

**UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENFERMAGEM
PROGRAMA DE PÓS-GRADUAÇÃO EM GESTÃO DE SERVIÇOS DE SAÚDE
MESTRADO PROFISSIONAL EM GESTÃO DE SERVIÇOS DE SAÚDE**

Joseli Azevedo Mendes Martins

**PRODUTO TÉCNICO RESULTANTE DO TRABALHO “PREVISÃO DE
DEMANDA DE PALIVIZUMABE PARA PROFILAXIA EM CRIANÇAS CONTRA
O VÍRUS SINCICIAL RESPIRATÓRIO EM FARMÁCIA REGIONAL DO ESTADO
DE MINAS GERAIS”**

Belo Horizonte
2025

Joseli Azevedo Mendes Martins

**PRODUTO TÉCNICO RESULTANTE DO TRABALHO “PREVISÃO DE
DEMANDA DE PALIVIZUMABE PARA PROFILAXIA EM CRIANÇAS CONTRA
O VÍRUS SINCICIAL RESPIRATÓRIO EM FARMÁCIA REGIONAL DO ESTADO
DE MINAS GERAIS”**

Produto Técnico resultante do Trabalho de Conclusão de Mestrado Profissional do Programa de Pós-Graduação em Gestão de Serviços de Saúde, da Escola de Enfermagem da Universidade Federal de Minas Gerais, como requisito parcial para obtenção do grau de Mestre em Gestão de Serviços de Saúde.

Área de concentração: Gestão de Serviços de Saúde.

Linha de pesquisa: Política, Planejamento e Avaliação em Saúde.

Orientadora: Prof^a. Dr^a. Keli Bahia Felicíssimo Zocratto.

Coorientador: Prof. Dr. Renzo Joel Flores Ortiz.

belo Horizonte
2025

PRODUTO TÉCNICO I


PAINEL DE CONTROLE: PAINEL de dados BI

Histórico do consumo total e por dose de aplicação de Palivizumabe em mL, número de pacientes total e por critério de uso na CAF/URS-BH de 2014 a 2024


- Link eletrônico para acesso a base de dados Power BI:

<https://app.powerbi.com/view?r=eyJrIjoibNDRIZmRiMTYtNDQ3Yi00YmY3LTIIYzUtZWl4MTgwNzM1OTUwIiwidCI6IjlmZDc2YzlyLWZhMjktNGFINS04OWE0LWQ2MGUxYzYzNDEzMzJ9>


CONSUMO DE PALIVIZUMABE EM ML NA REGIONAL DE BH DE 2014 A 2024




2014




2015




2016




2017



2018




2019




2020

ANO
2020




2021

ANO
2021




2022


ANO
2022



2023



2024



Fonte: Dados SES/MG, via portal e-SIC.

**UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENFERMAGEM
PROGRAMA DE PÓS-GRADUAÇÃO EM GESTÃO DE SERVIÇOS DE SAÚDE
MESTRADO PROFISSIONAL EM GESTÃO DE SERVIÇOS DE SAÚDE**

Joseli Azevedo Mendes Martins

**PRODUTO TÉCNICO RESULTANTE DO TRABALHO “PREVISÃO DE
DEMANDA DE PALIVIZUMABE PARA PROFILAXIA EM CRIANÇAS CONTRA
O VÍRUS SINCICIAL RESPIRATÓRIO EM FARMÁCIA REGIONAL DO ESTADO
DE MINAS GERAIS”**

Belo Horizonte
2025

Joseli Azevedo Mendes Martins

**PRODUTO TÉCNICO RESULTANTE DO TRABALHO “PREVISÃO DE
DEMANDA DE PALIVIZUMABE PARA PROFILAXIA EM CRIANÇAS CONTRA
O VÍRUS SINCICIAL RESPIRATÓRIO EM FARMÁCIA REGIONAL DO ESTADO
DE MINAS GERAIS”**

Produto Técnico resultante do Trabalho de Conclusão de Mestrado Profissional do Programa de Pós-Graduação em Gestão de Serviços de Saúde, da Escola de Enfermagem da Universidade Federal de Minas Gerais, como requisito parcial para obtenção do grau de Mestre em Gestão de Serviços de Saúde.

Área de concentração: Gestão de Serviços de Saúde.

Linha de pesquisa: Política, Planejamento e Avaliação em Saúde.

Orientadora: Prof^a. Dr^a. Keli Bahia Felicíssimo Zocratto.

Coorientador: Prof. Dr. Renzo Joel Flores Ortiz.

Belo Horizonte
2025

PRODUTO TÉCNICO II
PAINEL DE CONTROLE: MODELO PARA PREVISÃO DE DEMANDA DE
PALIVIZUMABE

Planilha para cálculo de Consumo de Palivizumabe de acordo com o modelo de previsão de demanda ARIMA (*AutoRegressive Integrated Moving Average*)*

- Link eletrônico para acesso a planilha:

https://docs.google.com/spreadsheets/d/1QraKQ_RwaVUFHlZRdByT0ga_iOr_Lsvd/edit?usp=sharing&ouid=111747327755219327680&rtpof=true&sd=true

Número de pacientes atual	Consumo em mL de acordo com o modelo arima por dose	Quantidade em mL para pedido por dose de aplicação	Quantidade total em mL considerando 5 doses para pedido (anual)
500	0,77	385	1925
		0	0
		0	0
		0	0
		0	0
		0	0
		0	0
		0	0
		0	0
		0	0
		0	0
		0	0
		0	0
		0	0
		0	0

* Preenche o número de pacientes atual e o consumo de acordo com o modelo ARIMA por dose (0,77mL): a quantidade em mL por dose de aplicação e a quantidade total considerando 5 doses são preenchidas automaticamente para cálculo do pedido.

* Exemplo de programação para 500 pacientes aplicado à planilha acima.

* Com o abastecimento de dados à série, ao passar dos anos pode-se ajustar o modelo e consumo previsto.

**UNIVERSIDADE FEDERAL DE MINAS GERAIS
ESCOLA DE ENFERMAGEM
PROGRAMA DE PÓS-GRADUAÇÃO EM GESTÃO DE SERVIÇOS DE SAÚDE
MESTRADO PROFISSIONAL EM GESTÃO DE SERVIÇOS DE SAÚDE**

Joseli Azevedo Mendes Martins

**PRODUTO TÉCNICO RESULTANTE DO TRABALHO “PREVISÃO DE
DEMANDA DE PALIVIZUMABE PARA PROFILAXIA EM CRIANÇAS CONTRA O
VÍRUS SINCICIAL RESPIRATÓRIO EM FARMÁCIA REGIONAL DO ESTADO DE
MINAS GERAIS”**

Belo Horizonte
2025

Joseli Azevedo Mendes Martins

**PRODUTO TÉCNICO RESULTANTE DO TRABALHO “PREVISÃO DE
DEMANDA DE PALIVIZUMABE PARA PROFILAXIA EM CRIANÇAS CONTRA
O VÍRUS SINCICIAL RESPIRATÓRIO EM FARMÁCIA REGIONAL DO ESTADO
DE MINAS GERAIS”**

Produto Técnico resultante do Trabalho de Conclusão de Mestrado Profissional do Programa de Pós-Graduação em Gestão de Serviços de Saúde, da Escola de Enfermagem da Universidade Federal de Minas Gerais, como requisito parcial para obtenção do grau de Mestre em Gestão de Serviços de Saúde.

Área de concentração: Gestão de Serviços de Saúde.

Linha de pesquisa: Política, Planejamento e Avaliação em Saúde.

Orientadora: Prof^a. Dr^a. Keli Bahia Felicíssimo Zocratto.

Coorientador: Prof. Dr. Renzo Joel Flores Ortiz.

Belo Horizonte
2025

PRODUTO TÉCNICO III

PAINEL DE CONTROLE: *Script* para aplicação no *software* RStudio®

Script para aplicação no *software* RStudio® para análise de dados

Um *script* é um conjunto de instruções ou comandos escritos em uma linguagem de programação que automatizam tarefas específicas. O *script* abaixo contém comandos dos modelos de previsão para aplicação nos próximos anos, com abastecimento de novos dados à série e novas previsões.

O modelo de previsão de demanda ARIMA (*AutoRegressive Integrated Moving Average*) apresentou o melhor resultado.

- *Script* aplicado ao RStudio® :

```
> ###AJUSTE DE MODELOS PARA PREVISÃO DE 2024###
```

```
# Carregar bibliotecas
library(openxlsx)
library(forecast)
library(lmtest)
library(fgarch)
```

```
# Carregar os dados
setwd("C:\\Users\\Joseli\\Desktop\\Mestrado UFMG\\Dados")
dt <- read.xlsx("dados_2.xlsx")
```

```
# Estruturar os dados
str(dt)
view(dt)
```

```
# Criar nova coluna
dt$consumo_p <- (dt$consumo / dt$pacientes) / 5
```

```
# Transformar em série temporal
dt_t <- ts(dt$consumo_p, start = 2014, frequency = 1)
```

```
# Dividir em conjunto de treino e teste
train_t <- window(dt_t, end = 2023)
test_t <- window(dt_t, start = 2024)
```

```
train <- dt[dt$ano >= 2014 & dt$ano <= 2023, ]
test <- dt[dt$ano == 2024, ]
```

```
plot(train_t, type = "o", main="série de Treinamento (2014 a 2023)", col = "black", xlab = "Ano", ylab="Proporção de consumo")
```

```

# Regressão linear
reg <- lm(consumo_p ~ ano, data = train)

# Exibir resumo do modelo
summary(reg)

# Previsão com modelo de regressão linear simples
pred_reg <- predict(reg, newdata = test)
pred_reg

# Métricas de avaliação da precisão do modelo
# 1. Erro absoluto médio (MAE)
mae <- mean(abs(test$consumo_p - pred_reg))
# 2. Raiz do erro quadrático médio (RMSE)
rmse <- sqrt(mean((test$consumo_p - pred_reg)^2))
# 3. Erro percentual absoluto médio (MAPE)
mape <- mean(abs((test$consumo_p - pred_reg) / test$consumo_p)) * 100
# 4. Desvio absoluto médio (MAD)
mad <- mean(abs(test$consumo_p - pred_reg))

# Exibir todas as métricas
cat("MAE: Erro absoluto médio", mae, "\n")
cat("RMSE: Raiz do erro quadrático médio", rmse, "\n")
cat("MAPE: Erro percentual absoluto médio", mape, "%\n")
cat("MAD: Desvio absoluto médio", mad, "\n")

# Plot das previsões
plot(train$ano, train$consumo_p, type = "o", main="Regressão Linear", col = "black", xlim =
range(dt$ano), ylim = range(dt$consumo_p), xlab = "Ano", ylab="Proporção de consumo")
points(test$ano, test$consumo_p, col = "red", pch = 16)
points(test$ano, pred_reg, col = "green", pch = 16)
legend("topleft", legend = c("Reta de regressão ajustada", "Treino", "Real", "Previsto"),
col = c("blue", "black", "red", "green"), lty = c(1, 1, NA, NA), pch = c(NA, NA, 16, 16))
abline(reg = lm(train_t ~ time(train_t)), col="blue")

#### Simple Exponential Smoothing (Suavização Exponencial simples) A suavização exponencial
simples é uma técnica usada para suavizar uma série temporal e dar mais peso aos valores
mais recentes. No R, você pode usar a função Holtwinters() para aplicar suavização
exponencial simples (SES)####

# Carregar bibliotecas necessárias
library(forecast)
library(tseries)

#Ajustar o modelo SES
ses_1 <- Holtwinters(train_t, beta = FALSE, gamma = FALSE)

#Exibindo resumo do modelo
summary(ses_1)

# Fazer previsões (por exemplo, 1 período à frente)
previsao <- forecast(ses_1, h = 1)
previsao

# Avaliar a precisão do modelo
metricas_acuracia <- accuracy(previsao, x = test_t)
print(metricas_acuracia)

# Plotando a série original de treino e a suavização exponencial simples
plot(train_t, type = "l", col = "black",
      main = "Ajuste de Suavização Exponencial Simples",
      xlab = "Ano", ylab = "Proporção de Consumo",
      pch = 16, xlim = c(2014, 2024), ylim = c(min(train_t)-0.1, max(train_t)+0.1))

# Adicionando a suavização exponencial simples ajustada
lines(ses_1$fitted[, 1], col = "blue")

```

```

# Previsões para os próximos períodos (2024)
previsao_ses <- predict(ses_1, n.ahead = length(test_t))

# Ajustando o eixo X para as previsões, começando do ano após o último valor de treino
anos_previsao <- seq(2024, 2024 + length(previsao_ses) - 1, by = 1)

# Verificando os valores de previsao_ses e anos_previsao para garantir que estão corretos
print(anos_previsao)
print(previsao_ses)

# Adicionando o ponto do valor real para 2024 no gráfico
points(test_t, col = "red", pch = 16) # Pontos reais em vermelho

# Adicionando pontos das previsões no gráfico
points(anos_previsao, previsao_ses, col = "green", pch = 16)

# Adicionando uma legenda ao gráfico
legend("topleft",
      legend = c("Série de Treinamento", "Suavização Exponencial Simples", "Real",
                  "Previsão"),
      col = c("black", "blue", "red", "green"),
      lty = c(1, 1, NA, NA), pch = c(NA, NA, 16, 16))

#### Holt's Exponential Smoothing (Suavização Exponencial de Holt)
Suavização Exponencial de Holt para prever séries temporais sem sazonalidade, considerando apenas o nível e a tendência. Este modelo de suavização exponencial é uma extensão do modelo simples de suavização exponencial, mas incorpora uma tendência linear na previsão.

# Carregar a biblioteca necessária
library(forecast)

# Ajuste do modelo Holt
modelo_holt <- holt(train_t, h = 1) # 'h' indica o número de passos à frente para prever

# Previsões futuras (por exemplo, 1 período à frente)
previsao <- forecast(modelo_holt, h = 1)
previsao

# Avaliação da precisão do modelo
metricas_acuracia <- accuracy(previsao, x = test_t)
print(metricas_acuracia)

# Plotando a série original de treino e a suavização exponencial de Holt
plot(train_t, type = "l", col = "black",
      main = "Ajuste de Suavização Exponencial de Holt",
      xlab = "Ano", ylab = "Proporção de Consumo",
      pch = 16, xlim = c(2014, 2024), ylim = c(min(train_t)-0.1, max(train_t)+0.1))

# Adicionar o ajuste do modelo de Holt aos dados de treinamento
lines(modelo_holt$fitted, col = "blue")

# Adicionar as previsões do modelo de Holt
anos_previsao <- seq(2024, 2024 + length(test_t) - 1, by = 1)
lines(anos_previsao, modelo_holt$mean, col = "red", lwd = 2, lty = 2)

# Adicionar os pontos das previsões
points(anos_previsao, modelo_holt$mean, col = "green", pch = 16)

```

```

# Adicionando o ponto do valor real para 2024 no gráfico
points(test_t, col = "red", pch = 16) # Pontos reais em vermelho

# Adicionar uma legenda
legend("topleft",
      legend = c("série de Treinamento", "Suavização Exponencial de Holt", "Real",
"Previsão"),
      col = c("black", "blue", "red", "green"),
      lty = c(1, 1, NA, NA), pch = c(NA, NA, 16, 16))

#### ARIMA ####
# Carregar bibliotecas necessárias
library(tseries)
library(forecast)

# Verificar a autocorrelação/dependência (ACF e PACF) (Relação entre a variável resposta e
a variável explicativa)
par(mfrow = c(1, 2))
acf(train_t, main = "ACF da Série Original")
pacf(train_t, main = "PACF da Série Original")

# Teste de Dickey-Fuller para verificar estacionariedade da série temporal. Se o valor-p (p
.value) for maior que 0.05, a série não é estacionária.
adf_original <- adf.test(train_t)
print(adf_original)

# Se a série não for estacionária, aplicar diferenciação
#Diferenciação de ordem 1
if (adf_original$p.value > 0.05) {

  # Diferenciação de ordem 1
  diff_train_t <- diff(train_t, differences = 1)

  # Teste de Dickey-Fuller após diferenciação
  adf_differenced <- adf.test(diff_train_t)

  #Exibir resultado do teste
  print(adf_differenced)
}

#Diferenciação de ordem 2
# Aplicando diferenciação de ordem 2
diff_train_t <- diff(train_t, differences = 2)

# Teste ADF após segunda diferenciação
adf_differenced2 <- adf.test(diff_train_t)

# Exibir resultado do teste
print(adf_differenced2)

#Diferenciação de ordem 3
# Aplicando diferenciação de ordem 3
diff_train_t <- diff(train_t, differences = 3)

# Teste ADF após terceira diferenciação
adf_differenced3 <- adf.test(diff_train_t)

# Exibir resultado do teste
print(adf_differenced3)

par(mfrow = c(1, 1))
# Plot da série diferenciada
plot(diff_train_t, main = "Série Diferenciada (d=3)", ylab = "valores", xlab = "Tempo")

```

```

# Ajustar modelo ARIMA automaticamente
arima_model <- auto.arima(train_t, d = 3) # Força a ordem de diferenciação (d=3)

# Exibir resumo do modelo
summary(arima_model)

# Verificando os resíduos do modelo
checkresiduals(arima_model)
adf_residuos <- adf.test(residuals(arima_model))
print(adf_residuos)

# Previsão com ARIMA (1 passo à frente)
previsao <- forecast(arima_model, h = 1)
print(previsao)

# Calcular métricas de acurácia com dados de teste
metricas_acuracia <- accuracy(previsao, x = test_t)
print(metricas_acuracia)

# Plot da série original (treinamento)
plot(train_t, type = "l", col = "black",
      main = "Previsão com ARIMA",
      xlab = "Ano", ylab = "Proporção de Consumo",
      pch = 16, xlim = c(2014, 2024),
      ylim = c(min(c(train_t, arima_model$fitted, previsao$mean)) - 0.1,
               max(c(train_t, arima_model$fitted, previsao$mean)) + 0.1))
lines(arima_model$fitted, col = "blue") # Linha do modelo ARIMA

# Adicionando as previsões do modelo ARIMA para os próximos anos (2024)
anos_previsao <- seq(2024, 2024 + length(previsao$mean) - 1, by = 1)
lines(anos_previsao, previsao$mean, col = "red", lwd = 2, lty = 2)

# Adicionando pontos das previsões no gráfico
points(anos_previsao, previsao$mean, col = "green", pch = 16)

# Adicionando o ponto do valor real para 2024 no gráfico
points(test_t, col = "red", pch = 16) # Pontos reais em vermelho

legend("topleft", legend = c("Modelo ARIMA", "Série de Treinamento", "Previsão", "Real"),
      col = c("blue", "black", "green", "red"),
      lty = c(1, 1, NA, NA), pch = c(NA, NA, 16, 16))

```