

Patrícia de Souza Medeiros Pina Ximenes

**SENSIBILIDADE DE ALARME EM UM SISTEMA DE
VIGILÂNCIA EPIDEMIOLÓGICA SINDRÔMICA E PROPOSTA
DE REDE BAYESIANA**

Recife

2 de abril de 2018



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM BIOMETRIA E ESTATÍSTICA APLICADA

**SENSIBILIDADE DE ALARME EM UM SISTEMA DE VIGILÂNCIA EPIDEMIOLÓGICA
SINDRÔMICA E PROPOSTA DE REDE BAYESIANA**

**Dissertação julgada adequada para obtenção
do título de Mestre em Biometria e Estatística Aplicada, com defesa em 27/02/2018 pela
comissão examinadora**

Área de concentração: Biometria e Estatística Aplicada

Orientador: Dr. Kleber Régis Santoro

Recife

2 de abril de 2018

Agradecimentos

À Deus pela graça de poder concluir mais uma etapa em minha carreira profissional.

Aos meus pais Renato Medeiros e Cristina Medeiros pelo amor e educação que me proporcionaram desde o meu nascimento permitindo que eu chegasse até aqui.

À minha irmã Renata Medeiros que sempre foi uma inspiração como profissional.

Ao meu esposo Fleber Ximenes que sempre apoiou todas as escolhas que fiz.

Ao meu orientador, professor Kleber Régis Santoro, pela paciência e instruções que brilhantemente me foram dadas.

Aos meus colegas de curso, pela parceria e incentivo durante todo o mestrado.

Ao professor Samuel Silva, por me ajudar a configurar esta dissertação em \LaTeX .

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão de bolsa de estudos e também através do projeto número 203/13.

À Universidade Federal Rural de Pernambuco, que me proporcionou cursar o mestrado em Biometria e Estatística Aplicada.

A todos que direta e indiretamente me ajudaram nesta jornada, muito obrigada.

*Que darei eu ao Senhor, por todos
os benefícios que me tem feito?
(Bíblia Sagrada, Salmos 116:12)*

Resumo

A eficiência de um sistema de vigilância sindrômica foi avaliada para mortalidade em aves de postura tendo como base de comportamento recomendações internacionais. 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 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.

Palavras-chaves: 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. The alarm techniques of the system 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 contributed the most to the correct detection of outbreaks, with a probability greater than 95% in the detection of true positives and only 4.6% of false positives. In order to correct the system's sensitivity in detecting outbreaks, a Bayesian network was developed. This network was proposed as part of the evaluation of the results of the system giving greater accuracy. The proposed Bayesian network was able to correct errors of the evaluated system, proving to be a viable addition to the syndromic surveillance system.

Key-words: Outbreak detection, Bayesian networks, animal surveillance.

Lista de Figuras

Figura 1 – Vigilância sindrômica frente a métodos tradicionais de diagnóstico.	5
Figura 2 – Passos para implementar um sistema de vigilância sindrômica, desde a extração de dados até a interface do usuário.	6
Figura 3 – Estrutura esquemática de um objeto <i>syndromic</i> e suas conexões com as diferentes etapas das análises no pacote <i>vetsyn</i>	7
Figura 4 – Modelo de um de gráfico de controle.	9
Figura 5 – Exemplo de Rede Bayesiana.	15
Figura 6 – Representação do critério <i>d</i> -separação.	17
Figura 7 – Tipos de ruído.	24
Figura 8 – Rede Bayesiana proposta apresentando o número de níveis para o nó (*) e BIC para a força de ligação (**).	34
Figura 9 – Sugestão de aperfeiçoamento do sistema <i>vetsyn</i> inserindo a rede Bayesiana proposta.	37

Lista de tabelas

Tabela 1 – Exemplo de tabela 2x2.	12
Tabela 2 – Quatro casos de problemas de aprendizado em BN (BEN-GAL, 2007).	18
Tabela 3 – Sensibilidade do sistema com ruído spike e pré-processamento GLM *.	25
Tabela 4 – Sensibilidade do sistema com ruído spike e pré-processamento diferenciação *.	26
Tabela 5 – Sensibilidade do sistema com pré-processamento GLM *.	28
Tabela 6 – Sensibilidade do sistema com pré-processamento diferenciação *.	29
Tabela 7 – Porcentagem de alarmes verdadeiro positivos acionados para cada combinação de técnicas de detecção e magnitude (λ).	32
Tabela 8 – Correlação entre as técnicas *.	33
Tabela 9 – Probabilidades para a rede Bayesiana proposta.	35
Tabela 10 – Melhorias do sistema com ajuste através da rede Bayesiana proposta.	39

Lista de abreviaturas e siglas

AHSyS	Animal Health Surveillance
BIC	Bayesian Information Criterion
BN	Rede Bayesiana
CDC	Centers for Disease Control and Prevention
CT	Correlação Tetracórica
CUSUM	Gráfico de Controle das Somas Acumuladas
DAG	Grafo Acíclico Dirigido
DIFF	Diferenciação
DPC	Distribuição de Probabilidade Conjunta
EWMA	Gráfico de Controle de Média Model Ponderado Exponencialmente
FP	Falso Positivo
FN	Falso Negativo
GLM	Modelo Linear Generalizado
HW	Suavização Exponencial Holt-Winters
LC	Linha Central
LIC	Limite Inferior de Controle
LSC	Limite Superior de Controle
MCC	Coefficiente de Correlação de Matthews
MCMC	Markov Chain Monte Carlo
SH	Gráfico de Controle Shewhart
SIG	Sistemas de Informação Geográfica
VP	Verdadeiro Positivo
VN	Verdadeiro Negativo
VS	Vigilância Síndrômica

Sumário

1	Introdução Geral	1
2	Revisão de Literatura	4
2.1	Vigilância Sindrômica	4
2.2	O pacote <i>vetsyn</i>	6
2.2.0.1	Suavização exponencial de Holt-Winters (HW)	8
2.2.0.2	Gráfico de controle Shewhart (SH)	9
2.2.0.3	Gráfico de controle da soma cumulativa (CUSUM)	10
2.2.0.4	Gráfico de controle de média móvel ponderado exponencialmente (EWMA)	10
2.3	Métodos de concordância em dados categóricos	11
2.3.1	Coeficiente de correlação de Matthews (MCC)	11
2.3.2	Correlação Tetracórica (CT)	12
2.3.3	Sensibilidade	13
2.4	Redes Bayesianas	14
2.4.1	Inferência em Redes Bayesianas	17
2.4.2	Aprendizado em Redes Bayesianas	18
3	SENSIBILIDADE DE ALARME EM UM SISTEMA DE VIGILÂNCIA SINDRÔMICA EPIDEMIOLÓGICA	20
3.1	Resumo	20
3.2	Introdução	20
3.3	Materiais e Método	22
3.4	Resultados	25
3.5	Discussão	35
3.6	Agradecimentos	40
4	Conclusão	41
	Referências Bibliográficas	42

1 Introdução Geral

A epidemiologia pode ser definida como o estudo da doença e dos fatores que determinam sua ocorrência na população; já a epidemiologia veterinária é direcionada aos estudos de doenças em populações animais. Na avicultura a epidemiologia veterinária contribui fornecendo a frequência e a distribuição da saúde e da doença das aves, identificando os fatores que influenciam a ocorrência e severidade da doença na população em estudo, além de quantificar a inter-relação entre saúde e doença (THRUSFIELD, 2004).

O conjunto de atividades que permite reunir informações indispensáveis para conhecer em todo momento o comportamento ou história natural das doenças, detectar ou prever qualquer mudança que possa ocorrer por alterações dos fatores condicionantes, com o fim de recomendar oportunamente, sobre bases firmes, as medidas indicadas à prevenção e controle da doença é chamada de vigilância epidemiológica (FOSSAERT; LLOPIS; TIGRE, 1974).

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 (MNAT-SAKANYAN et al., 2009).

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, permite alcançar os objetivos centrais da vigilância de doenças (ZENG et al., 2005).

A informática aplicada a doenças infecciosas seriam ciências e tecnologias necessárias para coletar, compartilhar, relatar, analisar e visualizar dados de doenças infecciosas as quais forneceriam suporte de dados e de tomada de decisão para estas doenças. Esta existe como uma área interdisciplinar, a qual envolve uma variedade de tecnologias da informação como, por exemplo, compartilhamento de dados e segurança, sistemas de informação geográfica (SIG), mineração de dados, gerenciamento de conhecimento, bioestatística e bioinformática (CHEN et al., 2005; ZENG et al., 2005).

Devido à falta de especificidade associada aos dados de pré-diagnóstico, este novo tipo de vigilância visa grupos gerais de doenças ou síndromes e, portanto, é muitas vezes referido como “Vigilância Síndromica (VS)” (HENNING, 2004). Um dos principais registros da VS foi dado pelo quadro de avaliação do *Centers for Disease Control and Prevention* (CDC) nos Estados Unidos, pouco antes dos atentados terroristas de 2001 no país. Embora a necessidade de técnicas de vigilância inovadoras já tivessem sido identificadas, este acontecimento acelerou a implementação de sistemas de vigilância síndromica nos Estados Unidos (HENNING, 2004).

Uma definição mais abrangente sobre VS e, provavelmente, a mais adequada a ser adotada, foi dada pelo projeto europeu *Triple-S* que a descreveu como a coleta, análise, interpretação e divulgação em tempo real (ou quase em tempo real) de dados relacionados à saúde para permitir a identificação precoce do impacto (ou ausência de impacto) de potenciais ameaças humanas ou veterinárias de saúde pública que exigem uma ação efetiva de saúde pública (HULTH, 2014). O objetivo fundamental da vigilância sindrômica é identificar doenças precocemente, antes que os diagnósticos laboratoriais sejam confirmados e reportados às agências de saúde pública para mobilizar uma resposta rápida, reduzindo assim a morbidade e a mortalidade (HENNING, 2004).

Dórea, Sanchez e Revie (2011) forneceram uma abordagem abrangente das iniciativas de Vigilância Sindrômica em Saúde Animal - *Animal Health Syndromic Surveillance* (AHSyS), concluindo que o campo era incipiente, mas crescia rapidamente, o que foi confirmado em 2013 quando o projeto europeu *Triple-S* produziu um inventário dos sistemas AHSyS europeus atuais e previstos de 12 países; e as primeiras orientações européias sobre a vigilância sindrômica na saúde humana e animal (DUPUY et al., 2013).

Com o crescente interesse de pesquisadores em investigar a VS, Dórea e Vial (2016) desenvolveram uma revisão sistemática da literatura sobre o progresso da VS. Neste estudo várias abordagens estatísticas foram identificadas como estratégia de investigação na VS, entre elas: geoestatística, gráficos de controle, modelos de regressão, redes Bayesianas e análise de cluster.

Uma das principais características de um sistema AHSyS eficiente é capturar diferentes informações contidas em observações de diferentes fontes de dados, tornando-o um sistema multivariado por natureza, isto é, um sistema que avalia simultaneamente várias combinações de múltiplos conjuntos de dados (DÓREA; VIAL, 2016). Os métodos univariados são menos sensíveis às mudanças na incidência da doença e sofrem com uma taxa maior de alertas falsos, fazendo com que os usuários ignorem os alertas. Por este motivo, Dórea e Vial (2016) afirmaram que as metodologias Bayesianas, como as desenvolvidas por vários pesquisadores (ROBERTSON et al., 2011; ANDERSSON et al., 2014; FISCHER et al., 2015), são muito mais aptas a descobrir a interação entre múltiplas fontes de dados, tornando-se cada vez mais comuns nos sistemas de monitoramento on-line e espera-se que desempenhem um papel importante no futuro da AHSyS.

As Redes Bayesianas (BN) oferecem uma abordagem para o raciocínio probabilístico que engloba teoria de grafos, para o estabelecimento das relações entre sentenças e ainda, teoria de probabilidades, para a atribuição de níveis de confiabilidade (MARQUES; DUTRA, 2002a). Os primeiros estudos sobre BN surgiram na década de 80 pelo professor Judea Pearl, tendo como principal objetivo calcular as probabilidades de distribuição de um grupo de variáveis (OLIVA et al., 2009). Desde o surgimento, as BN tem sido utilizadas para solucionar ou contribuir com a solução de diversos tipos de problemas, em diversas áreas, como por exemplo: diagnóstico médico (NIKOVSKI, 2000), epidemiologia (RODIN; BOERWINKLE, 2005), ecologia e gestão de recursos naturais (MCCANN; MARCOT; ELLIS, 2006).

No contexto de vigilância sindrômica podemos encontrar alguns estudos que envolveram redes Bayesianas no processo de detecção de surtos em humanos (WONG et al., 2003; MNATSAKANYAN

et al., 2009). A maioria destes estudos utilizou diferentes tipos de variáveis para a confecção das redes, como por exemplo: idade, clima, condições de alimentação, estação do ano, etc (WONG et al., 2003).

Desenvolver sistemas de vigilância que sejam capazes de detectar surtos de doenças é de grande valor, não apenas para a saúde animal, mas também para a saúde humana. Em um período onde a coleta eletrônica de dados de saúde animal está em ascensão, especialistas em vigilância estão interessados em desenvolver e executar sistemas de vigilância que monitoram simultaneamente vários fluxos de dados na detecção de surtos (DÓREA; VIAL, 2016). Desta forma, desenvolver pesquisas que investigam sistemas de VS já utilizados visando aprimorar seus resultados contribuem significativamente para o desenvolvimento da VS em saúde animal.

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

2 Revisão de Literatura

2.1 Vigilância Sindrômica

Os primeiros registros de sistemas de vigilância sindrômica estabelecidos na cidade de Nova York foram na década de 90 e tinham como objetivo detectar surtos de doenças transmitidas pela água (HEFFERNAN et al., 2004). Em 2001 após os ataques do World Trade Center surgiu uma preocupação com o bioterrorismo, o que impulsionou o desenvolvimento de sistemas de vigilância para acompanhar as principais queixas dos pacientes (HEFFERNAN et al., 2004).

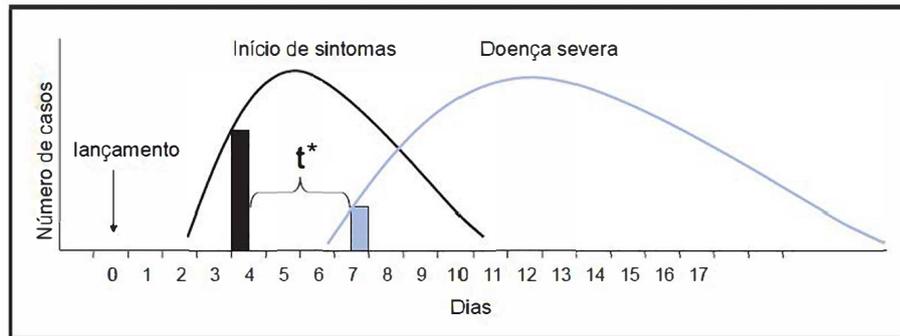
Um dos objetivos do *Center for Disease Control and Prevention* (CDC) nos Estados Unidos, foi desenvolver programas de detecção precoce e investigação de surtos (HEFFERNAN et al., 2004). A princípio, funcionários de saúde pública começaram a melhorar a detecção de infecções e doenças emergentes causadas por agentes biológicos, com o objetivo de detectar precocemente estas infecções e doenças. Embora a necessidade de técnicas de vigilância já tivessem sido identificadas, o surto de Antrax em 2001 acelerou a implementação de sistemas de vigilância sindrômica nos Estados Unidos (HEFFERNAN et al., 2004).

A partir do uso de ferramentas da informática, sistemas de vigilância sindrômica foram desenvolvidos, utilizando dados de pré-diagnóstico já disponíveis (MANDL et al., 2004) como, por exemplo, dados laboratoriais (BUEHLER et al., 2003), queixa principal do paciente na visita de emergência (HEFFERNAN et al., 2004), solicitação de testes laboratoriais (DÓREA; WIDGRÉN; LINDBERG, 2015), entre outros.

O principal objetivo da vigilância sindrômica é identificar grupos de doenças antes que os diagnósticos sejam confirmados e reportados às agências de saúde pública, reduzindo assim a morbidade e a mortalidade (HENNING, 2004). Na Figura 1, pode-se observar uma ilustração da atuação da VS frente a métodos tradicionais de diagnóstico. Inicialmente uma doença é lançada na população e em pouco tempo os primeiros sintomas são identificados a partir de sistemas de vigilância sindrômica, pouco tempo depois, os métodos tradicionais de diagnóstico identificam estes sintomas e como consequência, iniciam as providências no combate a doença identificada. A vigilância sindrômica busca identificar um número mínimo de casos iniciais, permitindo a detecção de um surto t dias antes ao relato tradicional de casos confirmados (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 et al., 2001), vigilância prodome (MOSTASHARI; KARPATI, 2002), sistema de bio-vigilância (OLSON; MANDL, 2002), no entanto o

Figura 1 – Vigilância sindrômica frente a métodos tradicionais de diagnóstico.



*tempo entre detecção por vigilância sindrômica (pré-diagnóstico) e detecção por vigilância tradicional (baseada no diagnóstico).

Fonte: (HENNING, 2004)

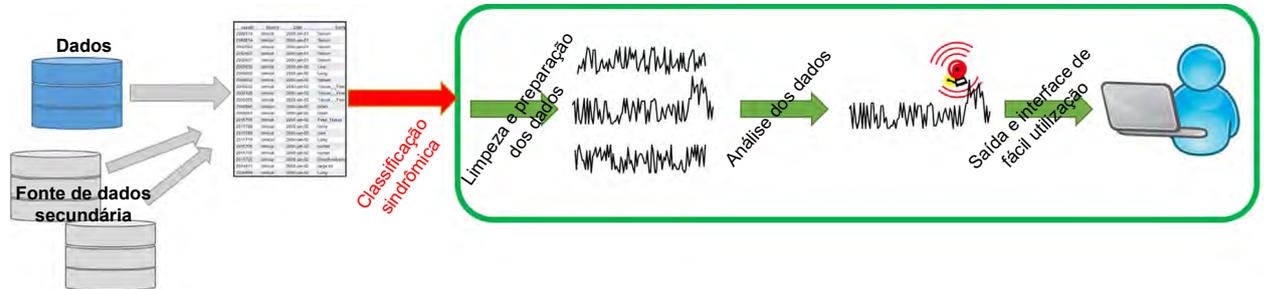
termo vigilância sindrômica persistiu (HENNING, 2004).

Segundo Henning (2004), diferentes tipos de sistemas de VS foram utilizados, onde variavam de acordo com a duração que atuavam e a maneira de adquirir dados. Dentre os tipos de sistemas encontrados o *drop-in surveillance* consistia em projetos de curto prazo, onde os médicos que trabalhavam com o sistema necessitavam coletar informações não rotineiras dos pacientes, atrapalhando a atuação médica necessária no atendimento (CONTROL; CDC et al., 2002). Outro tipo de sistema de VS foi o manual, que era baseado em relatórios via fax, o que demorava certo tempo para a construção dos resultados (BEGIER et al., 2003). Dentre todos os sistemas de VS propostos, os eletrônicos foram os que apresentaram melhor resultados, principalmente pela rapidez em transferir dados em respostas, pois baseavam-se na implementação rápida de dados transferidos eletronicamente (GESTELAND et al., 2002).

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 et al., 2004), teste de razão de verossimilhança generalizada (WALLENSTEIN; NAUS, 2004), controle estatístico de qualidade (ROGERSON; YAMADA, 2004), geoestatística (BRONNER et al., 2015), séries temporais (DÓREA; WIDGRÉN; LINDBERG, 2015); além destas, Dórea e Vial (2016) apresentam aquelas que foram aplicadas em sistemas de VS nos anos 2011 a 2015.

A partir da Figura 2 é possível observar os passos para implementação de um sistema de VS, desde a extração de dados até a interface do usuário.

Figura 2 – Passos para implementar um sistema de vigilância sindrômica, desde a extração de dados até a interface do usuário.



Fonte: Dórea, Widgrén e Lindberg (2015)

2.2 O pacote *vetsyn*

Dentre os vários sistemas de VS disponíveis está o *vetsyn*, desenvolvido por Dórea, Widgrén e Lindberg (2015) e disponibilizado gratuitamente como uma biblioteca para o software R (R Core Team, 2017) automatizando o processo de análise de dados de saúde animal pré-classificados em informações epidemiológicas.

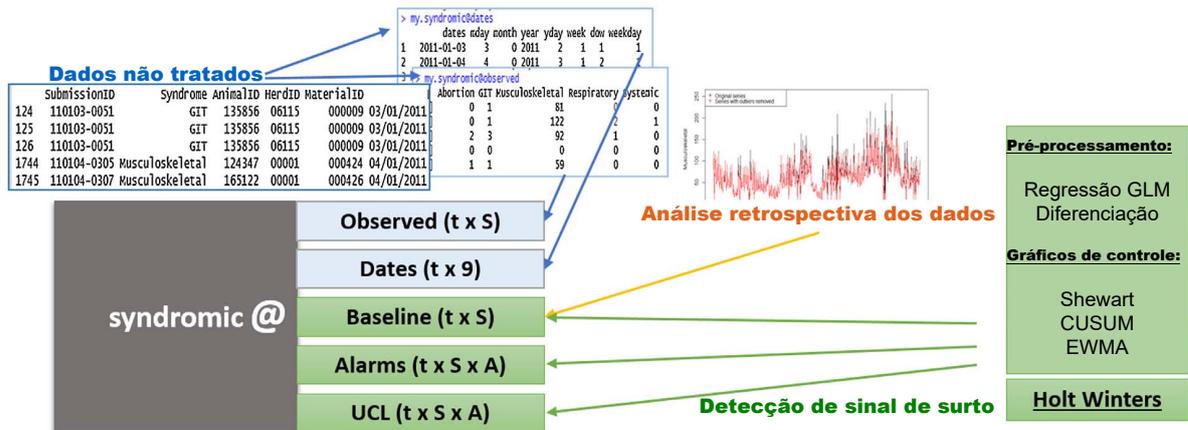
O centro do pacote *vetsyn* são objetos da classe *syndromic*. Esses objetos são projetados para conter todas as informações extraídas dos dados e relevantes para vigilância sindrômica, desde contagens até alarmes, em um único local (DOREA, 2017). O objeto *syndromic* é uma classe S4, o que significa que o objeto é dividido em *slots*, com as seguintes descrições:

- *@observed* - txS dimensões : armazenamento de dados, com o número de eventos observados no tempo. Possui tantas colunas quantas síndromes (doenças) a serem monitoradas e linhas equivalentes aos pontos no tempo, onde cada ponto se refere a um dia.
- *@dates* tx9 dimensões : sequência de datas dos dados inseridos em *@observed*.
- *@baseline* - txS dimensões : armazenamento da linha de base após a retirada de observações indesejadas. Este passo será descrito detalhadamente abaixo.
- *@alarms* - txSxA dimensões : armazenamento dos resultados do algoritmo de detecção aplicado aos dados. Podem ser utilizados vários algoritmos, logo *@alarms* é uma matriz onde alarmes para cada dia (linha - t), cada síndrome (coluna - S) e cada algoritmo/ técnica de detecção (A) são armazenados.
- *@UCL* - txSxA dimensões : armazenamento do número mínimo de eventos (limite de controle superior) que geraria um alarme por dia e síndrome, para cada algoritmo (desde que seja dado um limite de detecção específico para cada algoritmo).

- @LCL - txSxA dimensões : armazenamento do número máximo de eventos (menor limite de controle) que geraria um alarme por dia e síndrome, para cada algoritmo (desde que seja dado um limite de detecção específico para cada algoritmo).

A partir da Figura 3 é possível observar graficamente a estrutura esquemática de um objeto *syndromic* e suas conexões com as diferentes etapas das análises. Maiores detalhes podem ser obtidos com os autores em sítio web apropriado (DOREA, 2017).

Figura 3 – Estrutura esquemática de um objeto *syndromic* e suas conexões com as diferentes etapas das análises no pacote *vetsyn*.



S = número de síndromes monitoradas; t = número de pontos de tempo nos dados; A = número de algoritmos de detecção de sinal de surto utilizados.

Fonte: Dórea, Widgrén e Lindberg (2015)

A partir dos dados armazenados em *@observed*, o sistema permite que o usuário inicie as etapas de análise. À medida que as análises são realizadas, os *slots* adicionais são construídos no objeto *syndromic*.

A primeira análise realizada no pacote é retrospectiva, onde são geradas estatísticas de resumo dos dados, através de análise exploratória básica detalhada (DÓREA et al., 2013), com armazenamento das estatísticas de resumo e modelos de regressão adequados aos dados, para uma avaliação de seu comportamento. O objetivo principal da análise retrospectiva é identificar possíveis efeitos temporais nos dados.

Para a remoção de sinais de surtos e o ruído excessivo nos dados, dois métodos (paramétrico e não-paramétrico) foram descritos em Dórea et al. (2013) sendo utilizados para construir uma linha de base livre de surtos que servirá para treinar o algoritmo de detecção. O método paramétrico utiliza os dados disponíveis para se ajustarem a um modelo de regressão e as observações acima do intervalo de confiança de 95% do modelo são substituídas pelo limite do intervalo. Estão disponíveis qualquer família para um modelo linear generalizado (GLM), e o modelo é definido pelo usuário com base na avaliação

retrospectiva. A versão não-paramétrica funciona de forma semelhante, mas os percentis são usados em vez de modelos de regressão.

Uma vez que um objeto sindrômico é submetido à linha de base, as observações são utilizadas para criar a linha de base livre de surto, que será armazenada em seguida.

O próximo passo para a configuração do sistema é implementar as técnicas de detecção. Quatro técnicas foram implementadas no pacote: suavização exponencial de Holt-Winters (HW), gráfico de controle de média móvel ponderado exponencialmente (EWMA), gráfico de controle Shewhart (SH) e gráficos de controle das somas acumuladas (CUSUM). Neste estudo foram utilizadas HW, SH e EWMA.

2.2.0.1 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 de 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 (VERÍSSIMO et al., 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).

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 a 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.

Quadro 1 - Equações comparativas dos modelos de Holt-Winters multiplicativo e aditivo (SAMOHYL; ROCHA; MATTOS, 2001).

	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	$x_t(\hat{k}) = (L_t + kT_t)I_{t-s+k}$	$x_t(\hat{k}) = L_t + kT_t + I_{t-s+k}$

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

$x_t(\hat{k})$ - Valor observado

γ, α e β - Parâmetros exponenciais alisadores, do nível, da tendência e da sazonalidade, respectivamente.

Tal que esses parâmetros estão dentro do intervalo $(0,1)$.

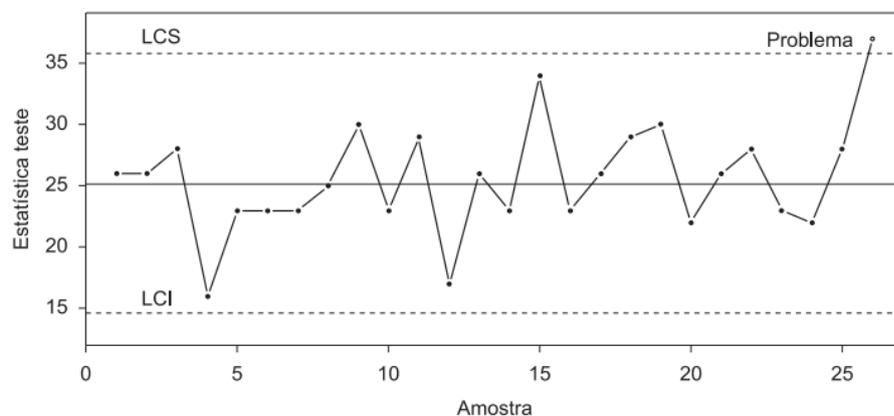
2.2.0.2 Gráfico de controle Shewhart (SH)

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 do 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). Um exemplo pode ser visto na Figura 4.

Figura 4 – Modelo de um de gráfico de controle.



Fonte: Walter et al. (2013)

Os limites de controle para o gráfico SH são dados por:

$$\begin{cases} LSC = \mu + k \frac{\sigma}{\sqrt{n}} \\ LC = \mu \\ LIC = \mu - k \frac{\sigma}{\sqrt{n}} \end{cases} \quad (2.1)$$

em que,

μ = média de X .

σ = 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).

2.2.0.3 Gráfico de controle da soma cumulativa (CUSUM)

Este gráfico é indicado para detecção de pequenas mudanças na média do processo e é 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 a média teórica do processo μ . 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:

$$\begin{cases} c_i^+ = \max[0, x_i - (\mu_0 + K) + c_{i-1}^+] \\ c_i^- = \max[0, (\mu_0 - K) - x_i + c_{i-1}^-] \end{cases} \quad (2.2)$$

onde,

K = valor de tolerância ou folga,

x_i = i -ésima observação do processo,

μ_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).

2.2.0.4 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:

$$\begin{cases} LSC = \mu_0 + L\sigma \sqrt{\frac{\lambda}{(2-\lambda)} [1 - (1-\lambda)^{2i}]} \\ LC = \mu_0 \\ LIC = \mu_0 - L\sigma \sqrt{\frac{\lambda}{(2-\lambda)} [1 - (1-\lambda)^{2i}]} \end{cases} \quad (2.3)$$

onde,

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

λ = constante de amortecimento.

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

2.3 Métodos de concordância em dados categóricos

Para saber se determinada caracterização ou classificação de um objeto é confiável, é necessário que este tenha sido caracterizado ou classificado várias vezes, por exemplo, por mais de um avaliador. A intensidade da concordância entre dois ou mais avaliadores é dada a partir de métodos de concordância e dentre estes estão o coeficiente de correlação de Matthews e a correlação tetracórica.

2.3.1 Coeficiente de correlação de Matthews (MCC)

O coeficiente de correlação de Matthews foi desenvolvido em 1975 por Brian W. Matthews (MATTHEWS, 1975) e corresponde a um coeficiente de correlação entre classificações binárias observadas e previstas. O MCC retorna a um valor entre -1 e 1, onde -1 indica desacordo total entre a previsão e a observação e 1 representa uma previsão perfeita, podendo ser obtida por:

$$MCC = \frac{(VP * VN - FP * FN)}{\sqrt{((VP + FP) * (VP + FN) * (VN + FP) * (VN + FN))}}$$

onde,

VP = Verdadeiro Positivo,

VN = Verdadeiro Negativo,

FP = Falso Positivo,

FN = Falso Negativo.

2.3.2 Correlação Tetracórica (CT)

A correlação tetracórica (PEARSON, 1900), para dados binários, é uma técnica que avalia a taxa de concordância entre variáveis (UEBERSAX, 2006) e estima o grau de correlação entre avaliadores se as classificações fossem feitas em uma escala contínua.

Imagine X e Y duas variáveis que após dicotomização podem ser expressas pela tabela 2x2,

Tabela 1 – Exemplo de tabela 2x2.

		Variável X		
		1	0	Total
Variável Y	1	a	b	a + b
	0	c	d	c + d
Total		a + c	b + d	n

Sendo,

$$p = \frac{(a+b)}{n}; q = \frac{(c+d)}{n} = 1 - p \quad (2.4)$$

$$p' = \frac{(a+c)}{n}; q' = \frac{(b+d)}{n} = 1 - p' \quad (2.5)$$

$n = a + b + c + d$ (total de observações).

Dessa forma; a, b, c e d são as frequências da tabela 2x2 e z é o valor correspondente à área menor ou igual a p . Por exemplo, se $p = 0.50$, então tem-se que $z = 0$ (tabela de áreas sob a curva normal) (LIRA, 2004);

Segundo Elderton (1952) a equação tetracórica é dada por:

$$\frac{ad - bc}{yy'n^2} = \hat{\rho}_t + \hat{\rho}_t^2 \frac{zz'}{2} + \hat{\rho}_t^3 \frac{(z^2 - 1)(z'^2 - 1)}{6} + \hat{\rho}_t^4 \frac{z(z^2 - 3)(z'^2 - 3)}{24} + \hat{\rho}_t^5 \frac{(z^4 - 6z^2 + 3)(z'^4 - 6z'^2 + 3)}{120} \\ + \hat{\rho}_t^6 \frac{z(z^4 - 10z^2 + 15)z'(z'^4 - 10z'^2 + 15)}{720} + \hat{\rho}_t^7 \frac{(z^6 - 15z^4 + 45z^2 - 15)(z'^6 - 15z'^4 + 45z'^2 + 15)}{5040} + \dots (2.6)$$

onde,

$\hat{\rho}_t$ é o coeficiente de correlação tetracórico;

a, b, c e d são as frequências da tabela 2x2;

z é o valor correspondente à área menor ou igual a p ;
 z' é o valor correspondente à área menor ou igual a p' ;
 y é o valor da ordenada no ponto p ;
 y' é o valor da ordenada no ponto p' ;
 $n = (a + b + c + d)$ é o número de observações da amostra.

Uma solução aproximada do cálculo da CT, ignorando os termos de grau superior a 2, na expressão (2.6) foi apresentada por Guilford (1950), sendo:

$$\frac{ad - bc}{yy'n^2} = \hat{\rho}_t + \hat{\rho}_t^2 \frac{zz'}{2} \quad (2.7)$$

Admitindo o primeiro termo da expressão (2.7) como **c**; o coeficiente de $\hat{\rho}_t$ como **b** e $\frac{zz'}{2}$ como **a**, tem-se uma equação de segundo grau:

$$a\hat{\rho}_t^2 + b\hat{\rho}_t + c = 0 \quad (2.8)$$

Podendo ser resolvida através de:

$$\hat{\rho}_t = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}$$

Para a utilização do coeficiente de correlação tetracórico, algumas suposições básicas devem ser atendidas, são elas: as variáveis X e Y devem ser contínuas e normalmente distribuídas, relacionadas linearmente; ainda, X e Y devem ser dicotomizadas o mais próximo possível à mediana.

Segundo Guilford (1950) o coeficiente de correlação tetracórico é menos confiável que o de Pearson, sendo que sua variabilidade é cerca de 50% maior, quando $\rho = 0$. Uma forma de se obter a mesma confiabilidade no coeficiente de correlação tetracórico que a obtida no coeficiente de correlação de Pearson, é utilizando o dobro do tamanho da amostra. Recomenda-se que se utilizem amostras superiores a 300 observações (LIRA, 2004).

2.3.3 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):

$$Sensibilidade = \frac{VerdadeiroPositivo(VP)}{VerdadeiroPositivo(VP) + FalsoNegativo(FN)} \quad (2.9)$$

onde VP e FN são encontrados na tabela de frequência 2x2 gerada com os resultados da variável em estudo.

2.4 Redes Bayesianas

As Redes Bayesianas - *Bayesian networks* (BN) são uma representação compacta de uma tabela de probabilidades conjunta do universo do problema (MARQUES; DUTRA, 2002b).

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). Em particular, 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 genealogicos 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 e Dutra (2002b), a construção de uma BN consiste do seguinte:

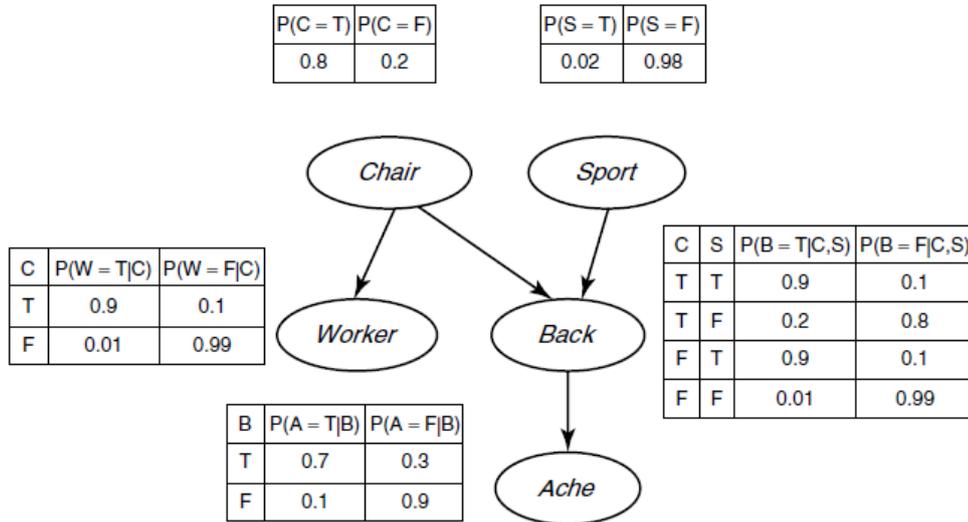
- Um conjunto de variáveis e um conjunto de arcos ligando as variáveis.
- Cada variável possui um conjunto limitado de estados mutuamente exclusivos.
- As variáveis e arcos formam um grafo acíclico dirigido - *Directed Acyclic Graph* (DAG).
- Para cada variável A que possui como pais B_1, \dots, B_n , 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 factorização da probabilidade conjunta de uma coleção de nós.

Na Figura 5 é possível observar a estrutura de uma BN. Neste exemplo as variáveis *Chair* e *Sport* são variáveis pai, tendo como descendentes as variáveis *Worker* e *Back*. A variável *Ache* é filha da variável *Back*. Este é um exemplo clássico que considera uma pessoa que pode sofrer uma lesão nas costas, evento representado pela variável *Back* (denotada por B). Tal lesão pode causar uma dor nas costas, evento representado pela variável *Ache* (denotada por A). A lesão nas costas pode resultar de uma atividade esportiva incorreta, representada pela variável *Sport* (denotada por S) ou por novas cadeiras desconfortáveis instaladas no escritório da pessoa, representadas pela variável *Chair* (denotada por C). No último caso, é razoável assumir que um colega de trabalho sofrerá e relatará uma síndrome da dor nas costas semelhante, um evento representado pela variável *Worker* (denotada por W). Todas as variáveis são binárias; sendo verdadeiras (denotadas por “T”) ou falsas (denotadas por “F”) (BEN-GAL, 2007).

Este exemplo tem a finalidade de identificar, em termos de probabilidade, quais variáveis mais influenciam a dor nas costas (variável *Ache*) de um indivíduo. As tabelas de probabilidades conjunta apresentadas para as variáveis *Back* e *Worker* são obtidas a partir de probabilidades condicionais destas

Figura 5 – Exemplo de Rede Bayesiana.



Fonte: Ben-Gal (2007)

variáveis relacionadas com as variáveis *Sport* e *Chair*, já a tabela de probabilidades conjunta apresentada para variável *Ache* é obtida a partir de probabilidades condicionais entre esta variável e a variável *Back*.

As BN construídas com variáveis discretas satisfazem a condição de Markov que diz que cada variável é condicionalmente independente do conjunto de todos os seus não-descendentes dado o conjunto de todos os seus pais (NEAPOLITAN et al., 2004).

A distribuição conjunta de variáveis de um grupo de variáveis discretas $\{X_1, X_2, \dots, X_n\}$ é dada pela regra da cadeia,

$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | Pa_i) \quad (2.10)$$

Os parâmetros de uma BN são definidos da seguinte forma:

$$\Theta_i = P(X_i | Pa_i), i = 1, \dots, n. \quad (2.11)$$

Em que Θ_i são as probabilidades condicionais de X_i dados seus pais Pa_i (KARCHER, 2009).

Dessa forma, seus parâmetros são dado por $\Theta_s = \Theta_1, \Theta_2, \dots, \Theta_n$ sendo todas as tabelas de probabilidades condicionais com as variáveis discretas $\{X_1, X_2, \dots, X_n\}$ que compõem a rede (KARCHER, 2009).

Dado o pressuposto de independência das BN, várias afirmações podem ser observadas neste caso. Por exemplo, na Figura 5 as variáveis *Chair* e *Sport* são marginalmente independentes, mas quando *Back* é fornecido, elas tornam-se condicionalmente dependentes. Quando *Chair* é dada, *Worker* e *Back* são condicionalmente independentes. Quando *Back* é dado, *Ache* é condicionalmente independente de seus ancestrais *Chair* e *Sport*.

A declaração de independência condicional da BN fornece uma compactação das distribuições de probabilidade conjunta (DPC). Em vez de fatorizar a distribuição conjunta de todas as variáveis pela regra da cadeia, ou seja,

$$P(C, S, W, B, A) = P(C)P(S|C)P(W|S, C)P(B|W, S, C)P(A|B, W, S, C)$$

a BN define uma distribuição de probabilidade conjunta única em uma forma de fator, ou seja,

$$P(C, S, W, B, A) = P(C)P(S)P(W|C)P(B|S, C)P(A|B)$$

Dessa forma, reduz-se o número dos parâmetros do modelo, que pertencem a uma distribuição multinomial. Essa redução proporciona grandes benefícios de inferência, aprendizagem (estimativa de parâmetros) e perspectiva computacional. Um critério gráfico prático que ajuda a investigar a estrutura da DPC modelada por uma BN é chamado *d*-separação (BEN-GAL, 2007).

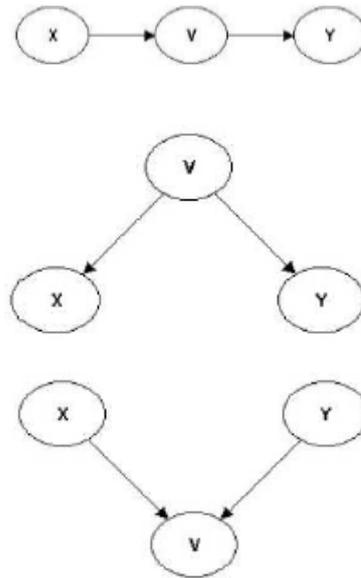
Segundo Jensen (2001) dois vértices distintos X e Y estão *d*-separados em uma BN se, para todos os caminhos entre X e Y existe um vértice intermediário V (diferente de X e Y) tal que a conexão entre X e Y através de X e Y :

- é divergente ou serial e V recebeu uma evidência, ou;
- é convergente e nem V nem seus descendentes receberam uma evidência.

Na Figura 6 é possível observar a representação do critério *d*-separação. De cima para baixo temos em ordem:

1. Conexão Serial: X e Y estão separados se V recebe uma evidência.
2. Conexão Divergente: X e Y estão separados se V recebe uma evidência.
3. Conexão Convergente: X e Y estão separados se nem V nem seus descendentes receberam uma evidência.

Figura 6 – Representação do critério d -separação.



Fonte: Karcher (2009)

As evidências citadas no critério d -separação estão relacionadas ao fato de que em uma BN um conjunto de variáveis E com valores conhecidos, ($E = e$), em uma dada situação, é comumente chamado de evidência, por exemplo, $E = \{X_2 = x_2, X_6 = x_6\}$. Estas evidências permitem que as BN possam ser utilizadas para calcular novas probabilidades (a posteriori) sobre uma ou mais variáveis da rede (KARCHER, 2009).

2.4.1 Inferência em Redes Bayesianas

Apesar do nome, as redes Bayesianas não implicam necessariamente um compromisso com as estatísticas bayesianas. De fato, é comum usar métodos de frequência para estimar os parâmetros da DPC mas, são chamadas assim porque usam a regra de Bayes para a inferência probabilística (MURPHY, 1998).

Dado que a BN especifica a DPC em uma forma fatorada, pode-se avaliar todas as possíveis consultas de inferência por marginalização. Frequentemente dois tipos de suporte de inferência são considerados: suporte preditivo para o nó X_i , com base em nós de evidência conectados a X_i através de seus nós pai (raciocínio descendente) e suporte de diagnóstico para o nó X_i , com base em nós de evidência conectados para X_i através de seus nós filhos (raciocínio ascendente) (BEN-GAL, 2007).

Dado o exemplo da Figura 5, pode-se considerar o suporte de diagnóstico para a crença em novas cadeiras desconfortáveis instaladas no escritório da pessoa, dada a observação de que a pessoa sofre de uma dor nas costas. Esse suporte é formulado da seguinte forma:

$$P(C = T|A = T) = \frac{P(C = T, A = T)}{P(A = T)} \quad (2.12)$$

onde,

$$P(C = T, A = T) = \sum_{S, W, B \in \{T, F\}} P(C = T)P(S) * P(W|C = T)P(B|S, C = T)P(A = T|B) \quad (2.13)$$

e

$$P(A = T) = \sum_{S, W, B \in \{T, F\}} P(C)P(S)P(W|C)P(B|S, C) * P(A = T|B) \quad (2.14)$$

Note-se que mesmo para o caso binário, o DPC tem tamanho 2^n , onde n é o número de nós. Logo, somar a DPC leva um tempo exponencial.

Em geral, a soma completa em variáveis discretas é chamada de inferência exata e é conhecida como um problema *NP-hard*. Alguns algoritmos eficientes podem resolver o problema de inferência exato nas classes de redes restritas. Dentre eles o *message passing algorithm* que resolve o problema em n passos (linear no número de nós) para *polytrees* (também chamadas de redes conectadas individualmente), onde há no máximo um caminho entre dois nós (BEN-GAL, 2007).

2.4.2 Aprendizado em Redes Bayesianas

No processo de construção de uma BN a configuração estrutural da rede (topologia gráfica) é, em muitos casos, desconhecida e nestas situações é necessário aprender com os dados (CUSSENS, 2012). Este problema é comumente chamado de problema de aprendizagem de redes Bayesianas (*BN learning problem*) que consiste em estimar a topologia e os parâmetros da DPC da rede.

Aprender a estrutura de uma rede Bayesiana é um problema difícil de solucionar e além disso, surge outro problema que é em situações de observabilidade, isto é, quando os nós estão ocultos ou quando faltam dados (BEN-GAL, 2007).

Frequentemente quatro casos de aprendizagem de BN são considerados e, para estes, são propostos diferentes métodos de aprendizado (MURPHY, 1998) como mostra na Tabela 2.

Tabela 2 – Quatro casos de problemas de aprendizado em BN (BEN-GAL, 2007).

Caso	Estrutura da BN	Observabilidade	Método de aprendizagem proposto
1	Conhecido	Total	Estimativa de máxima verossimilhança
2	Conhecido	Parcial	EM (<i>Expectation Maximization</i>) ou MCMC
3	desconhecido	Total	Procurar no espaço do modelo
4	desconhecido	Parcial	Pesquisa EM + procurar no espaço do modelo

MCMC = *Markov Chain Monte Carlo*

No Caso 1, apresentado na Tabela 2, o objetivo da aprendizagem é encontrar os valores dos parâmetros BN que maximizem o log da probabilidade do conjunto de dados de treinamento, que contém

m casos que geralmente são assumidos como independentes. Dado o conjunto de dados de treinamento $\Sigma = x_1, \dots, x_m$, onde $x_1 = (x_{11}, \dots, x_{1n})^T$ e o conjunto de parâmetros $\Theta = (\Theta_1, \dots, \Theta_n)$, onde Θ_i é o vetor de parâmetros para a distribuição condicional da variável X_i (representado por um nó no gráfico), a probabilidade do conjunto de dados de treinamento é uma soma de termos, um para cada nó:

$$\log L(\Theta|\Sigma) = \sum_m \sum_n \log P(x_{li}|\pi_i, \theta_i) \quad (2.15)$$

A função de log-verossimilhança se decompõe de acordo com a estrutura do grafo; portanto, pode-se maximizar a contribuição para o logaritmo da probabilidade de cada nó de forma independente ou, como alternativa, pode-se atribuir uma função de densidade de probabilidade *a priori* a cada vetor de parâmetros e usar os dados de treinamento para calcular a distribuição de parâmetros *a posteriori* e as estimativas de Bayes (BEN-GAL, 2007).

Para o caso 2 com estrutura conhecida e observabilidade parcial, pode-se usar o algoritmo EM (MOON, 1996) para encontrar uma estimativa localmente ideal de máxima verossimilhança dos parâmetros. O algoritmo de Simulação de Monte Carlo em Cadeias de Markov (Markov Chain Monte Carlo - MCMC) é uma abordagem alternativa que pode ser usada para estimar os parâmetros do modelo BN.

O caso 3 tem como objetivo aprender um DAG que melhor explique os dados. Este é um problema *NP-hard*, uma vez que o número de DAGs nas variáveis N é super exponencial em N . Uma estratégia é prosseguir com a suposição mais simples de que as variáveis são condicionalmente independentes, dada uma classe, que é representada por um único nó pai comum a todos os nós variáveis.

Para o caso 4, com observabilidade parcial e estrutura de gráfico desconhecida, é necessário marginalizar os nós ocultos, bem como os parâmetros. Uma vez que isso geralmente é intratável, é comum usar uma aproximação assintótica ao critério de informação Bayesiano chamado *posteriori* (*Bayesian information criterion* - BIC) (MURPHY, 1998).

3 SENSIBILIDADE DE ALARME EM UM SISTEMA DE VIGILÂNCIA SINDRÔMICA EPIDEMIOLÓGICA

P.S.M.P. Ximenes¹, K.R. Santoro²

Universidade Federal Rural de Pernambuco^{1,2}

patricia.medeiross10@gmail.com¹

kleber.santoro@ufrpe.br²

1 3.1 Resumo

2 A eficiência de um sistema de vigilância sindrômica foi avaliada para mortalidade em aves de postura
3 tendo como base de comportamento recomendações internacionais. As técnicas de alarme do sistema
4 foram analisadas segundo suas sensibilidades bem como a correlação entre os respectivos resultados. Entre
5 as técnicas utilizadas pelo sistema, o gráfico Shewhart foi o que mais contribuiu para a detecção correta
6 de surtos, apresentando probabilidade maior que 95% na detecção de verdadeiros positivos e apenas 4,6%
7 de falsos positivos. A fim de corrigir a sensibilidade do sistema em detectar surtos, uma rede Bayesiana
8 foi desenvolvida. Esta rede foi proposta como parte da avaliação dos resultados do sistema conferindo
9 maior precisão. A rede Bayesiana proposta conseguiu corrigir erros do sistema avaliado, demonstrando
10 ser um acréscimo viável ao sistema de vigilância sindrômica.

11 **Palavras chaves: Detecção de surtos, redes Bayesianas, vigilância animal.**

12 1

13 3.2 Introdução

14 A detecção prévia e precisa de surtos de doenças é crucial para a execução de uma resposta
15 eficiente à saúde pública, principalmente para limitar a mortalidade e a morbidade na população (MNAT-
16 SAKANYAN et al., 2009).

¹ As configurações estabelecidas neste capítulo seguem as exigências para publicação de artigo na revista Tropical Animal Health and Production, disponibilizadas em Anexos.

17 Schwabe (1982) definiu a evolução dos métodos de vigilância de doenças em medicina veterinária
18 como uma revolução epidemiológica, marcada pelo uso de inteligência epidemiológica e análise de
19 ferramentas chave para diagnóstico e decisão. Neste contexto, fornecer abordagens efetivas e abrangentes
20 para o gerenciamento e análise sistemática da informação desempenha um papel central na obtenção dos
21 objetivos da vigilância das doenças (ZENG et al., 2005).

22 A informática aplicada à doenças infecciosas seria ciências e tecnologias necessárias para coletar,
23 compartilhar, relatar, analisar e visualizar dados de doenças infecciosas fornecendo suporte de dados
24 e de tomada de decisão para estas doenças. Esta existe como uma área interdisciplinar, a qual envolve
25 uma variedade de tecnologias da informação como, por exemplo, compartilhamento de dados e segu-
26 rança, sistemas de informação geográfica (SIG), mineração de dados, gerenciamento de conhecimento,
27 bioestatística e bioinformática (CHEN et al., 2005; ZENG et al., 2005).

28 Devido à falta de especificidade associada aos dados de pré-diagnóstico, este novo tipo de
29 vigilância visa grupos gerais de doenças ou síndromes e, portanto, é muitas vezes referido como “Vigilância
30 Síndrômica (VS)” (HENNING, 2004).

31 A partir do uso de ferramentas da informática, sistemas de vigilância síndrômica foram desenvol-
32 vidos utilizando dados de pré-diagnóstico já disponíveis (MANDL et al., 2004) como por exemplo dados
33 laboratoriais (BUEHLER et al., 2003), queixa principal do paciente na visita de emergência (HEFFER-
34 NAN et al., 2004), solicitação de testes laboratoriais (DÓREA; WIDGRÉN; LINDBERG, 2015), entre
35 outros.

36 Para a construção de um sistema de VS é necessário escolher uma ou mais técnicas que monitorem
37 os dados que serão avaliados. Na literatura, várias metodologias foram testadas, como por exemplo:
38 estatística de teste bivariada (OZONOFF et al., 2004), teste de razão de verossimilhança generalizada
39 (WALLENSTEIN; NAUS, 2004), controle estatístico de qualidade (ROGERSON; YAMADA, 2004),
40 geoestatística (BRONNER et al., 2015), séries temporais (DÓREA; WIDGRÉN; LINDBERG, 2015).

41 Dentre os vários sistemas de VS disponíveis está o *vetsyn*, desenvolvido por Dórea, Widgrén e
42 Lindberg (2015) e disponibilizado gratuitamente como uma biblioteca para o software R (R Core Team,
43 2017), automatizando o processo de análise de dados de saúde animal pré-classificados em informações
44 epidemiológicas.

45 O sistema tem apresentado grande aceitação, sendo eficiente e tendo como vantagens a simplici-
46 dade na entrada e administração de dados, a rapidez e eficiência da análise e a apresentação de resultados
47 de interpretação direta e simples. Como todo sistema de vigilância, o *vetsyn* possui alarmes falso positivo
48 e falso negativo, que na vigilância sindrômica representam problemas na identificação de surtos, e requer
49 um aprimoramento de forma a reduzi-los ao máximo. O sistema deve ser então avaliado e possíveis
50 propostas de correção de erros para elevar a sua confiabilidade devem ser propostos.

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

55 3.3 Materiais e Método

56 Segundo Gibbens et al. (2001) a progressão temporal de um surto é difícil de prever em medicina
57 veterinária, onde a unidade epidemiológica é o rebanho em vez de animais individuais, uma vez que uma
58 grande proporção de transmissão é devido ao contato indireto entre as fazendas localmente e também em
59 grandes distâncias. Além disso, desenvolvimento de um experimento controlado para induzir enfermidades
60 diferentes que causem mortalidade, as quais também possuem comportamentos variados, visando testar
61 o sistema é impraticável, seja devido aos custos, operacionalização ou as questões bioéticas envolvidas.
62 Por esse motivo foram simuladas várias formas de eventos epidemiológicos com diferentes cenários
63 previamente propostos na literatura (DÓREA et al., 2013a)

64 As simulações para mortalidade de aves de postura tomaram como base o desenvolvimento
65 padrão das aves HylineW-36 (HY-LINE, 2016). O período simulado para a série de mortalidade foi de
66 630 dias, divididos em quatro períodos arbitrariamente escolhidos de acordo com o desenvolvimento e
67 produção das aves, sendo: 1º (dia 1 a 119) , 2º (dia 120 a 259), 3º (dia 260 a 532), 4º (dia 533 a 630).
68 As séries foram geradas sem perturbações, para que não acionasse o alarme de nenhum dos métodos
69 de avaliação empregados no *vetsyn*, representando a linha de comportamento base diário, caracterizado
70 por uma distribuição de Poisson com $\lambda = 10$, sendo a distribuição amostrada aleatoriamente a cada 1000
71 valores simulados.

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

80 O resultado final é representado pela linha de base com a perturbação, magnitude e duração
 81 específicos (Figura 7), as quais foram usadas como entrada para o sistema *vetsyn* analisar e verificar ou
 82 não a ocorrência de alarme pelo sistema usando as técnicas de modelos lineares generalizados (GLM) e
 83 diferenciação (DIFF) e posteriormente por um dos métodos empregados: gráfico de controle de média
 84 móvel ponderado exponencialmente (EWMA), gráfico de controle Shewhart (SH), suavização exponencial
 85 de Holt-Winters (HW). Qualquer resposta positiva de pelo menos um dos métodos gera um alarme. Foram
 86 simuladas 200 séries para cada cenário possível, totalizando 20.800.

87 A verificação da concordância entre os resultados dos métodos e a simulação e entre os méto-
 88 dos foi verificada através dos coeficientes de correlação de Matthews (MCC) (MATTHEWS, 1975) e
 89 correlação tetracórica (CT) (UEBERSAX, 2006).

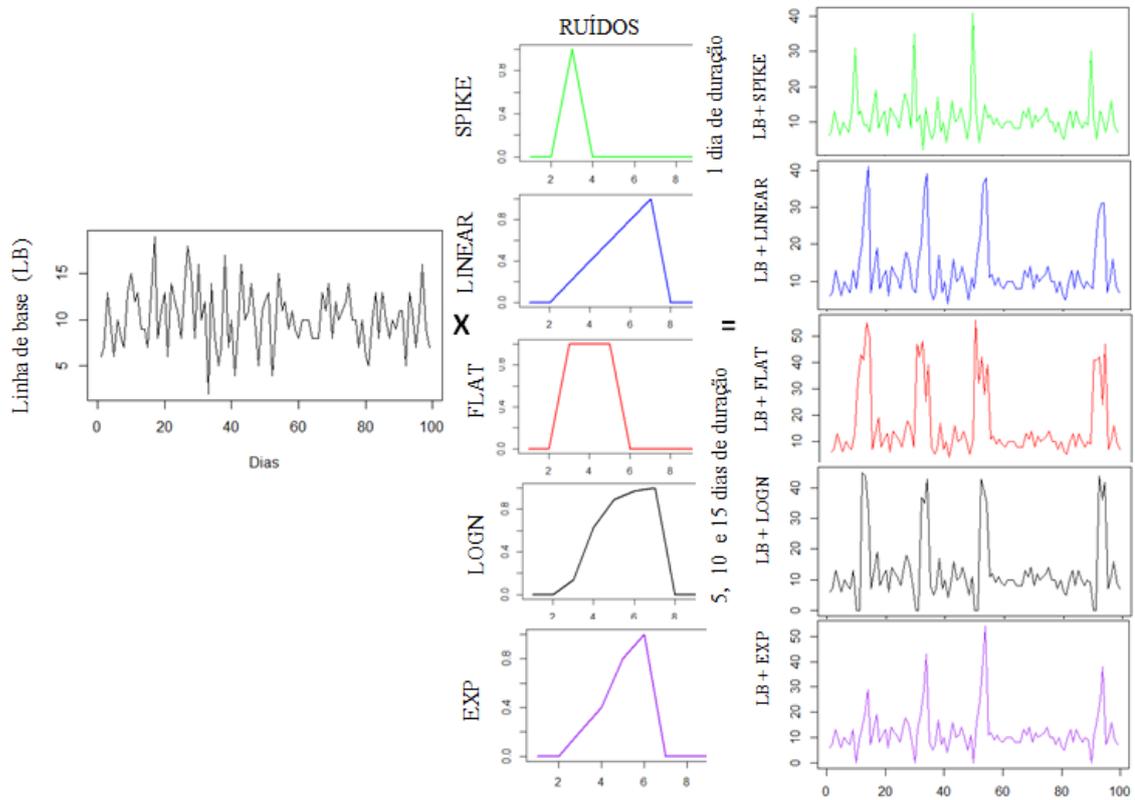
90 A sensibilidade de um método reflete o quanto este é capaz de identificar corretamente, dentre
 91 todos os indivíduos avaliados, aqueles que realmente apresentam uma característica de interesse podendo
 92 ser obtida a partir da fórmula (LALKHEN; MCCLUSKEY, 2008):

$$Sensibilidade = \frac{VerdadeiroPositivo(VP)}{VerdadeiroPositivo(VP) + FalsoNegativo(FN)} \quad (3.1)$$

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

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

Figura 7 – Tipos de ruído.



98 A obtenção das correlações foram feitas a partir do pacote *mccr* (IUCHI, 2017) para MCC
 99 e o pacote *psych* (REVELLE, 2017) para CT; para construção da rede Bayesiana utilizou-se *bnlearn*
 100 (SCUTARI, 2010) e *gRain* (HØJSGAARD, 2012).

101 3.4 Resultados

102 Dentre as técnicas aplicadas o gráfico Shewart apresentou maior sensibilidade, independente da
 103 magnitude. A técnica EWMA mostrou um alto número de alarmes falso negativos ao avaliar séries com
 104 ruídos de magnitudes 20 e 30. Como esperado, o aumento da magnitude do surto repercutiu em aumento
 105 da sensibilidade das técnicas como pode ser observado no desempenho da suavização exponencial de
 106 Holt-Winters e Shewhart (Tabela 3).

107 Comparando os resultados obtidos com pré-processamento GLM (Tabela 3) aos obtidos com
 108 pré-processamento diferenciação (Tabela 4) a detecção de surtos com ruído spike e magnitude 20 tem
 109 maior sensibilidade com pré-processamento GLM para todas as técnicas estudadas. A técnica EWMA não
 110 apresentou bons resultados na detecção de surtos com magnitude 20 e pré-processamento diferenciação.
 111 Por outro lado a técnica SH mostrou-se eficiente na detecção de surtos independente da magnitude do
 112 surto e do pré-processamento utilizado.

113 A detecção de surtos falsos positivos é menor para a técnica EWMA com o pré-processamento
 114 diferenciação; no entanto para a técnica SH esse valor varia de 0 para 99.5% com ruídos de magnitude 20. A
 115 técnica HW também apresentou uma diminuição do percentual de falsos positivos com pré-processamento
 116 diferenciação, comparado com o GLM.

Tabela 3 – Sensibilidade do sistema com ruído spike e pré-processamento GLM *.

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

* 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 Model Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters.

Tabela 4 – Sensibilidade do sistema com ruído spike e pré-processamento diferenciação*.

Pré-processamento diferenciação						
Técnica	EWMA	SH	HW	EWMA	SH	HW
Duração (dia)	1			1		
Magnitude	20			30		
Detecção (VP)	0,0	43,0	31,0	189,0	200,0	185,0
Detecção (FN)	200,0	157,0	169,0	11,0	0,0	15,0
Sensibilidade (%)	0,0	21,5	15,5	94,5	100,0	92,5
Detecção (FP) (%)	0,0	99,5	3,0	24,7	0,0	5,0
Magnitude	40			50		
Detecção (VP)	191,0	200,0	193,0	200,0	200,0	200,0
Detecção (FN)	9,0	0,0	7,0	0,0	0,0	0,0
Sensibilidade (%)	95,5	100,0	96,5	100,0	100,0	100,0
Detecção (FP) (%)	22,3	0,33	6,17	9,83	0,0	14,5

* 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 Model Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters.

117 Para ruídos do tipo FLAT com pré-processamento GLM todas as técnicas apresentaram excelente
 118 desempenho na detecção de surtos, independente da duração e magnitude, diferentemente quando utilizado
 119 o pré-processamento diferenciação, onde a técnica EWMA apresentou sensibilidade zero quando o surto
 120 tem duração de cinco dias, mesmo aumentando a magnitude a técnica não apresentou melhora no
 121 desempenho (Tabelas 5 e 6). As técnicas SH e HW apresentaram excelente desempenho para ruídos do
 122 tipo flat independente da duração do surto e do pré-processamento aplicado.

123 A performance do sistema à detecções com ruídos do tipo linear e pré-processamento GLM foram
 124 bem sucedidas com o aumento da magnitude pelas técnicas SH e HW, mas apresentaram baixa sensibili-
 125 dade em detecções de ruídos com duração de 10 dias. Utilizando o pré-processamento diferenciação as
 126 técnicas HW e SH apresentaram bom desempenho na identificação de surtos com duração 5 e 10 dias
 127 (Tabelas 5 e 6).

128 Para ruídos do tipo exponencial o sistema apresentou baixa sensibilidade na detecção de surtos
 129 com a técnica EWMA para ruídos de magnitude 20 e pré-processamento GLM, melhorando com o
 130 aumento da magnitude. Neste mesmo cenário, mudando para o pré-processamento diferenciação, a
 131 técnica apresentou sensibilidade zero para ruídos com duração de 5 e 15 dias e também para ruídos
 132 com magnitude 40, independente da duração. As técnicas SH e HW apresentaram alta sensibilidade na
 133 detecção com magnitudes de 30 a 50, independente do pré-processamento e duração; as mesmas técnicas

134 apresentam baixa sensibilidade quando avaliaram séries com ruídos de magnitude 20 e durações 5 e 15
135 dias, independente do método de pré-processamento (Tabelas 5 e 6).

136 A técnica EWMA apresentou o pior desempenho na detecção de ruídos do tipo lognormal, com
137 sensibilidade zero para magnitudes 30 e 40, independente da duração e do método de pré-processamento.
138 SH e HW mostraram alta sensibilidade na detecção, independente da magnitude e duração para ruídos do
139 tipo lognormal, com exceção apenas da detecção com duração de 5 dias e magnitude 20 para a técnica
140 HW (Tabelas 5 e 6).

141 Dentre as três técnicas utilizadas, a EWMA apresentou menor sensibilidade, principalmente na
142 utilização do pré-processamento diferenciação. As técnicas SH e HW em todos os casos apresentam um
143 aumento da sensibilidade, quando a duração e a magnitude dos surtos aumentaram, independente do
144 método de pré-processamento aplicado aos dados (Tabelas 5 e 6).

145 Na detecção de surtos falsos positivos (FP) as técnicas apresentaram comportamentos distintos.
146 A EWMA apresentou altos percentuais de FP com ruídos de magnitude 20 em todos os tipos de ruído
147 com pré-processamento GLM. Estes percentuais decaíram quando utilizada diferenciação. A técnica SH
148 apresentou os menores percentuais de detecção FP, tendo em sua maioria percentuais zero. Por outro lado
149 a HW apresentou o pior desempenho detectando surtos FP, em quase todas as séries que foram utilizadas
150 para testar o sistema, tanto com pré-processamento GLM, quanto com diferenciação (Tabelas 5 e 6).

Tabela 5 – Sensibilidade do sistema com pré-processamento GLM*.

Técnica	EWMA			SH			HW			EWMA			SH			HW			
	5	10	15	5	10	15	5	10	15	5	10	15	5	10	15	5	10	15	
FLAT																			
Magnitude	20																		
Deteção (VP)	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200
Deteção (FN)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Sensibilidade (%)	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
Deteção (FP) (%)	49	90	95	0	51	38,5	58	66	76	0	0	0	0	0	0	0	0	0	0
Magnitude	50																		
Deteção (VP)	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200
Deteção (FN)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Sensibilidade (%)	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
Deteção (FP) (%)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
LJNEAR																			
Magnitude	20																		
Deteção (VP)	87	115	200	181	92	200	200	95	90	136	200	200	200	200	200	200	196	200	165
Deteção (FN)	113	85	0	19	108	0	105	110	64	0	0	0	0	0	0	0	4	0	35
Sensibilidade (%)	43,5	57,5	100	90,5	46	100	47,5	45	68	100	100	100	100	100	100	100	98	100	82,5
Deteção (FP) (%)	98,5	93	71,5	7	0,5	0	17	39	71,5	15	0	0	0	0	0	0	0	0	0
Magnitude	40																		
Deteção (VP)	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	199	200	195
Deteção (FN)	0	0	0	0	0	0	0	1	0	3	0	0	0	0	0	0	1	0	5
Sensibilidade (%)	100	100	100	100	100	100	99,5	100	98,5	100	100	100	100	100	100	100	99,5	100	97,5
Deteção (FP) (%)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
EXPONENCIAL																			
Magnitude	20																		
Deteção (VP)	94	130	7	94	200	66	90	179	61	200	200	189	200	200	200	197	200	200	199
Deteção (FN)	106	70	193	106	0	134	110	21	139	0	0	11	0	0	0	3	0	0	1
Sensibilidade (%)	47	65	3,5	47	100	33	45	89,5	30,5	100	100	94,5	100	100	100	98,5	100	99,5	99,5
Deteção (FP) (%)	90,5	95,5	92,5	1	0	19	21,5	68	89,5	43,5	35	75,5	0	0	0	34	74,5	83,5	83,5
Magnitude	40																		
Deteção (VP)	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200	200
Deteção (FN)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Sensibilidade (%)	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
Deteção (FP) (%)	0,5	22,5	0	0	0	0	82	98	97	0	0	0	0	0	0	96	100	100	100
LOGNORMAL																			
Magnitude	20																		
Deteção (VP)	163	197	200	200	200	200	68	200	200	200	0	0	0	200	200	200	200	200	200
Deteção (FN)	37	3	0	0	0	0	132	0	0	200	200	200	0	0	0	0	0	0	0
Sensibilidade (%)	81,5	98,5	100	100	100	100	34	100	100	0	0	0	0	100	100	100	100	100	100
Deteção (FP) (%)	57,5	41	34,5	0	0	0	28,5	73	94	0	0	0	0	0	0	64,5	100	100	100
Magnitude	40																		
Deteção (VP)	0	200	200	200	200	200	200	200	200	200	0	0	0	200	200	200	200	200	200
Deteção (FN)	200	0	0	0	0	0	0	0	0	0	200	200	0	0	0	0	0	0	0
Sensibilidade (%)	0	100	100	100	100	100	100	100	100	100	0	0	0	100	100	100	100	100	100
Deteção (FP) (%)	0	0	0	0	0	0	100	100	100	0	0	0	0	0	0	0	0	0	0

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

Tabela 6 – Sensibilidade do sistema com pré-processamento diferenciação *.

Técnica	EWMA			SH			HW			EWMA			SH			HW			
	5	10	15	5	10	15	5	10	15	5	10	15	5	10	15	5	10	15	
FLAT																			
Magnitude																			
20																			
Deteção (VP)	0	200	0	157	199	193	127	157	174	0	200	200	200	200	200	200	200	200	199
Deteção (FN)	200	0	200	43	1	7	73	43	26	200	0	0	0	0	0	0	0	0	1
Sensibilidade (%)	0	100	0	78,5	99,5	96,5	63,5	78,5	87	0	100	100	100	100	100	100	100	100	99,5
Deteção (FP) (%)	0	77	0	11,2	35,5	1	19	60,5	78	0	0	0	0	0	0	0	0	0	100
40																			
Deteção (VP)	0	0	0	200	200	200	200	200	200	0	0	0	200	200	200	200	200	200	200
Deteção (FN)	200	200	200	0	0	0	0	0	0	200	200	200	0	0	0	0	0	0	0
Sensibilidade (%)	0	0	0	100	100	100	100	100	100	0	0	0	100	100	100	100	100	100	100
Deteção (FP) (%)	0	0	0	0,5	0	0	100	100	100	0	0	0	0,5	0	0	0	0	0	100
LINEAR																			
Magnitude																			
20																			
Deteção (VP)	0	0	0	186	179	200	92	79	143	0	200	200	200	200	200	200	200	200	162
Deteção (FN)	200	200	200	14	21	0	108	121	57	200	0	0	0	0	0	0	0	0	38
Sensibilidade (%)	0	0	0	93	89,5	100	46	39,5	71,5	0	100	100	100	100	100	100	100	100	81
Deteção (FP) (%)	0	0	0	18,5	12,8	0	4,5	13,3	23,3	0	0	0	0	0	0	0	0	25,3	32,5
40																			
Deteção (VP)	0	0	0	200	200	194	200	200	197	0	0	0	200	200	87	199	200	200	193
Deteção (FN)	200	200	200	0	0	6	0	0	3	200	200	200	0	0	11,3	1	0	7	
Sensibilidade (%)	0	0	0	100	100	97	100	100	98,5	0	0	0	100	100	43,5	99,5	100	96,5	
Deteção (FP) (%)	0	0	0	0	0	0	32,8	100	100	0	0	0	0	0	0	0	0	100	100
EXPONENCIAL																			
Magnitude																			
20																			
Deteção (VP)	0	135	0	136	200	72	90	182	55	0	200	200	200	200	200	200	200	200	200
Deteção (FN)	200	65	200	64	0	128	110	18	145	200	0	0	0	0	0	0	0	0	0
Sensibilidade (%)	0	67,5	0	68	100	36	45	91	27,5	0	100	100	100	100	100	100	100	100	100
Deteção (FP) (%)	0	30,8	30	23	0	4,17	31	21,3	30,6	0	0	0	0	0	0	0	0	100	99,9
40																			
Deteção (VP)	0	0	0	200	200	200	200	200	200	0	200	200	200	200	200	200	200	200	200
Deteção (FN)	200	200	200	0	0	0	0	0	0	200	0	0	0	0	0	0	0	0	0
Sensibilidade (%)	0	0	0	100	100	100	100	100	100	0	100	100	100	100	100	100	100	100	100
Deteção (FP) (%)	0	0	0	0,17	0	0	100	100	100	0	0	0	0	0	0	0	0	32,5	100
LOGNORMAL																			
Magnitude																			
20																			
Deteção (VP)	0	200	0	164	200	200	70	200	200	0	0	0	200	200	200	200	200	200	200
Deteção (FN)	200	0	200	36	0	0	130	0	0	200	200	200	0	0	0	0	0	0	0
Sensibilidade (%)	0	100	0	82	100	100	35	100	100	0	0	0	100	100	100	100	100	100	100
Deteção (FP) (%)	0	38	0	16	0	0	32,5	72,5	100	0	0	0	0	0	0	0	0	100	100
40																			
Deteção (VP)	0	200	200	200	200	200	200	200	200	0	0	0	200	200	200	200	200	200	200
Deteção (FN)	200	0	0	0	0	0	0	0	0	200	200	200	0	0	0	0	0	0	0
Sensibilidade (%)	0	100	100	100	100	100	100	100	100	0	0	0	100	100	100	100	100	100	100
Deteção (FP) (%)	0	0	0	0	0	0	100	100	100	0	0	0	0	0	0	0	0	100	100

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

151 O gráfico de controle Shewhart combinado ao pré-processamento GLM, quando avaliado in-
152 dependentemente, identificou 100% dos surtos simulados nos dados em todos os tipos de ruídos com
153 magnitude acima de 30; esse valor diminuiu quando avaliadas séries com magnitude 20 apresentando
154 menor percentual de detecção para o ruído exponencial identificando apenas 60% dos surtos (Tabela 7).
155 Um comportamento similar para a mesma técnica foi visto na detecção de surtos combinada com pré-
156 processamento diferenciação, apresentando menor percentual de detecção com ruído spike de magnitude
157 20. Esta técnica quando combinada com outras, não apresenta melhora significativa na detecção de surtos.

158 A técnica EWMA apresentou alto percentual de detecção VP para séries com ruídos flat, linear e
159 exponencial para magnitudes de 30 a 50, este percentual de detecção é reduzido ao avaliar as mesmas
160 séries com ruídos de magnitude 20 chegando a um percentual de detecção 38,5% em séries com ruídos
161 do tipo exponencial. A técnica apresentou baixos percentuais de detecção quando combinada com pré-
162 processamento diferenciação, com exceção a séries com ruído spike de magnitudes 20 e 30 (Tabela
163 7).

164 A suavização exponencial de Holt-Winters demonstrou um comportamento similar na detecção de
165 todos os tipos de ruídos aplicados e pré-processamentos diferentes. Para séries com ruídos de magnitudes
166 20 a técnica apresentou percentuais menores de detecção, onde a medida que a magnitude do ruído
167 aumentou, o percentual de detecção também aumentou, com exceção apenas do ruído spike com pré-
168 processamento GLM e magnitude 30 que passou de 92% para 0,5%, voltando a aumentar quando a
169 magnitude do ruído aumentou (Tabela 7).

170 Foi observado que a combinação das técnicas, quando avaliadas simultaneamente, resultaram
171 em altos percentuais de detecção para séries com ruídos de magnitudes acima de 30, como foi o caso da
172 combinação SH e EWMA independente e com pré-processamento GLM; esta combinação apresentou os
173 maiores percentuais de detecção de VP simultaneamente (Tabela 7).

174 A combinação das técnicas EWMA e HW independente também apresentou altos percentuais
175 de detecção com pré-processamento GLM, com exceção do ruído lognormal e magnitude 50 (Tabela
176 7). As séries com ruído lognormal apresentaram menores percentuais de detecção na combinação das
177 três técnicas (SH, EWMA e HW) independente do pré-processamento aplicado. A combinação das três
178 técnicas apresentaram melhores resultados na detecção de ruídos do tipo flat com pré-processamento
179 GLM.

180 A combinação das técnicas SH com HW apresentou maiores coeficientes de correlações tanto na
181 correlação tetracórica quanto no coeficiente de correlação de Matthews, destacando-se na detecção de
182 ruídos do tipo exponencial tanto com pré-processamento GLM, quanto com diferenciação (Tabela 8).

183 A combinação de EWMA com HW também apresentou altos coeficientes de correlação quando
184 pré-processados por GLM na detecção de surtos do tipo exponencial.

185 Comportamentos antagônicos, demonstrados através de correlações negativas também puderam
186 ser observados (Tabela 8), destacando-se no caso de ruídos com formato exponencial de magnitude 30, 15
187 dias de duração e pré-processamento GLM que apresentou correlação -0,84 para a relação EWMA com
188 HW.

189 A maioria das correlações com pré-processamento diferenciação apresentam baixos índices de
190 correlação diferentemente das calculadas com pré-processamento GLM (Tabela 8).

Tabela 7 – Porcentagem de alarmes verdadeiro positivos acionados para cada combinação de técnicas de detecção e magnitude (λ).

Pré-process.	Combinação*	Técnica e magnitude (λ)																	
		Spike			Flat			Linear			Exponencial			LogNormal					
		20	30	40	50	20	30	40	50	20	30	40	50	20	30	40	50		
GLM	SH (indep.)	99	100	100	100	99,8	100	100	100	78,8	100	100	100	60	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	
	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	
	SH !EWMA	80	100	6,5	0	0	0	0	0	18,8	0	0	0	21,5	1,8	0	0	16,7	
	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	
	EWMA !SH	0,5	0	0	0	0,17	0	0	0	7	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	
	HW !SH	0	0	0	0	0	0	0	0	0,83	0	0	0	3,2	0	0	0	0	
	HW !EWMA	17	92	6	0	0	0	0	0	12	0	0	0	18	1,8	0	2	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	
	(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	
	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	
	(SH & HW) !EWMA	17	92	6	0	0	0	0	0	11,5	0	0	0	14,8	0,19	0	2	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	
(EWMA & HW) !SH	0	0	0	0	0	0	0	0	0,33	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		
Diferenciação	SH (indep.)	21,5	100	100	100	91,5	100	100	100	94,2	100	99	81,2	68	100	100	94	100	
	EWMA (indep.)	0	94,5	95,5	100	33,3	66,7	0	0	66,7	0	0	22,5	66,7	0	66	33,3	0	
	HW (indep.)	15,5	92,5	96,5	100	76,3	99,8	100	100	52,3	93,7	99,5	98,7	54,5	100	100	78,3	100	
	SH !EWMA	21,5	5,5	4,5	0	58,3	33,3	100	100	94,2	33,3	99	0,17	45,5	33,3	100	33	16	
	SH !HW	12	7,5	3,5	0	19,5	0,17	0	0	42,7	6,33	0,5	81,2	14,7	0	0	61	0	
	EWMA !SH	0	0	3	0	0,17	0	0	0	0	0	0	0	0	0	0	0	0	
	EWMA !HW	0	5	0	0	7,17	0,17	0	0	6,33	0	0	0,17	0	0	0	0	0	
	HW !SH	6	0	0	0	4,33	0	0	0	0,83	0	1	17,7	1,17	0	0	0,17	0	
	HW !EWMA	15,5	3	4	0	50,2	33,3	100	100	52,3	33,3	99,5	17,7	32,2	33,3	100	33	44,6	
	SH & EWMA (indep.)	0	94,5	95,5	100	33,2	66,7	0	0	66,7	0	0	22,5	66,7	0	67	33,3	0	
	(SH & EWMA) !HW	0	5	3	0	7	0,17	0	0	6,33	0	0	0,17	0	0	0	0	0	
	SH & HW (indep.)	9,5	92,5	96,5	100	72	99,8	100	100	51,5	93,7	98,5	81	0,53	100	100	78	100	
	(SH & HW) !EWMA	9,5	3	4	0	45,8	33,3	100	100	51,5	33,3	98,5	81	31	33	100	33	44,6	
	EWMA & HW (indep.)	0	89,5	92,5	100	26,2	66,5	0	0	60,3	0	0	22,3	33,3	0	67	33,3	0	
(EWMA & HW) !SH	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
SH & EWMA & HW	0	89,5	92,5	100	26,2	66,5	0	0	60,3	0	0	22,3	33,3	0	67	33,3	0		

*Resultado médio para duração de 5, 10 e 15 dias **Indicações: “indep”(independente da outra técnica), “&” (simultaneamente a outra técnica), “!” (a técnica não alarma). EWMA = Gráfico de Controle de Média Model Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. GLM = Pré-processamento realizado por um modelo de regressão.

Tabela 8 – Correlação entre as técnicas *.

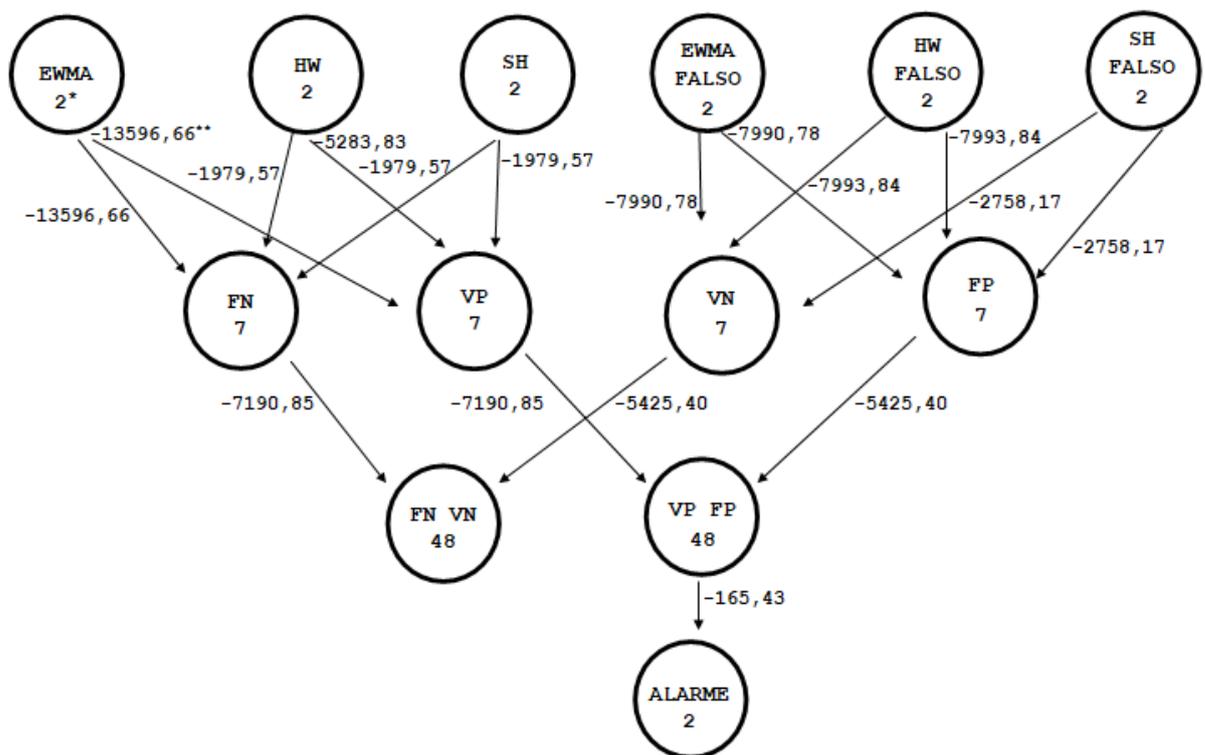
Correlação Tetracórica		Pré-processamento GLM															
MAGNITUDE (λ)	Duração (dias)	SPIKE			FLAT			LINEAR			EXPONENCIAL			LOGNORMAL			
		EWMA: SH	EWMA: HW	SH: HW	EWMA: SH	EWMA: HW	SH: HW	EWMA: SH	EWMA: HW	SH: HW	EWMA: SH	EWMA: HW	SH: HW	EWMA: SH	EWMA: HW	SH: HW	
20	1	-0,32	-0,54	0,89													
	5						0,94	-0,65	-0,47	0,98	0,99	1	0,99			0,18	
	10							0,95	0,93	0,98			0,69				
	15											0,98	0,98	0,77			
	15												-0,84				
40	1			0,21													
Pré-processamento diferenciação																	
20	1																
	5									0,97						0,99	
	10									0,70					0,81		0,72
	15									0,14						0,88	
	15																
30	1			0,67													
	1			0,3													
	15																
40	1																
	15																
50	1																
	15																
Coeficiente de correlação de Matthews																	
Pré-processamento GLM																	
MAGNITUDE (λ)	Duração (dias)	SPIKE			FLAT			LINEAR			EXPONENCIAL			LOGNORMAL			
		EWMA: SH	EWMA: HW	SH: HW	EWMA: SH	EWMA: HW	SH: HW	EWMA: SH	EWMA: HW	SH: HW	EWMA: SH	EWMA: HW	SH: HW	EWMA: SH	EWMA: HW	SH: HW	
20	1	-0,07	-0,19	0,04													
	5									0,08							
	10																
	15																
	15																
30	1																
	1																
	15																
40	1			0,06													
	15																
Pré-processamento diferenciação																	
20	1																
	5																
	10																
	15																
	15																
30	1			0,34													
	1			0,08													
	15																
40	1																
	15																
50	1																
	5																
	10																
	15																
	15																

* Espaços em branco e correlações omitidas apresentaram valor zero ou foram impossíveis de se calcular. EWMA = Gráfico de Controle de Média Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters.

191 A rede proposta contém seis variáveis pai, onde três representam alarmes verdadeiros (EWMA,
192 HW, SH) e três representam alarmes falsos (EWMA FALSO, HW FALSO, SH FALSO).

193 A probabilidade do sistema apresentar alarme verdadeiro positivo (VP) ou falso positivo (FP) foi
194 de 99,72% observado para os dados simulados e de 99,87% pelo cálculo da rede (Tabela 9). Diferentes
195 probabilidades para as mesmas condições de alarme acionado ou não, foram encontrados para todas as
196 técnicas (Tabela 10). Caso o alarme seja acionado as probabilidades de FP para EWMA e SH seriam mais
197 baixas que HW. Entretanto as falhas para não acionamento do alarme considerando FN seriam baixas
198 para EWMA e HW e elevadas para SH.

Figura 8 – Rede Bayesiana proposta apresentando o número de níveis para o nó (*) e BIC para a força de ligação (**).



Todas as arestas foram significativas pelo teste qui-quadrado ($p < 0,01$). EWMA = Gráfico de Controle de Média Model 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 9 – 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			0,069792	0,930208		
SH_FALSO			0,338091	0,661909		
HW_FALSO			0,621112	0,378888		
Alarme = Sim						
EWMA	0,465483	0,534517				
SH	0,045379	0,954621				
HW	0,103285	0,896715				
EWMA_FALSO			0,170625	0,829375		
SH_FALSO			0,045851	0,954149		
HW_FALSO			0,817880	0,182120		

*FN = Falso Negativo, VP = Verdadeiro Positivo, FP = Falso Positivo e VN = Verdadeiro Negativo. EWMA = Gráfico de Controle de Média Model Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters.

199 3.5 Discussão

200 A partir dos resultados apresentados nas tabelas 3 e 4 é possível identificar uma mudança na
 201 sensibilidade da técnica SH para detecções de surtos do tipo spike com magnitude 20 quando utilizado o
 202 pré-processamento diferenciação. Esta técnica apresentou os melhores resultados na identificações de
 203 surtos do tipo spike quando os dados foram pré-processados com GLM. As técnicas EWMA e HW não
 204 apresentaram diferenças significativas na utilização de ambos pré-processamentos, por outro lado, os

205 índices de alarmes FP foram maiores quando utilizado pré-processamento GLM.

206 A sensibilidade do sistema avaliando ruídos do tipo flat e linear apresentou melhores resultados
207 com a utilização do pré-processamento GLM, principalmente na utilização da técnica EWMA. Para
208 a detecção de ruídos do tipo exponencial e lognormal a utilização de ambos pré-processamentos não
209 apresentou diferenças significativas.

210 Os maiores coeficientes de correlação identificados foram dados pela relação entre as técnicas
211 SH e HW destacando-se na detecção de ruídos do tipo exponencial.

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

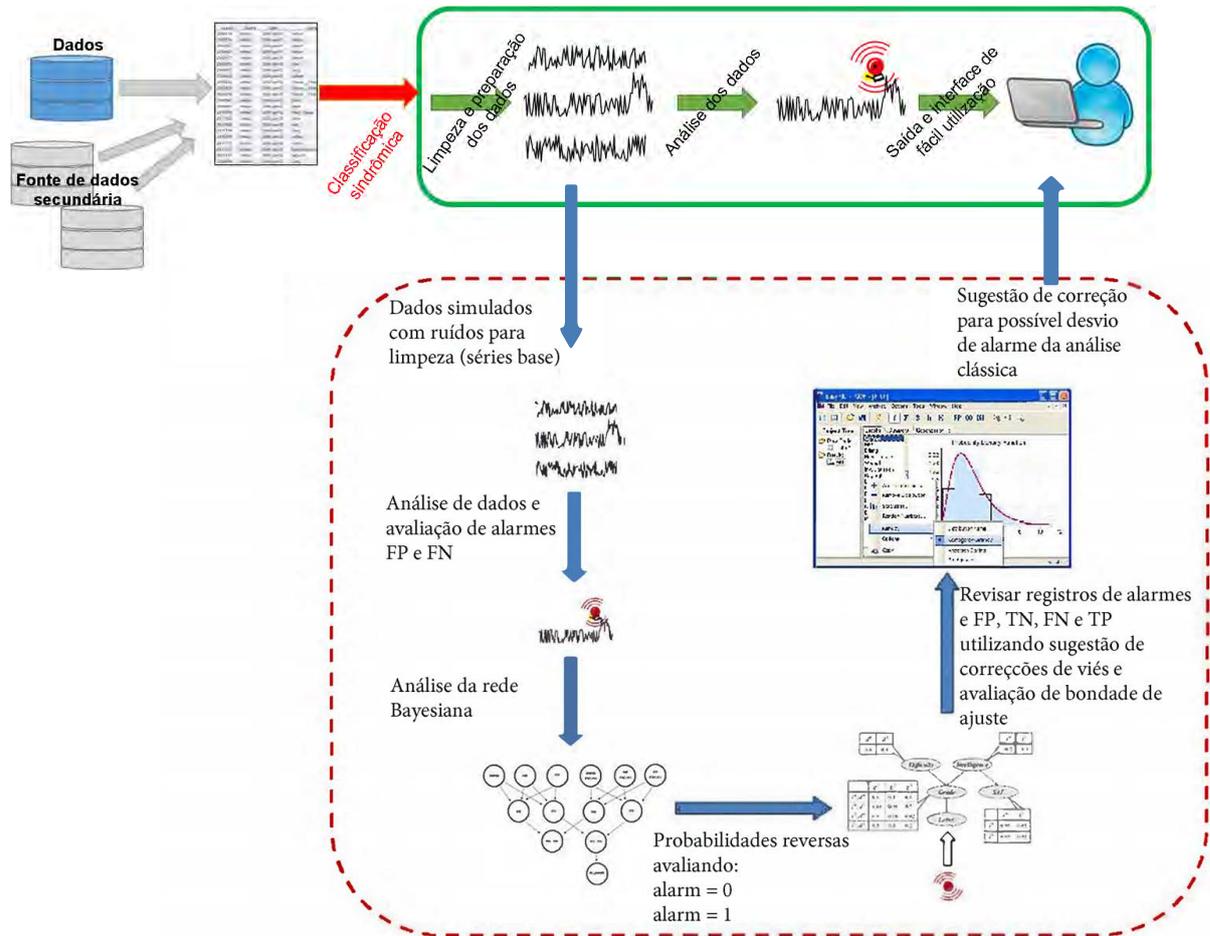
221 A rede Bayesiana proposta permitiu identificar as probabilidades de erros de cada técnica utilizada
222 no sistema, isto é, identificar FP quando o alarme foi acionado, ou FN dado que o alarme não foi acionado.
223 A partir da rede proposta foi possível identificar que a técnica HW apresentou maior probabilidade de
224 FP (81,78%), dado que o alarme foi acionado. Para o caso de FN a técnica EWMA apresentou maior
225 probabilidade (46,54%), dado que o sistema não foi alarmado (Tabela 9).

226 Neste estudo, considerando os dados simulados, a rede revelou que a técnica SH exibiu o melhor
227 índice de detecção verdadeira com menor probabilidade para falsos positivos. Os resultados também
228 possibilitam ao usuário identificar o desempenho de cada técnica utilizada no sistema em termos de
229 probabilidade (Tabela 9).

230 Uma das formas de melhorar a sensibilidade do sistema desenvolvido por Dórea, Widgrén e
231 Lindberg (2015) é identificando os erros e corrigindo-os. Esta identificação pode ser dada a partir da
232 rede Bayesiana proposta, a qual identifica quais técnicas estão fornecendo os maiores índices de alarmes

233 FP e FN, em termos de probabilidade. A rede poderia ser inserida como parte da avaliação do sistema
 234 corrigindo os alarmes como mostra a Figura 9.

Figura 9 – Sugestão de aperfeiçoamento do sistema *vetsyn* inserindo a rede Bayesiana proposta.



235 Assim, um conjunto de dados simulados seriam inseridos no sistema, já implementado, e após
 236 análise dos dados a rede Bayesiana seria construída fornecendo as probabilidades de acionamento, ou
 237 não, do alarme. Dessa forma o usuário teria acesso à uma tabela de probabilidades (Tabela 9), a qual
 238 identificaria quais técnicas apresentam os maiores índices de FP e FN. Após obtenção das probabilidades,
 239 o usuário poderia corrigir todos os níveis para as duas variáveis FN VN e VP FP (48 níveis diferentes)
 240 escolhendo uma probabilidade de corte para correção. Em consequência os níveis que apresentavam
 241 valores um receberão valores zero e vice-versa para todos os pontos no vetor de alarmes, alterando os
 242 pontos que foram classificados como FN para VP e os FP para VN; da mesma forma podem ocorrer
 243 ajustes desfavoráveis como um substituição de VP por FN e VN por FP.

244 Esta correção foi implementada no *vetsyn* tomando os parâmetros estatísticos dos dados simulados
245 como sendo a amostra, e os resultados podem ser observados na Tabela 10. É possível observar que com
246 probabilidade de correção 0,1% erros já são corrigidos no sistema, como o índice de valores FN para a
247 técnica SH que diminuiu de 0,046154 para 0,025622. Com o aumento da probabilidade de correção para
248 5% os valores melhoram ainda mais, como por exemplo o índice de FN das técnicas SH e HW quem
249 são todos corrigidos. Com uma probabilidade de correção de 30% os alarmes FN e FP são totalmente
250 corrigidos tanto quanto os alarmes VP e VN para todas as técnicas avaliadas.

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

Tabela 10 – 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
Observada*	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
0,01	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
0,1	EWMA	0,446299	0,553701		
	SH	0,025622	0,974378		
	HW	0,082789	0,917211		
	EWMA_FALSO			0,159375	0,840625
	SH_FALSO			0,031442	0,968558
	HW_FALSO			0,814086	0,185914
0,5	EWMA	0,403222	0,596778		
	SH	0,008799	0,991201		
	HW	0,044183	0,955817		
	EWMA_FALSO			0,117692	0,882309
	SH_FALSO			0,002307	0,997693
	HW_FALSO			0,788269	0,211731
1	EWMA	0,388799	0,611201		
	SH	0,008799	0,991201		
	HW	0,019327	0,980673		
	EWMA_FALSO			0,108317	0,891683
	SH_FALSO			0,002307	0,997693
	HW_FALSO			0,778894	0,221106
5	EWMA	0,36101	0,638990		
	SH	0	1		
	HW	0	1		
	EWMA_FALSO			0,058798	0,941202
	SH_FALSO			0	1
	HW_FALSO			0,754038	0,245962
10	EWMA	0,328750	0,671250		
	SH	0	1		
	HW	0	1		
	EWMA_FALSO			0	1
	SH_FALSO			0	1
	HW_FALSO			0,695240	0,304760
20	EWMA	0,328750	0,671250		
	SH	0	1		
	HW	0	1		
	EWMA_FALSO			0	1
	SH_FALSO			0	1
	HW_FALSO			0,695240	0,304760
30	EWMA	0	1		
	SH	0	1		
	HW	0	1		
	EWMA_FALSO			0	1
	SH_FALSO			0	1
	HW_FALSO			0	1

FN = Falso Negativo, VP = Verdadeiro Positivo, FP = Falso Positivo e VN = Verdadeiro Negativo. EWMA = Gráfico de Controle de Média Model Ponderado Exponencialmente, SH = Gráfico de Controle Shewhart e HW = Suavização Exponencial Holt-Winters. EWMA_FALSO = Gráfico de Controle de Média Model Ponderado Exponencialmente apresentando alarmes falsos, SH_FALSO = Gráfico de Controle Shewhart apresentando alarmes falsos e HW_FALSO = Suavização Exponencial Holt-Winters apresentando alarmes falsos.

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

263 3.6 Agradecimentos

264 Este estudo recebeu o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
265 (CAPES) através do projeto número 203/13, e também do Programa de Pós-graduação em Biometria e
266 Estatística Aplicada (PPGBEA) da Universidade Federal Rural de Pernambuco (UFRPE).

4 Conclusão

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 model Ponderado Exponencialmente e a suavização exponencial Holt-Winters não apresentaram diferenças significativas na utilização de ambos pré-processamentos. A sensibilidade do sistema avaliando ruídos do tipo flat e linear apresentou melhores resultados com a utilização do pré-processamento GLM. o gráfico de controle Shewhart exibiu o melhor índice de detecção verdadeira com menor probabilidade para alarmes falsos positivos. Os maiores coeficientes de correlação identificados foram dados pela relação entre as técnicas 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 do *vetsyn*.

Referências Bibliográficas

- ANDERSSON, M. G. et al. Using bayes' rule to define the value of evidence from syndromic surveillance. **PLoS one**, Public Library of Science, v. 9, n. 11, p. e111335, 2014.
- BEGIER, E. M. et al. The national capitol region's emergency department syndromic surveillance system: do chief complaint and discharge diagnosis yield different results? **Emerging infectious diseases**, Centers for Disease Control and Prevention, v. 9, n. 3, p. 393, 2003.
- BEN-GAL, I. Bayesian networks. **Encyclopedia of statistics in quality and reliability**, Wiley Online Library, 2007.
- BOWER, K. M. Using exponentially weighted moving average (ewma) charts. **Asia Pacific Process Engineer**, 2000.
- BRONNER, A. et al. Syndromic surveillance of abortions in beef cattle based on the prospective analysis of spatio-temporal variations of calvings. **Scientific reports**, Nature Publishing Group, v. 5, p. 18285, 2015.
- BUEHLER, J. W. et al. Syndromic surveillance and bioterrorism-related epidemics. **Emerging infectious diseases**, Centers for Disease Control and Prevention, v. 9, n. 10, p. 1197, 2003.
- CHEN, H. et al. Knowledge management, data mining, and text mining in medical informatics. In: **Medical Informatics**. [S.l.]: Springer, 2005. p. 3–33.
- CONTROL, C. for D.; CDC, P. et al. Syndromic surveillance for bioterrorism following the attacks on the world trade center–new york city, 2001. **MMWR. Morbidity and mortality weekly report**, v. 51, p. 13, 2002.
- COSTA, A. F. B.; EPPRECHT, E. K.; CARPINETTI, L. C. R. **Controle estatístico de qualidade**. [S.l.]: Atlas São Paulo, 2005.
- CUSSENS, J. Bayesian network learning with cutting planes. **arXiv preprint arXiv:1202.3713**, 2012.
- DOREA, F. **Welcome to the vetsyn package**. 2017. Disponível em: <<https://github.com/nandadorea/vetsyn/wiki>>. Acesso em: 09/01/2018.
- DÓREA, F.; WIDGRÉN, S.; LINDBERG, A. Vetsyn: An r package for veterinary syndromic surveillance. **Preventive veterinary medicine**, Elsevier, v. 122, n. 1, p. 21–32, 2015.
- DÓREA, F. C. et al. Retrospective time series analysis of veterinary laboratory data: Preparing a historical baseline for cluster detection in syndromic surveillance. **Preventive veterinary medicine**, Elsevier, v. 109, n. 3, p. 219–227, 2013.
- DÓREA, F. C.; SANCHEZ, J.; REVIE, C. W. Veterinary syndromic surveillance: Current initiatives and potential for development. **Preventive veterinary medicine**, Elsevier, v. 101, n. 1, p. 1–17, 2011.

- DÓREA, F. C.; VIAL, F. Animal health syndromic surveillance: a systematic literature review of the progress in the last 5 years (2011–2016). **Veterinary Medicine-Research and Reports**, DOVE MEDICAL PRESS LTD PO BOX 300-008, ALBANY, AUCKLAND 0752, NEW ZEALAND, v. 7, p. 157–169, 2016.
- DUPUY, C. et al. Inventory of veterinary syndromic surveillance initiatives in europe (triple-s project): Current situation and perspectives. **Preventive veterinary medicine**, Elsevier, v. 111, n. 3, p. 220–229, 2013.
- ELDERTON, W. P. **Frequency curves and correlation**. [S.l.]: Cambridge University Press, 1952.
- FISCHER, E. A. et al. The joint risk score for vector-borne diseases used for early detection. In: **14th international symposium on veterinary epidemiology and economics**. [S.l.: s.n.], 2015.
- FOSSAERT, H.; LLOPIS, A.; TIGRE, C. H. **Sistemas de vigilancia epidemiológica**. 1974.
- GESTELAND, P. H. et al. Rapid deployment of an electronic disease surveillance system in the state of utah for the 2002 olympic winter games. In: AMERICAN MEDICAL INFORMATICS ASSOCIATION. **Proceedings of the AMIA Symposium**. [S.l.], 2002. p. 285.
- GUILFORD, J. P. **Fundamental statistics in psychology and education**. McGraw-Hill, 1950.
- HEFFERNAN, R. et al. New york city syndromic surveillance systems. **Morbidity and Mortality Weekly Report**, JSTOR, p. 25–27, 2004.
- HENNING, K. J. What is syndromic surveillance? **Morbidity and Mortality Weekly Report**, JSTOR, p. 7–11, 2004.
- HØJSGAARD, S. Graphical independence networks with the gRain package for R. **Journal of Statistical Software**, v. 46, n. 10, p. 1–26, 2012. Disponível em: <<http://www.jstatsoft.org/v46/i10/>>.
- HULTH, A. First european guidelines on syndromic surveillance in human and animal health published. **Eurosurveillance**, v. 19, p. 41, 2014.
- JENSEN, F. V. **Bayesian Networks and Decision Graphs. Series for Statistics for Engineering and Information Science**. [S.l.]: Springer Verlag, 2001.
- KARCHER, C. **Redes Bayesianas aplicadas à análise do risco de crédito**. Tese (Doutorado) — Universidade de São Paulo, 2009.
- LALKHEN, A. G.; MCCLUSKEY, A. Clinical tests: sensitivity and specificity. **Continuing Education in Anaesthesia Critical Care & Pain**, Oxford University Press, v. 8, n. 6, p. 221–223, 2008.
- LIRA, S. A. **Análise de correlação: abordagem teórica e de construção dos coeficientes com aplicações**. Curitiba–Universidade Federal do Paraná, 2004.
- MANDL, K. D. et al. Implementing syndromic surveillance: a practical guide informed by the early experience. **Journal of the American Medical Informatics Association**, BMJ Group BMA House, Tavistock Square, London, WC1H 9JR, v. 11, n. 2, p. 141–150, 2004.
- MARQUES, R. L.; DUTRA, I. **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, 2002.
- MARQUES, R. L.; DUTRA, I. **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, 2002.

- MATTHEWS, B. W. Comparison of the predicted and observed secondary structure of t4 phage lysozyme. **Biochimica et Biophysica Acta (BBA)-Protein Structure**, Elsevier, v. 405, n. 2, p. 442–451, 1975.
- MCCANN, R. K.; MARCOT, B. G.; ELLIS, R. Bayesian belief networks: applications in ecology and natural resource management. **Canadian Journal of Forest Research**, NRC Research Press, v. 36, n. 12, p. 3053–3062, 2006.
- MINGOTI, S. A.; YASSUKAWA, F. R. Uma comparação de gráficos de controle para a média de processos autocorrelacionados. **Revista Eletrônica Sistemas & Gestão**, v. 3, n. 1, p. 55–73, 2008.
- MNATSAKANYAN, Z. R. et al. Bayesian information fusion networks for biosurveillance applications. **Journal of the American Medical Informatics Association**, BMJ Group BMA House, Tavistock Square, London, WC1H 9JR, v. 16, n. 6, p. 855–863, 2009.
- MONTGOMERY, D. C. **Introduction to statistical quality control**. [S.l.]: John Wiley & Sons, 2007.
- MOON, T. K. The expectation-maximization algorithm. **IEEE Signal processing magazine**, IEEE, v. 13, n. 6, p. 47–60, 1996.
- MOSTASHARI, F.; KARPATI, A. Towards a theoretical (and practical) framework for prodromic surveillance. In: **International Conference on Emerging Infectious Diseases, Atlanta, GA, March**. [S.l.: s.n.], 2002.
- MURPHY, K. A brief introduction to graphical models and bayesian networks. 1998.
- NEAPOLITAN, R. E. et al. **Learning bayesian networks**. [S.l.]: Pearson Prentice Hall Upper Saddle River, NJ, 2004. v. 38.
- NIKOVSKI, D. Constructing bayesian networks for medical diagnosis from incomplete and partially correct statistics. **IEEE Transactions on Knowledge and Data Engineering**, IEEE, v. 12, n. 4, p. 509–516, 2000.
- OLIVA, G. M. et al. Bayesian networks applications on dependability, risk analysis and maintenance. **IFAC Proceedings Volumes**, Elsevier, v. 42, n. 5, p. 215–220, 2009.
- OLSON, K. L.; MANDL, K. D. Geocoding patient addresses for biosurveillance. In: AMERICAN MEDICAL INFORMATICS ASSOCIATION. **Proceedings of the AMIA Symposium**. [S.l.], 2002. p. 1119.
- OZONOFF, A. et al. Bivariate method for spatio-temporal syndromic surveillance. **Morbidity and Mortality Weekly Report**, JSTOR, p. 61–66, 2004.
- PEARSON, K. Mathematical contributions to the theory of evolution. vii. on the correlation of characters not quantitatively measurable. **Philosophical Transactions of the Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character**, JSTOR, v. 195, p. 1–405, 1900.
- R Core Team. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2017. Disponível em: <<https://www.R-project.org/>>.
- ROBERTS, S. Control chart tests based on geometric moving averages. **Technometrics**, Taylor & Francis, v. 1, n. 3, p. 239–250, 1959.
- ROBERTSON, C. et al. A hidden markov model for analysis of frontline veterinary data for emerging zoonotic disease surveillance. **PLoS One**, Public Library of Science, v. 6, n. 9, p. e24833, 2011.

- RODIN, A. S.; BOERWINKLE, E. Mining genetic epidemiology data with bayesian networks i: Bayesian networks and example application (plasma apoe levels). **Bioinformatics**, Oxford University Press, v. 21, n. 15, p. 3273–3278, 2005.
- ROGERSON, P. A.; YAMADA, I. Approaches to syndromic surveillance when data consist of small regional counts. **Morbidity and Mortality Weekly Report**, JSTOR, p. 79–85, 2004.
- SAMOHYL, R. W.; ROCHA, R.; MATTOS, V. L. D. d. Utilização do método de holt-winters para previsão do leite entregue às indústrias catarinenses. 2001.
- SCHWABE, C. The current epidemiological revolution in veterinary medicine. part i. **Preventive Veterinary Medicine**, Elsevier, v. 1, n. 1, p. 5–15, 1982.
- SCUTARI, M. bnlearn: Bayesian network structure learning. **R package**, 2010.
- SILVA, W. V. da; SAMOHYL, R. W.; COSTA, L. S. Comparação entre os métodos de previsão univariados para o preço médio da soja no brasil. **Anais XXII Encontro Nacional de Engenharia de Produção 2002**, p. 1–8, 2002.
- THRUSFIELD, M. **Epidemiologia veterinária**. [S.l.]: Roca São Paulo, 2004.
- UEBERSAX, J. S. Introduction to the tetrachoric and polychoric correlation coefficients. **Obtido de <http://www.john-uebersax.com/stat/tetra.htm>**. [Links], 2006.
- VERÍSSIMO, A. J. et al. Métodos estatísticos de suavização exponencial holt-winters para previsão de demanda em uma empresa do setor metal mecânico. **Revista Gestão Industrial**, v. 8, n. 4, 2013.
- WAGNER, M. M. et al. The emerging science of very early detection of disease outbreaks. **Journal of public health management and practice**, ASPEN PUBLICATION, v. 7, n. 6, p. 51–59, 2001.
- WALLENSTEIN, S.; NAUS, J. Scan statistics for temporal surveillance for biologic terrorism. **Morbidity and Mortality Weekly Report**, JSTOR, p. 74–78, 2004.
- WALTER, O. et al. Aplicação individual e combinada dos gráficos de controle shewhart e cusum: uma aplicação no setor metal mecânico. **Gestão & Produção**, v. 20, n. 2, p. 271–286, 2013.
- WINTERS, P. R. Forecasting sales by exponentially weighted moving averages. **Management science**, INFORMS, v. 6, n. 3, p. 324–342, 1960.
- WONG, W.-K. et al. Bayesian network anomaly pattern detection for disease outbreaks. In: **Proceedings of the 20th International Conference on Machine Learning (ICML-03)**. [S.l.: s.n.], 2003. p. 808–815.
- ZENG, D. et al. Infectious disease informatics and outbreak detection. In: **Medical Informatics**. [S.l.]: Springer, 2005. p. 359–395.