

Lab. 06: Consertando o Modelo com Dropout e Early Stopping

Aléssio Miranda Júnior

Agosto - 2026/2

Lab. 06: Regularização e Dropout

Capítulo em Revisão

Este conteúdo está sendo revisado. Algumas informações podem estar preliminares, conter erros de formatação ou sofrer alterações na versão final.

★ Objetivo do Laboratório

No Lab 05, você provocou Overfitting deliberadamente e viu a “boca de jacaré” entre as curvas de treino e validação. Hoje você vai **curar** aquele modelo doente. Usando o **mesmo dataset**, aplicará três técnicas profissionais — Dropout, Regularização L2 e EarlyStopping — e comparará visualmente os gráficos **Antes vs Depois**. Ao final, terá dominado a **caixa de ferramentas completa** contra o Overfitting, a mesma usada em produção por engenheiros do Google e da Meta.

 CAPÍTULO EM REVISÃO (24 de agosto de 2026) - O conteúdo pode sofrer alterações.

1 Parte 1: O Problema F — Estilo Maratona

Problema F: A Clínica do Modelo Doente

Contexto: No Lab 05, o modelo da *SmartFactory* atingiu 99% de acurácia no treino, mas apenas $\approx 75\%$ na validação — ele “decorou” os dados em vez de aprender padrões. O CTO da empresa está furioso: “*Gastamos milhares em GPU para um modelo que não funciona em produção!*”. Sua missão é **curar** o modelo usando a caixa de ferramentas de regularização.

Condições do Experimento:

- **Dataset:** Idêntico ao Lab 05 (500 amostras, 10 features, $\text{flip_y}=0.1$)
- **Modelo doente (controle):** Rede 256-128-64 sem proteção, 300 épocas
- **Modelo curado (tratamento):** Rede 128-64-32 com Dropout + L2 + Early Stopping

Modelo de Saída: Gráfico comparativo **Antes vs Depois** mostrando:

- **Antes:** Curvas divergentes (boca de jacaré) — Overfitting
- **Depois:** Curvas paralelas (caminham juntas) — Modelo saudável

Critérios de Aprovação:

- 1 **Early Stopping** ativou antes de 500 épocas
- 2 **Gap** (loss validação – loss treino) do modelo regularizado < gap do modelo sem proteção
- 3 Previsões do modelo no intervalo válido $[0, 1]$
- 4 `restore_best_weights = True` configurado no callback

2 Parte 2: Recriando o Dataset do Lab 05 (5 min)

Crie o arquivo `src/modelo_regularizado.py`. Reutilizaremos o mesmo dataset do Lab 05 para garantir comparação justa:

```
1 import numpy as np
2 import os
3 os.environ['TF_CPP_MIN_LOG_LEVEL'] = '2'
4
5 import matplotlib
6 matplotlib.use('Agg')
```

```


7 import matplotlib.pyplot as plt
8 from sklearn.datasets import make_classification
9 from sklearn.model_selection import train_test_split
10 from sklearn.preprocessing import StandardScaler
11 from tensorflow.keras.models import Sequential
12 from tensorflow.keras.layers import Dense, Dropout
13 from tensorflow.keras.callbacks import EarlyStopping
14 from tensorflow.keras.regularizers import l2
15
16 # Mesmo dataset do Lab 05 (reprodutibilidade garantida)
17 X, y = make_classification(
18     n_samples=500, n_features=10,
19     n_informative=5, n_redundant=3,
20     random_state=42, flip_y=0.1
21 )
22
23 X_train, X_test, y_train, y_test = train_test_split(
24     X, y, test_size=0.2, random_state=42)
25
26 scaler = StandardScaler()
27 X_train_norm = scaler.fit_transform(X_train)
28 X_test_norm = scaler.transform(X_test)

```


3 Parte 3: Diagnóstico Visual — Rede Doente vs Curada

Antes de codar, observe o diagrama que compara as duas arquiteturas. A chave está nos blocos de Dropout (representados como “filtros” que desligam neurônios) e na penalidade L2 nos pesos:

Modelo Doente (Lab 05)



Modelo Curado (Lab 06)



⇒
Dropout
L2
Early Stop

4 Parte 4: O Modelo Curado com Dropout + L2 (10 min)

Construa o modelo regularizado. Observe as três camadas de defesa:

```
1 def criar_modelo_regularizado():
2     """Rede com Dropout + L2 como vacina contra Overfitting."""
3     model = Sequential()
4     # L2 penaliza pesos grandes na loss
5     model.add(Dense(128, activation='relu', input_shape=(10,),
6                     kernel_regularizer=l2(0.001)))
7     model.add(Dropout(0.3)) # Desliga 30% dos neurônios
8
9     model.add(Dense(64, activation='relu',
10                    kernel_regularizer=l2(0.001)))
11    model.add(Dropout(0.3))
12
13    model.add(Dense(32, activation='relu'))
14    model.add(Dropout(0.2)) # Menos agressivo perto da saída
15
16    model.add(Dense(1, activation='sigmoid'))
17
18    model.compile(
19        optimizer='adam',
20        loss='binary_crossentropy',
21        metrics=['accuracy']
22    )
23    return model
```

• Teoria: As Três Defesas Combinadas

Técnica	Mecanismo	Analogia
Dropout (0.3)	Desliga 30% dos neurônios a cada batch	"Rodízio de funcionários"
L2 ($\lambda=0.001$)	Penaliza $\sum w_i^2$ na loss	"Imposto sobre pesos grandes"
Early Stopping	Para o treino quando val_loss sobe	"Sentinela automática"

Nenhuma técnica sozinha resolve todos os casos. Na prática, **combinamos as três** — assim como um médico prescreve múltiplos tratamentos para uma doença resistente.

5 Parte 5: Configurando o Early Stopping (8 min)

Configure o callback que monitora val_loss e para o treino automaticamente:

```
1 # O "vigia" que monitora a validação
2 vigilante = EarlyStopping(
3     monitor='val_loss', # Métrica monitorada
```

```


4     patience=15,                # Tolerância: 15 épocas sem melhora
5     restore_best_weights=True   # Restaura os pesos do vale!
6 )

```

△ Importante: O Erro de Esquecer `restore_best_weights`

Sem `restore_best_weights=True`, o Keras para o treino mas mantém os **últimos** pesos (que já estão contaminados pelo início do Overfitting). Com a flag ativa, ele “viaja no tempo” e restaura os pesos do momento ótimo — a época onde `val_loss` atingiu o mínimo global.

A. Linha do Tempo do Early Stopping



6 Parte 6: Treinamento Comparativo (12 min)

Treine ambos os modelos (doente e curado) com o mesmo dataset para comparação justa:

```

1  # === MODELO CURADO (com proteção) ===
2  modelo_reg = criar_modelo_regularizado()
3  hist_reg = modelo_reg.fit(
4      X_train_norm, y_train,
5      epochs=500,                # Teto alto (Early Stopping decide)
6      batch_size=16,
7      validation_split=0.2,
8      callbacks=[vigilante],
9      verbose=0
10 )
11
12 # === MODELO DOENTE (controle, sem proteção) ===
13 def criar_modelo_sem_protecao():
14     """Rede do Lab 05 sem nenhuma defesa."""
15     model = Sequential()
16     model.add(Dense(256, activation='relu', input_shape=(10,)))
17     model.add(Dense(128, activation='relu'))
18     model.add(Dense(64, activation='relu'))
19     model.add(Dense(1, activation='sigmoid'))
20     model.compile(optimizer='adam', loss='binary_crossentropy',
21                 metrics=['accuracy'])
22     return model
23

```

```

24 modelo_sem = criar_modelo_sem_protecao()
25 hist_sem = modelo_sem.fit(
26     X_train_norm, y_train,
27     epochs=300, batch_size=16,
28     validation_split=0.2, verbose=0
29 )

```

Agora gere o gráfico comparativo lado a lado:

```

1 def plotar_comparacao(hist_sem, hist_reg):
2     """Compara Antes (overfitting) vs Depois (regularizado)."""
3     fig, (ax1, ax2) = plt.subplots(1, 2, figsize=(14, 5))
4
5     # Gráfico 1: SEM proteção
6     ax1.plot(hist_sem.history['loss'], 'b-',
7             label='Loss Treino')
8     ax1.plot(hist_sem.history['val_loss'], 'r-',
9             label='Val Loss')
10    ax1.set_title('SEM Regularização (Overfitting)')
11    ax1.set_xlabel('Épocas')
12    ax1.set_ylabel('Loss')
13    ax1.legend()
14    ax1.grid(True, alpha=0.3)
15
16    # Gráfico 2: COM Dropout + L2 + Early Stopping
17    ax2.plot(hist_reg.history['loss'], 'b-',
18            label='Loss Treino')
19    ax2.plot(hist_reg.history['val_loss'], 'r-',
20            label='Val Loss')
21    ax2.set_title(f'COM Regularização (parou na época '
22                f'{len(hist_reg.epoch)})')
23    ax2.set_xlabel('Épocas')
24    ax2.set_ylabel('Loss')
25    ax2.legend()
26    ax2.grid(True, alpha=0.3)
27
28    plt.tight_layout()
29    plt.savefig('modelo_consertado.png', dpi=150)
30    plt.close()
31    print("Gráfico salvo: modelo_consertado.png")

```

B. Tabela Comparativa Esperada

Ao rodar o script, você deve observar números semelhantes a estes:

Métrica	Sem Proteção (Lab 05)	Com Regularização (Lab 06)
Épocas executadas	300 (todas)	≈60–120 (Early Stopping)
Acurácia no treino	≈99%	≈82–88%
Acurácia na validação	≈75–80%	≈80–85%
Gap (treino – val)	≈20%	≈2–5%
Loss treino final	≈0.02	≈0.35
Loss validação final	≈0.70	≈0.40
Tempo de treino	Longo (300 épocas)	Curto (Early Stop)

Observe o paradoxo: o modelo regularizado tem acurácia **menor** no treino (não decora!), mas acurácia **maior** na validação (generaliza!). Isso é exatamente o que queremos em produção.

7 Parte 7: Bloco Principal e Execução (5 min)

Monte o bloco principal com o relatório completo:

```


1 if __name__ == "__main__":
2     plotar_comparacao(hist_sem, hist_reg)
3
4     epocas_exec = len(hist_reg.epoch)
5     _, acc_reg = modelo_reg.evaluate(
6         X_test_norm, y_test, verbose=0)
7     _, acc_sem = modelo_sem.evaluate(
8         X_test_norm, y_test, verbose=0)
9
10    print(f"\n{'='*50}")
11    print(f"    MODELO SEM PROTEÇÃO (Lab 05):")
12    print(f"        Épocas: 300 (todas)")
13    print(f"        Acc Teste: {acc_sem:.2%}")
14    print(f"")
15    print(f"    MODELO REGULARIZADO (Lab 06):")
16    print(f"        Épocas: {epocas_exec} (Early Stopping)")
17    print(f"        Acc Teste: {acc_reg:.2%}")
18    print(f"{'='*50}")

```

Execute `python src/modelo_regularizado.py` e verifique que o Early Stopping parou antes de 500 épocas e que as curvas do gráfico caminham juntas.

8 Parte 8: A Receita Profissional (Referência)

Ao completar este lab, você dominou todos os passos da receita profissional de Machine Learning:



Esta receita é válida para **qualquer** problema de classificação com dados tabulares. É a base que você usará no **TP1** do módulo.

9 Parte 9: Garantia de Qualidade — Testes CI/CD (5 min)

Os testes já estão prontos no arquivo `tests/test_regularizado.py` do seu repositório:

```

1 import numpy as np
2 from src.modelo_regularizado import (
3     criar_modelo_regularizado, criar_modelo_sem_protecao,
4     X_train_norm, y_train, X_test_norm, y_test,
5     hist_reg, hist_sem, modelo_reg, vigilante
6 )
7
8 def test_early_stopping_ativou():
9     """Early Stopping DEVE ter parado antes de 500."""
10    epocas = len(hist_reg.epoch)
11    assert epocas < 500, \
12        f"Early Stopping falhou: {epocas} épocas"
13
14 def test_gap_reduzido():
15     """Gap treino-validação menor com regularização."""
16    loss_reg = hist_reg.history['loss'][-1]
17    val_loss_reg = hist_reg.history['val_loss'][-1]
18    gap_reg = abs(val_loss_reg - loss_reg)
19
20    loss_sem = hist_sem.history['loss'][-1]
21    val_loss_sem = hist_sem.history['val_loss'][-1]
22    gap_sem = abs(val_loss_sem - loss_sem)
23
24    assert gap_reg < gap_sem, \
25        f"Gap não reduziu: {gap_reg:.4f} >= {gap_sem:.4f}"
26
27 def test_modelo_funcional():
28     """Previsões devem estar entre 0 e 1."""
29    preds = modelo_reg.predict(X_test_norm, verbose=0)
30    assert preds.shape == (len(X_test_norm), 1)
31    assert np.all(preds >= 0) and np.all(preds <= 1)
32
33 def test_callback_configurado():
34     """restore_best_weights DEVE estar ativo."""
35    assert vigilante.restore_best_weights == True

```

- 1 Rode os testes no terminal: `pytest tests/test_regularizado.py -v`.
- 2 Se a tela exibir **4 passed** em verde, sua implementação está correta.

10 Parte 10: Commit e Push (5 min)

Com todos os testes passando localmente, efetue o envio para o GitLab:

```
1 git add src/modelo_regularizado.py modelo_consertado.png
2 git commit -m "Lab 06: Dropout + L2 + Early Stopping vs Overfitting"
3 git push origin main
```

O GitLab CI interceptará seu push e executará o pytest automaticamente. O **Selo Verde** confirma sua pontuação.

△ Importante: Se o Pipeline Falhar

Os erros mais comuns são: (1) esquecer o `import from tensorflow.keras.regularizers import l2`, (2) não passar `callbacks=[vigilante]` no `fit()`, (3) esquecer `restore_best_weights=True` no `EarlyStopping`. O CI roda os **mesmos testes** que você rodou localmente.

Conclusão: O que Você Construiu Hoje

✓ Takeaways

- Você aplicou **Dropout (30%)** entre camadas densas, impedindo que neurônios se co-adaptem e memorizem ruído — cada neurônio agora é “independente” e útil sozinho.
- Adicionou **Regularização L2** ($\lambda = 0.001$) que penaliza pesos grandes na função de perda: $\mathcal{L}_{total} = \mathcal{L}_{dados} + \lambda \sum w_i^2$.
- Configurou **Early Stopping** com `patience=15` e `restore_best_weights=True`, automatizando a parada ótima e restaurando os pesos do melhor momento.
- Comparou visualmente o gráfico **Antes (Overfitting)** vs **Depois (Regularizado)**, comprovando que as curvas agora caminham juntas e o gap é mínimo.
- Dominou a **receita profissional de 6 passos** para treinar qualquer modelo de classificação tabular robusto.

◇ Informação

Gancho para a Próxima Aula: Até agora, todos os seus modelos processaram **tabelas numéricas** (X com linhas e colunas). Mas a IA do mundo real precisa enxergar **imagens**: fotos, radiografias, satélites. Uma imagem 256×256 RGB tem $256 \times 256 \times 3 = 196.608$ pixels — se aplicássemos um Dense diretamente, teríamos **milhões de parâmetros** e Overfitting instantâneo. Na próxima aula, entraremos no universo das **Redes Convolucionais (CNNs)**, que exploram a *estrutura espacial* dos pixels para aprender com ordens de grandeza menos parâmetros, e do **Transfer Learning** — onde aproveitamos redes pré-treinadas por Google e Meta para resolver problemas com *poucos dados*.