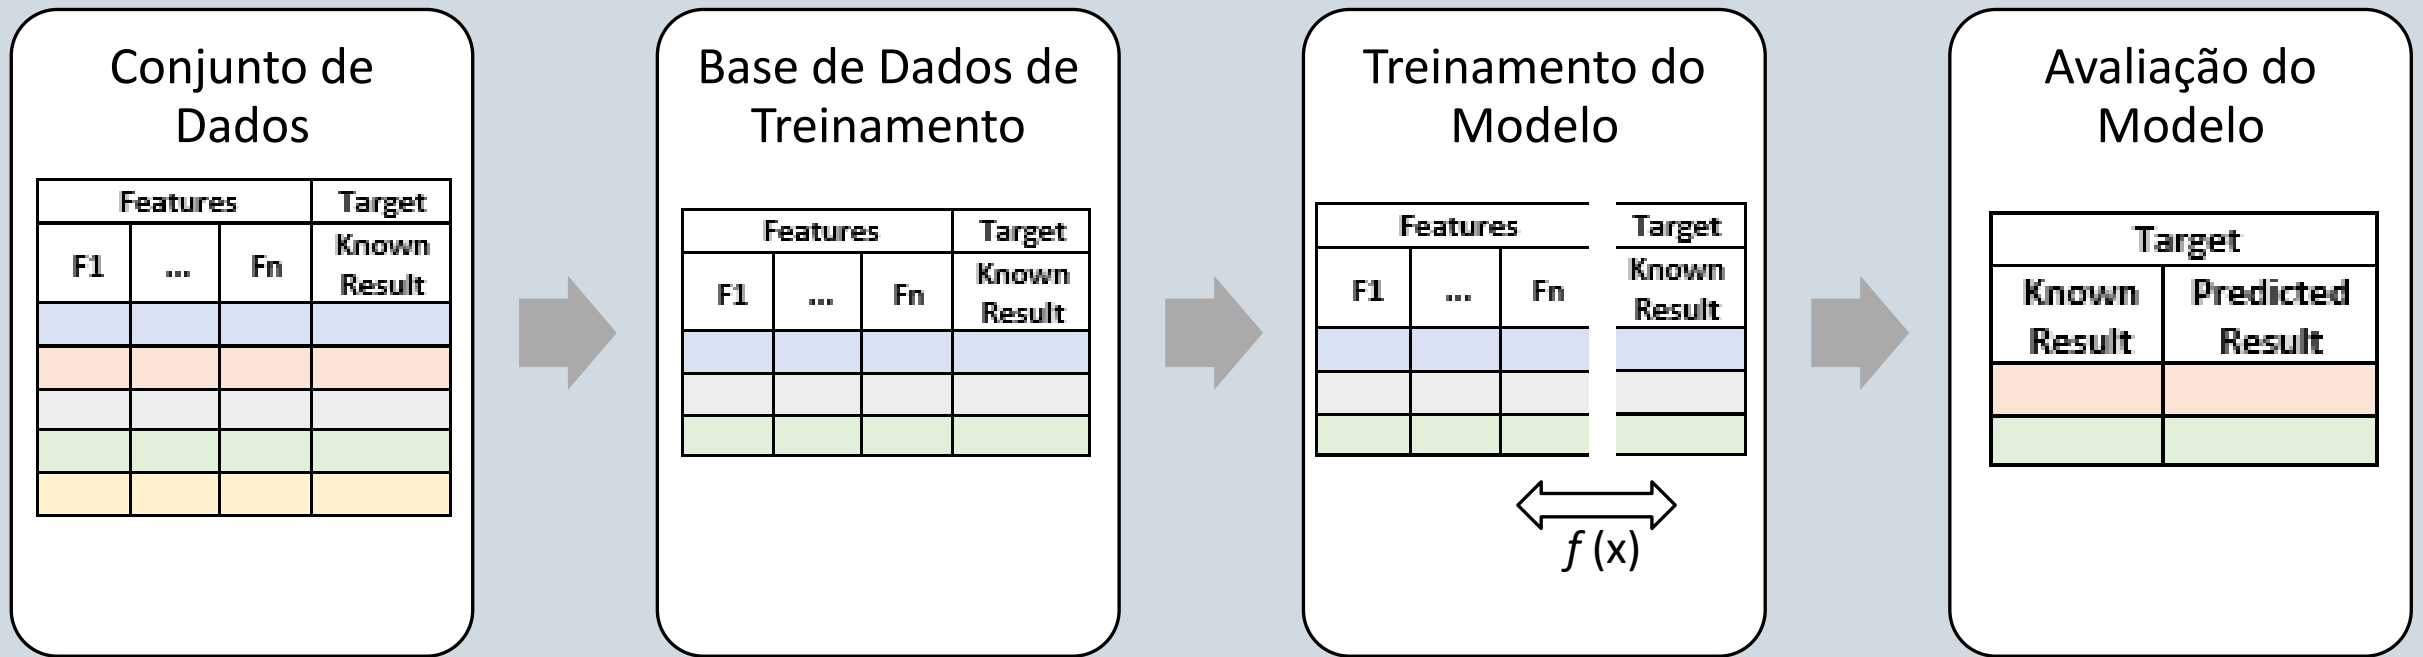
APRENDIZADO DE MÁQUINA

DEFINIÇÃO: área de estudos da estatística, combinada com desenvolvimentos em ciência da computação. Se baseia em dados de observações, para interpretá-los, criar modelos e fazer a previsão de resultados.

APRENDIZADO SUPERVISIONADO: cada cenário observado, e descrito através de características específicas, é associado a um resultado observado para a variável que se pretende prever.

ML: Fundamentos

APRENDIZADO DE MÁQUINA



ML: Fundamentos

APRENDIZADO DE MÁQUINA

APLICAÇÕES: Medicina, **Engenharia**, Economia, Segurança Pública, etc.



TIPOS DE PROBLEMA: Classificação e **Regressão**

REGRESSÃO: a variável que se deseja prever é um número real; a equação resultante não é possível de ser transcrita.

ML: Fundamentos


SUPPORT VECTOR MACHINE REGRESSION (SVR)

- Generalização do classificador de margem máxima;
- Os pontos de dados são dispostos no espaço e separados por um hiperplano ótimo;
- Utilizam funções quadráticas, cúbicas, polinomiais, sigmoides ou gaussianas para acomodar margens não lineares.



ML: Fundamentos

RANDOM FOREST REGRESSION (RFR)



ML: Fundamentos


RANDOM FOREST REGRESSION (RFR)

- Baseado nos resultados de múltiplas árvores de decisão;
- Parcelas dos dados de treinamento são sucessivamente separadas e submetidas ao modelo de árvores de decisão;
- As diversas árvores que compõem a floresta funcionam em paralelo, sem qualquer interação entre elas;
- Os resultados são obtidos através das médias dos valores previstos por cada árvore;
- A cada divisão de um ramo, uma amostra aleatória das variáveis é escolhida como candidata à divisão desse ramo;
- Garante que todas as variáveis sejam consideradas.

ML: Fundamentos

ARTIFICIAL NEURAL NETWORK REGRESSION (ANN)

- Baseados na emulação do funcionamento do sistema nervoso humano;
- Rede interconectada, disposta em camadas que interagem trocando informações;
- Interações ativadas por funções de ativação, com otimização bidirecional de seus pesos;
- Otimização por gradientes descentes da matriz de pesos.



ML: Estudo de Caso

OBJETIVO: Prever a curva de evolução do IRI ao longo do tempo.

METODOLOGIA: Treinar um modelo de ML com base em dados históricos de desempenho de pavimento.

DADOS UTILIZADOS:

- Histórico de 20 anos, de 23 rodovias segmentadas em trechos de 200m;
- Informações de projeto: Estrutura, materiais, idade, tráfego;
- Informações de cronograma: Idade, ciclos de conserva.

BASE DE DADOS RESULTANTE: 11.471 segmentos utilizados no treinamento.

RESULTADOS OBTIDOS: D_0 [$R^2 = 0,99$ e $EMQ = 2 * 10^{-2}$ mm]

IRI [$R^2 = 0,91$ e $EMQ = 0,03$ m/km]

ML: Estudo de caso


PREPARAÇÃO DOS DADOS

- **Limpeza de dados:** Exclusão de dados não confiáveis (falhas na identificação, dados incompletos, erros de procedimento de ensaio, erros de resultados)
- **Consolidação dos dados:** Junção de tabelas (FWD, IRI, Tráfego, Idade)
- **Inserção de dados:** Rodovias em pior estado de conservação
- **Séries Temporais:** Limitação de 3 anos consecutivos de histórico
- **Feature Engineering:** Cálculo de indicadores conhecidos na engenharia de pavimentos (parâmetros de bacia de deflexão, categorias de tráfego)

ML: Estudo de caso

FEATURE ENGINEERING

Extrair informações de dados brutos e transformá-las em variáveis mais adequadas para o modelo de *machine learning*




ML: Estudo de caso

Cenário	Preditores	Configuração Algoritmo	SVR			
			2-year history		3-year history	
			R ²	RMSE	R ²	RMSE
				(10 ⁻³ mm)		(10 ⁻³ mm)
1	Dados Brutos	Default	0.12	116	0.14	122
2	Parâmetros da Bacia de Deflexão	Default	0.11	117	0.14	122
3	Classes da Bacia de Deflexão	Default	0.11	117	0.15	119
4	Classes da Bacia de Deflexão e de Tráfego	Default	0.91	38	0.97	23
5	Dados Brutos	Otimizada	0.82	53	0.77	63
6	Classes da Bacia de Deflexão e de Tráfego	Otimizada	0.91	37	0.99	16


ML: Estudo de caso

Test Segment	D ₀ (10 ⁻³ mm)	AREA (mm)	IRI (m/km)	N AASHTO	Surface Age (years)
1	221	530	3.01	6.94E+05	2
2	501	332	1.99	6.69E+06	5
3	168	504	2.04	4.55E+05	5
4	514	320	2.41	6.24E+05	6
5	244	372	1.74	1.71E+07	3
6	318	438	2.85	4.35E+05	5
7	171	452	1.40	9.92E+07	3
8	145	573	2.49	1.65E+07	7
9	190	475	1.67	1.76E+07	5
10	116	576	1.85	3.39E+07	2
11	444	385	2.53	4.74E+05	5
12	191	282	2.78	2.70E+06	3
13	402	202	2.56	5.06E+07	1



ML: Teste de curto prazo (1 ano)





ML: Teste de curto prazo (1 ano)





ML: Teste de longo prazo (5 anos)



ML: Teste de longo prazo (5 anos)



ML: Teste de longo prazo (5 anos)



ML: Exemplo de análise

D0_i	D0_m	CF_i	FV_AASHTO	AREA_c	N_c	age	1	2	3	4	5	6	7
15,1	23,3	4,4	3,0	2	2	5	31,0	39,1	46,7	53,5	59,0	63,5	66,8
18,4	18,9	4,1	3,0	2	2	2	19,4	21,3	23,4	26,6	29,8	33,0	36,8
26,2	27,5	5,5	3,1	2	2	5	28,8	30,2	31,8	33,5	36,1	40,0	44,8
21,1	22,4	6,1	3,2	1	3	5	23,8	25,9	27,8	30,7	33,6	36,6	39,3
13,9	14,3	3,0	3,5	3	5	1	15,5	16,7	18,0	19,3	20,5	23,3	26,7
12,1	12,4	3,0	3,5	3	5	1	13,3	14,4	16,0	17,6	19,0	21,5	23,8
13,4	16,2	2,0	1,9	3	4	2	19,0	21,9	24,9	27,7	30,6	33,5	37,0
16,1	16,3	4,6	1,9	2	4	2	16,6	16,9	17,5	18,6	20,9	23,2	25,9
19,5	20,1	4,3	2,1	2	5	4	20,7	21,3	22,1	23,1	25,1	27,3	30,2
21,8	23,6	6,6	2,1	2	5	6	25,5	27,5	29,8	32,6	35,7	38,1	41,4
11,5	11,5	4,5	2,1	2	5	6	12,7	14,4	16,6	18,9	21,7	24,2	26,7
17,2	19,5	6,0	2,1	2	4	2	21,7	23,7	25,7	27,6	29,6	31,5	33,5

ML: Exemplo de análise

IRI_i	IRI_m	D0_i	D0_f	D0_m	CF_i	FV_AASHTO	AREA_c	N_c	age	1	2	3	4	5	6
1,93	2,57	15,1	31,0	23,3	4,4	3,0	2	2	5	2,88	3,14	3,38	3,61	3,82	4,02
2,74	2,76	18,4	19,4	18,9	4,1	3,0	2	2	2	2,83	2,95	3,15	3,28	3,56	3,87
1,61	1,71	26,2	28,8	27,5	5,5	3,1	2	2	5	1,84	1,97	2,06	2,18	2,28	2,47
1,78	1,96	21,1	23,8	22,4	6,1	3,2	1	3	5	2,06	2,16	2,25	2,43	2,60	2,76
1,42	1,42	13,9	15,5	14,3	3,0	3,5	3	5	1	1,58	1,76	1,88	2,01	2,22	2,44
1,29	1,30	12,1	13,3	12,4	3,0	3,5	3	5	1	1,44	1,58	1,79	1,90	2,05	2,22
1,46	1,47	13,4	19,0	16,2	2,0	1,9	3	4	2	1,55	1,64	1,80	1,95	2,09	2,25
1,31	1,32	16,1	16,6	16,3	4,6	1,9	2	4	2	1,44	1,64	1,81	2,00	2,15	2,32
1,00	1,04	19,5	20,7	20,1	4,3	2,1	2	5	4	1,15	1,28	1,49	1,70	1,90	2,10
1,04	1,05	21,8	25,5	23,6	6,6	2,1	2	5	6	1,23	1,44	1,68	1,93	2,17	2,34
1,40	1,52	11,5	12,7	11,5	4,5	2,1	2	5	6	1,71	1,88	2,11	2,32	2,51	2,68
2,67	2,84	17,2	21,7	19,5	6,0	2,1	2	4	2	3,02	3,21	3,88	4,32	4,96	5,07

Considerações finais

- Modelagem depende muito da qualidade dos dados
- HDM - 4: Dificuldades de calibração e inserção dos dados
- HDM - 4: Funções consagradas e de fácil interpretação
- HDM - 4: Precisão menor dos modelos
- ML: Depende da disponibilidade de dados regionais para treinamento
- ML: Praticidade no carregamento de dados e geração de resultados
- ML: Modelos muito precisos

Obrigada!

analuisa.aranha@gmail.com

https://www.teses.usp.br/teses/disponiveis/3/3138/tde-04042023-075119/publico/AnaLuisaAranhaCorr23_upload.pdf