

**Sensibilidade de alarme em um sistema de vigilância sindrômica epidemiológica e proposta de rede bayesiana**

**Sensitivity of alarm in an epidemiological syndromic surveillance system and proposed bayesian network**

**Sensibilidad de alarma en un sistema de vigilancia sindrômica epidemiológica y propuesta de red bayesiana**

Recebido: 24/11/2020 | Revisado: 25/11/2020 | Aceito: 29/11/2020 | Publicado: 04/12/2020

**Patricia de Souza Medeiros Pina Ximenes**

ORCID: <https://orcid.org/0000-0003-2468-1683>

Universidade Federal Rural de Pernambuco, Brasil

E-mail: [patricia.medeiross10@gmail.com](mailto:patricia.medeiross10@gmail.com)

**Kleber Régis Santoro**

ORCID: <https://orcid.org/0000-0002-7592-8423>

Universidade Federal do Agreste de Pernambuco, Brasil

E-mail: [Kleber.Santoro@ufape.edu.br](mailto:Kleber.Santoro@ufape.edu.br)

**Resumo**

A eficiência de um sistema de vigilância sindrômica foi avaliada para mortalidade em aves de postura tendo como base de comportamento recomendações internacionais. Foram simuladas várias formas de eventos epidemiológicos com diferentes cenários. As técnicas de alarme do sistema foram analisadas segundo suas sensibilidades bem como a correlação entre os respectivos resultados. Entre as técnicas utilizadas pelo sistema, o gráfico Shewhart foi o que mais contribuiu para a detecção correta de surtos, apresentando probabilidade maior que 95% na detecção de alarmes verdadeiros positivos e apenas 4,6% de falsos positivos. A fim de corrigir a sensibilidade do sistema em detectar surtos, uma rede Bayesiana foi desenvolvida. Esta rede foi proposta como parte da avaliação dos resultados do sistema conferindo maior precisão. A rede Bayesiana proposta conseguiu corrigir erros do sistema avaliado, demonstrando ser um acréscimo viável ao sistema de vigilância sindrômica. Os maiores coeficientes de correlação identificados foram dados pela relação entre o gráfico de controle Shewhart e suavização exponencial Holt-Winters. O sistema tende a superestimar a ocorrência de alarmes através de falso positivos, entretanto a rede Bayesiana proposta corrigiu a um nível de 30% todas as falhas.

**Palavras-chave:** Detecção de surtos; Redes bayesianas; Vigilância animal.

### **Abstract**

The efficiency of a syndromic surveillance system was evaluated for mortality in poultry based on international recommendations. Various forms of epidemiological events were simulated with different scenarios. The system's alarm techniques were analyzed according to their sensitivities as well as the correlation between the respective results. Among the techniques used by the system, the Shewhart chart was the one that most contributed to the correct detection of outbreaks, presenting a probability greater than 95% in the detection of true positive alarms and only 4.6% of false positives. In order to correct the sensitivity of the system in detecting outbreaks, a Bayesian network was developed. This network was proposed as part of the evaluation of the results of the system, providing greater precision. The proposed Bayesian network was able to correct errors in the evaluated system, proving to be a viable addition to the syndromic surveillance system. The highest correlation coefficients identified were given by the relationship between the Shewhart control graph and Exponentially Weighted Moving Average (EWMA). The system tends to overestimate the occurrence of alarms through false positives; however the proposed Bayesian network corrected all failures to a level of 30%.

**Keywords:** Outbreak detection; Bayesian networks; Animal surveillance.

### **Resumen**

Se evaluó la eficiencia de un sistema de vigilancia sindrómica para la mortalidad en aves ponedoras según las recomendaciones internacionales. Se simularon diversas formas de eventos epidemiológicos con diferentes escenarios. Se analizaron las técnicas de alarma del sistema de acuerdo con sus sensibilidades así como la correlación entre los respectivos resultados. Entre las técnicas empleadas por el sistema, la gráfica de Shewhart fue la que más contribuyó a la correcta detección de brotes, presentando una probabilidad superior al 95% en la detección de verdaderas alarmas positivas y sólo el 4,6% de falsos positivos. Para corregir la sensibilidad del sistema en la detección de brotes, se desarrolló una red bayesiana. Esta red se propuso como parte de la evaluación de los resultados del sistema, proporcionando una mayor precisión. La red bayesiana propuesta fue capaz de corregir errores en el sistema evaluado, demostrando ser una adición viable al sistema de vigilancia sindrómica. Los coeficientes de correlación más altos identificados fueron dados por la relación entre el gráfico de control de Shewhart y el suavizado exponencial de Holt-Winters. El sistema tiende

a sobreestimar la ocurrencia de alarmas a través de falsos positivos, sin embargo, la red bayesiana propuesta corrigió todas las fallas a un nivel del 30%.

**Palabras clave:** Detección de brotes; Redes bayesianas; Vigilancia animal.

## 1. Introdução

A detecção prévia e precisa de surtos de doenças é crucial para a execução de uma resposta eficiente à saúde pública, principalmente para limitar a mortalidade e a morbidade na população (Mnatsakanyan, Burkom, Coberly, & Lombardo, 2009; Barboza, 2018).

Schwabe (1982) definiu a evolução dos métodos de vigilância de doenças em medicina veterinária como uma revolução epidemiológica, marcada pelo uso de inteligência epidemiológica e análise de ferramentas chave para diagnóstico e decisão. Neste contexto, fornecer abordagens efetivas e abrangentes para o gerenciamento e análise sistemática da informação desempenha um papel central na obtenção dos objetivos da vigilância das doenças (Zeng, Chen, Lynch, Eidson & Gotham, 2005).

A partir do uso de ferramentas da informática, vários sistemas de vigilância foram desenvolvidos utilizando dados de pré-diagnóstico já disponíveis (Mandl, Overhage, Wagner, Lober, Sebastiani, Mostashari & Hutwagner, 2004) como por exemplo, dados laboratoriais (Buehler, Berkelman, Hartley & Peters, 2003), queixa principal do paciente na visita de emergência (Heffernan, Mostashari, Das, Besculides, Rodriguez, Greenko & Phillips, 2004), solicitação de testes laboratoriais (Dórea, Widgren & Lindberg, 2015), entre outros.

Dentre estes sistemas, a “Vigilância Sindrômica (VS)” se destacou por permitir a identificação precoce do impacto (ou ausência de impacto) de potenciais ameaças (humana ou veterinária) à saúde pública (Henning, 2004; Edo-Osagie, Smith, Lake, Edeghere & De La Iglesia, 2019).

Os primeiros registros de sistemas de VS estabelecidos na cidade de Nova York foram na década de 90 e tinham como objetivo detectar surtos de doenças transmitidas pela água (Henning, 2004). Desde o seu surgimento, a VS recebeu diferentes definições, inclusive o nome do sistema era um tanto impreciso. Diversos nomes foram utilizados para descrever sistemas de vigilância para a detecção precoce de surtos como, por exemplo, sistema de alerta precoce (Wagner, Tsui, Espino, Dato, Sittig, Caruana & Fridsma, 2001), vigilância prodome (Mostashari & Karpati, 2002), sistema de bio-vigilância (Olson & Mandl, 2002), no entanto o termo vigilância sindrômica persistiu (Henning, 2004).

Para a construção de um sistema de VS é necessário escolher uma ou mais técnicas que monitorem os dados que serão avaliados. Na literatura, várias metodologias foram testadas, como por exemplo: estatística de teste bivariada (Ozonoff, Forsberg, Bonetti & Pagano, 2004), teste de razão de verossimilhança generalizada (Wallenstein & Naus, 2004), controle estatístico de qualidade (Rogerson & Yamada, 2004), geoestatística (Bronner, Morignat, Fournié, Vergne, Vinard, Gay & Calavas, 2015) e séries temporais (Dórea, Widgren & Lindberg, 2015).

O *vetsyn* é um dos sistemas de VS disponíveis na literatura. Foi desenvolvido por Dórea, Widgren & Lindberg (2015) e disponibilizado gratuitamente como uma biblioteca para o software R (R Core Team, 2020). De forma geral, este sistema funciona automatizando o processo de análise de dados de saúde animal, pré-classificados em informações epidemiológicas. O sistema tem apresentado grande aceitação, sendo eficiente e tendo como vantagens a simplicidade na entrada e administração de dados, a rapidez e eficiência da análise e a apresentação de resultados com interpretação simples.

Como todo sistema de vigilância, o *vetsyn* possui alarmes falsos positivos e falsos negativos, que na vigilância sindrômica representam problemas na identificação de surtos, e requer um aprimoramento de forma a reduzi-los ao máximo. O sistema deve ser então avaliado e possíveis correções de erros para elevar a sua confiabilidade devem ser propostas.

Neste sentido, o objetivo deste estudo foi verificar a sensibilidade do sistema de VS desenvolvido por Dórea, Widgren & Lindberg (2015), avaliando o número de falhas (falsos positivos e/ou falsos negativos) em dados de mortalidade para aves de postura, haja vista que o sistema ainda não foi avaliado para este tipo situação, com a proposição de método de correção, utilizando redes bayesianas, para aumentar sua confiabilidade.

## **2. Metodologia**

### **2.1 Dados**

Segundo Gibbens, Wilesmith, Sharpe, Mansley, Michalopoulou, Ryan, & Hudson (2001) a progressão temporal de um surto é difícil de prever em medicina veterinária, pois a unidade epidemiológica é o rebanho em vez de animais individuais, e a grande proporção de transmissão é devido ao contato indireto entre as fazendas locais ou em grandes distâncias. Além disso, o desenvolvimento de um experimento controlado para induzir enfermidades diferentes que causem mortalidade é impraticável, seja devido aos custos, operacionalização

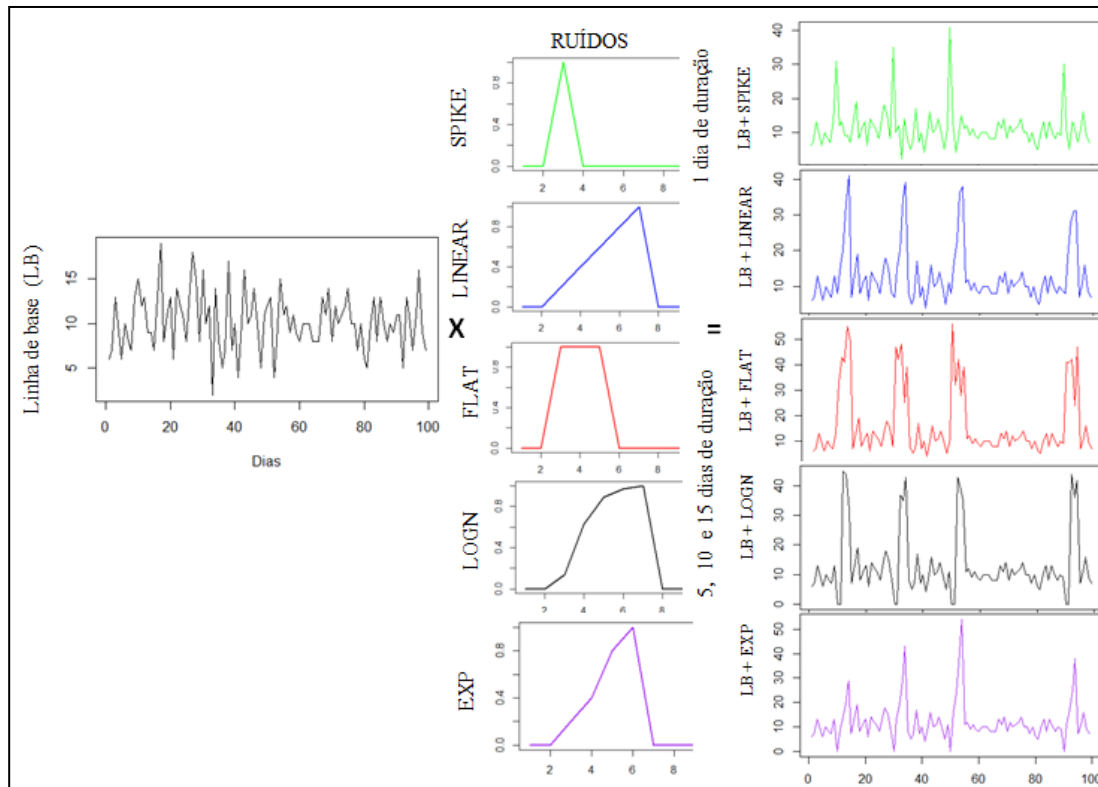
ou as questões bioéticas envolvidas. Por esse motivo, este estudo foi conduzido utilizando dados simulados com várias formas de eventos epidemiológicos em diferentes cenários previamente propostos na literatura (Dórea, Revie, McEwen, McNab, Kelton, & Sanchez, 2013).

As simulações para mortalidade de aves de postura tomaram como base o desenvolvimento padrão das aves Hyline W-36 (Hy-Line, 2016). O período simulado para a série de mortalidade foi de 630 dias, divididos em quatro períodos arbitrariamente escolhidos de acordo com o desenvolvimento e produção das aves, sendo: 1º (dia 1 a 119), 2º (dia 120 a 259), 3º (dia 260 a 532) e 4º (dia 533 a 630). As séries foram geradas sem perturbações, para que não acionasse o alarme de nenhum dos métodos de avaliação empregados no *vetsyn*, representando a linha de comportamento base diário, caracterizado por uma distribuição de Poisson com  $\lambda = 10$ , sendo a distribuição amostrada aleatoriamente a cada 1000 valores simulados.

Sobre as linhas de base foram combinadas perturbações (ruídos) com objetivo de representar o comportamento de fatos epidemiológicos que originariam a mortalidade das aves. Estes ruídos são do tipo estacionário com níveis/magnitude de 20, 30, 40 e 50 sendo todos construídos a partir da distribuição de Poisson. A cada nível de ruído foram combinados ainda, de forma multiplicativa, cinco tipos de comportamento (surtos), conforme Dórea, Revie, McEwen, McNab, Kelton, & Sanchez (2013): spike, linear, flat, logn e exponencial. Com exceção do primeiro, todos os outros foram combinados com períodos de duração de 5, 10 e 15 dias. Assim, resultando em 52 combinações (cenários) possíveis, que foram atribuídos a quatro pontos aleatórios das séries de comportamento base.

O resultado final é representado pela linha de base com a perturbação, magnitude e duração específica (Figura 1), as quais foram usadas como entrada para o sistema *vetsyn* analisar e verificar a ocorrência de surtos, utilizando métodos como gráfico de controle de média móvel ponderado exponencialmente (EWMA), gráfico de controle Shewhart (SH), suavização exponencial de Holt-Winters (HW). Qualquer resposta positiva de pelo menos um dos métodos gera um alarme. Foram simuladas 200 séries para cada um dos 52 cenários possíveis, totalizando 10.400 séries testadas. O presente estudo é uma pesquisa de natureza quantitativa (Pereira, Shitsuka, Parreira & Shitsuka, 2018)

**Figura 1.** Tipos de ruído.



Fonte: Autores, (2020).

## 2. Métodos

### 2.1 Suavização exponencial de Holt-Winters (HW)

A suavização exponencial de Holt-Winters (Winters, 1960) é um método recursivo de previsão, capaz de modificar as previsões em resposta ao comportamento de séries temporais e é um dos mais utilizados para previsão em curto prazo, devido à sua simplicidade, baixo custo de operação, boa precisão e capacidade de ajustamento automático e rápido a mudanças na série em análise (Verissimo, Alves, Henning, Amaral, & Cruz, 2013). Considerando que determinadas séries possuem um fator sazonal, a técnica de HW propõe métodos de projeção para essas séries, considerando dois tipos de efeitos sazonais: multiplicativo e aditivo (Quadro 1).

**Quadro 1.** Equações comparativas dos modelos de Holt-Winters multiplicativo e aditivo (Silva, Samohyl & Costa, 2002).

	Multiplicativo	Aditivo
Nível	$L_t = \alpha(X_t/I_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1})$	$L_t = \alpha(X_t - I_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1})$
Tendência	$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1}$	$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1}$
Sazonalidade	$I_t = \beta(x_t/L_t) + (1 - \beta)I_{t-s}$	$I_t = \beta(x_t - L_t) + (1 - \beta)I_{t-s}$
Previsão	$x_t(k) = (L_t + kT_t)I_{t-s+k}$	$x_t(k) = L_t + kT_t + I_{t-s+k}$

Fonte: Autores.

em que,

$t$  - número de ordem da observação,  $t = 1, 2, 3, \dots$

$s$  - Comprimento da sazonalidade

$L_t$  - Nível da série

$T_t$  - Tendência

$I_t$  - Componente sazonal

$F_{t+m}$  - Previsão para o período  $k$  adiante

$x_t(k)$  - Valor observado

$\gamma$ ,  $\alpha$  e  $\beta$  - Parâmetros exponenciais alisadores, do nível, da tendência e da sazonalidade, respectivamente. Tal que esses parâmetros estão dentro do intervalo (0,1).

O modelo de Holt-Winters aditivo possui uma extensão da variação temporal constante ao longo do tempo, isto é, as diferenças entre os menores e maiores valores da série pouco se alteram (Silva, Samohyl & Costa, 2002). No caso multiplicativo, o modelo tem como premissa básica a suposição de que a amplitude da sazonalidade é variante no tempo, e provavelmente, essa variação ocorre de forma crescente. No que diz respeito à componente de tendência, ela continua possuindo uma formulação aditiva. Portanto, esse modelo é capaz de incorporar tanto a tendência linear quanto o efeito sazonal. Então, se há presença de componentes de tendência e de sazonalidade, torna-se possível a utilização do método de HW para efetuar previsões.

### 2.1.1 Gráfico de controle Shewhart (SH)

Dentre os gráficos de controle propostos na literatura, o gráfico de controle Shewhart foi o primeiro a ser apresentado e consiste na representação gráfica do comportamento da

característica de qualidade  $X$  medida em uma ou mais amostras aleatórias de um processo (Mingoti & Yassukawa, 2008).

O SH delimita uma região onde os valores de  $X$ , ou de estimativas de parâmetros de sua distribuição de probabilidades como a média ou o desvio padrão, devem permanecer enquanto o processo estiver sob condição de controle estatístico. Os gráficos de controle são caracterizados por apresentarem limites de controle, estes limites são estabelecidos para a configuração do gráfico e são representados da seguinte forma: Linha Central (LC), que representa o valor médio da característica de qualidade, Limite Superior de Controle (LSC) e Limite Inferior de Controle (LIC) que são determinados utilizando as distribuições de probabilidades da característica de qualidade  $X$  (Montgomery, 2007). Os limites de controle para o gráfico SH são dados por:

$$\begin{cases} LSC = \mu + k \frac{\sigma}{\sqrt{n}} \\ LC = \mu \\ LIC = \mu - k \frac{\sigma}{\sqrt{n}} \end{cases}$$

em que,

$\mu$  = média de  $X$ .

$s$  = desvio padrão de  $X$ .

$k$  = distância dos limites de controle em relação à linha central.

Alguns autores mostram que o gráfico de controle Shewhart é mais apropriado para detecção de ocorrência de grandes desvios da média do processo (Costa; Epprecht & Carpinetti, 2005).

### **2.1.2 Gráfico de controle da soma cumulativa (CUSUM)**

Este gráfico é indicado para detecção de pequenas mudanças na média de um processo, sendo fundamentado em somas cumulativas das estimativas do parâmetro de interesse (Mingoti & Yassukawa, 2008). A construção do CUSUM é feita acumulando-se os desvios dos valores amostrais de  $X$  em relação à média teórica do processo  $\mu$ . Os desvios positivos são acumulados na estatística  $c^+$  e os negativos na estatística  $c^-$ , estes recebem o



nome de CUSUMs unilaterais superior e inferior, respectivamente sendo calculados da seguinte forma:

$$\begin{cases} c_i^+ = \max [0, x_i - (\mu_0 + K) + c_{i-1}^+] \\ c_i^- = \max [0, (\mu_0 + K) - x_i + c_{i-1}^-] \end{cases}$$

em que,

$K$  = valor de tolerância ou folga,

$x_i$  =  $i$ -ésima observação do processo,

$\mu_0$  = valor médio do alvo do processo.

O processo é considerado fora de controle quando  $c^+$  ou  $c^-$  excedem um limite pré-especificado  $H$ . Estudos mostram que o gráfico CUSUM é mais poderoso que o gráfico Shewhart para a detecção de pequenos desvios na média do processo (Costa; Epprecht & Carpinetti, 2005).

### 2.1.3 Gráfico de controle de média móvel ponderado exponencialmente (EWMA)

O gráfico de controle EWMA (Roberts, 1959) também é indicado na detecção de pequenas mudanças na média de um processo e depende da especificação de um valor alvo e de uma estimativa conhecida ou confiável do desvio padrão (Bower, 2000).

Definida a estatística  $Z_i = \lambda X_i + (1 - \lambda)Z_{i-1}$ , onde  $0 < \lambda \leq 1$ , o gráfico consiste na construção de  $Z_i$  versus o número da amostra  $i$  (Mingoti & Yassukawa, 2008). Para este gráfico, a linha central e os limites de controle, construídos sob a suposição de normalidade, são dados por:

$$\begin{cases} LSC = \mu_0 + L\sigma \sqrt{\frac{\lambda}{(2-\lambda)} [1 - (1-\lambda)^{2i}]} \\ LC = \mu_0 \\ LIC = \mu_0 - L\sigma \sqrt{\frac{\lambda}{(2-\lambda)} [1 - (1-\lambda)^{2i}]} \end{cases}$$

em que,

$L$  = coeficiente de abertura dos limites de controle (limites de  $K$ -sigma).

$\lambda$  = constante de amortecimento.

Os parâmetros que definem o planejamento do gráfico EWMA são os valores de  $L$  e  $\lambda$ .

#### 2.1.4 Redes Bayesianas

As Redes Bayesianas - *Bayesian networks* (BN) são representações compactas de uma tabela de probabilidades conjunta do universo de um problema (Marques & Dutra, 2002). A estrutura de uma BN é definida por dois conjuntos: o conjunto de nós (vértices) e o conjunto de arcos direcionados, onde os nós representam variáveis aleatórias e normalmente são desenhados como círculos rotulados pelos nomes das variáveis; os arcos representam a dependência direta entre as variáveis e são desenhados por setas entre os nós (Ben-Gal, 2007). De forma geral, um arco do nó  $X_i$  para o nó  $X_j$  representa uma dependência estatística entre as variáveis correspondentes, isto é, a seta indica que um valor obtido pela variável  $X_j$  depende do valor obtido pela variável  $X_i$  ou, aproximadamente, que a variável  $X_i$  “influencia” a variável  $X_j$ .

Em BN se existir um arco direcionado do nó  $X_i$  para  $X_j$ , então  $X_i$  é dito pai de  $X_j$  e  $X_j$  é filho de  $X_i$ . Estes termos genealógicos são frequentemente usados para definir os conjuntos de nós descendentes, que são nós que podem ser alcançados em um caminho direto do nó ou nós antepassados e, segundo Marques & Dutra (2002), a construção de uma BN consiste do seguinte:

- Um conjunto de variáveis e um conjunto de arcos ligando as variáveis.
- Cada variável possui um conjunto limitado de estados mutuamente exclusivos.
- As variáveis e arcos formam um grafo acíclico dirigido - *Directed Acyclic Graph (DAG)*.
- Para cada variável  $A$  que possui como pais  $B_1, \dots, B_n$ ; existe uma tabela  $P(A | B_1, \dots, B_n)$ .

A estrutura de grafos acíclicos garante que não existe um nó que possa ser seu próprio antepassado ou seu próprio descendente; esta condição é de grande importância para a fatorização da probabilidade conjunta de uma coleção de nós.

A utilização de redes bayesianas requer a análise de alguns pressupostos que não serão expostos por fugir do escopo deste trabalho. Mais detalhes sobre a utilização e aplicação de redes bayesianas podem ser encontrados em Marques & Dutra (2002).

### 2.1.5 Sensibilidade

A sensibilidade de um método reflete o quanto este é capaz de identificar corretamente, dentre todos os indivíduos avaliados, aqueles que realmente apresentam uma característica de interesse podendo ser obtida a partir da fórmula (Lalkhen & Mccluskey, 2008):

$$Sensibilidade = \frac{VerdadeiroPositivo(VP)}{VerdadeiroPositivo(VP)+FalsoNegativo(FN)}$$

onde VP e FN são encontrados na tabela de frequência 2x2 gerada com os resultados da variável em estudo. A partir da fórmula acima se obteve as sensibilidades apresentadas neste estudo.

A rede Bayesiana foi desenvolvida interpretando o envolvimento entre as diferentes técnicas e seus possíveis resultados (níveis de resposta), levando a melhor associação possível entre estes componentes, em uma abordagem onde as técnicas estavam no nível inicial e o alarme no nível final.

Todas as análises realizadas neste estudo foram processadas utilizando a linguagem de programação R (R Core Team, 2020); para construção da rede bayesiana foram utilizados os pacotes *bnlearn* (Scutari, 2010) e *gRain* (Højsgaard, 2012).

## 3 Resultados e Discussão

O sistema *vetsyn* foi testado com cinco diferentes tipos de ruído e quatro magnitudes diferentes. Nesta seção apresentaremos os resultados por tipo de ruído facilitando a compreensão do leitor. Antes de apresentar os resultados é importante destacar que quando trabalhamos com sistemas de vigilância o percentual de alarmes VP detectados não influencia no percentual de FP como mostrado na fórmula de sensibilidade apresentada na metodologia. Por exemplo, imagine que uma série de dados com 630 informações está sendo analisada por um sistema de detecção de surtos. Esta série contém 30 observações com um determinado tipo de surto/ruído, ou seja, 600 observações estão livres de ruído e 30 contêm ruído. Se o sistema de vigilância detectar os 30 surtos da série poderemos afirmar que a sensibilidade deste sistema é de 100%, pois ele conseguiu detectar todos os surtos presentes na série. Mas suponha que, apesar do sistema ter identificado os 30 surtos presentes na série, este também detectou mais 3 que na verdade não eram um surto, ou seja 3 alarmes falsos positivos foram

acionados. Portanto, a detecção de alarmes verdadeiros positivos não influencia na detecção de falsos positivos. Esse esclarecimento será relevante na análise dos resultados.

A Tabela 1 apresenta a sensibilidade do sistema *vetsyn* quando testado com o ruído do tipo spike. É possível observar que dentre as técnicas aplicadas, o gráfico SH apresentou maior sensibilidade, independente da magnitude do ruído. A técnica EWMA mostrou um alto percentual de alarmes falsos positivos (FP) ao avaliar séries com ruídos de magnitudes 20 e 40. Como esperado, o aumento da magnitude do surto repercutiu em aumento da sensibilidade de algumas técnicas como pode ser observado no desempenho da suavização exponencial de Holt-Winters (HW) e o gráfico de Shewhart (SH). De forma geral, o *vetsyn* apresentou um excelente desempenho na detecção de surtos do tipo spike principalmente no uso do gráfico SH.

**Tabela 1.** Sensibilidade do sistema com ruído spike\*.

Técnica	EWMA	SH	HW	EWMA	SH	HW
<b>Duração (dia)</b>	<b>1</b>			<b>1</b>		
<b>Magnitude</b>	<b>20</b>			<b>30</b>		
<b>Detecção (VP)</b>	39,0	198,0	35,0	0,0	200,0	184,0
<b>Detecção (FN)</b>	161,0	2,0	165,0	200,0	0,0	16,0
<b>Sensibilidade (%)</b>	19,5	99,0	17,5	0,0	100,0	92,0
<b>Detecção (FP) (%)</b>	94,5	0,0	3,0	0,0	0,0	17,0
<b>Magnitude</b>	<b>40</b>			<b>50</b>		
<b>Detecção (VP)</b>	187,0	200,0	193,0	200,0	200,0	199,0
<b>Detecção (FN)</b>	13,0	0,0	7,0	0,0	0,0	1,0
<b>Sensibilidade (%)</b>	93,5	100,0	96,5	100,0	100,0	99,5
<b>Detecção (FP) (%)</b>	72,5	0,0	19,5	37,5	0,0	46,5

\* VP = Verdadeiro Positivo, FN = Falso Negativo, FP = Falso Positivo. Verdadeiro Negativo (VN) pode ser obtido. VN = 200 - FP. EWMA = Gráfico de Controle de Média Móvel Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. Fonte: Autores.

A análise do sistema *vetsyn* para detecção de surtos do tipo flat apresentou excelentes resultados. Na Tabela 2 observamos que as técnicas EWMA e SH apresentaram sensibilidade de 100% para quase todas as séries analisadas, independente da magnitude e tempo de duração do ruído. A técnica HW apresentou uma sensibilidade mais baixa quando analisou

séries com ruídos de magnitude 20, mas à medida que aumentamos a magnitude do ruído, a sensibilidade aumentou para 100%, assim como as demais técnicas. A detecção de alarmes falsos positivos apresentou diferentes comportamentos de uma técnica para outra. O EWMA apresentou um alto percentual de detecção FP ao analisar séries com magnitude 20. O percentual variou de acordo com a duração do ruído, iniciando em 49% das séries (duração de 5 dias), chegando a 95% das séries para o ruído de duração 15 dias. Da mesma forma o gráfico SH Também apresentou alarmes FP ao avaliar o ruído flat com magnitude 20, mas ambas as técnicas reduziram o percentual de FP ao aumentar a magnitude do ruído. Diferentemente do EWMA e SH a suavização exponencial de Holt-Winters (HW) apresentou elevados percentuais de FP. Com o aumento da magnitude do ruído a técnica elevou o percentual de FP para 100%. Apesar de o HW apresentar alta sensibilidade na detecção de surtos com o padrão flat o alto percentual de alarmes FP inviabiliza a utilização desta técnica na detecção deste tipo de surto.

**Tabela 2.** Sensibilidade do sistema com ruído flat\*.

Técnica	EWMA			SH			HW		
Duração	5	10	15	5	10	15	5	10	15
<b>FLAT</b>									
<b>Magnitude</b>	<b>20</b>								
<b>Detecção (VP)</b>	200	200	200	199	200	200	113	153	176
<b>Detecção (FN)</b>	0	0	0	1	0	0	87	47	24
<b>Sensibilidade (%)</b>	100	100	100	99,5	100	100	56,5	76,5	88
<b>Detecção (FP) (%)</b>	49	90	95	0	51	38,5	58	66	76
<b>Magnitude</b>	<b>30</b>								
<b>Detecção (VP)</b>	200	200	200	200	200	200	200	200	199
<b>Detecção (FN)</b>	0	0	0	0	0	0	0	0	1
<b>Sensibilidade (%)</b>	100	100	100	100	100	100	100	100	99,5
<b>Detecção (FP) (%)</b>	0	0	0	0	0	0	100	100	100
<b>Magnitude</b>	<b>40</b>								
<b>Detecção (VP)</b>	200	200	200	200	200	200	200	200	200
<b>Detecção (FN)</b>	0	0	0	0	0	0	0	0	0

<b>Sensibilidade (%)</b>	100	100	100	100	100	100	100	100	100
<b>Detecção (FP) (%)</b>	0	0	0	0	0	0	100	100	100
<b>Magnitude</b>	<b>50</b>								
<b>Detecção (VP)</b>	200	200	200	200	200	200	200	200	200
<b>Detecção (FN)</b>	0	0	0	0	0	0	0	0	0
<b>Sensibilidade (%)</b>	100	100	100	100	100	100	100	100	100
<b>Detecção (FP) (%)</b>	0	0	0	0	0	0	100	100	100

\* VP = Verdadeiro Positivo, FN = Falso Negativo e FP = Falso Positivo. Verdadeiro Negativo (VN) pode ser obtido VN = 200 - FP. EWMA = Gráfico de Controle de Média Móvel Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. Fonte: Autores, (2020).

A análise das séries com ruídos do tipo linear foi bem similar as séries de ruídos do tipo flat. O sistema apresentou excelentes resultados ao processar dados com ruídos de magnitude 30, 40 e 50 (Tabela 3). É possível observar que as técnicas EWMA e SH conseguiram detectar todos os ruídos em quase 100% das séries analisadas, com exceção da técnica EWMA que em 15% das séries de magnitude 30 e cinco dias de duração identificou alarmes FP. Para as demais séries analisadas a sensibilidade esteve sempre em 100% e não foram detectados alarmes FP. Assim como observadas nas tabelas anteriores, o sistema apresenta dificuldades em detectar ruídos de magnitude 20. Para o caso do ruído do tipo linear não foi diferente; todas as técnicas identificaram ruídos falsos, independente do tempo de duração do ruído, com exceção do SH com 15 dias de duração que não apresentou FP. A técnica HW apresentou resultados não tão eficientes quanto às demais técnicas. A partir da Tabela 3 podemos observar que apesar da técnica apresentar alta sensibilidade, ainda assim foram acionados vários alarmes FP e muitos ruídos não foram identificados (FN), como pode ser visto para séries de magnitude 20, independente do tempo de duração do surto.

**Tabela 3.** Sensibilidade do sistema com ruído linear\*.

Técnica	EWMA			SH			HW		
Duração	5	10	15	5	10	15	5	10	15
<b>LINEAR</b>									
<b>Magnitude</b>	<b>20</b>								
<b>Detecção (VP)</b>	87	115	200	181	92	200	95	90	136
<b>Detecção (FN)</b>	113	85	0	19	108	0	105	110	64
<b>Sensibilidade (%)</b>	43,5	57,5	100	90,5	46	100	47,5	45	68
<b>Detecção (FP) (%)</b>	98,5	93	71,5	7	0,5	0	17	39	71,5
<b>Magnitude</b>	<b>30</b>								
<b>Detecção (VP)</b>	200	200	200	200	200	200	196	200	165
<b>Detecção (FN)</b>	0	0	0	0	0	0	4	0	35
<b>Sensibilidade (%)</b>	100	100	100	100	100	100	98	100	82,5
<b>Detecção (FP) (%)</b>	15	0	0	0	0	0	0	0	0
<b>Magnitude</b>	<b>40</b>								
<b>Detecção (VP)</b>	200	200	200	200	200	200	199	200	197
<b>Detecção (FN)</b>	0	0	0	0	0	0	1	0	3
<b>Sensibilidade (%)</b>	100	100	100	100	100	100	99,5	100	98,5
<b>Detecção (FP) (%)</b>	0	0	0	0	0	0	0	0	0
<b>Magnitude</b>	<b>50</b>								
<b>Detecção (VP)</b>	200	200	200	200	200	200	199	200	195
<b>Detecção (FN)</b>	0	0	0	0	0	0	1	0	5
<b>Sensibilidade (%)</b>	100	100	100	100	100	100	99,5	100	97,5
<b>Detecção (FP) (%)</b>	0	0	0	0	0	0	100	100	100

\* VP = Verdadeiro Positivo, FN = Falso Negativo e FP = Falso Positivo. Verdadeiro Negativo (VN) pode ser obtido VN = 200 - FP. EWMA = Gráfico de Controle de Média Móvel Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. Fonte: Autores, (2020).

Para ruídos do tipo exponencial o sistema apresentou diferentes comportamentos na detecção dos surtos (Tabela 4). É possível observar que para surtos de magnitude 20, o sistema apresentou baixa sensibilidade quando a duração do surto era de cinco ou 15 dias,

esse comportamento foi o mesmo para todas as técnicas do sistema. À medida que a magnitude dos surtos aumentou a sensibilidade também aumentou. Apesar de observarmos um aumento na sensibilidade, a técnica EWMA também aumentou a detecção de surtos FP vindo a cessar apenas para séries com ruídos de magnitude 50. As técnicas SH e HW apresentaram alta sensibilidade na detecção com surtos de magnitudes 30 a 50; as mesmas técnicas apresentam baixa sensibilidade quando avaliadas séries com ruídos de magnitude 20 e durações cinco e 15 dias. Apesar de alta sensibilidade, a técnica HW apresentou altos percentuais de alarmes FP.

**Tabela 4.** Sensibilidade do sistema com ruído exponencial\*.

Técnica	EWMA			SH			HW		
Duração	5	10	15	5	10	15	5	10	15
<b>EXPONENCIAL</b>									
<b>Magnitude</b>	<b>20</b>								
Detecção (VP)	94	130	7	94	200	66	90	179	61
Detecção (FN)	106	70	193	106	0	134	110	21	139
Sensibilidade (%)	47	65	3,5	47	100	33	45	89,5	30,5
Detecção (FP) (%)	90,5	95,5	92,5	1	0	19	21,5	68	89,5
<b>Magnitude</b>	<b>30</b>								
Detecção (VP)	200	200	189	200	200	200	197	200	199
Detecção (FN)	0	0	11	0	0	0	3	0	1
Sensibilidade (%)	100	100	94,5	100	100	100	98,5	100	99,5
Detecção (FP) (%)	43,5	35	75,5	0	0	0	34	74,5	83,5
<b>Magnitude</b>	<b>40</b>								
Detecção (VP)	200	200	200	200	200	200	200	200	200
Detecção (FN)	0	0	0	0	0	0	0	0	0
Sensibilidade (%)	100	100	100	100	100	100	100	100	100
Detecção (FP) (%)	0,5	22,5	0	0	0	0	82	98	97
<b>Magnitude</b>	<b>50</b>								
Detecção (VP)	200	200	200	200	200	200	200	200	200



<b>Detecção (FN)</b>	0	0	0	0	0	0	0	0	0
<b>Sensibilidade (%)</b>	100	100	100	100	100	100	100	100	100
<b>Detecção (FP) (%)</b>	0	0	0	0	0	0	96	100	100

\* VP = Verdadeiro Positivo, FN = Falso Negativo e FP = Falso Positivo. Verdadeiro Negativo (VN) pode ser obtido VN = 200 - FP. EWMA = Gráfico de Controle de Média Móvel Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. Fonte: Autores, (2020).

A técnica EWMA apresentou o pior desempenho na detecção de ruídos do tipo lognormal. O sistema apresentou sensibilidade zero ao analisar séries com surtos de magnitude 30 e 50, mas apesar de baixa sensibilidade, a técnica não detectou FP para séries com ruídos de magnitude acima de 20. As técnicas SH e HW mostraram alta sensibilidade na detecção de surtos, independente da magnitude e duração dos ruídos, com exceção apenas para a técnica HW ao analisar séries com ruídos de duração cinco dias e magnitude 20. Na detecção de surtos falsos positivos as técnicas apresentaram comportamentos distintos. A EWMA apresentou altos percentuais de FP com ruídos de magnitude 20. A técnica SH apresentou os menores percentuais de detecção FP, tendo em sua maioria percentual zero. Por outro lado a HW apresentou o pior desempenho detectando surtos FP, em quase todas as séries que foram utilizadas para testar o sistema.

**Tabela 5.** Sensibilidade do sistema com ruído lognormal\*.

<b>Técnica</b>	<b>EWMA</b>			<b>SH</b>			<b>HW</b>		
<b>Duração</b>	<b>5</b>	<b>10</b>	<b>15</b>	<b>5</b>	<b>10</b>	<b>15</b>	<b>5</b>	<b>10</b>	<b>15</b>
<b>LOGNORMAL</b>									
<b>Magnitude</b>	<b>20</b>								
<b>Detecção (VP)</b>	163	197	200	200	200	200	68	200	200
<b>Detecção (FN)</b>	37	3	0	0	0	0	132	0	0
<b>Sensibilidade (%)</b>	81,5	98,5	100	100	100	100	34	100	100
<b>Detecção (FP) (%)</b>	57,5	41	34,5	0	0	0	28,5	73	94
<b>Magnitude</b>	<b>30</b>								
<b>Detecção (VP)</b>	0	0	0	200	200	200	200	200	200
<b>Detecção (FN)</b>	200	200	200	0	0	0	0	0	0
<b>Sensibilidade (%)</b>	0	0	0	100	100	100	100	100	100

<b>Detecção (FP) (%)</b>	0	0	0	0	0	0	64,5	100	100
<b>Magnitude</b>	<b>40</b>								
<b>Detecção (VP)</b>	0	200	200	200	200	200	200	200	200
<b>Detecção (FN)</b>	200	0	0	0	0	0	0	0	0
<b>Sensibilidade (%)</b>	0	100	100	100	100	100	100	100	100
<b>Detecção (FP) (%)</b>	0	0	0	0	0	0	100	100	100
<b>Magnitude</b>	<b>50</b>								
<b>Detecção (VP)</b>	0	0	0	200	200	200	200	200	200
<b>Detecção (FN)</b>	200	200	200	0	0	0	0	0	0
<b>Sensibilidade (%)</b>	0	0	0	100	100	100	100	100	100
<b>Detecção (FP) (%)</b>	0	0	0	0	0	0	100	100	100

\* VP = Verdadeiro Positivo, FN = Falso Negativo e FP = Falso Positivo. Verdadeiro Negativo (VN) pode ser obtido VN = 200 - FP. EWMA = Gráfico de Controle de Média Móvel Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. Fonte: Autores, (2020).

A Tabela 6 foi desenvolvida para observarmos o comportamento de cada técnica utilizada no *vetsyn* de forma independente e também combinada com outras técnicas.

O gráfico de controle Shewhart, quando avaliado independentemente, identificou 100% dos surtos simulados nos dados em todos os tipos de ruídos com magnitude acima de 30; esse valor diminuiu quando avaliadas séries com magnitude 20 apresentando menor percentual de detecção para séries com ruído do tipo exponencial identificando apenas 60% dos surtos (Tabela 6). Esta técnica quando combinada com outras, não apresenta melhora significativa na detecção de surtos.

A técnica EWMA apresentou alto percentual de detecção VP para séries com ruídos flat, linear e exponencial para magnitudes 30, 40 e 50, este percentual de detecção é reduzido ao avaliar as mesmas séries com ruídos de magnitude 20. Para séries com ruídos do tipo Spike e lognormal a técnica apresentou comportamentos distintos. Para ruídos do tipo Spike observamos alto percentual ao detectar surtos de magnitude 40 (93,5%) e 50 (100%), já no caso dos ruídos lognormal a técnica apresentou alto percentual de detecção VP para surtos de magnitude 20 (93,3%) e 40 (66,7%). Esta técnica quando combinada com outras, diminuiu o percentual de detecção dos surtos.

A suavização exponencial de Holt-Winters demonstrou um comportamento similar na detecção dos surtos. Para séries com ruídos de magnitudes 20 a técnica apresentou percentuais

menores de detecção, onde à medida que a magnitude do ruído aumentou, o percentual de detecção também aumentou, com exceção apenas do ruído spike com magnitude 30 e 40 que passou de 92% para 0,5%, voltando a aumentar quando a magnitude do ruído aumentou (Tabela 6). Esta técnica quando combinada com outras também diminuiu o percentual de detecção dos surtos.

A combinação das técnicas, quando avaliadas simultaneamente, resultou em altos percentuais de detecção para séries com ruídos de magnitudes acima de 30, como foi o caso da combinação SH e HW independente; esta combinação apresentou os maiores percentuais de detecção de VP simultaneamente. A combinação das técnicas EWMA e HW independente, bem como SH e EWMA independente também apresentaram altos percentuais de detecção de surtos, com exceção das séries com ruído lognormal. A combinação das três técnicas SH & EWMA & HW apresentou melhores resultados na detecção de ruídos do tipo flat.

**Tabela 6.** Percentual de alarmes verdadeiros positivos acionados para cada combinação de técnicas de detecção e magnitude ( $\lambda$ ).

	Técnicas e magnitude ( $\lambda$ )																			
	Spike				Flat				Linear				Exponencial				Lognormal			
Combinação*	20	30	40	50	20	30	40	50	20	30	40	50	20	30	40	50	20	30	40	50
SH (indep.)	99	100	100	100	99,8	100	100	100	78,8	100	100	100	60	100	100	100	100	100	100	100
EWMA (indep.)	19,5	0	93,5	100	100	100	100	100	67	100	100	100	38,5	100	100	100	93,3	0	66,7	0
HW (indep.)	17,5	92	0,5	99,5	73,3	99,9	100	100	53,5	93,5	99,9	99,1	46	99,5	100	100	78	100	100	100
SH!EWMA	80	100	6,5	0	0	0	0	0	18,8	0	0	0	21,5	1,8	0	0	16,7	100	33,3	100
SH!HW	81,5	8	3,5	0,5	26,1	0,17	0	0	26,2	6,5	6,67	1,17	8,2	0,7	0	0	22	0	0	0
EWMA!SH	0,5	0	0	0	0,17	0	0	0	7	0	0	0	0	0	0	0	0	0	0	0
EWMA!HW	19	0	3	0,5	26,3	0,17	0	0	25,5	6,5	6,67	1,17	1,5	0,7	0	0	17,3	0	0	0
HW!SH	0	0	0	0	0	0	0	0	0,83	0	0	0	3,2	0	0	0	0	0	0	0
HW!EWMA	17	92	6	0	0	0	0	0	12	0	0	0	18	1,8	0	0	2	100	33,3	100
SH & EWMA (indep.)	19	0	93,5	100	99,8	100	100	100	60	100	100	100	38,5	98,2	100	100	93,3	0	66,7	0
(SH & EWMA)!HW	81,5	0	3	0,5	26,2	0,17	0	0	18,8	6,5	6,67	1,17	1,5	0,17	0	0	17,3	0	0	0

SH & HW (indep.)	17,5	92	96,5	99,5	73,7	99,8	100	100	52,7	93,5	99,3	99	51,8	99,3	100	100	78	100	83	100
(SH & HW)!EWMA	17	92	6	0	0	0	0	0	11,5	0	0	0	14,8	0,19	0	0	2	100	33,3	100
EWMA & HW (indep.)	0,5	0	90,5	99,5	73,7	99,8	100	100	41,5	93,5	99,5	99	37	96,8	100	100	76	0	66	0
(EWMA & HW)!SH	0	0	0	0	0	0	0	0	0,33	0	0	0	0	0	0	0	0	0	0	0
SH & EWMA & HW	0,5	0	90,5	99,5	73,7	99,9	100	100	41,2	93,5	99,5	99,1	37	97,5	100	100	76	0	66,7	0

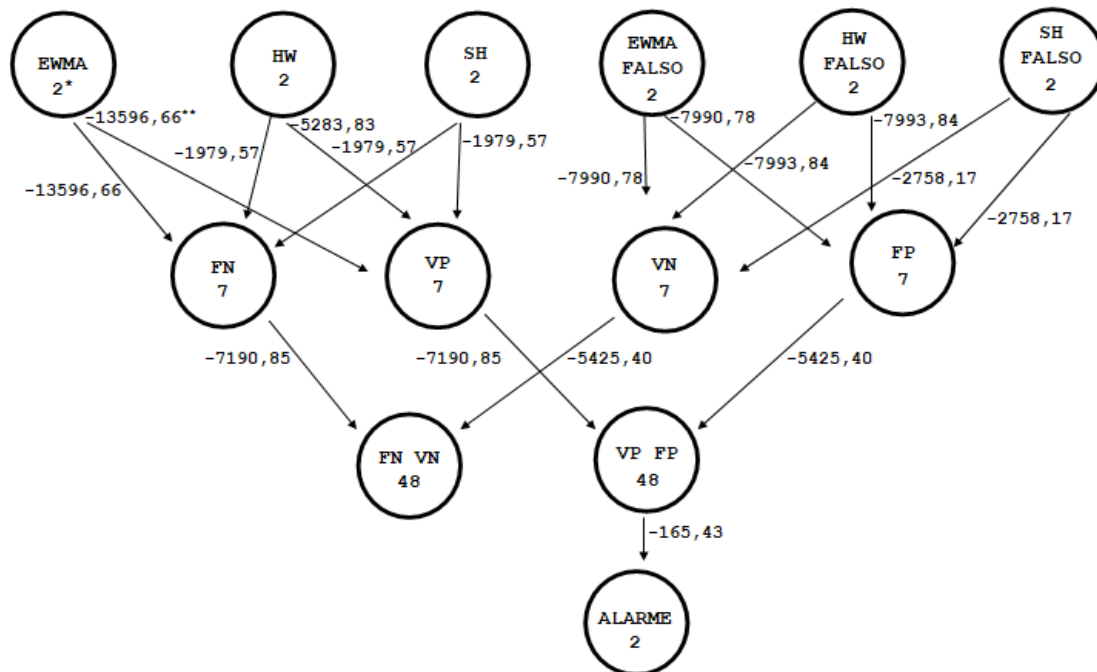
\*Resultado médio para duração de 5, 10 e 15 dias

\*Indicações: “indep”(independente da outra técnica), “&” (simultaneamente a outra técnica), “!” (a técnica não detectou). EWMA = Gráfico de Controle de Média Móvel Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. Fonte: Autores, (2020).

Após analisar a eficiência de cada técnica utilizada no *veysyn* uma rede bayesiana é proposta com o intuito melhorar a eficiência do sistema. A rede proposta contém seis variáveis “pais”, onde três representam alarmes verdadeiros (EWMA, HW, SH) e três representam alarmes falsos (EWMA FALSO, HW FALSO, SH FALSO).

A probabilidade de o sistema apresentar alarme verdadeiro positivo (VP) ou falso positivo (FP) foi de 99,72% para os dados simulados e de 99,87% pelo cálculo da rede (Tabela 7). Diferentes probabilidades para as mesmas condições de alarme acionado ou não, foram encontradas para todas as técnicas (Tabela 7). Caso o alarme seja acionado as probabilidades de FP para EWMA e SH seriam mais baixas que HW. Entretanto as falhas para não acionamento do alarme considerando FN seriam baixas para EWMA e HW, e elevadas para SH.

**Figura 2.** Rede Bayesiana proposta apresentando o número de níveis para o nó (\*) e BIC para a força de ligação (\*\*).



Fonte: Autores, (2020).

Todas as arestas foram significativas pelo teste qui-quadrado ( $p < 0,01$ ). EWMA = Gráfico de Controle de Média Móvel Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. FN = Falso Negativo, VP = Verdadeiro Positivo, VN = Verdadeiro Negativo e FP = Falso Positivo.

**Tabela 7.** Probabilidades para a rede Bayesiana proposta.

Frequência observada para os dados simulados						
Nó	FN	VP	FP	VN	NÃO	SIM
EWMA	0,465240	0,534760				
SH	0,046154	0,953846				
HW	0,103558	0,896442				
EWMA_FALSO			0,170481	0,829519		
SH_FALSO			0,046202	0,953798		
HW_FALSO			0,817644	0,182356		
ALARME					0,002788	0,997212
Probabilidade Ajustada						
EWMA	0,465242	0,534758				
SH	0,046176	0,953824				
HW	0,103577	0,896423				
EWMA_FALSO			0,170497	0,829503		
SH_FALSO			0,046224	0,953776		
HW_FALSO			0,817629	0,182371		
ALARME					0,001275	0,998724
Probabilidades condicionais						
Alarme = não						
EWMA	0,276448	0,723552				
SH	0,669849	0,330151				
HW	0,331798	0,668202				
EWMA_FALSO			0,069702	0,930208		
SH_FALSO			0,338191	0,661909		
HW_FALSO			0,621112	0,378888		
Alarme = sim						
EWMA	0,465483	0,534517				
SH	0,045379	0,954621				

<b>HW</b>	0,103285	0,896715				
<b>EWMA_FALSO</b>			0,170625	0,829375		
<b>SH_FALSO</b>			0,045851	0,954149		
<b>HW_FALSO</b>			0,817880	0,182120		

FN = Falso Negativo, VP = Verdadeiro Positivo, FP = Falso Positivo e VN = Verdadeiro Negativo. EWMA = Gráfico de Controle de Média Móvel Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. Fonte: Autores, (2020).

Em termos gerais o *vetsyn*, ao utilizar as três técnicas de detecção de surto, tende a superestimar a ocorrência de alarmes através de FP e apresentando altas taxas de detecção de surtos VP. Em outras palavras o sistema sempre vai apresentar alarme, independente de ter ocorrido surto, pois o alarme é acionado a qualquer momento, tanto quando ocorre FP quanto VP. Este resultado parece bom sob o aspecto de sempre acionar o sistema de vigilância sanitária a qualquer mínimo comportamento fora do normal, mas a facilidade de ocorrer FP eleva muito o estresse do sistema de vigilância, que pode ser representado pelo excessivo número de análises laboratoriais, mão de obra e recursos financeiros a serem alocados, podendo acarretar simplesmente a exaustão do sistema, ou seja, o gasto em excesso dos mais diversos recursos leva a sua não sustentação, seja por falta de dinheiro, falta de mão de obra entre outros.

A rede Bayesiana proposta permitiu identificar as probabilidades de erros de cada técnica utilizada no sistema, isto é, identificar FP quando o alarme foi acionado, ou FN dado que o alarme não foi acionado. A partir da rede proposta foi possível identificar que a técnica HW apresentou maior probabilidade de FP (81,78%), dado que o alarme foi acionado. Para o caso de FN a técnica EWMA apresentou maior probabilidade (46,54%), dado que o sistema não foi alarmado (Tabela 7).

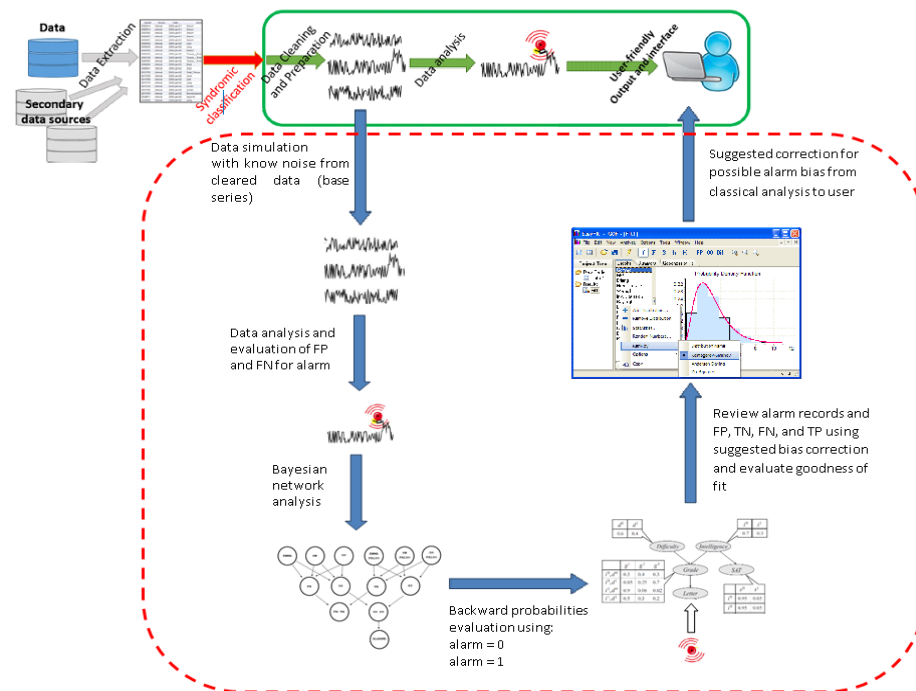
Neste estudo, considerando os dados simulados, a rede revelou que a técnica SH exibiu o melhor índice de detecção verdadeira com menor probabilidade para falsos positivos. Os resultados também possibilitam ao usuário identificar o desempenho de cada técnica utilizada no sistema em termos de probabilidade (Tabela 7).

Uma das formas de melhorar a sensibilidade do sistema desenvolvido por Dórea, Widgrén e Lindberg (2015) é identificando os erros e corrigindo-os. Este processo pode ser dado a partir da rede Bayesiana proposta, a qual identifica quais técnicas estão fornecendo os maiores índices de alarmes FP e FN, em termos de probabilidade. Com este intuito criamos a Figura 3 que apresenta o fluxograma original das etapas de funcionamento do sistema *vetsyn* e



incluimos a rede Bayesiana proposta neste estudo como parte da análise dos dados. A rede poderia ser inserida como parte da avaliação do sistema corrigindo os alarmes como mostra a Figura 3.

**Figura 3** - Sugestão de aperfeiçoamento do sistema *vetsyn* inserindo a rede Bayesiana proposta.



Fonte: Autores, (2020).

Assim, um conjunto de dados simulados seriam inseridos no sistema já implementado, e após análise dos dados a rede Bayesiana seria construída fornecendo as probabilidades de acionamento, ou não, do alarme. Dessa forma o usuário teria acesso a uma tabela de probabilidades (Tabela 7), a qual identificaria quais técnicas apresentam os maiores índices de FP e FN. Após obtenção das probabilidades, o usuário poderia corrigir todos os níveis para as duas variáveis FN VN e VP FP escolhendo uma probabilidade de corte para correção. Em consequência os níveis que apresentavam valores 1 receberão valores 0 e vice-versa para todos os pontos no vetor de alarmes, alterando os pontos que foram classificados como FN para VP e os FP para VN; da mesma forma podem ocorrer ajustes desfavoráveis como uma substituição de VP por FN e VN por FP.

Esta correção foi implementada no *vetsyn* tomando os parâmetros estatísticos dos dados simulados como sendo a amostra, e os resultados podem ser observados na Tabela 8. É possível observar que com probabilidade de correção 0,1% alguns erros já são corrigidos no

sistema, como o índice de valores FN para a técnica SH que diminuiu de 0,046154 para 0,025622. Com o aumento da probabilidade de correção para 5% os valores melhoram ainda mais, como por exemplo, o índice de FN das técnicas SH e HW quem são todos corrigidos. Com uma probabilidade de correção de 30% os alarmes FN e FP são totalmente corrigidos tanto quanto os alarmes VP e VN para todas as técnicas avaliadas.

Apesar de esses resultados aplicarem-se a dados simulados, onde se conhece exatamente a distribuição dos dados, a ocorrência ou não dos surtos e a adequação dos métodos na análise desses, a abordagem apresentada para a correção dos erros não perde importância frente a dados reais. A diferença está em que o novo sistema apresentaria a sugestão de correção ao analista e este seria responsável por avaliar a sugestão e acatá-la ou não, e tal decisão não se faria exclusivamente de forma subjetiva, mas com suporte probabilístico. Além disso, a abordagem pode ser estendida para qualquer espécie e doença, uma vez que não altera o modo básico de análise e tampouco o sistema de alarmes.

**Tabela 8.** Melhorias do sistema com ajuste através da rede Bayesiana proposta.

Frequência de mudança para os níveis de resposta					
Mudança na aceitação da resposta (%)	Nó	FN	VP	FP	VN
<b>Observada*</b>	<b>EWMA</b>	0,465240	0,534760		
	<b>SH</b>	0,046154	0,953846		
	<b>HW</b>	0,103558	0,896442		
	<b>EWMA_FALSO</b>			0,170481	0,829519
	<b>SH_FALSO</b>			0,046202	0,953798
	<b>HW_FALSO</b>			0,817644	0,182356
<b>0,01</b>	<b>EWMA</b>	0,465240	0,534760		
	<b>SH</b>	0,046154	0,953846		
	<b>HW</b>	0,103558	0,896442		
	<b>EWMA_FALSO</b>			0,170481	0,829519
	<b>SH_FALSO</b>			0,046202	0,953798
	<b>HW_FALSO</b>			0,817644	0,182356
<b>0,1</b>	<b>EWMA</b>	0,446299	0,553701		

	<b>SH</b>	0,025722	0,974278		
	<b>HW</b>	0,082789	0,917211		
	<b>EWMA_FALSO</b>			0,159375	0,840625
	<b>SH_FALSO</b>			0,031442	0,968558
	<b>HW_FALSO</b>			0,814086	0,185914
<b>0,5</b>	<b>EWMA</b>	0,403222	0,596778		
	<b>SH</b>	0,008799	0,991201		
	<b>HW</b>	0,044183	0,955817		
	<b>EWMA_FALSO</b>			0,117692	0,882309
	<b>SH_FALSO</b>			0,002307	0,997693
	<b>HW_FALSO</b>			0,788269	0,211731
<b>1</b>	<b>EWMA</b>	0,388799	0,611201		
	<b>SH</b>	0,008799	0,991201		
	<b>HW</b>	0,019327	0,980673		
	<b>EWMA_FALSO</b>			0,108317	0,891683
	<b>SH_FALSO</b>			0,002307	0,997693
	<b>HW_FALSO</b>			0,778894	0,221106
<b>5</b>	<b>EWMA</b>	0,36101	0,638990		
	<b>SH</b>	0	1		
	<b>HW</b>	0	1		
	<b>EWMA_FALSO</b>			0,058798	0,941202
	<b>SH_FALSO</b>			0	1
	<b>HW_FALSO</b>			0,754038	0,245962
<b>10</b>	<b>EWMA</b>	0,328750	0,671250		
	<b>SH</b>	0	1		
	<b>HW</b>	0	1		
	<b>EWMA_FALSO</b>			0	1
	<b>SH_FALSO</b>			0	1
	<b>HW_FALSO</b>			0,695240	0,304760

20	<b>EWMA</b>	0,328750	0,671250		
	<b>SH</b>	0	1		
	<b>HW</b>	0	1		
	<b>EWMA_FALSO</b>			0	1
	<b>SH_FALSO</b>			0	1
	<b>HW_FALSO</b>			0,695240	0,304760
30	<b>EWMA</b>	0	1		
	<b>SH</b>	0	1		
	<b>HW</b>	0	1		
	<b>EWMA_FALSO</b>			0	1
	<b>SH_FALSO</b>			0	1
	<b>HW_FALSO</b>			0	1

FN = Falso Negativo, VP = Verdadeiro Positivo, FP = Falso Positivo e VN = Verdadeiro Negativo. EWMA = Gráfico de Controle de Média Móvel Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. EWMA\_FALSO = Gráfico de Controle de Média Móvel Ponderado Exponencialmente apresentando alarmes falsos, SH\_FALSO = Gráfico de Controle Shewhart apresentando alarmes falsos e HW\_FALSO = Suavização Exponencial Holt-Winters apresentando alarmes falsos. Fonte: Autores, (2020).

Diante destes resultados pode-se afirmar que o sistema *vetsyn* apresenta alta sensibilidade para a detecção de surtos a partir de dados simulados de mortalidade para aves de postura, contudo sendo necessárias correções na detecção de alarmes FP e FN, dado que estes podem despender gasto em excesso dos mais diversos recursos. A rede Bayesiana sugerida como ferramenta de identificação de situações falsas (FP e FN) e suas correções aumentaram a sensibilidade e a confiabilidade do sistema *vetsyn*.

#### 4. Conclusões

A partir dos resultados apresentados pode-se concluir que dentre as técnicas avaliadas no sistema *vetsyn*, o gráfico de controle Shewhart apresentou os melhores resultados na identificação de surtos verdadeiros positivos. O gráfico de controle de média móvel Ponderado Exponencialmente e a suavização exponencial Holt-Winters não apresentaram diferenças significativas em sua utilização. O gráfico de controle Shewhart exibiu o melhor índice de detecção verdadeira com menor probabilidade para alarmes falsos positivos. O

sistema tende a superestimar a ocorrência de alarmes falso positivos, entretanto a rede bayesiana proposta corrigiu a um nível de 30% todas as falhas do *vetsyn*.

Para trabalhos futuros esperamos utilizar dados reais para testar o sistema *vetsyn* com as modificações recomendadas neste estudo. Além disso, planejamos avaliar se dados provenientes de diferentes espécies animais resultam em diferentes resultados na eficiência de cada técnica ao identificar surtos verdadeiros positivos.

## Referências

Barboza, V. H. D. (2018). Bioterrorismo e suas perspectivas em saúde pública. Recuperado de <https://repositorio.uniceub.br/jspui/handle/235/11667>

Ben-Gal, I. (2007). Bayesian networks. *Encyclopedia of statistics in quality and reliability, 1*. <https://doi.org/10.1002/9780470061572.eqr089>

Bower, K. M. (2000). Using exponentially weighted moving average (EWMA) charts. *Asia Pacific Process Engineer*. (October 2000) Recuperado de: [https://www.researchgate.net/profile/Keith\\_M\\_Bower/publication/337801788\\_Using\\_Exponentially\\_Weighted\\_Moving\\_Average\\_EWMA\\_Charts/links/5deadfb54585159aa4689348/Using-Exponentially-Weighted-Moving-Average-EWMA-Charts.pdf](https://www.researchgate.net/profile/Keith_M_Bower/publication/337801788_Using_Exponentially_Weighted_Moving_Average_EWMA_Charts/links/5deadfb54585159aa4689348/Using-Exponentially-Weighted-Moving-Average-EWMA-Charts.pdf)

Bronner, A., Morignat, E., Fournié, G., Vergne, T., Vinard, J. L., Gay, E., & Calavas, D. (2015). Syndromic surveillance of abortions in beef cattle based on the prospective analysis of spatio-temporal variations of calvings. *Scientific reports, 5*, 18285. <https://doi.org/10.1038/srep18285>.

Buehler, J. W., Berkelman, R. L., Hartley, D. M., & Peters, C. J. (2003). Syndromic surveillance and bioterrorism-related epidemics. *Emerging infectious diseases, 9*(10), 1197. <https://doi.org/10.3201/eid0910.030231>

Costa, A. F. B., Epprecht, E. K., & Carpinetti, L. C. R. (2005). *Controle estatístico de qualidade* (pp. 185-94). São Paulo: Atlas.

Dórea, F. C., Revie, C. W., McEwen, B. J., McNab, W. B., Kelton, D., & Sanchez, J. (2013). Retrospective time series analysis of veterinary laboratory data: preparing a historical baseline for cluster detection in syndromic surveillance. *Preventive veterinary medicine*, *109*(3-4), 219-227. <https://doi.org/10.1016/j.prevetmed.2012.10.010>

Dórea, F. C., Widgren, S., & Lindberg, A. (2015). Vetsyn: an R package for veterinary syndromic surveillance. *Preventive veterinary medicine*, *122*(1-2), 21-32. <https://doi.org/10.1016/j.prevetmed.2015.10.002>

Edo-Osagie, O., Smith, G., Lake, I., Edeghere, O., & De La Iglesia, B. (2019). Twitter mining using semi-supervised classification for relevance filtering in syndromic surveillance. *PloS one*, *14*(7), e0210689. <https://doi.org/10.1371/journal.pone.0210689>

Gibbens, J. C., Wilesmith, J. W., Sharpe, C. E., Mansley, L. M., Michalopoulou, E., Ryan, J. B. M., & Hudson, M. (2001). Descriptive epidemiology of the 2001 foot-and-mouth disease epidemic in Great Britain: the first five months. *Veterinary Record*, *149*(24), 729-743. <http://dx.doi.org/10.1136/vr.149.24.729>

Heffernan, R., Mostashari, F., Das, D., Besculides, M., Rodriguez, C., Greenko, J., ... & Phillips, M. (2004). New York City syndromic surveillance systems. *Morbidity and Mortality Weekly Report*, 25-27.

Henning, K. J. (2004). What is syndromic surveillance? *Morbidity and mortality weekly report*, 7-11.

Højsgaard, S. (2012). Graphical independence networks with the gRain package for R. *Journal of Statistical Software*, *46*(10), 1-26.

Hy-Line (2016). Guia de manejo para poedeiras comerciais Hy-Line W-36. Recuperado de <https://www.hyline.com/french/filesimages/Hy-Line-Products/Hy-Line-Product-PDFs/W-36/36%20COM%20POR.pdf>

Lalkhen, A. G., & McCluskey, A. (2008). Clinical tests: sensitivity and specificity. *Continuing Education in Anaesthesia Critical Care & Pain*, 8(6), 221-223. <https://doi.org/10.1093/bjaceaccp/mkn041>

Mandl, K. D., Overhage, J. M., Wagner, M. M., Lober, W. B., Sebastiani, P., Mostashari, F., & Hutwagner, L. (2004). Implementing syndromic surveillance: a practical guide informed by the early experience. *Journal of the American Medical Informatics Association*, 11(2), 141-150. <https://doi.org/10.1197/jamia.M1356>

Marques, R. L., & Dutra, I. N. Ê. S. (2002). Redes Bayesianas: o que são, para que servem, algoritmos e exemplos de aplicações. *Coppe Sistemas–Universidade Federal do Rio de Janeiro, Rio de Janeiro, Brasil*. Recuperado de: <https://cos.ufrj.br/~ines/courses/cos740/leila/cos740/Bayesianas.pdf>

Mingoti, S. A., & Yassukawa, F. R. (2008). Uma comparação de gráficos de controle para a média de processos autocorrelacionados. *Sistemas & Gestão*, 3(1), p.55-73.

Mnatsakanyan, Z. R., Burkom, H. S., Coberly, J. S., & Lombardo, J. S. (2009). Bayesian information fusion networks for biosurveillance applications. *Journal of the American Medical Informatics Association*, 16(6), 855-863. <https://doi.org/10.1197/jamia.M2647>

Montgomery, D. C. (2007). *Introduction to statistical quality control*. John Wiley & Sons. Arizona-US.

Mostashari, F., & Karpati, A. (2002). Towards a theoretical (and practical) framework for prodromic surveillance. In *International Conference on Emerging Infectious Diseases, Atlanta, GA, March*.

Olson, K. L., & Mandl, K. D. (2002). Geocoding patient addresses for biosurveillance. In *Proceedings of the AMIA Symposium* (p. 1119). American Medical Informatics Association.

Ozonoff, A., Forsberg, L., Bonetti, M., & Pagano, M. (2004). Bivariate method for spatio-temporal syndromic surveillance. *Morbidity and Mortality Weekly Report*, 61-66.

R Core Team (2020). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. Recuperado de <https://www.R-project.org/>.

Pereira, A. S., Shitsuka, D. M., Parreira, F. J., & Shitsuka, R. (2018). *Metodologia da pesquisa científica. [e-book]. Santa Maria. Ed. UAB/NTE/UFSM*. Recuperado de: [https://repositorio.ufsm.br/bitstream/handle/1/15824/Lic\\_Computacao\\_Metodologia-Pesquisa-Cientifica.pdf](https://repositorio.ufsm.br/bitstream/handle/1/15824/Lic_Computacao_Metodologia-Pesquisa-Cientifica.pdf).

Roberts, S. W. (2000). Control chart tests based on geometric moving averages. *Technometrics*, 42(1), 97-101.

Rogerson, P. A., & Yamada, I. (2004). Approaches to syndromic surveillance when data consist of small regional counts. *Morbidity and Mortality Weekly Report*, 79-85.

Schwabe, C. (1982). The current epidemiological revolution in veterinary medicine. Part I. *Preventive Veterinary Medicine*, 1(1), 5-15. [https://doi.org/10.1016/0167-5877\(82\)90003-4](https://doi.org/10.1016/0167-5877(82)90003-4)

Scutari, M. (2010). Learning Bayesian Networks with the bnlearn R Package. *Journal of Statistical Software*, 35(3), 1-22. Recuperado de <http://www.jstatsoft.org/v35/i03/>

Silva, W. V. da; Samohyl, R. W.; Costa, L. S. (2002). Comparação entre os métodos de previsão univariados para o preço médio da soja no brasil. *Anais XXII Encontro Nacional de Engenharia de Produção 2002*, 1-8.

Veríssimo, A. J., Alves, C. C., Henning, E., Amaral, C. E., Cruz, A. C. (2013). Métodos estatísticos de suavização exponencial holt-winters para previsão de demanda em uma empresa do setor metal mecânico. *Revista Gestão Industrial*, 8(4). <https://doi.org/10.3895/S1808-04482012000400009>



Wagner, M. M., Tsui, F. C., Espino, J. U., Dato, V. M., Sittig, D. F., Caruana, R. A., & Fridsma, D. B. (2001). The emerging science of very early detection of disease outbreaks. *Journal of public health management and practice*, 7(6), 51-59.

Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management science, INFORMS*, 6(3), 324–342. <https://doi.org/10.1287/mnsc.6.3.324>

Zeng, D., Chen, H., Lynch, C., Eidson, M., & Gotham, I. (2005). Infectious disease informatics and outbreak detection. In *Medical Informatics* (pp. 359-395). Springer, Boston, MA.

**Porcentagem de contribuição de cada autor no manuscrito**

Patricia de Souza Medeiros Pina Ximenes – 50%

Kleber Régis Santoro – 50%