



UNIVERSIDADE DE BRASÍLIA
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA

**PADRÕES TEMPORAIS E ESPACIAIS NA DETECÇÃO DE RESÍDUOS E
CONTAMINANTES NA PRODUÇÃO DE AVES E SUÍNOS NO BRASIL**

ANNA JÚLIA PORTZ

DISSERTAÇÃO DE MESTRADO EM CIÊNCIAS ANIMAIS

BRASÍLIA/DF
FEVEREIRO DE 2016



**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA**

**PADRÕES TEMPORAIS E ESPACIAIS NA DETECÇÃO DE RESÍDUOS E
CONTAMINANTES NA PRODUÇÃO DE AVES E SUÍNOS NO BRASIL**

Aluno: Anna Júlia Portz

Orientadora: Concepta Margaret McManus Pimentel

Coorientador: Nilton Correia Silva

DISSERTAÇÃO DE MESTRADO EM CIÊNCIAS ANIMAIS

Publicação: 158/2016

**BRASÍLIA/DF
FEVEREIRO DE 2016**

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE AGRONOMIA E MEDICINA VETERINÁRIA**

**PADRÕES TEMPORAIS E ESPACIAIS NA DETECÇÃO DE RESÍDUOS E
CONTAMINANTES NA PRODUÇÃO DE AVES E SUÍNOS NO BRASIL**

ANNA JÚLIA PORTZ

**DISSERTAÇÃO DE MESTRADO SUBMETIDA
AO PROGRAMA DE PÓS-GRADUAÇÃO EM
CIÊNCIAS ANIMAIS, COMO PARTE DOS
REQUISITOS NECESSÁRIOS À OBTENÇÃO
DO GRAU DE MESTRE EM CIÊNCIAS
ANIMAIS.**

APROVADA POR:

CONCEPTA MARGARET MCMANUS PIMENTEL
Doutora - Universidade de Brasília
(ORIENTADORA)

CRISTIANO BARROS MELO
Doutor - Universidade de Brasília
(EXAMINADOR INTERNO)

LUIZ FELIPE RAMOS CARVALHO
Doutor - Ministério Agricultura, Pecuária e Abastecimento
(EXAMINADOR EXTERNO)

BRASÍLIA/DF, 29 de Fevereiro de 2016

REFERÊNCIA BIBLIOGRÁFICA E CATALOGAÇÃO

PORTZ, A. J. **Padrões temporais e espaciais na detecção de resíduos e contaminantes na produção de aves e suínos no Brasil.** Brasília: Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília, 2016, 91 p. Dissertação de Mestrado.

Documento formal, autorizando reprodução desta dissertação de mestrado para empréstimo ou comercialização, exclusivamente para fins acadêmicos, foi passado pelo autor à Universidade de Brasília e acha-se arquivado na Secretaria do Programa. O autor e o seu orientador reservam para si os outros direitos autorais, de publicação. Nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor ou do seu orientador. Citações são estimuladas, desde que citada a fonte.

FICHA CATALOGRÁFICA

PORTZ, Anna Júlia. **Padrões temporais e espaciais na detecção de resíduos e contaminantes na produção de aves e suínos no Brasil.**

Brasília: Faculdade de Agronomia e Medicina Veterinária da Universidade de Brasília. 2016. 110 p. Dissertação (Mestrado em Ciências Animais) – Faculdade de Agronomia e Medicina Veterinária da Universidade de Brasília, 2016.

1. Resíduos. 2. Aprendizagem de Máquina. 3. Segurança do Alimento. 4. Saúde Pública.

CDD ou CDU
Agris / FAO

AGRADECIMENTOS

Em primeiro lugar a Deus, que me permitiu concluir mais essa etapa de meu amadurecimento profissional.

À minha família e namorado, que sempre me deram suporte em minhas escolhas e decisões.

Aos meus irmãos de comunidade e minha amiga Laurinda, por suas orações nesse período.

Às minhas amigas Karina Reis, Aryana Dias e Thamires Quinhões, pelas palavras amigas nos momentos necessários.

Ao meu colega e amigo Antonizete Reis que me incentivou a iniciar esse curso.

Aos colegas, chefes e amigos que conheci na CCRC e na CGAL durante o período em que lá trabalhei, pelo aprendizado enorme que me proporcionaram: Rodrigo Dantas, Leandro Feijó, Héber, Leonardo, Marcelo, Angelo e Leandro Barbieri.

Aos meus diretores, vice-presidentes e presidente da Associação Brasileira de Proteína Animal, que me permitiram dar continuidade a esse curso e pelo crescimento profissional que tem me proporcionado.

Ao meu co-orientador, Dr. Nilton Correia, e sua equipe: Dr. Fabrício Ataíde, Gustavo Correa e Hialo Muniz, pela paciência e ajuda com os ensinamentos teóricos e práticos.

Aos professores e aos colegas de Ciências Animais, com os quais aprendi e compartilhei dúvidas e opiniões.

À minha orientadora, Concepta Margaret McManus Pimentel, a quem muito admiro, pelo conhecimento que me proporcionou ao longo desses 2 anos.

ÍNDICE

RESUMO	viii
ABSTRACT.....	ix
LISTA DE ILUSTRAÇÕES.....	x
LISTA DE TABELAS.....	xi
1 CAPÍTULO 1.....	1
1.1 INTRODUÇÃO.....	2
1.1.1 Problemática e Relevância	2
1.1.2 Objetivos.....	3
1.1.3 Objetivo geral.....	3
1.1.4 Objetivos específicos.....	3
1.2 REVISÃO DE LITERATURA.....	4
1.2.1 Cadeia produtiva de aves e suínos.....	4
1.2.2 Segurança Alimentar.....	6
1.2.3 Análise de risco em alimentos.....	8
1.2.4 Resíduos e Contaminantes em alimentos de origem animal.....	9
1.2.5 Monitoramento de Resíduos e Contaminantes no Mundo.....	11
1.2.6 Monitoramento de Resíduos e Contaminantes no Brasil.....	13
1.2.7 Aprendizagem de Máquina.....	14
1.2.7.1 Árvore de Decisão.....	15
1.2.7.1.1 Algoritmo C4.5.....	17
1.2.7.1.2 <i>Software</i> YADT.....	18
1.2.8 Redes Neurais Artificiais.....	18
1.2.8.1 SOM.....	19
1.2.8.2 TASOM.....	20
2 CAPÍTULO II.....	21
RESUMO.....	22
ABSTRACT.....	23
2.1 INTRODUÇÃO.....	24
2.2 MATERIAL E MÉTODOS.....	26
2.2.1 Origem dos dados - PNCRC.....	26
2.2.2 Descrição dos dados.....	28
2.2.3 Metodologia de Análise por Aprendizagem de Máquina.....	30
2.2.3.1 Árvore de Decisão.....	30
2.2.3.2 Redes Neurais.....	32
2.2.4 Metodologia de Análise Espacial – QGIS.....	33

2.2.5	Metodologia de Análise Temporal – Gráficos e Regressão Linear.....	34
2.3	RESULTADOS E DISCUSSÃO.....	36
2.3.1	Árvore de Decisão.....	36
2.3.2	Redes Neurais.....	38
2.3.3	Mapas de distribuição espacial.....	42
2.3.4	Gráficos de distribuição temporal.....	45
2.4	CONCLUSÕES.....	47
3	REFERÊNCIAS BIBLIOGRÁFICAS.....	48
4	ANEXOS.....	56

RESUMO

PADRÕES TEMPORAIS E ESPACIAAIS NA DETECÇÃO DE RESÍDUOS E CONTAMINANTES NA PRODUÇÃO DE AVES E SUÍNOS NO BRASIL

Anna Júlia Portz¹

Concepta Margaret McManus Pimentel²

1 - Mestranda em Ciências Animais, FAV-UnB. Brasília/DF, Brasil.

2 - Professora Titular, FAV-UnB. Brasília/DF, Brasil.

A segurança alimentar é um tema de grande relevância para a saúde pública e o comércio internacional de alimentos. Os resíduos de produtos veterinários e contaminantes ambientais em produtos de origem animal podem causar doenças em organismos expostos a estas substâncias em doses elevadas por um longo período de tempo. Este estudo avaliou dados de monitoramento oficiais de resíduos e contaminantes do Ministério da Agricultura, Pecuária e Abastecimento em tecidos de aves e suínos no período entre 2002 e 2014, a fim de verificar a existência de padrões ocultos nos dados. A análise dos dados foi realizada utilizando dois métodos de aprendizado de máquina: árvore de decisão e redes neurais, além de avaliação visual através de gráficos e mapas. No final do estudo, foi identificado um padrão de distribuição espacial das detecções de substâncias por região, e não foi observado padrão de distribuição temporal.

Palavras-chave: resíduos, aprendizagem de máquina, segurança do alimento, saúde pública.

ABSTRACT

TEMPORAL AND SPACIAL PATTERNS IN THE DETECTION OF RESIDUES AND CONTAMINANTS IN POULTRY AND PORK PRODUCTION IN BRAZIL

Anna Júlia Portz¹

Concepta Margaret McManus Pimentel²

1 - Master's candidate in Animal Sciences, FAV-UnB, Brasília/DF, Brazil.

2 - Professor, FAV-UnB, Brasília/DF, Brazil.

Food Safety is an important topic for public health and international trade in food. Residues of veterinary products and environmental contaminants in animal products can cause diseases in organisms exposed to these substances in high doses for a long time. This study evaluated official monitoring data of residues and contaminants from the Ministry of Agriculture, Livestock and Supply in tissues of poultry and pork in the period between 2002 and 2014 to check for hidden patterns in the data. The analysis of data was performed by using two machine learning methods: decision tree and neural networks, in addition to visual evaluation through graphs and maps. At the end of the study a spatial distribution pattern of detections of substances by region was identified, but no pattern of temporal distribution was observed.

Keywords: residues, machine learning, food security, public health.

LISTA DE ILUSTRAÇÕES

Capítulo 2

Figura 1 Parte das substâncias avaliadas no PNCR 2014	27
Figura 2 Árvore de Decisão referente ao banco de dados de suínos.....	37
Figura 3 Árvore de Decisão referente ao banco de dados de aves.....	37
Figura 4 Posição dos dados de aves em mapas 5X5.....	41
Figura 5 Posição dos dados de aves em mapas 9X9.....	41
Figura 6 Resíduos de Produtos Veterinários em aves.....	42
Figura 7 Resíduos de Produtos Veterinários em suínos	43
Figura 8 Níveis de detecção de substâncias em aves e suínos.....	45

LISTA DE TABELAS

Capítulo 1

Tabela 1 Tipos de Algoritmos	15
Tabela 2 Tipos de dados e características reconhecidos pelo Software YADT.....	18

Capítulo 2

Tabela 1 Dados do SISRES	29
Tabela 2 Status dos Resultados de Análise	30
Tabela 3 Status dos Resultados de Análise após a criação do Status 5.....	31
Tabela 4 Descrição dos Metadados.....	32
Tabela 5 Parâmetros utilizados nos algoritmos SOM e TASOM.....	33
Tabela 6 Substâncias selecionadas para análise dos resultados.....	34
Tabela 7 Período de análise das substâncias selecionadas.....	35
Tabela 8 LMR das substâncias analisadas.....	35
Tabela 9 Número de resultados por Status de Análise.....	38
Tabela 10 Percentual dos dados agrupados em cada neurônio.....	38
Tabela 11 Número de resultados da base de dados por Status de Análise.....	39
Tabela 12 Percentual dos dados agrupados sem resultados negativos.....	39
Tabela 13 Percentual dos dados agrupados sem a variável resultados de análise.....	40
Tabela 14 Número de aves e suínos abatidos em SIFs por Estado.....	44
Tabela 15 Percentual de Análises Não conformes em aves e suínos.....	46

CAPÍTULO I

INTRODUÇÃO

O Brasil é referência no agronegócio mundial, se destacando no mercado de carnes como primeiro maior exportador de carne de frango e quarto maior exportador de carne suína. Em 2014, o Brasil exportou 4.099 mil toneladas de carne de frango e 505 mil toneladas de carne suína. Esses números são surpreendentes quando se compara os volumes de produção e exportação de 18 anos atrás: em 1996 o Brasil exportava 571 mil toneladas de carne de frango e 50 mil toneladas de carne suína, valores aproximadamente 10 vezes menores (ABPA,2015). Esse fato se deve à organização e modernização dessas cadeias ao longo dos anos, o que permite um controle da produção também no que diz respeito às boas práticas agropecuárias e de fabricação.

A fim de garantir a manutenção desses mercados e o acesso a outros, bem como o consumo interno desses alimentos, é essencial os cuidados com a segurança dos alimentos, exigência que, segundo Page (2014), adquire maior importância à medida que aumenta o poder aquisitivo das pessoas. Segurança do alimento refere-se à garantia de que um alimento não causará dano ao consumidor, seja através de perigos físicos, químicos ou biológicos, quando preparado ou consumido de acordo com o uso esperado (Codex Alimentarius, 2003).

Em relação aos perigos químicos, resíduos e contaminantes podem causar efeitos adversos no organismo, como toxicidade aguda, reações alérgicas, efeitos reprodutivos e carcinogenicidade. Seu controle é realizado por meio da adoção de boas práticas agropecuárias, que mitigam o risco de essas substâncias estarem presentes em quantidades prejudiciais à saúde humana (Gehring et al.,2006).

A preocupação com a segurança do alimento quanto aos perigos químicos tornou-se Plano Oficial sob gerenciamento do Ministério da Agricultura, Pecuária e Abastecimento, em 1978 (Feijó et al., 2013), quando foi instituído o Plano Nacional de Controle de Resíduos - PNCRC, que teve suas diretrizes estabelecidas por meio da Instrução Normativa nº 42, de 20 de dezembro de 1999 (Brasil, 1999) e é gerenciado por meio de um Sistema Informatizado – SISRES.

A grande quantidade de dados gerados por sistemas informatizados pode ser de difícil interpretação quando analisados de forma manual. Para possibilitar a análise desse grande volume de dados, cada vez mais são utilizadas ferramentas de aprendizagem de máquina – AM, abordagem baseada em dados para resolver problemas, em que os padrões e tendências ocultos nesses dados são detectados e utilizados na tomada de decisões do processo (Brink & Richards, 2014).

1.1.1 Problemática e Relevância

O monitoramento de resíduos e contaminantes em alimentos de origem animal é uma exigência de diversos países que importam esses produtos do Brasil. Seja por questões de saúde pública, seja por questões culturais, os países que exportam carnes devem ter um programa de monitoramento de resíduos de produtos veterinários e contaminantes ambientais,

reconhecido a nível internacional para garantir o acesso e a manutenção a esses mercados. No Brasil está instituído desde 1978 o Plano Nacional de Controle de Resíduos e Contaminantes - PNCR, gerenciado pelo Ministério de Agricultura, Pecuária e Abastecimento. Esse Plano segue as diretrizes recomendadas pela Comissão Codex Alimentarius, para definição do Plano amostral anual.

Este trabalho objetiva verificar a existência de padrões de distribuição especial ou temporal nos dados de monitoramento de resíduos e contaminantes em amostras de aves e suínos do PNCR e para auxiliar na avaliação do Plano de Monitoria deste programa.

1.1.2 Objetivos

1.1.3 Objetivo geral

Analisar os dados de monitoria oficial de resíduos e contaminantes na produção de aves e suínos durante o período de 2002 a 2014.

1.1.4 Objetivos específicos

1. Avaliação dos dados por meio da utilização de ferramentas de aprendizagem de máquina.
2. Análise da distribuição espaço-temporal dos dados das detecções a fim de verificar a existência de padrões

REVISÃO DE LITERATURA

1.2.1 Cadeia produtiva de aves e suínos

O Brasil é o maior exportador de carne de aves do mundo, desde 2004 (Penz Junior & Bruno). Em 2015 foram exportados 3,74 milhões de toneladas de carne de aves (United States Department of Agricultural, 2015), 69,25% a mais do que a União Europeia, 2º maior exportador de carne de aves neste mesmo ano (United States Department of Agricultural, 2015). Em relação à carne suína o Brasil é o quarto maior produtor e quarto maior exportador, tendo exportado 565 mil toneladas em 2015, ficando atrás apenas da União Europeia, Estados Unidos e Canadá, respectivamente (United States Department of Agricultural, 2015).

Segundo dados da Associação Brasileira de Proteína Animal, em 2014 os principais estados exportadores de carne suína foram Santa Catarina (37,01%), seguido pelo Rio Grande do Sul (30,32%). O principal produto exportado foram cortes *in natura*, representando 82,65% das exportações de carne suína nesse ano. O Brasil hoje exporta carne suína para 89 países. Quanto ao histórico de exportações, o país tem se mantido na faixa entre 500 a 600 mil toneladas desde 2004.

O cenário para carne de frango ainda é mais favorável, pois a exportação de carne de frango tem apresentado crescimento contínuo desde 1996, quando o Brasil exportou 571 mil toneladas. Atualmente o Brasil exporta para 146 países, sendo que em 2014 os principais produtos exportados foram cortes *in natura* (54,13%) e frangos inteiros (34,87%).

Os principais estados exportadores estão localizados na região sul, sendo Paraná responsável por 32,21% das exportações, Santa Catarina por 24,45%, e Rio Grande do Sul 18,35% (ABPA,2015).

A produção de carne de aves iniciou no país na década de 50 (Penz Junior & Bruno), começou a migrar para o sistema de integração na década de 60 e teve grandes investimentos na década de 90 (Dambrós Junior, 2010). Essa alteração de sistema de produção é decorrente dos processos de urbanização, crescimento de renda, maior disponibilização de tecnologias e globalização, fatores que conduzem as cadeias produtivas a uma maior coordenação vertical por agentes privados a fim de atender as demandas de mercados cada vez mais diferenciados (Zylbersztajn & Farina,1999).

A suinocultura no Brasil também teve seu crescimento estimulado pela inovação tecnológica nas áreas de sanidade, manejo, genética e nutrição. Os investimentos na área de nutrição e genética dos suínos foram realizados objetivando melhoria da eficiência e lucratividade da produção, com desenvolvimento de linhagens de suínos que produzem mais carne e menos gordura a fim de se adequar às preferências dos consumidores por carnes com esse perfil (Cosser, 2010).

Os setores de avicultura e suinocultura no Brasil atualmente funcionam por meio de sistemas de integração, o que garante a competitividade desses produtos no mercado internacional. Nesse sistema, o as agroindústrias (integradores), são responsáveis por fornecer os animais, insumos, alimentação e assistência técnica, enquanto que o os produtores (integrados) devem arcar com a infraestrutura física e o manejo dos animais, devendo comercializar todos os animais no período de encerramento do ciclo produtivo com o integrador. O modelo de integração é vantajoso para os integradores por possibilitar a obtenção de matéria-prima a um custo menor do que por produção própria e para os integrados, devido a proporcionar maior segurança em relação a constância da produção, garantia de escoamento da produção, acesso mais fácil a crédito e inovações tecnológicas (Brasil, 2014c).

A qualidade das carnes de aves e suínos do Brasil se deve ao empreendedorismo das agroindústrias e da disponibilidade de terras e água, alta produção de grãos e alta incidência solar do país. (Brasil, 2014c). Todos esses fatores permitiram que o país alcançasse essa posição de destaque na produção e exportação de carne de frango e suíno

no mercado internacional, na qual se mantém até hoje.

1.2.2 Segurança Alimentar

No Brasil, desde os tempos coloniais, havia uma preocupação por parte dos governantes com a alimentação da população. Essa preocupação termina por se transformar em políticas públicas a partir do século XX, com a emergência dos movimentos sociais contra a carestia. As políticas implementadas desde o início do século passado abrangiam diversos itens como a política agrícola, os sistemas de abastecimento, controle de preços, distribuição de alimentos etc. Em 1996 o governo brasileiro, juntamente com outra centena de países, passou a olhar esse conjunto de políticas dentro de um esforço geral para a redução da situação de fome em seus territórios. Reunidos na Cúpula Mundial da Alimentação, em Roma, diversos dirigentes de países – entre eles o Brasil – firmaram um compromisso de reduzir pela metade o número de pessoas famintas até 2015. Essa mudança fundamental na forma de encarar o direito à alimentação e o compromisso internacional de redução das estatísticas relacionadas com a fome colocam o Estado na posição de provedor e responsável pelo bem estar alimentar de sua população (Belik, 2003).

A segurança alimentar como um conceito surgiu apenas em meados dos anos 1970, nas discussões dos problemas internacionais de alimentos em um momento de crise global de alimentos. O foco inicial de atenção foi principalmente em problemas de abastecimento de alimentos - de assegurar a disponibilidade e até certo ponto a estabilidade dos preços dos alimentos básicos em nível internacional e nacional. Este conceito foi sendo aprimorado nas seguintes Cúpulas Mundiais de Alimentação, e, em 2001, foi refinado para: "Segurança alimentar é uma situação que existe quando todas as pessoas, em todos os momentos, têm acesso físico, social e econômico a uma alimentação suficiente, segura e nutritiva que atenda às suas necessidades dietéticas e preferências alimentares para uma vida ativa e saudável " (FAO, 2003).

No Brasil, de acordo com documento aprovado na II Conferência Nacional de Segurança Alimentar e Nutricional, e incorporado na Lei Orgânica de Segurança Alimentar e Nutricional – LOSAN (Lei Nº11.346, de 15 de julho de 2006), o conceito de segurança alimentar e nutricional envolve questões de acesso a alimentos de qualidade, práticas alimentares saudáveis, práticas sustentáveis de produção, cidadania e direitos

humanos, passando a ser definido como: “a realização do direito de todos ao acesso regular e permanente a alimentos de qualidade, em quantidade suficiente, sem comprometer o acesso a outras necessidades essenciais, tendo como base práticas alimentares promotoras de saúde, que respeitem a diversidade cultural e que sejam social, econômica e ambientalmente sustentáveis” (Keppeler & Correa, 2011).

O conceito de segurança alimentar, em inglês Food Security, muitas vezes é confundido com o conceito de segurança do alimento, em inglês Food Safety, tendo em vista a similaridade dessas palavras em muitas línguas, no entanto os conceitos são bem distintos. A segurança dos alimentos consiste em uma parte da segurança alimentar e está mais relacionada a qualidade dos alimentos (Araújo, 2007).

Segurança dos alimentos consiste na garantia de que um alimento não causará dano ao consumidor, seja através de perigos químicos físicos ou biológicos, quando preparado e consumido conforme o uso recomendado (Codex Alimentarius, 2003).

Ainda segundo o Codex Alimentarius, os alimentos são geralmente considerados seguros, desde que seja tomado cuidado durante o desenvolvimento, a produção primária, processamento, armazenamento, manuseio e preparação; para lidar com riscos químicos, como resíduos de agrotóxicos, contaminantes, aditivos alimentares e auxiliares tecnológicos, a análise de risco já é usada a bastante tempo para tratar os riscos químicos e está sendo cada vez mais utilizada para tratar os riscos microbiológicos e fatores nutricionais (Codex Alimentarius, 2003).

Os sistemas de produção modernos devem ser projetados para assegurar que os alimentos produzidos não representam risco à saúde humana (Codex Alimentarius, 2009). A segurança dos alimentos é responsabilidade de todos os envolvidos na cadeia produtiva, desde a produção até o consumo do alimento (Brasil, 2014d).

1.2.3 Análise de Risco em alimentos

Existem muitas substâncias químicas que podem causar eventos adversos em seres humanos ou animais a eles expostos. Essas substâncias, no contexto de análise de risco, representam perigos, ao passo que, a probabilidade de ocorrência desses perigos é denominada risco (Gehring et al., 2006).

A Análise de Risco consiste em um processo formado por em três componentes: avaliação, gestão e comunicação de risco (Codex Alimentarius, 2007).

A avaliação de risco é um processo de base científica que compreende os procedimentos realizados para estimar a probabilidade de que os seres humanos ou sistemas ecológicos serão prejudicados por um agente químico sob um conjunto específico de condições. O objetivo das avaliações de risco é fornecer informação abrangente ainda objectivo de gerentes de risco, os decisores políticos e reguladores, para que eles possam tomar as melhores decisões possíveis (Paustenbach, 2002). As subetapas dessa etapa são: identificação do perigo, caracterização do perigo, avaliação da exposição, e caracterização do risco (Codex Alimentarius, 2007).

A gestão de riscos é um processo no qual são consideradas as informações de natureza política, social e econômica, além dos resultados da avaliação de riscos para definir regulamentação adequada a um potencial perigo para a saúde (Paustenbach, 2002), a partir da ponderação em consulta as partes interessadas (Codex Alimentarius, 2007). No que se refere aos medicamentos e aditivos veterinários, essa etapa inclui o desenvolvimento de valores de segurança nos alimentos, definição de períodos de carência dos medicamentos em animais que produzem carne, leite, ovos e outros alimentos após terapia com esses medicamentos e monitoramento de resíduos nesses alimentos (Gaylor et al., 1998) .

A comunicação de risco consiste na troca interativa de informações e opiniões durante o processo de análise de risco, sendo essas informações fatores relacionados com riscos e percepção do risco, trocadas entre avaliadores e gestores dos riscos, consumidores , indústria, comunidade acadêmica e outras partes interessadas, incluindo a explicação de risco resultados da avaliação e com base em decisões de gestão de risco. O objetivo global da análise de risco aplicada à segurança dos alimentos é assegurar a proteção da saúde dos consumidores e a promoção de práticas de comércio justo (Codex Alimentarius, 2007).

1.2.4 Resíduos e contaminantes em alimentos de origem animal

Medicamentos veterinários utilizados em animais de produção possuem fins terapêuticos ou profiláticos, podendo ser administrados via alimento ou via bebida e consistem em diferentes tipos de substâncias (McEvoy, 2002). Esses medicamentos podem deixar resíduos em alimentos, quando utilizados de forma inadequada na produção animal. Outras substâncias que podem contaminar esses alimentos são os contaminantes ambientais que porventura entrem na cadeia produtiva desses animais (Junior et al., 2012).

O uso adequado de antibióticos na produção de aves permite disponibilidade de carne de alta qualidade a um custo acessível ao consumidor, isso porque essas substâncias aumentam a eficiência da conversão alimentar e reduzem a incidência de doenças nesses animais. Entretanto, existe a possibilidade de resíduos desse e outros medicamentos permanecerem na carne quando são utilizados de forma inadequada, seja por descumprimento das instruções da bula, seja por uso de medicamentos ilegais, seja pelo uso de medicamentos aprovados para outra espécie animal (Donughue, 2003).

Os prejuízos que essas substâncias podem trazer à saúde, quando presentes em concentrações altas, são diversos, como por exemplo: intoxicações que causam náuseas, tremores e dores de cabeça, a partir da ingestão de resíduos de clenbuterol em carne de carneiros e bovinos (Barbosa *et al*, 2005 *apud* Reig & Toldrá, 2007); reações alérgicas ou resistência bacteriana a partir do consumo de resíduos de antibióticos (Butaye, Devriese & Haesebrouck, 2001 *apud* Reig & Toldrá, 2007); alterações na flora intestinal a partir da sensibilização por resíduos de antibióticos (Vollard & Clasener, 1994 *apud* Reig & Toldrá, 2007); desenvolvimento de cancer hormônio-dependente a partir do consumo de carne bovina com hormônios (EFSA 2007 *apud* Reig & Toldrá, 2007).

Entre as substâncias que podem estar presentes nos alimentos estão os contaminantes naturais, como as micotoxinas, contaminantes ambientais, como praguicidas ou dioxinas (McEvoy,2002)

Micotoxinas são produzidas por fungos presentes nos alimentos, principalmente vegetais, que podem contaminar as plantas durante sua produção, processamento, coleta ou armazenamento (Adami, 2000 et al., *apud* McEvoy, 2002) e os animais a partir da ingestão de rações, outros alimentos ou água contaminados. As micotoxinas mais importantes em relação à saúde pública com as aflatoxinas e a ocratoxina

A (McEvoy, 2002). As aflatoxinas, em especial a aflatoxina B1, podem causar câncer em humanos (Adami, 2000 et al., *apud* McEvoy,2002).

Dioxinas são contaminantes persistentes lipofílicos (Guruge, 2004), que podem estar presentes em solo, água, ar, sedimentos, animais e vegetação, a partir de processos de combustão e outros processos químicos industriais (Fiedler,1997). Foram relatados surtos de contaminação de alimentos de origem animal, como carne de suínos, frango, leite e ovos, com essa substância na Bélgica, em 1999, a partir da queima de óleo, o que afetou várias fazendas produtoras neste país (Bernard et al.,2002 *apud* McEvoy,2002). Também há relato de casos de premix utilizado em rações animais contaminado com essa substância e exportados dos EUA para o Brasil, em 2002 (Sanco, 2002 *apud* McEvoy,2002).

Medicamentos veterinários em produção animal geralmente são administrados via alimentação ou água de bebida em sistemas de produção intensiva como de aves e suínos. A presença desses medicamentos em doses excessivas nas rações animais pode ser prejudicial tanto para os animais quanto para os consumidores da carne desse animal. Os efeitos prejudiciais para os animais podem ocorrer se o medicamento possui uma baixa margem de segurança entre espécies diferentes ou se possui reação cruzada com outros medicamentos. Para os homens, resíduos dos medicamentos veterinários em doses excessivas (acima de seus LMRs) podem causar problemas de saúde ou fazer com que desenvolvam resistência a antibióticos. (Anadon & Martinez-Larranaga, 1999 *apud* McEvoy,2002).

Os cocidiostáticos ionóforos (monensina, lasalocida, narasina e semduramicina), amplamente utilizados no controle de coccidiose em aves, possuem estreita margem de segurança e podem provocar miocardiopatias e lesão muscular em espécies animais mais sensíveis (McEvoy,2002).

Ractopamina é um β -agonista utilizado como promotor de crescimento. Seu uso é autorizado em mais de 20 países, no entanto, alguns países como União Europeia e China proíbem sua utilização (Thompson et al.,2007). Seu mecanismo de ação diminui a espessura de toucinho e aumenta a porcentagem de carne magra, por meio da redução da síntese e deposição de gordura subcutânea (Cantarelli et al, 2009) e do aumento da síntese de proteínas (Schinkel et al, 2003).

Sulfonamidas são antimicrobianos de amplo espectro de ação, utilizados no

tratamento de diversas espécies animais, podendo ser administrado via parenteral, intramamária ou via ração. Clortetraciclina é utilizado em aves e suínos para o tratamento de doenças respiratórias, também podendo ser administrado via água, porém geralmente é acrescentado à ração animal (Bishop, 1996, *apud* McEvoy,2002).

Nicarbazina é um medicamento veterinário (coccidiostático químico) administrado via ração, amplamente utilizado no controle de coccídios em frangos de corte. (Peebles et al., 2012).

Nitrofuranos e Cloranfenicol são antimicrobianos de amplo espectro que tiveram seu uso banido em alguns países devido à sua relação com carcinogenicidade (Kennedy, 2003). Na Europa foram banidos em 1993, através de sua inclusão no Anexo IV do Council Regulation 2377/90/EEC (Barbosa et al., 2011) e no Brasil, em 2003, por meio da Instrução Normativa nº 9, de 27 de junho de 2003 (BRASIL, 2003).

1.2.5 Monitoramento de Resíduos e Contaminantes no Mundo

No sistema europeu de segurança alimentar, a avaliação de riscos para monitoramento de resíduos em alimentos é feita pela EFSA, que produz pareceres científicos e orientações para fornecer uma base sólida para as políticas e legislação europeias e apoiar a Comissão Europeia, o Parlamento Europeu e os Estados-Membros da UE em tomar decisões eficazes e oportunas de gestão de risco. A EFSA é responsável também por fazer a gestão do risco, tendo como compromisso fornecer aconselhamento objetivo e independente baseado na ciência, bem como a comunicação do risco, fornecendo informações eficazes, consistentes, precisas e oportunas a todos os interessados e ao público em geral, com base nas avaliações de risco e conhecimento científico do Comité Científico da Autoridade e Painéis. Por fim, a EFSA também realiza pesquisas quanto à percepção dos riscos alimentares por parte dos consumidores (EFSA, 2010). A definição dos LMRs, essencial para licenciamento de medicamentos veterinários na União Europeia, é de competência do Comitê dos Medicamentos Veterinários (CVPM), que faz parte da Agência Europeia de Avaliação de Medicamentos (EMA), conforme disposições do Regulamento 2377/90/EEC (Anon, 1990, *apud* McEvoy,2002). O Food Veterinary Office - FVO, trabalha para garantir sistemas de controle eficazes e avaliar a conformidade com os padrões da União Europeia nas áreas de segurança alimentar e de alimentação, saúde animal, bem-estar animal e da fitossanidade. Esse trabalho é realizado principalmente através da realização de inspeções e

auditorias nos Estados-Membros (European Commission, 2014). De acordo com a Diretiva 96/23/EC, todos os estados membros da União Europeia devem monitorar resíduos de medicamentos veterinários que possuem LMR definido; substâncias de uso proibido na produção de animais e, portanto, não têm LMR definido, como medicamentos veterinários banidos, hormônios e promotores de crescimento; contaminantes ambientais, como metais pesados, micotoxinas e pesticidas; aditivos zootécnicos. Quando são identificadas violações, são iniciadas imediatamente ações de investigação (McEvoy, 2002).). Ademais, a União Europeia possui um Sistema de Alerta Rápido, *Rapid Alert System for Food and Feed (RASFF)*, instituído em 1979 e regulamentado em 2002, para informar aos países membros quando são identificados resíduos de substâncias que representam risco para a saúde pública em produtos importados de países terceiros (Kennedy, 2003).

Nos Estados Unidos, a Food and Drug Administration (FDA) é a agência reguladora responsável pela aprovação de antibióticos e outros medicamentos veterinários, tendo também responsabilidade quanto a vigilância do uso correto desses medicamentos na produção animal, esta última compartilhada com o United States Department of Agriculture (USDA). O FDA realiza avaliação de risco dos medicamentos veterinários a partir dos dados fornecidos por fabricantes dessas substâncias, para analisar a segurança desses medicamentos, também quanto a possibilidade de deixar resíduos em alimentos que serão destinados a consumo humano. Ademais, para realizar monitoramento de uso dessas substâncias, O FDA e o USDA têm programas em que são analisadas amostras de aves para diversas substâncias que podem estar presentes na cadeia produtiva desse animal e, a partir da identificação de níveis inadequados dessas substâncias, são adotadas medidas corretivas, para evitar a recorrência dessas não-conformidades, medidas que variam de acordo com a severidade da não conformidade, indo desde a orientação até a prisão do responsável (Donoghue, 2003).

Internacionalmente, procedimentos de avaliação do risco são conduzidos pelos comitês científicos da Organização Mundial de Saúde - OMS e Organização para Alimentação e Agricultura, Food and Agriculture Organization – FAO, para subsidiar o estabelecimento de padrões alimentares pelo Codex Alimentarius. (WHO 2007 *apud* Jardim e Caldas, 2009). O JECFA - Joint FAO/WHO Expert Committee on Food Additives, avalia questões relativas a aditivos alimentares, contaminantes e drogas veterinárias e o JMPR - Joint FAO/WHO Meeting on Pesticide Residues aquelas relacionadas a resíduos de

pesticidas (Jardim e Caldas, 2009).

1.2.6 Monitoramento de Resíduos e Contaminantes no Brasil

No Brasil, definição dos LMR's é competência da ANVISA e o monitoramento desses resíduos é competência do Ministério da Agricultura, Pecuária e Abastecimento, que instituiu o monitoramento oficial de resíduos de produtos veterinários e contaminantes em carnes por meio da publicação da Instrução Normativa n° 86, de 26 de janeiro de 1979 (Brasil, 1979) e o regulamentou por meio da publicação da Instrução Normativa n°42, de 20 de dezembro de 1999 (Brasil, 1999).

O PNCR é subdividido em programas setoriais, de acordo com a origem e objetivo das análises. Sendo eles: Subprograma de Monitoramento, no qual são analisadas as amostras para monitoramento de resíduos de substâncias de interesse nacional objetivando gerar as informações sobre a frequência, níveis e distribuição dos resíduos no país, ao longo do tempo, a amostragem é anual e aleatória; Subprograma Exploratório, em que são podem ser realizadas análises para se estudar a ocorrência de resíduos de substâncias para as quais não há limites máximos de resíduos estabelecidos, pode ter uma amostragem aleatória ou dirigida, seus resultados não levam a ações regulatórias; Subprograma de Investigação, que é iniciado a partir de violações identificadas no Subprograma de Monitoramento ou de denúncias de uso de substâncias de uso proibido e que consiste na intensificação de amostragem dirigida da propriedade de origem dos animais que geraram a referida violação ou denúncia até que não ocorram mais violações consecutivas nessa propriedade e investigação das causas dessa violação; Subprograma de Controle de Produtos Importados, no qual está prevista a análise de resíduos e contaminantes em alimentos importados pelo Brasil (BRASIL, 1999).

O escopo analítico do Subprograma de monitoramento do PNCR é publicado anualmente no Diário Oficial da União, com informações quanto à quais substâncias e quantas amostras serão analisadas nesse período. A amostragem do PNCR tem é definida com base na metodologia recomendada pelo Codex Alimentarius sendo este um modelo estatístico de distribuição binomial (Codex Alimentarius, 2009). As amostras são coletadas em estabelecimentos sob Inspeção Federal, selecionados aleatoriamente por meio de um Sistema Informatizado. As coletas são realizadas por funcionários do governo e são analisadas em laboratórios da Rede de Laboratórios Agropecuários, composta por

laboratórios oficiais e laboratórios privados credenciados no MAPA, com recursos públicos. Ao final do cumprimento do escopo anual programado, os resultados de monitoramento são publicados no Diário Oficial da União (Brasil, 1999).

Este Plano está alinhado com as recomendações de várias agências de segurança alimentar internacionais e com os princípios de análise de risco recomendados pelo Codex Comitê Alimentarius/FAO/OMS (IDF, 2013), monitorando substâncias que representam risco à saúde pública, bem como substâncias que provocam restrições comerciais, tais como Dioxinas, subprodutos não intencionais de processos químicos, principalmente os de combustão (Malisch e Kot, 2014), e Ractopamina, um beta-adrenoreceptor usado na fase de terminação de suínos que é aprovado para uso em vários países (FAO, 2004), respectivamente.

1.2.7 Aprendizagem de Máquina

O aumento da capacidade de coletar, transportar e armazenar dados dos sistemas de computação que tem sido intensificado nas últimas décadas, fenômeno conhecido como *Big Data*, gerou a necessidade de desenvolvimento e aprimoramento de técnicas e ferramentas que permitam a avaliação dessa grande massa de dados (Jordan & Mitchell, 2015).

Já no fim da década de 80 e início da década de 90 era utilizado, para avaliação de dados, o processo de descoberta do conhecimento de bases de dados, do inglês *Knowledge Discovery in Databases* – KDD (Coenen, 2011), que pode ser definido como o processo não trivial de descoberta de informações válidas e potencialmente úteis que estavam ocultos nos dados (Fayyad et al., 1996).

O processo global de KDD possui algumas etapas, sendo essas: seleção, pré-processamento, transformação, mineração e avaliação/interpretação dos dados (Widener, 1996).

A Mineração de dados, em inglês *data mining*, pode ser definida como um conjunto de mecanismos e técnicas realizadas com a utilização de *softwares*, para extrair informações ocultas nos dados, consistindo na aplicação da tecnologia Aprendizagem de Máquina e da estatística para obtenção dessas informações (Coenen, 2011).

Aprendizagem de máquina oferece uma grande quantidade de algoritmos estatísticos para mineração, análise e previsão de dados. Estas incluem várias técnicas como mineração de regras por associação, árvores de decisão, regressão, máquinas de suporte vetorial e outras técnicas de mineração de dados (Upadhyaya, 2012). Esses métodos podem ser

simples ou complexos, desde regressões lineares até redes neurais com centenas de neurônios (Lima, 2015). Na Tabela 1 estão listados alguns tipos de algoritmos utilizados na aprendizagem de máquina e algumas de suas características.

Os modelos de aprendizagem de máquina podem ser paramétricos ou não paramétricos. Os primeiros assumem que há um formato de curva pré-definido para a predição, resultado da avaliação dos dados, já os últimos mapeiam os dados de entrada e de saída, porém não pressupõem um formato de curva para a predição (Jordan, 2015).

Problemas de predição podem ser divididos em duas categorias: classificação e regressão. Na classificação, os parâmetros a serem preditos são binários, enquanto na regressão, o parâmetro é um número real. Classificação refere-se a um problema de atribuir uma dada amostra em uma ou duas (e ou mais) categorias baseadas em várias medidas. Aplicações típicas incluem predição em que se espera uma resposta binária (sim ou não). Regressão refere-se a um problema de predição de um número real. A palavra regressão é potencialmente uma fonte de confusão. Em matemática, regressão essencialmente significa ajuste de curva (Vidyasagar, 2015).

Por fim, é relatado na literatura que os algoritmos de aprendizagem de máquina podem ser classificados em supervisionados ou não supervisionados. O primeiro caso ocorre quando os algoritmos recebem um conjunto de dados de treinamento já rotulados e conseguem realizar predições para os dados que não possuem rótulo a partir da associação das características dos dados com seus rótulos. O segundo caso ocorre quando os algoritmos trabalham com dados que não possuem rótulos e os agrupam em categorias (Mohr et al., 2012).

Tabela 1. Tipos de algoritmos (Brink et al., 2013)

Nome	Tipo	Parametrização
Regressão Linear	Regressão	Paramétrico
Regressão Logística	Classificação	Paramétrico
SVM	Classificação/Regressão	Não Paramétrico
SVM com Kernel	Classificação/Regressão	Não Paramétrico
K Vizinhos mais Próximos	Classificação/Regressão	Não Paramétrico
Árvores de Decisão	Classificação/Regressão	Não Paramétrico
Floresta Randômica	Classificação/Regressão	Não Paramétrico
Boosting	Classificação/Regressão	Não Paramétrico
Rede Neural	Classificação/Regressão	Não Paramétrico

1.2.7.1 Árvore de Decisão

Árvore de Decisão é um dos algoritmos de classificação mais comuns usado na

mineração de dados. Algoritmos para a construção de árvores de decisão estão entre os métodos de aprendizagem de máquina mais conhecidos e utilizados (Salzberg, 1993). Isso ocorre devido à sua representação gráfica, que torna mais fácil sua interpretação e utilização para processos de classificação (Stiglic et al., 2012). Sua representação gráfica consiste em uma árvore em que cada ramo consiste nas escolhas e cada folha consiste na decisão ou resposta (Saini & Rajavat, 2013). Para Kam, et al. (2009), árvore de decisão consiste em um “*método estatístico para se encontrar relação entre variáveis com base em probabilidades condicionais*”.

Além da função de classificação, que se busca identificar classes bem definidas no conjunto de dados, segundo Murthy (1998), a árvore de classificação pode explorar um conjunto de dados também com as seguintes funções: descrição, quando se procura reduzir o volume de dados, obtendo um resumo preciso dos mesmos e generalização, em que se pretende obter um mapeamento a partir de variáveis independentes que possibilite prever o valor de variáveis dependentes futuramente.

Salzberg (1994) relatou que as árvores de decisão iniciam com um conjunto de casos ou exemplos a partir dos quais passa a classificar novos casos, sendo que cada nó da árvore de decisão possui um teste, que é utilizado para decidir o ramo a partir desse nó.

Os primeiros modelos de árvore de decisão elaborados datam da década de 1960 e são muito semelhantes aos modelos atualmente utilizados (Saini & Rajavat, 2013). A utilização desse algoritmo é muito vasta, sendo utilizada em diversas áreas de conhecimento. Como exemplo de algumas áreas de pesquisa nas quais foram utilizadas árvore de decisão tem-se: identificação de preditores eficazes no tratamento de ovulação (Zhang et al., 2010), avaliação de perfil de consumidor para elaboração de estratégia de marketing (Saini & Rajavat, 2013), manutenção de asfalto em rodovia (Kang et al, 2009).

A construção de uma árvore de decisão consiste em duas principais etapas: crescimento e poda (Kotsiantis, 2014). Durante a fase de crescimento os dados vão sendo classificados de acordo com o teste realizado em cada nó da árvore, de acordo com as características comuns que possuem, e recebem rótulo em que cada folha da árvore, que consiste no resultado de saída de cada dado. Um dado é classificado de forma errada se o valor de saída do dado não corresponde ao rótulo correto do dado. A proporção de dados classificado corretamente por uma árvore é conhecida como sua *acurácia* enquanto que a proporção de dados classificados de forma incorreta consiste no *erro* da árvore. A poda consiste na remoção dos ramos que não estão contribuindo de forma significativa para a precisão da generalização

da árvore de decisão, essa etapa é realizada posteriormente a fase de crescimento da árvore (Murthy, 1998).

A definição adequada do número de casos mínimo para construção de ramos e o nível de confiança para poda é importante para que a árvore apresente uma taxa de precisão adequada na classificação dos dados de treinamento e dos dados de teste. Se o número de casos mínimo é muito pequeno, a árvore pode ficar muito grande, possuindo ramos que apresentem ruídos, apresentar uma boa taxa de precisão nos dados de treinamento, mas uma precisão ruim nos dados de teste, problema conhecido como *overfitting*. Porém se o número de casos mínimo for muito grande, a árvore pode ficar pequena e apresentar uma taxa de precisão ruim nos dados de treinamento e melhor nos dados de teste. É difícil definir o conjunto certo de características para que seja feita uma boa classificação. A abordagem mais comum é a coleta do maior número de dados antes da fase de modelagem de dados, no entanto para a maioria dos problemas de classificação padrão, definir um pequeno conjunto de dados é necessário para uma classificação adequada (Lin & Chen, 2011). Entre os algoritmos que podem ser utilizados para a elaboração de uma árvore de decisão o "ID3" e seu sucessor, o "C4.5" são os mais os mais populares (Salzberg, 1994).

1.2.7.1.1 Algoritmo C4.5

O algoritmo C4.5 possui um método aperfeiçoado de poda, que diminui os erros de classificação devido ao ruído e pelo excesso de detalhes no conjunto de dados de treinamento (Dudde & Apte, 2014). Foi desenvolvido por Quinlan em 1993, mesmo desenvolvedor do algoritmo ID.3 (Saini & Rajavat, 2013).

A forma de atuação desse algoritmo consiste na estratégia “dividir e conquistar”, em que inicialmente todos os dados estão associados à raiz da árvore com o mesmo peso para cada dado. A cada teste realizado, novos nós são formados, sendo cada nó associado a um conjunto de dados que possuem características e peso em comum. Esse algoritmo não permite rearranjo dos nós, apenas podas para eliminação dos ruídos. O ganho de informação é calculado com base no número de casos para cada nó. O erro de um nó consiste na soma dos erros de seus nós filhos, ou seja, os nós que foram originados deste primeiro nó. Quando a soma do erro das nós filhos é superior ao erro de classificação, esses nós filhos são podados e o nó maior passa a ser um nó-folha, ou seja, finaliza o ramo com um resultado (Ruggieri, 2004).

1.2.6.1.2 *Software Yet Another Decision Tree (YADT)*

O *Software YADT*, utiliza o algoritmo C4.5 para a elaboração de árvores de Decisão, a partir de uma tabela contendo os dados de treinamento, uma tabela contendo os dados de teste e uma tabela contendo os metadados, ou seja, a descrição dos dados. É possível não utilizar uma tabela de dados para teste, neste caso, defini-se uma porcentagem dos dados da tabela de dados de treinamento para a etapa de teste. A descrição dos atributos consiste em três informações: nome do dado, tipo do dado e tipo da característica que o dado representa (Ruggieri, 2004). A Tabela 2 detalha os tipos de dados possíveis e os tipos de características de dados possíveis.

Tabela 2. Tipos de dados e características reconhecidos pelo *Software YADT* (Ruggieri, 2010)

	Nomenclatura	Definição
	Null	Sem valor
Tipo de dado	String	Cadeia de valor delimitada pelo separador
	Integer	Valor Inteiro
	Float	Valor de vírgula variável
	Ignore	Informação deve ser ignorada
Tipo de Característica	Discrete	Atributo discreto
	Continuous	Atributo Contínuo
	Wheights	Informação é utilizada para se ponderar os casos
	Class	Contém valores de classe

Há ainda duas informações que devem ser inseridas no *Software* para elaboração da árvore de decisão: número de casos mínimos para a criação de um novo caso e o valor de confiança necessário para a poda da árvore, dado em porcentagem (Ruggieri, 2004).

A árvore de decisão construída é exportada em três formatos: ".txt", ".xml" e em formato binário ".tree", sendo este último que este último formato apresenta a interface gráfica da árvore quando aberto com o *Software YADT* (Ruggieri, 2004).

1.2.8 Redes Neurais Artificiais

As redes neurais artificiais são estruturas de processamento de informações compostas por um grande número de pequenas unidades de processamento interligadas que

funcionam paralelamente umas as outras. Seu desenvolvimento foi inspirado na estrutura do cérebro humano (Husien & Badi, 2015).

1.2.8.1 SOM

O mapa de auto-organização SOM, do inglês *Self-Organizing Map*, também conhecido como mapa de Kohonen, (Mcmullen, 2001) é uma rede neural clássica de aprendizagem não supervisionada (Chen et al., 2014), cujos neurônios são organizados em uma estrutura 2D em que todos os neurônios processam todos os dados que entram na rede (Sinclair et al, 2013), ajustando seus pesos com base principalmente nas retroalimentações laterais. Dessa forma, não é necessário conhecimento prévio dos valores-alvo, sendo visíveis os aglomerados, ou *clusters*, formados por neurônios contendo dados com propriedades semelhantes (Kiang, 2001).

Essa rede neural tem a capacidade de transformar dados complexos e multi-dimensionais em clusters que podem ser interpretados visualmente, tendo sido inspirado no mapeamento neurológico que as impressões sensoriais provocam nos humanos, transformando estímulos em conexões bidimensionais entre neurônios no cérebro (Kohonen 1984, 1989, 1995, *apud* Kiang, 2001).

É um algoritmo bastante utilizado em processamento de dados de vídeo, para reconhecimento de som e imagem (Chen et al., 2014), tendo como duas de suas principais características a redução da dimensionalidade dos dados com manutenção da topologia de sua rede, já que seus neurônios não apresentam deslocamentos na rede. Na mineração de dados o SOM é amplamente utilizado para a visualização das informações ocultas nos dados. (Ramos et al.,2012).

Nas análises por clusters objetiva-se identificar características semelhantes em dados por meio de seu agrupamento. A utilização de redes neurais SOM permite a visualização desses agrupamentos em mapas bidimensionais por meio da construção de mapas em tamanhos correspondentes ao número desejado de aglomerados, ou seja, um mapa 2x2 possui quatro nós, que devem formar quatro grupos distintos. Quando o número de nós é diferente do número de aglomerados é necessária realização de outras análises para avaliar o mapa mais profundamente (Kiang, 2001).

O SOM não funciona em ambientes incrementais, isso ocorre porque seus parâmetros de aprendizagem são os mais altos no início da etapa de treinamento e vão diminuindo até que se estabilizam de acordo com a topografia desses dados (Shah- Hosseini &

Safabaksh, 2003).

1.2.8.2 TASOM

A rede neural TASOM, do inglês *Time Adaptative Self-Organizing* foi construída a partir da rede SOM, possuindo a capacidade de aprender em ambientes incrementais, ou seja, que possuem nova entrada de dados durante o treinamento. Esse aprendizado é possível devido à adaptação dos parâmetros de aprendizagem dos neurônios a cada nova entrada de dados (Shah-Hosseini & Safabaksh, 2003). Além de trabalhar em ambientes dinâmicos, essa rede neural também é capaz de aprender em ambientes estáticos (Sha-Hosseini, 2011).

CAPÍTULO II

RESUMO

Padrões temporais e espaciais na detecção de resíduos e contaminantes na produção de aves e suínos no Brasil

A segurança alimentar é um tema de grande relevância para a saúde pública e o comércio internacional de alimentos. Os resíduos de produtos veterinários e contaminantes ambientais em produtos de origem animal podem causar doenças em organismos expostos a estas substâncias em doses elevadas por um longo período de tempo. Este estudo avaliou dados de monitoramento oficiais de resíduos e contaminantes do Ministério da Agricultura, Pecuária e Abastecimento em tecidos de aves e suínos no período entre 2002 e 2014, a fim de verificar a existência de padrões ocultos nos dados. A análise dos dados foi realizada utilizando dois métodos de aprendizado de máquina: árvore de decisão e redes neurais, além de avaliação visual através de gráficos e mapas. No final do estudo, foi identificado um padrão de distribuição espacial das detecções de substâncias por região, e não foi observado padrão de distribuição temporal.

Palavras-chave: resíduos, aprendizagem de máquina, segurança do alimento, saúde pública.

ABSTRACT

Temporal and Spacial patterns in the detection of residues and contaminants in Poultry and Pork production in Brazil

Food Safety is an important topic for public health and international trade in food. Residues of veterinary products and environmental contaminants in animal products can cause diseases in organisms exposed to these substances in high doses for a long time. This study evaluated official monitoring data of residues and contaminants from the Ministry of Agriculture, Livestock and Supply in tissues of poultry and pork in the period between 2002 and 2014 to check for hidden patterns in the data. The analysis of data was performed by using two machine learning methods: decision tree and neural networks, in addition to visual evaluation through graphs and maps. At the end of the study, a spatial distribution pattern of detections of substances by region was identified, but no pattern of temporal distribution was observed.

Keywords: residues, machine learning, food security, public health.

INTRODUÇÃO

O Brasil tem papel de destaque no cenário internacional como produtor e exportador de produtos agropecuários, pois com apenas 20% de sua produção agropecuária sendo exportada, abastece mais de 180 países com esses produtos (Brasil, 2014a). No setor de aves e suínos esse cenário não é diferente. O Brasil exporta carne de frango para 146 países e carne suína para 89 países (ABPA, 2015).

A fim de zelar pela saúde pública e manter a confiança dos consumidores de aves e suínos domésticos e internacionais, são essenciais sistemas efetivos de segurança dos alimentos. As contaminações químicas e microbiológicas são as principais causas de doenças transmitidas por alimentos (Padula, 2014).

Dentre as contaminações químicas, resíduos de medicamentos veterinários e contaminantes ambientais que entram na cadeia produtiva podem causar efeitos adversos no organismo, como toxicidade aguda, reações alérgicas, efeitos reprodutivos e carcinogenicidade. Seu controle é realizado por meio da adoção de boas práticas agropecuárias, que mitigam o risco de essas substâncias estarem presentes em quantidades prejudiciais à saúde humana (Gehring et al., 2006).

O Brasil realiza o monitoramento de resíduos e contaminantes na produção animal desde 1986, quando foi instituído o Plano Nacional de Resíduos e Contaminantes pelo Ministério da Agricultura, Pecuária e Abastecimento. Esses dados são analisados ao final de cada ano para possibilitar a elaboração do plano de monitoramento do ano seguinte (Brasil,

1999).

A necessidade de decisões rápidas e assertivas em órgãos públicas e privados demanda o uso de ferramentas de tomada de decisão que podem auxiliar no processo decisório (Silva et al., 2008), demanda que pode ser atendida por meio da utilização de técnicas de mineração de dados.

MATERIAL E MÉTODOS

2.2.1 Origem dos dados - Plano Nacional de Controle de Resíduos - PNCR

Nesta pesquisa foram avaliados dados de monitoramento de resíduos de produtos veterinários e contaminantes ambientais em aves e suínos no âmbito do Plano Nacional de Controle de Resíduos e Contaminantes do MAPA.

Esse Plano, que foi instituído pela Portaria Ministerial nº 51, de 06 de maio de 1986 e adequado pela Portaria Ministerial nº 527, de 15 de Agosto de 1995, visa conhecer o potencial de exposição da população aos resíduos nocivos à saúde do consumidor e impedir o abate e comercialização para consumo de animais oriundos de estabelecimentos nos quais foram constatadas violações de Limites Máximos de Resíduos – LMR's e uso de drogas proibidas no território nacional (Brasil, 1999).

Os resíduos a serem monitorados são publicados anualmente no Diário Oficial da União por meio de uma Instrução Normativa, a qual detalha quais grupos de substâncias serão analisados para cada espécie, quantas amostras serão analisadas e qual o Limite de Referência utilizado para a análise de cada substância. Na Figura 1 há um detalhamento de parte do PNCR do ano de 2014.

ANEXO I

SUBPROGRAMAS DE MONITORAMENTO DE CONTROLE DE RESÍDUOS E CONTAMINANTES

QUADRO 1 – SUBPROGRAMA DE MONITORAMENTO DE CONTROLE DE RESÍDUOS E CONTAMINANTES EM CARNES – PNCR/2014

Grupo	Analito	Matriz	LIMITES DE REFERÊNCIA (µg/Kg)						Nº de amostras		
			Bovina	Equina **	Suína	Aves	Avestruz ***	Caprina / Ovina ***			
Antimicrobianos	Lincomicina	R	1500	1500	1500	500	--	--	B (510) A (485) S (510) E (2)**		
	Eritromicina		200	200	200	100	--	--			
	Tilosina		100	100	100	100	--	--			
	Neomicina		10000	5000	10000	10000	--	--			
	Estreptomina		1000	500	1000	1000	--	--			
	Espectinomicina		5000	5000	5000	5000	--	--			
	Dihidroestreptomina		1000	200	1000	1000	--	--			
	Kanamicina		2500	2500	2500	2500	--	--			
	Apramicina		20000	2000	2000	1000	--	--			
	Gentamicina		5000	500	5000	500	--	--			
	Tobramicina		500	500	500	500	--	--			
	Higromicina		500	500	500	500	--	--			
	Tilmicosina		300	1000	1000	600	--	--			
	Amicacina		500	500	500	500	--	--			
	Clindamicina		200	200	200	200	--	--			
	Ampicilina		50	50	50	50	--	--			
	Cefazolina		50	50	50	50	--	--			
	Oxacilina		300	300	300	300	--	--			
	Penicilina G		50	50	50	50	--	--			
	Penicilina V		25	25	25	25	--	--			
	Nitrofurazona- SEM		M	1 (III)	1 (III)	1 (III)	1 (III)	1 (III)		--	B (75) A (920) S (85) AZ(30) E (2)**
	Furazolidona- AOZ			1 (III)	1 (III)	1 (III)	1 (III)	1 (III)		--	
	Furaltadona- AMOZ			1 (III)	1 (III)	1 (III)	1 (III)	1 (III)		--	
Nitrofurantoina- AHD	1 (III)	1 (III)		1 (III)	1 (III)	1 (III)	--				
Florfenicol	M	200	--	200	--	--	--	B (75) A (75) S (75) AZ(30) E (2)**			
Cloranfenicol		0,30(III)	0,30(III)	0,30(III)	0,30(III)	0,30(III)	--				
Tianfenicol**		50	--	50	--	--	--				

Figura 1. Parte das substâncias avaliadas no PNCR 2014 (Brasil, 2014b).

As substâncias analisadas no âmbito do PNCR podem ser prejudiciais à saúde humana apenas quando presentes em grandes concentrações nos alimentos, o valor de concentração a partir do qual essas substâncias passam a ser nocivas é chamado de Limite de Tolerância, Limite de Segurança ou Limite Máximo de Resíduo – LMR (Brasil, 1999b). Os Limites de Referência utilizados nas análises do PNCR são adotados pelo MAPA com base nos limites determinados pela Agência Nacional de Vigilância Sanitária – ANVISA (Brasil, 1999a) quando existentes, e os sugeridos pelo Codex Alimentarius para as outras substâncias. Esses limites são definidos com base em estudos toxicológicos realizados em instituições com idoneidade científica, analisados pelo Joint FAO/WHO Expert Committee on Food Additives (JECFA) e recomendados pelo Codex Alimentarius, ficando a critério de seus países signatários sua adoção (Brasil, 1999b).

As amostras coletadas são determinadas por sorteio semanal realizado por meio do Sistema de Resíduos (SISRES), sistema que distribui as amostras aleatoriamente, entre os estabelecimentos com registro no Serviço de Inspeção Federal (SIF). A coleta das amostras é feita de acordo com as instruções do Manual de coleta de amostras do Plano Nacional de Resíduos e contaminantes, que consiste na atualização dos procedimentos de coleta descritos na IN 42 de 1999.

As análises são realizadas em laboratórios da Rede Oficial, com utilização de métodos de análise de *High-performance liquid chromatography* (HPLC) e as amostras são rastreáveis por meio de Sistema de Informações Gerenciais para Laboratórios de Resíduos e Contaminantes em Alimentos (SIGLA), que é interligado ao SISRES.

Os resultados de não conformidades, que consistem nos resultados das análises que ultrapassaram os LMRs são publicados anualmente no Diário Oficial da União por meio de Instrução Normativa, na qual são detalhados os resultados de não conformidades por grupo de substância para cada espécie e é apresentada a porcentagem de resultados conformes do Plano.

2.2.2 Descrição dos dados

Para esse estudo foram utilizados os dados de detecção de resíduos e contaminantes do PNCR nas espécies aves e suínos no período compreendido entre janeiro de 2002 e outubro de 2014. Esses dados foram obtidos por meio do download a partir da base de dados do Sistema SISRES, com autorização formalizada do Ministério da Agricultura, Pecuária e Abastecimento, por meio do Ofício CRC/SDA nº 11/2013.

Na primeira etapa deste estudo, que consiste na análise dos dados por aprendizagem de máquina, foram utilizados resultados de análise de todas as substâncias analisadas no âmbito do PNCR para as cadeias de aves e suínos no período entre janeiro de 2002 e outubro de 2014. Cada resultado de análise está correlacionado às informações que permitem a rastreabilidade das amostras, sendo essas informações referentes ao período em que as amostras foram coletadas e ao local em que essa coleta ocorreu. Dessa forma, foram exportados da base de dados do SISRES para o Excel os dados distribuídos nas categorias listadas na Tabela 1.

Tabela 1. Dados do SISRES

NOME DADO	DESCRIÇÃO DADO
CÓDIGO RESÍDUO	CÓDIGO REFERENTE À SUBSTÂNCIA ANALISADA
UF	UNIDADE DA FEDERAÇÃO
CÓDIGO ESPÉCIE	CÓDIGO DE INDICA A ESPÉCIE AMOSTRADA PARA REALIZAÇÃO DA ANÁLISE
SIF	NÚMERO REGISTRADO NO SERVIÇO DE INSPEÇÃO FEDERAL DO ESTABELECIMENTO NO QUAL FOI COLETADA A AMOSTRA
SEMANA ANÁLISE	SEMANA EM QUE OCORREU A ANÁLISE
TECIDO	TECIDO DO QUAL FOI COLETADA A AMOSTRA: RIM, FÍGADO, GORDURA OU URINA
PROPRIETÁRIO	NOME DO PROPRIETÁRIO DA PROPRIEDADE DE ORIGEM DO(S) ANIMAI(S) DO(S) QUAL(IS) FOI COLETADA A AMOSTRA PARA ANÁLISE
ENDEREÇO PROPRIETÁRIO	ENDEREÇO DO PROPRIETÁRIO DA PROPRIEDADE DE ORIGEM DO(S) ANIMAI(S) DO(S) QUAL(IS) FOI COLETADA A AMOSTRA PARA ANÁLISE
PROPRIEDADE	NOME DA PROPRIEDADE DE ORIGEM DO(S) ANIMAI(S) DO(S) QUAL(IS) FOI COLETADA A AMOSTRA PARA ANÁLISE
ENDEREÇO PROPRIEDADE	ENDEREÇO DA PROPRIEDADE DE ORIGEM DO(S) ANIMAI(S) DO(S) QUAL(IS) FOI COLETADA A AMOSTRA PARA ANÁLISE
CÓDIGO DO MUNICÍPIO	CÓDIGO DO MUNICÍPIO DE LOCALIZAÇÃO DO ESTABELECIMENTO DO QUAL FOI COLETADA A AMOSTRA
UF PROPRIEDADE	UNIDADE DA FEDERAÇÃO DA PROPRIEDADE DE ORIGEM DO(S) ANIMAI(S) DO(S) QUAL(IS) FOI COLETADA A AMOSTRA PARA ANÁLISE
NOME MUNICÍPIO	NOME DO MUNICÍPIO DE LOCALIZAÇÃO DO ESTABELECIMENTO DO QUAL FOI COLETADA A AMOSTRA
QUANTIDADE DE ANIMAIS	Nº DE ANIMAIS QUE COMPÕE O LOTE DE ANIMAIS DO(S) QUAL(IS) FOI(RAM) COLETADA(S) A(S) AMOSTRA(S)

SITUAÇÃO DA VIOLAÇÃO	AMOSTRA “CONFORME” OU “NÃO CONFORME”, DE ACORDO COM O STATUS 6 OU 7 DA ANÁLISE, RESPECTIVAMENTE
STATUS	STATUS DAS ANÁLISES REFERENTE AO RESULTADO DE ANÁLISE
CEP	CÓDIGO POSTAL DE LOCALIZAÇÃO DO ESTABELECIMENTO EM QUE FOI COLETADA A AMOSTRA
CEP 2	CÓDIGO POSTAL DO ENDEREÇO DO PROPRIETÁRIO
ANO	ANO EM QUE OCORREU A ANÁLISE

Os dados utilizados nessa pesquisa consistem não apenas nos resultados de análises que estão acima do LMR de cada substância, mas também nos resultados de análises que apresentaram valor igual a zero ou resultado entre zero e o LMR de cada substância. Para diferenciação desses resultados é utilizada a variável “Status de Análise”, cujo resultado está categorizado de acordo com a tabela 2, para os valores para os quais foi feito download no Sistema.

Tabela 2. Status dos Resultados de Análise

STATUS	RESULTADOS DE ANÁLISE
6	Entre zero e o LMR de cada substância
7	Maior que o LMR de cada substância

2.2.3 Metodologia de Análise por Aprendizagem de Máquina

2.2.3.1 Árvore de Decisão

Para elaboração da árvore de decisão, inicialmente foi realizada a etapa de pré-processamento e transformação, ou engenharia de característica dos dados, que consistiu na limpeza e seleção dos dados a fim de retirar dados que possam gerar ruídos, interferindo na análise dos dados e no preenchimento de valores ausentes.

Essa limpeza e seleção consistiu na inclusão de um novo status de análise, status 5, que corresponde aos resultados de análise iguais a 0 e na exclusão de algumas informações. Após essa alteração, a tabela 1 ficou representada como detalhado na Tabela 3.

Tabela 3. Status dos Resultados de Análise após a criação do Status 5.

STATUS	RESULTADOS DE ANÁLISE	RESULTADO
5	Igual a 0	Negativo
6	Entre 0,1 e o LMR de cada substância	Conforme
7	Igual ou maior que o LMR de cada substância	Não conforme

Os dados excluídos foram: os confidenciais (nome e endereço das propriedades em que foram coletadas as amostras, bem como de seus proprietários, nº do CEP do proprietário e unidade da federação da propriedade de origem do(s) animal(is) do(s) qual(is) foi coletada a amostra); indiferentes para as análise realizadas nos dados (código da espécie – já que as duas espécies foram analisadas de forma individual, código referente ao tipo de proprietário - pessoa física ou jurídica, código do tecido –informação desnecessária pois cada substância é avaliada em apenas um tecido, nos dados utilizados nesse estudo); duplicados (código do município, permanecendo o dado com o nome do município), situação da violação (informação substituída pelo dado status). Alguns dados foram corrigidos pois apresentaram problemas quando realizado o download do Sistema: um resultado de análise com valor negativo para suínos foi considerado positivo, já que não há resultado negativo nesse caso e resultados de análise que estavam em branco foram excluídos, tendo em vista esse valor ser essencial para a avaliação do dado

Após o pré-processamento dos dados, a árvore de decisão foi elaborada com o *software* livre YADT, disponível para download no seguinte endereço: <http://www.di.unipi.it/~ruggieri/software.html>.

Para a mineração dos dados, foram inseridos no *software* dois arquivos, um com a base de dados para treinamento e outro com os metadados, ou seja, a descrição dos dados por coluna, conforme Tabela 4. Não foi utilizada uma base de dados para teste, sendo preenchido no YADT o valor de 25% de utilização da base de treinamento para realização do teste. Também foram preenchidos dois outros fatores necessários para a criação da árvore de decisão: SPLIT, que é descrito como o número de novos casos para evitar a criação de novos ramos e CONFIDENCE, sendo este o valor utilizado para a poda do algoritmo C4.5. Os valores utilizados são os mais citados na literatura: 2 e 25%, respectivamente.

Tabela 4. Descrição dos Metadados

Nome Dado	Tipo de Dado	Tipo da característica
ANO	STRING	DISCRETE
SEMANA	INTEGER	DISCRETE
CÓDIGO RESÍDUO	INTEGER	DISCRETE
QUANTIDADE DE ANIMAIS	INTEGER	DISCRETE
SIF	INTEGER	DISCRETE
UF	STRING	DISCRETE
MUNICIPIO	STRING	DISCRETE
CEP	STRING	DISCRETE
RESULTADO	FLOAT	CONTINUOUS
STATUS	INTEGER	CLASS

2.2.3.2 Redes Neurais

Redes Neurais consistem em algoritmos formados por um conjunto de pequenas unidades de processamento, denominadas neurônios, as quais são fornecidas entradas e que geram saídas interconectadas, o que lhes permite identificar especificidades mais facilmente (Mitchel, 1997).

As bases de dados de suínos e aves foram analisadas com a utilização das redes neurais *Self-Organizing Map* (SOM) e *Time-Adaptive Self-Organizing Map* (TASOM), na Faculdade UnB Gama.

A rede SOM consiste em uma rede neural que trabalha com aprendizagem não supervisionada e funciona apenas em ambientes estáticos, nos quais não há entrada de novos dados durante o treinamento. O TASOM trabalha preferencialmente em ambientes incrementais, ou seja, aprende continuamente, conforme novas entradas chegam ao Sistema (He et al., 2011). As principais características de uma base de dados para a utilização de algoritmos que trabalhem com aprendizado incremental consistem em: necessidade constante de realizar previsão com os dados, base de dados evolui com o tempo, a base de dados apresenta um crescimento infinito, porém os recursos de armazenamento são finitos (Read et al., 2013).

Para a realização dessa análise foi utilizado um protótipo de sistema da Embarcadero®. Os dados foram carregados nessa plataforma no formato “.csv”.

Os dois algoritmos foram parametrizados com os dados detalhados na Tabela 5. As amostras do banco de dados utilizado já possuem o rótulo que classifica o resultado de análise,

denominado de Status. A análise realizada consistiu na verificação da eficiência dos neurônios dos algoritmos em agrupar as amostras de acordo com esse rótulo. Para medir essa eficiência foram registradas as porcentagens da presença de cada classe em cada um dos neurônios das redes. O resultado ideal é que um neurônio possua alta densidade de uma determinada classe e baixa densidade das outras, o que significa que as classificou corretamente.

Tabela 5. Parâmetros utilizados nos algoritmos SOM e TASOM.

Parâmetro	Valor utilizado
Altura do Mapa	2(m)
Largura do Mapa	2(m)
Raio da Vizinhança Inicial	4(m)
Taxa de Aprendizagem Inicial	1
Decaimento da Taxa de aprendizagem	1%
Decaimento do Raio de Vizinhança	1%

Para a verificação dos dados com utilização dos neurônios, no centro do protótipo havia duas tabelas, uma para cada neurônio, nas quais foram registrados os valores de entrada, a posição do neurônio e a taxa de erro da classificação dos dados. Para a realização do teste, os algoritmos (SOM e TASOM) foram alimentados primeiramente com todos os dados da tabela pré-processada. Posteriormente, os algoritmos foram alimentados com os dados da tabela pré-processada exceto os resultados com status igual a 5 (resultado igual a zero) e por último foram excluídos os resultados de análise, dado diretamente ligado ao status da análise, a fim de avaliar o comportamento dos algoritmos.

2.2.4 Metodologia de Análise espacial – Quantum GIS (QGIS)

Nesta etapa da análise dos dados, optou-se pela separação dos resultados por substância em planilhas distintas, para análise individual de cada série histórica, sendo selecionados apenas as substâncias que apresentaram um n° significativo de análises com resultados de Status 6 e 7, ou seja, com resultados diferentes de 0. A Tabela 6 representa as substâncias selecionadas para essa etapa.

Tabela 6. Substâncias selecionadas para análise dos resultados

Espécie	Substância	Nº de Resultados Conformes ou Não conformes
Aves	Closantel	181
	Diclazuril	30
	Nicarbazina	179
	Sulfaquinoxalina	108
Suínos	Doxiciclina	13
	Sulfametazina	133

A base de dados utilizada já havia passado pelas etapas de pré-processamento e transformação conforme descrito no item 2.4.3.1, adicionalmente, foram inseridas duas novas informações: nome das substâncias analisadas e semana de análise, que consiste em uma sequência numérica com início na primeira semana do primeiro ano da série histórica e final na última semana do último ano da série histórica de cada substância.

Para a elaboração dos mapas de distribuição dos resultados de análise com status 6 e 7 foi utilizado o software livre QUANTUMGIS®, cujo download pode ser efetuado no seguinte endereço: <http://www.qgis.org/en/site/>.

Inicialmente foi realizado download dos dados de geolocalização dos municípios brasileiros no site do IBGE, por meio do seguinte endereço: <http://www.ibge.gov.br/>. Os nomes dos municípios brasileiros e seus geocódigos, que consiste em um número com 7 dígitos, único para cada município, foram inseridos em uma planilha em Excel, na qual foram também inseridas os números de resultados com status 6 e 7 para cada cidade, sendo preenchidas com o número “0” as células referentes aos municípios nos quais não ocorreu detecção de resíduos de alguma dessas substâncias. Essa planilha foi convertida para o formato “.dbf”, necessário para leitura do arquivo pelo *software*, por meio da utilização do software livre Open Office®, cujo download pode ser realizado por meio seguinte link: <http://www.openoffice.org/download/>.

Foram inseridos no Sistema QUANTUMGIS® os dados do IBGE contendo a geolocalização dos municípios e em seguida foram também inseridos os dados com o número de detecção de resíduos para cada município. As duas tabelas foram unidas com a função “união” do Sistema e em seguida o layout do mapa foi alterado para permitir a visualização dos municípios em que ocorreram detecções das substâncias selecionadas de acordo com a Tabela 6.

2.2.5 Metodologia de Análise Temporal - Gráficos e Regressão Linear

Foram elaborados gráficos de distribuição temporal dos resultados de análise das

substâncias detalhadas na Tabela 7, a fim de se verificar a existência de padrões de distribuição nesses resultados, o que poderia auxiliar na avaliação dos motivos dessas não conformidades. Esses gráficos foram elaborados com *software* Microsoft Excel®, utilizando na base de dados a quantidade detectada de resíduos das substâncias em cada análise por semana de análise, sendo essas semanas um número sequencial que inicia na primeira semana de análise da substância na sua série histórica e encerra na última semana de análise da substância, conforme detalhado na Tabela 7.

Tabela 7. Período de análise das substâncias selecionadas

Substância/Espécie	Período de Análise	Número sequencial da última Semana
Closantel em Aves	Semana 03 de 2002 à 49 de 2007	251
Diclazuril em Aves	Semana 32 de 2008 a 18 de 2014	304
Nicarbazina em Aves	Semana 30 de 2008 a 17 de 2014	342
Sulfaquinoxalina em Aves	Semana 03 de 2002 a 18 de 2014	652
Doxiciclina em Suínos	Semana 10 de 2011 a 28 de 2011	131
Sulfametazina em Suínos	Semana 08 de 2002 a 38 de 2014	675

Nos gráficos elaborados nessa etapa também se pode verificar visualmente os casos em que houve extrapolação do Limite Máximo de Resíduo para essas substâncias, ou seja, os casos em que o resultado das análises apresenta status 7. Como os valores de LMR variam de acordo com cada substância, a Tabela 8 informa quais os LMR's considerados para cada substância avaliada nessa etapa, de acordo com as Instruções Normativas de Publicação dos PNCR's dos anos 2002 ao ano 2014.

Tabela 8. LMR das substâncias analisadas

Substância/Espécie	Limite Máximo de Resíduo – LMR (µg/Kg)
Closantel em Aves	1000
Diclazuril em Aves	500
Nicarbazina em Aves	200
Sulfaquinoxalina em Aves	100
Doxiciclina em Suínos	600
Sulfametazina em Suínos	100

RESULTADOS E DISCUSSÃO

2.3 Resultados

2.3.1 Árvore de Decisão

As árvores obtidas com essa metodologia de análise estão dispostas nas figuras 2 e 3. Os dois modelos obtidos apresentaram uma acurácia muito grande, a árvore de suínos apresentou apenas 0,22% de erro e a árvore de aves apenas 0,090%, porém utilizaram apenas a característica valor de resultado como ramos da árvore, impossibilitando a identificação de padrões nos dados por resultado de análise. Resultados semelhantes foram encontrados por Carvalho (2014).

Esse resultado pode ser decorrente do fenômeno de *overfitting*, um problema que ocorre em aprendizagem de máquina quando o algoritmo trabalha com muita precisão nos dados de treinamento do modelo, mas não tem boa precisão para os novos dados que serão analisados (Fahland & Alst, 2013), denominados dados de teste. O *overfitting* pode ocorrer quando a base de dados é muito pequena ou quando apresenta excesso de dados que não acrescentam informações significativas à análise, denominados ruídos, e a árvore de decisão passa a ser construída com base nesses ruídos (Kouvaris et al., 2015).

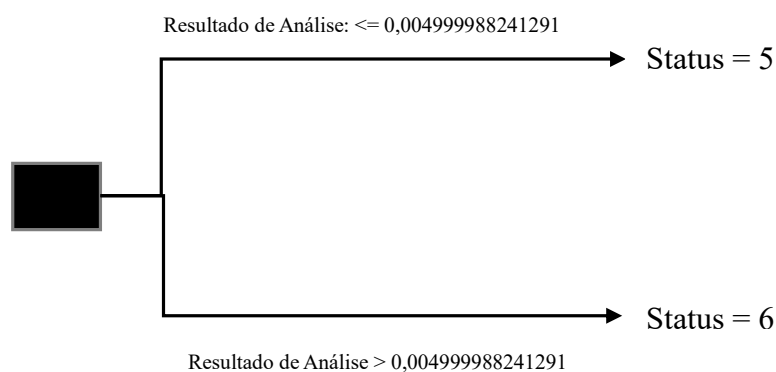


Figura 2. Árvore de Decisão referente ao banco de dados de suínos.

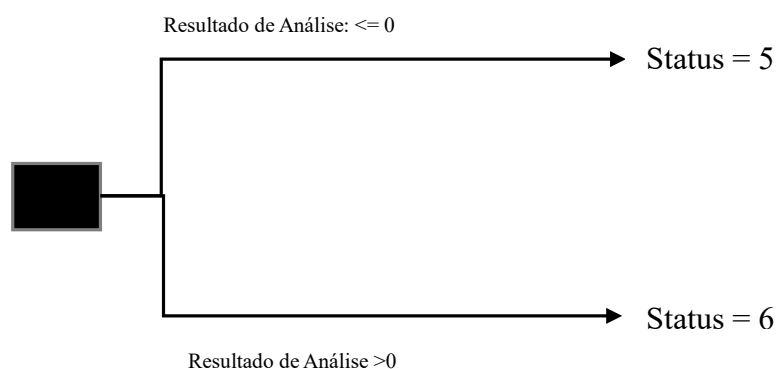


Figura 3. Árvore de Decisão referente ao banco de dados de aves.

Porém, também é possível que esse resultado seja decorrente de outro problema que é recorrente em modelos de aprendizagem de máquina, *underfitting*, que ocorre quando o modelo não consegue identificar os padrões ocultos nos dados do conjunto de treinamento por não ser apropriado para aquele tipo de problema (Fahland & Alst, 2013).

As árvores de decisão também não permitiram a identificação de padrão nem mesmo de resultado de análise para o Status Não conforme. Esse erro pode ser decorrente da diferença de LMRs, valores a partir dos quais ocorrem resultados não conformes, para cada substância analisada, bem como pela baixa representatividade desse número comparado ao total de resultados analisados, conforme é possível verificar na Tabela 9. Resultados semelhantes foram encontrados por Carvalho (2014).

Tabela 9. Número de resultados por Status utilizado

	Esperada/Obtida	Negativo	Conforme	Não Conforme
Suínos	Negativo	16930	0	0
	Conforme	0	114	0
	Não-Conforme	0	0	37
Aves	Negativo	47516	0	0
	Conforme	0	389	0
	Não-Conforme	0	0	43

2.3.2 Redes neurais

Nesta etapa a base de dados foi avaliada por meio da utilização de neurônios SOM e TASOM, para separação dos dados negativos, conformes e não conformes, segundo tabela 4, na tentativa de se identificar características em comum para resultados com mesmos status de análise.

A primeira análise de redes neurais considerou todos os dados da base pré-processada, ou seja, que apresentaram resultados de análise negativos, conformes e Não-Conforme, excluindo o rótulo (status de análise). Os algoritmos não separaram os dados em relação ao resultado de análise, devido aos resultados negativos representarem a maior parte da base de dados (Tabela 10). Essa informação pode ser confirmada quando observamos que a porcentagem de dados com resultados de análise Status Conformes e Não conformes representam apenas aproximadamente 1% do total das amostras (tabela 11).

Tabela 10. Percentual dos dados agrupado em cada neurônio

Espécie	Neurônio	SOM			TASOM		
		Negativos	Conformes	Não conformes	Negativos	Conformes	Não conformes
Aves	1	99,54	0,23	0,21	0	0	0
	2	99,45	0,40	0,13	99,40	0,41	0,18
	3	99,67	0,16	0,16	99,54	0,29	0,16
	4	99,46	0,37	0,15	99,52	0,26	0,21
Suínos	1	0	0	0	97,70	1,91	0,38
	2	98,60	1,09	0,30	99,25	0,35	0,38
	3	98,59	0,92	0,48	96,37	3,28	0,24

4	97,29	2,48	0,22	97,47	2,32	0,21
---	-------	------	------	-------	------	------

Tabela 11. Número de resultados da base de dados por Status de Análise

Espécie	Status Análise	Nº de Resultados	Resultados (%)
Aves	Negativo	47516	98,84
	Conforme	389	0,81
	Não-Conforme	43	0,089
Suínos	Negativo	16930	99,11
	Conforme	114	0,67
	Não-Conforme	37	0,22

Na segunda análise foram considerados apenas os dados de análise que apresentaram resultado Conformes e Não conformes. Em geral os dados de suínos apresentaram maior separação que os dados de aves, como podemos observar nos neurônios 2, 3 e 4 para o algoritmo SOM e 3 e 4 para o algoritmo TASOM (Tabela 12). O que indica que esses neurônios identificaram características comuns entre os dados com resultados de análise semelhantes.

Tabela 12. Percentual dos dados agrupados sem resultados negativos.

Espécie	Neurônio	SOM		TASOM	
		Conforme	Não - Conforme	Conforme	Não - Conforme
Aves	1	54,09	45,90	0	0
	2	74,28	25,71	43,93	56,06
	3	62,24	37,75	76,68	23,31
	4	60,20	39,79	65,64	34,35
Suínos	1	65,60	24,29	0	0
	2	86,74	13,25	62,42	37,57
	3	91,79	8,2	88,16	11,83
	4	91,88	8,12	95,66	4,33

A terceira análise foi realizada sem os valores de resultado da análise, que é fator determinante para a característica Conformidade ou Não-Conformidade dos resultados. Essa análise foi realizada para se identificar uma melhor separabilidade dos dados com base nas suas demais características. Como resultado houve uma melhor separabilidade dos dados de

suínos nos neurônios 1 e 2 do algoritmo SOM e 2 do algoritmo TASOM, porém ainda pouco significativa (tabela 13).

Tabela 13. Percentual dos dados agrupados sem a variável resultados de análise.

Espécie	Neurônio	SOM		TASOM	
		Conforme	Não-Conforme	Conforme	Não-Conforme
Aves	1	63,46	36,53	0	0
	2	0	0	69,28	30,73
	3	0	0	39,29	40,70
	4	0	8,11	0	0
Suínos	1	91,79	8,2	0	0
	2	91,96	8,03	100	0
	3	65,60	34,39	85,46	14,53
	4	89,24	11,03	87,73	12,26

Outra forma de avaliar os resultados de análise por essa metodologia consiste na verificação da dispersão do conjunto de dados nos mapas, utilizando a informação referente à posição do agrupamento de cada classe. Na figura 4 pode-se observar a separabilidade dos dados de aves por região de mapas 5X5 e na figura 5 está disposta a mesma informação, porém de mapas 9X9. Os dados de suínos apresentaram separabilidade semelhante às dispostas nas figuras 5 e 6.

Linha/Coluna	Classe 6 – SOM – 5X5					Classe 7 – SOM – 5X5				
	1	2	3	4	5	1	2	3	4	5
1	7	1	30	13	20	4	21	1	5	16
2	39	14	8	12	14	24	17	1	0	9
3	34	14	15	6	9	12	1	1	10	8
4	5	16	32	1	0	10	2	0	0	0
5	9	4	4	0	0	12	0	0	0	25
Linha/Coluna	Classe 6 – TASOM – 5X5					Classe 7 – TASOM – 5X5				
	1	2	3	4	5	1	2	3	4	5
1	0	0	0	0	0	0	0	0	0	0
2	0	43	0	0	0	0	24	0	0	0
3	0	93	36	56	22	0	56	12	40	26
4	7	12	0	3	0	12	0	0	3	0
5	0	27	0	5	0	0	0	0	5	0

Figura 4. Posição dos dados de aves em mapa 5X5

Linha/Coluna	Classe 6 – SOM – 9X9									Classe 7 – SOM – 9X9								
	1	2	3	4	5	6	7	8	9	1	2	3	4	5	6	7	8	9
1	14	13	1	7	11	12	6	6	6	18	2	25	0	0	12	0	0	0
2	15	20	9	8	2	7	5	1	8	9	5	1	0	0	0	0	0	0
3	10	16	5	0	2	2	1	2	0	5	1	4	0	12	0	0	0	0
4	20	11	3	4	5	1	1	1	0	16	1	1	0	0	12	0	0	0
5	7	3	2	2	0	2	2	3	0	0	0	0	0	0	0	0	0	0
6	4	1	0	0	1	1	0	4	0	0	0	1	0	0	0	0	0	0
7	0	3	2	0	1	1	2	0	0	0	0	0	9	0	0	0	0	0
8	4	1	1	2	0	0	0	0	0	0	21	0	0	0	4	0	0	0
9	4	0	1	1	2	2	0	0	0	12	0	0	0	0	0	0	0	8
Linha/Coluna	Classe 6 – TASOM – 9X9									Classe 7 – TASOM – 9X9								
	1	2	3	4	5	6	7	8	9	1	2	3	4	5	6	7	8	9
1	0	5	56	12	30	12	23	9	38	0	0	16	31	12	1	22	5	2
2	7	0	4	0	0	0	0	25	1	0	0	0	0	0	0	0	8	0
3	1	0	0	1	0	1	1	0	0	25	0	0	0	0	0	0	0	0
4	1	5	7	0	0	6	25	0	0	0	10	12	0	0	0	0	0	0
5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	0	1	0	0	0	40	0	0	0	0	0	0	0	0	24	0	0	0
7	0	0	0	9	0	0	0	0	0	0	0	0	9	0	0	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Figura 5. Posição dos dados de aves em mapa 9X9

Como resultado dessa etapa tem-se que não há informações suficientes no conjunto de dados para que se obtenha uma boa separação dos dados, tendo em vista que nenhum neurônio foi capaz de classificar os dados de acordo com seus status de análise, característica que classifica os dados em grupos de acordo com seu resultado de análise. Esse resultado pode indicar que os dados analisados possuem uma grande inseparabilidade linear, ou seja, não há características em comum entre os dados analisados que sejam suficientes para determinar os status de análise, bem como pode indicar a presença de características que interfiram na análise do conjunto de dados, ou seja, características não necessárias para essa análise, que geram ruídos e deveriam ter sido eliminadas na etapa de pré-processamento dos dados e engenharia de características.

2.3.3 Mapas de Distribuição Espacial

Na Figura 6 pode-se verificar a distribuição espacial das detecções de resíduos das substâncias Closantel, Diclazuril, Nicarbazina, e Sulfaquinoxalina aves e na Figura 7, a distribuição espacial das detecções de resíduos de Doxiciclina e Sulfametazina em suínos. Os mapas individualizados por ano para cada substância podem ser verificados no volume Anexos.

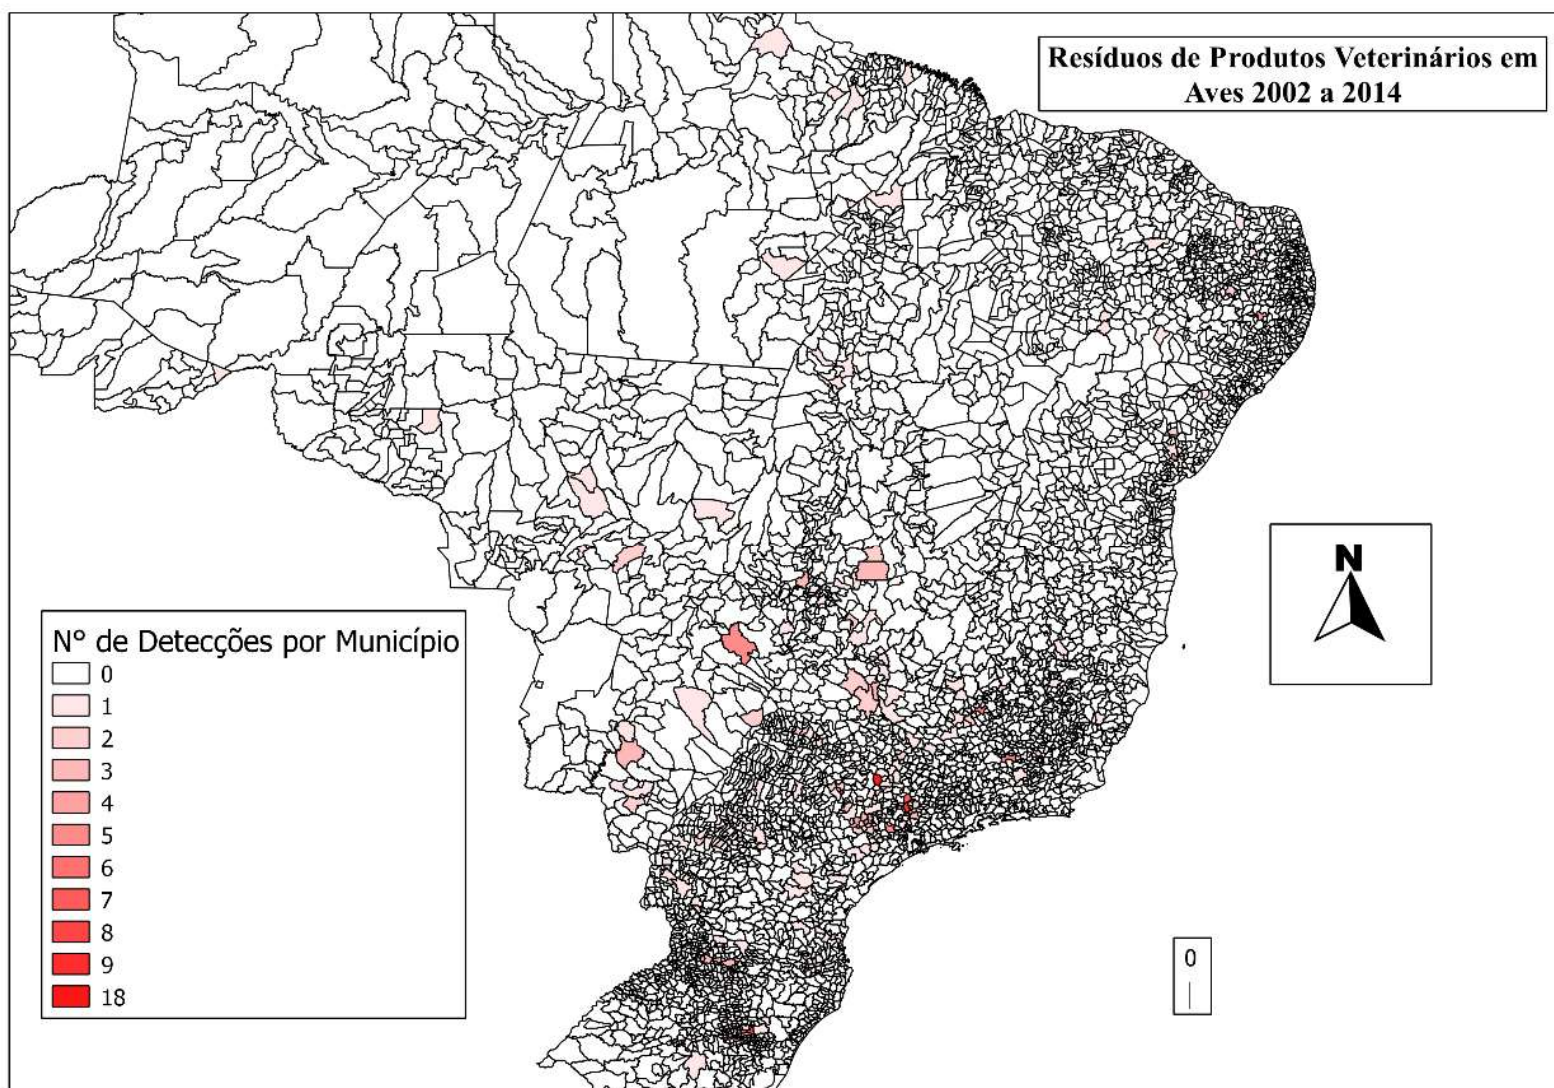


Figura 6. Resíduos de Produtos Veterinários em Aves. Período de 2002 a 2014.

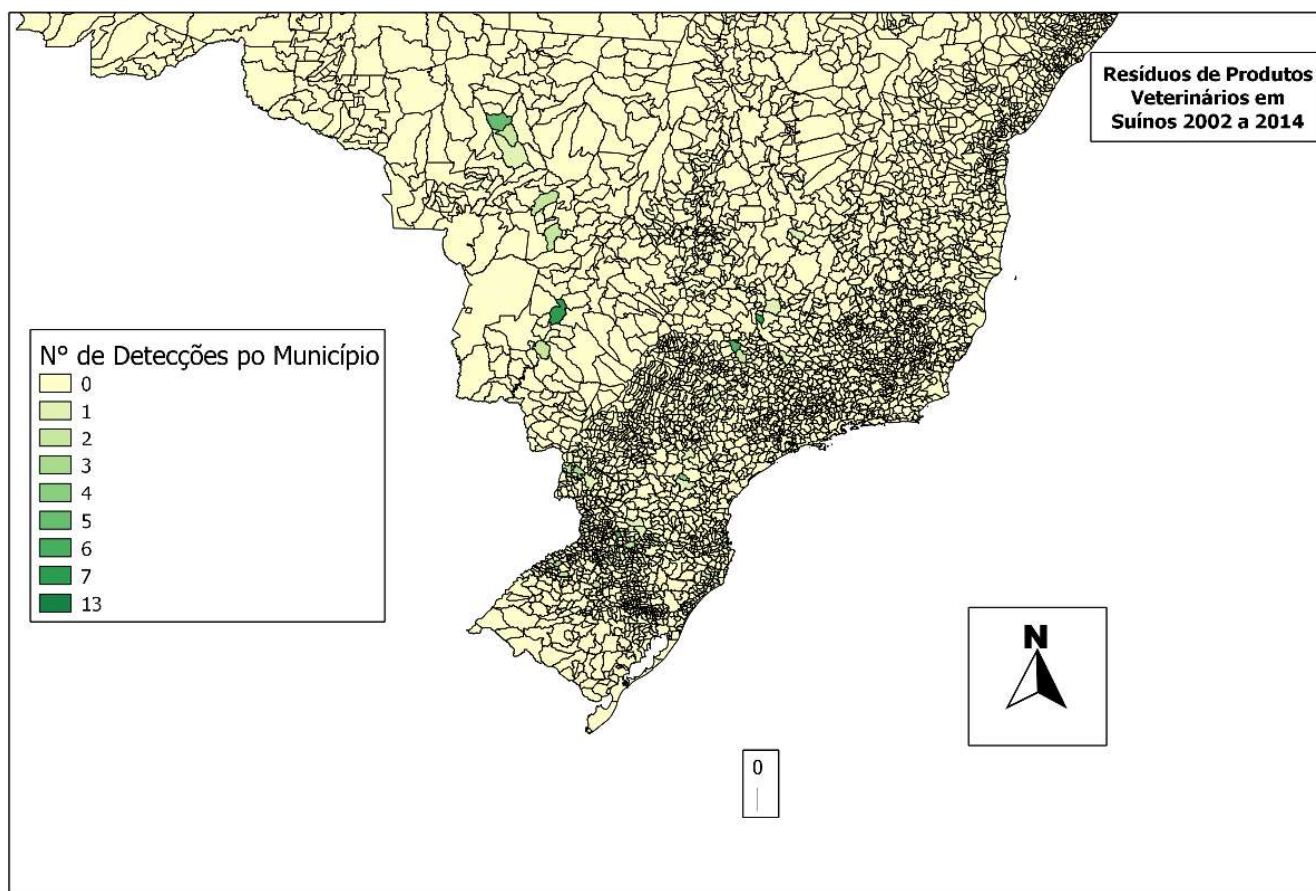


Figura 7. Resíduos de Produtos Veterinários em Suínos. Período de 2002 a 2014

Na figura 6 podemos verificar que ocorreram algumas detecções de resíduos nas regiões Norte e Nordeste, porém a maior parte das detecções de resíduos em aves ocorreu na região Centro-Oeste, Sudeste e Sul. Em suínos (figura 7) ocorreram detecções apenas nessas três últimas regiões. Essa informação pode ser explicada pelo fato de a maior parte dos estabelecimentos produtores de aves e suínos que possuem Serviço de Inspeção Federal estar localizados em uma destas três regiões, conforme podemos verificar na tabela 14, que contém total de abate em estabelecimentos com Inspeção Federal para aves e suínos, no período entre janeiro de 2002 a outubro de 2014 (MAPA, 2014). Ademais, o SISRES distribui aleatoriamente as amostras em que serão realizadas as análises, porém de acordo com o porte de produção de cada estabelecimento frigorífico. Dessa forma, um estabelecimento que abate vários lotes de animais por dia coleta mais amostras para análise de resíduos e contaminantes do que um estabelecimento que abate alguns lotes de animais por semana.

Tabela 14. Número de aves e suínos abatidos em SIFs por Estado.

Estado	Total Aves	Total Aves (%)	Total Suínos	Total Suínos (%)
Acre	0	0	0	0
Bahia	447753015	0,861004	437.576	0,135619
Distrito Federal	737931707	1,419001	1.393.434	0,431869
Espírito Santo	175987005	0,338413	39.928	0,012375
Goiás	2943868392	5,660891	18.247.231	5,655396
Maranhão	0	0	4.215	0,001306
Mato Grosso	1715812249	3,299409	14.999.395	4,648789
Mato Grosso do Sul	1566502066	3,012294	10.688.699	3,312767
Minas Gerais	3579682963	6,883527	30.722.967	9,522023
Pará	154729386	0,297536	0	0
Paraíba	90138110	0,17333	0	0
Paraná	14007224571	26,9351	57.737.369	17,89464
Pernambuco	210458112	0,404699	0	0
Piauí	7312661	0,014062	0	0
Rio de Janeiro	19896591	0,03826	0	0
Rio Grande do Norte	0	0	4.756	0,001474
Rio Grande do Sul	8970131584	0,178432	76.720.640	23,77816
Rondônia	92790950	0,178432	0	0
Roraima	0	0	15.581	0,004829
Santa Catarina	9844767235	18,93093	94.567.892	29,30959
São Paulo	7329522830	14,09426	17.001.370	5,269264
Sergipe	6247908	0,012014	70.638	0,021893
Tocantins	102861778	0,197797	0	0

Total	52.003.619.113	100	0	0
-------	----------------	-----	---	---

2.3.4. Gráficos de distribuição temporal

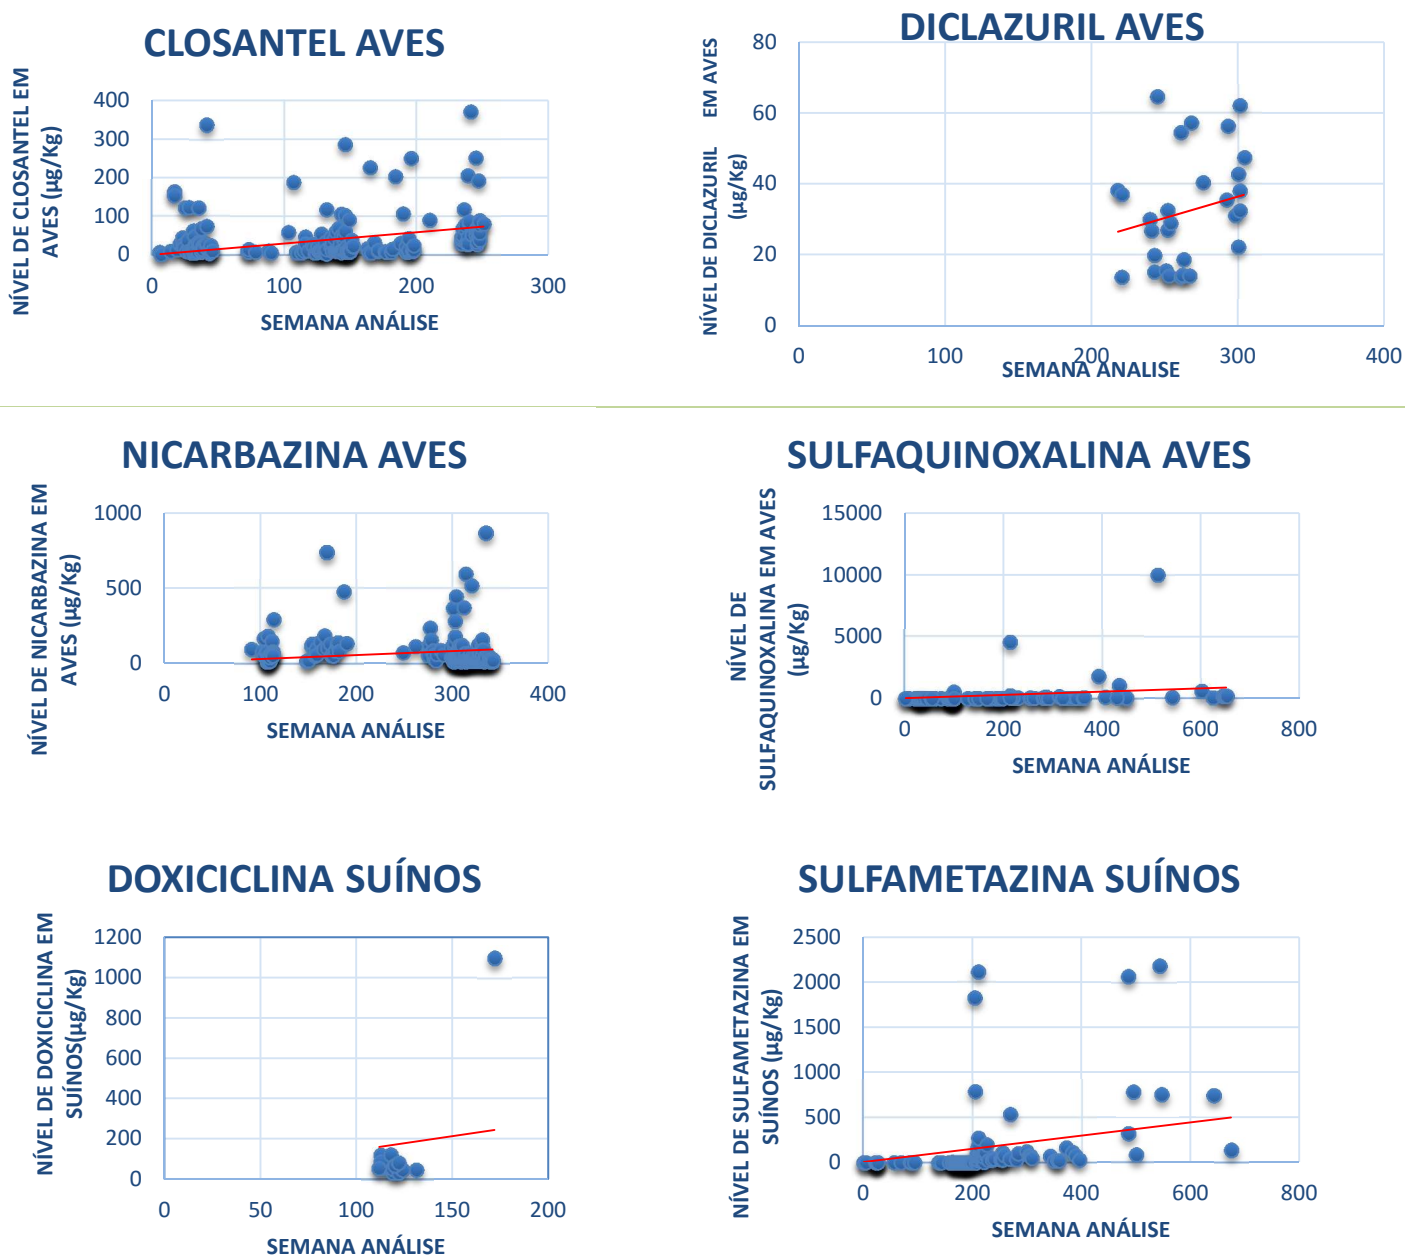


Figura 8. Nível de Detecção de Substâncias em Aves e Suínos no período entre 2002 e 2014.

Na figura 8 podemos avaliar os dados de distribuição temporal das substâncias, nos quais pode se observar que não houve um padrão de distribuição dos resultados por

sazonalidade. Para as substâncias Doxiciclina em suínos e Diclazuril em aves houve concentração de detecção de substâncias apenas em um determinado período: entre as semanas 100 e 150 para Doxiciclina e 200 e 300 para Diclazuril, porém para as demais substâncias houve uma distribuição constante das detecções até um determinado período e após esse período não foram identificadas outras detecções, sendo uma possível justificativa as ações oficiais do MAPA junto aos proprietários dos estabelecimentos de origem desses animais ou pela interrupção da série temporal. Quando analisamos os dados dos gráficos avaliando o LMR de cada substância, de acordo com a tabela 8, podemos verificar que são poucos os resultados que ultrapassaram o LMR, ou seja, que estavam em concentração que pode ser prejudicial à saúde do consumidor. A comparação dos dados de não conformidades em relação ao total de amostras analisadas está detalhada na tabela 15.

Tabela 15. Percentual de Análises Não conformes de Resíduos em aves e suínos.

Substância/Espécie	Nº de amostras analisadas	Nº de amostras conformes	Percentual de análises Não conformes (%)
Closantel/Aves	1938	0	0
Diclazuril/Aves	1059	0	0
Nicarbazina/Aves	2904	11	0,37
Sulfaquinoxalina/Aves	5441	14	0,26
Doxiciclina/Suínos	2375	1	0,042
Sulfametazina/Suínos	3182	21	0,66

CONCLUSÕES

Com este estudo pode-se concluir que:

1. não foi possível verificar padrões de distribuição temporal nas detecções de resíduos e contaminantes em aves e suínos;
2. a maioria das detecções das substâncias avaliadas estão concentradas nas regiões centro-oeste, sudeste e sul, regiões onde está concentrado o maior nº de estabelecimentos que produzem carne suína e de aves;
3. os dados desse estudo não foram suficientes para a elaboração de uma árvore de decisão capaz de realizar predições para auxiliar na avaliação e escolha de substâncias a serem monitoradas oficialmente.

REFERÊNCIAS BIBLIOGRÁFICAS

ASSOCIAÇÃO BRASILEIRA DE PROTEÍNA ANIMAL (Brasil) (Org.). Relatório Anual de Atividades 2014. São Paulo, 2015. 245 p. Disponível em: <http://novo.more.ufsc.br/relatorio_tecnico/inserir_relatorio_tecnico>. Acesso em: 15 fev. 2016.

UPADHYAYA, S. R.. Parallel approaches to machine learning - A comprehensive survey. Elsevier, Bangalore, p.284-292, 2013.

ARAÚJO, M. Safety e Security: Conceitos Diferentes. Segurança e Qualidade Alimentar, Lisboa, v. 3, p.62-63, nov. 2007. Mensal.

BARBOSA, Jorge et al. Detection, Accumulation, Distribution, and Depletion of Furaldone and Nifursol Residues in Poultry Muscle, Liver, and Gizzard. Journal Of Agricultural And Food Chemistry. Washington, D.c., p. 11927-11934. 19 out. 2011.

BELIK, W. A Política Brasileira de Segurança Alimentar e Nutricional: concepção e resultados. Segurança Alimentar e Nutricional, Campinas, p.94-110, 2012.

BRASIL. AGÊNCIA NACIONAL DE VIGILÂNCIA SANITÁRIA. Decreto 3029, de 16 de abril de 1999a. Aprova o Regulamento da Agencia Nacional de Vigilância Sanitária, e dá outras providências.

<http://www.anvisa.gov.br/hotsite/relatorio_atividades_06/anexo/anexo_2_4_decreto_3029.pdf>. Acesso em: 20 dez. 2015.

BRASIL. MINISTÉRIO DA AGRICULTURA PECUÁRIA E ABASTECIMENTO. Instrução Normativa 09, de 27 de junho de 2003. Proíbe a fabricação, a manipulação, o fracionamento, a comercialização, a importação e o uso dos princípios ativos cloranfenicol nitrofuranos e os produtos que contenham estes princípios ativos, para uso veterinário e suscetível de emprego na alimentação de todos os animais e insetos. Disponível em: <

<http://sistemasweb.agricultura.gov.br/sislegis/action/detalhaAto.do?method=visualizarAtoPortalMapa&chave=2112258128>>. Acesso em: 25/03/2016.

BRASIL. MINISTÉRIO DA AGRICULTURA PECUÁRIA E ABASTECIMENTO. Portaria Ministerial 86, de 26 de janeiro de 1979. Aprova o Programa Nacional de Controle de Resíduos Biológicos em Carnes. Disponível em: <<http://sistemasweb.agricultura.gov.br/sislegis/action/detalhaAto.do?method=consultarLegislacaoFederal>>. Acesso em: 20/10/2015.

BRASIL. MINISTÉRIO DA AGRICULTURA PECUÁRIA E ABASTECIMENTO. Instrução Normativa nº 42, de 20 de dezembro de 1999b. Altera o Plano Nacional de Controle de Resíduos em produtos de origem animal – PNCR e os Programas de Controle de Resíduos em Carne – PCR, Mel – PCRM, Leite – PCRL e Pescado – PCRP e dá outras providências. 1999b. Disponível em: <http://www.agricultura.gov.br/arq_editor/file/CRC/IN%2042-1999.pdf> Acesso em: 20/10/2015.

BRASIL. MINISTÉRIO DA AGRICULTURA PECUÁRIA E ABASTECIMENTO. Projeções do Agronegócio.: Brasil 2012/13 a 2022/23. 2013. Disponível em: <http://www.agricultura.gov.br/arq_editor/projecoes%20-%20versao%20atualizada.pdf>. Acesso em: 20 dez. 2015.

BRASIL. MINISTÉRIO DA AGRICULTURA PECUÁRIA E ABASTECIMENTO. Alimentos. 2014a. Disponível em: <www.agricultura.gov.br/vegetal/exportacao/alimentos>. Acesso em: 15 fev. 2016.

BRASIL. MINISTÉRIO DA AGRICULTURA PECUÁRIA E ABASTECIMENTO. Abate animais por estado. 2014b. Disponível em: <http://sigsif.agricultura.gov.br/sigsif_cons!/ap_abate_mensal_cons>. Acesso em: 15 fev. 2016.

BRASIL. CASTRO, A. G. M. Empresa Brasileira de Pesquisa Agropecuária (Org.). Sustentabilidade e sustentação da produção de alimentos no Brasil: Carne de aves e derivados. Brasília: Centro de Gestão e Estudos Estratégicos, 2014c. 208 p. (ISBN 978-85-60755-72-1).

BRASIL. PADULA, M. Empresa Brasileira de Pesquisa Agropecuária (Org.). Sustentabilidade e sustentação da produção de alimentos no Brasil: Interdependência: alimentos e segurança. Brasília: Centro de Gestão e Estudos Estratégicos, 2014d. 172 p. (ISBN 978-85-60755-71-4).

BRINK, H.; RICHARDS, J. W. Real-World Machine Learning. [s.n.], 2013. Disponível em: <http://www.manning.com/brink/RWML_MEAP_CH01.pdf>. Busta, 2012 apud CGEE cap. 5

CARVALHO, H. M. Aprendizado de Máquina voltado para Mineração de Dados: Árvores de Decisão. 2014. 96 f. TCC (Graduação) - Curso de Engenharia de Software, Faculdade Unb Gama, Universidade de Brasília, Brasília, 2014.

CANTARELLI, V.S.; FIALHO, E.T.; ALMEIDA, E.C. et al. Características da carcaça e viabilidade econômica do uso de cloridrato de ractopamina para suínos em terminação com alimentação à vontade ou restrita. *Ciência Rural*, v.39, n.3, p.844-851, 2009.

CHEN, Bin; ZHANG, An; CAO, Lu. Autonomous intelligent Decision-making System Based on Bayesian SOM Neural Network for robot soccer. *Neurocomputing*, Xi'an, v. 128, p.447-458, 23 ago. 2014.

CODEX ALIMENTARIUS. CAC/GL n° 44, de 2003. Principles For The Risk Analysis Of Foods Derived From Modern Biotechnology. Disponível em: <<http://www.fao.org/fao-who-codexalimentarius/standards/list-of-standards/en/>>. Acesso em: 12 fev. 2016.

CODEX ALIMENTARIUS. CAC/GL 62, 2007. Working principles for Risk Analysis for Food Safety for application by governments.

Disponível em:< <http://www.fao.org/fao-who-codexalimentarius/standards/list-of-standards/en/?provide=standards&orderField=fullReference&sort=asc&num1=CAC/GL>>. Acesso em: 20 jan. 2015.

CODEX ALIMENTARIUS. CAC/GL n° 71, de 2009. Guidelines for the Design and Implementation of National Regulatory Food Safety Assurance Programmes Associated with the Use of Veterinary Drugs in Food Producing Animals. Disponível em: <<http://www.fao.org/fao-who-codexalimentarius/standards/list-of-standards/en/?provide=standards&orderField=fullReference&sort=asc&num1=CAC/GL>>. Acesso em: 10 jan. 2016.>

COENEN, F. Data mining: past, present and future. *The Knowledge Engineering Review*, [s.l.], v. 26, n. 01, p.25-29, 7 fev. 2011. Cambridge University Press (CUP). DOI: 10.1017/s0269888910000378.

COSER, F. J. Contratos de Integração de Suínos: formatos, conteúdos e deficiências da estrutura de governança predominante na suinocultura brasileira. 2010. 160 f. Dissertação (Mestrado) - Curso de Gestão do Agronegócio, Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília, Brasília, 2010. Disponível em: <http://repositorio.unb.br/bitstream/10482/5990/1/2010_FabianoJoséCoser.PDF>. Acesso em: 13 fev. 2016.

CONCÓRDIA. D. D. J. Empresa Brasileira de Pesquisa Agropecuária (Org.). A avicultura no Brasil. 2010. Disponível em: <http://www.cnpsa.embrapa.br/cias/index.php?option=com_content&view=article&id=13&Itemid=15>. Acesso em: 20 out. 2015.

DONOGHUE, Dan J.. Antibiotic Residues In Poultry Tissues and Eggs: Human Health Concerns? *Poultry Science*, Oxford, v. 82, p.618-621, 2 dez. 2003.

DUDDE, N. B; APTE, S.s. Performance Analysis On Decision Tree Algorithms. *International Journal Of Advanced Research In Computer Science*, Solapur, v. 5, n. 7, p.199-201, 2014.

EUROPEAN COMMISSION. Food and Veterinary Office. Disponível em: <ec.europa.eu/food/index_en.htm>. Acesso em: 20 out. 2015.

EUROPEAN COMMISSION. Council Regulation (EEC) 2377/90 de 26 Junho de 1990. Prevê procedimento comunitário para o estabelecimento de limites máximos de resíduos de medicamentos veterinários nos alimentos de origem animal. Disponível em:

<http://ec.europa.eu/health/files/eudralex/vol-5/reg_1990_2377_cons_2008/reg_1990_2377_consol_pt.pdf>. Acessado em: 25 mar. 2016.

EUROPEAN FOOD SAFETY AUTHORITY – EFSA. Special Eurobarometer 354: Food-related risks. Belgium: TNS Opinion & Social, 2010. 168 p.

FAHLAND, Dikr; ALST, Wil M.p. van Der. Simplifying discovered process models in a controlled manner. *Information Systems*, v. 38, p.585-605, jul. 2013.

FAO. The State of Food Insecurity in the World 2003: monitoring progress towards the World Food Summit and Millenium Development Goals. Rome: Food And Agriculture Organization Of The United Nations, v. 1, 2003. Disponível em: <<ftp://ftp.fao.org/docrep/fao/006/j0083e/j0083e00.pdf>>. Acesso em: 20 out. 2015.

FAO. Residues of some veterinary drugs in animals and foods. *Food and Nutrition Paper*, Rome, v. 41/16, 2004. Disponível em: <www.fao.org/docrep/007/y5612e/y5612e00.htm>. Acessado em: 20/10/2015

FAYYAD, U.; PIATETSKY-SHAPIRO, G. The KDD Process fo Extracting Useful Knowledge from. *Communications Of The Acm, California*, v. 11, n. 39, p.27-34, nov. 1996.

FEIJÓ, L. D. et al. Identification and assessment of emerging issues associated with chemical contaminants in dairy products. *Bulletin Of The International Dairy Federation*, Brussels, v. 465, p.1-10, 2013.

FIEDLER, H. et al. Polychlorinated Dibenzo-p-dioxins and Polychlorinated Dibenzofurans (PCDD/PCDF) in Food Samples Collected in Southern Mississippi, USA. *Chemosphere*, v. 34, p.1411-1419, 1997.

GAYLOR, D.W., BOLGER, P.M. & SCHWETZ, B.A. U.S. Food and Drug Administration perspective of the inclusion of effects of low-level exposures in safety and risk assessment. *Environmental Health Perspectives*, v. 106, p. 391–394. 1998.

GEHRING, R.; BAYNES, R. E.; RIVIERI, J. E.. Application of risk assessment and management principles to the extralabel use of drugs in food-producing animals. *J. Vet. Pharmacol. Therap.*, v. 29, p.5-14, 2006.

GURUGE, K. S. et al. Polychlorinated dibenzo-p-dioxins, dibenzofurans, and biphenyls in domestic animal food stuff and their fat. *Chemosphere*, v. 58, p.883-889, 2005.

HE, H. et al. Incremental learning from stream data. 2011. Disponível em: <<http://www.ele.uri.edu/faculty/he/PDFfiles/incrementaldata.pdf>>.

HUSIEN, Sabah; BADI, Haitham. Artificial neural network for steganography. *The Natural Computing Applications, Baghdad*, v. 26, p.111-116, 2015.

CRESPO-RAMOS, M. et al. Detection of locally relevant variables using SOM–NG algorithm. *Elsevier, Coruña*, v. 26, p.1992-2000, 01 jul. 2013.

JARDIM, A. N. O. J.; CALDAS, E. D. Exposição humana a substâncias potencialmente

tóxicas na dieta e os riscos para a saúde. *Química Nova*, v. 32, n° 7, p. 1898-1909, 2009.

JORDAN, M. I.; MITCHELL, T. M.. Machine learning: Trends, perspectives, and prospects. *Science*, [s.l.], v. 349, n. 6245, p.255-260, 16 jul. 2015. American Association for the Advancement of Science (AAAS). DOI: 10.1126/science.aaa8415.

JUNIOR, W.C.P.M, BONNET, M., FEIJÓ, L.D. & SANTOS, M.T. Risk off Method: improvising data quality generated by chemical risk analysis of milk. In: Rahman H. & Ramos I (eds). *Cases on SMEs and open innovation: applications and investigations*. P. 40-64 (2012).

KANG, M.; KIM, M.; LEE, J. H. Analisis of Rigid Pavement Distresses on Interstate Highway Using Decision Tree Algorithms. *Journal Of Civil Engineering*, v. 2, n. 14, p.123-130, 2010.

KENNEDY, Glenn. Nitrofuranos em Avicultura. In: SIMPÓSIO BRASIL SUL DE AVICULTURA, Não use números Romanos ou letras, use somente números Arábicos., 2003, Chapecó. Anais... . Chapecó: Embrapa, 2003. p. 20 - 32. Disponível em: <http://www.cnpsa.embrapa.br/sgc/sgc_publicacoes/anais0304_bsa_kennedy.pdf>. Acesso em: 25 mar. 2016.

KEPPLE, A. W.; CORREA, A. M. S. C. Conceituando e medindo segurança alimentar e nutricional. *Ciência e Saúde Coletiva*, v. 16 (1), p. 187-199, 2011.

KIANG, Melody Y.. Extending the Kohonen self-organizing map networks for clustering analysis. *Computational Statistics & Data Analysis*, v. 38, p.161-180, 01 maio 2001.

KOTSIANTIS*, Sotiris. A hybrid decision tree classifier. *Journal Of Intelligent & Fuzzy Systems*, Patras, v. 26, p.327-336, 2014.

KOUVARIS, Kostas et al. How Evolution Learns to Generalise: Principles of under-fitting, over-fitting and induction in the evolution of developmental organisation. *Quantitative Biology*, v. 1, p.1-28, 27 ago. 2015. Disponível em: <<http://arxiv.org/format/1508.06854v1>>. Acesso em: 20 mar. 2016.

LIMA, G. C. Pesquisa e Desenvolvimento de um Método de Aprendizagem de Máquina: Agrupamento Incremental. 2015. 80 f. TCC (Graduação) - Curso de Engenharia de Software, Faculdade Unb Gama, Universidade de Brasília, Brasília, 2015.

LIN, Keng-pei; CHEN, Ming-syan. On the Design and Analysis of the Privacy-Preserving SVM Classifier. *Ieee Trans. Knowl. Data Eng.*, v. 23, n. 11, p.1704-1717, nov. 2011. Institute of Electrical & Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/tkde.2010.193>.

MALISCH, Rainer; KOTX, Alexander. Dioxins and PCBs in feed and food - Review from European perspective. *Science of the Total Environment*, Freiburg, v. 10, n. 2, p.491-492, 2014.

MCEVOY, J.d.g.. Contamination of animal feedingstuffs as a cause of residues in food: a review of regulatory aspects, incidence and control. *Analytica Chimica Acta*, v. 473, p.3-26, 11 jul. 2002.

MCMULLEN, Patrick R. A Kohonen self-organizing map approach to addressing a multiple objective, mixed-model JIT sequencing problem. *International Journal Of Production*

Economics, [s.l.], v. 72, n. 1, p.59-71, jun. 2001. DOI: 10.1016/s0925-5273(00)00091-8. Disponível em: <<http://api.elsevier.com/content/article/PII:S0925527300000918?httpAccept=text/xml>>. Acesso em: 19 fev. 2016.

MITCHELL, T. Machine Learning. New York, NY: McGraw-Hill, 1997. ISBN 0-07-042807-7.

MOHR, M.; ROSTAMIZADEH, A.; TALWALKAR, A. Foundations of Machine Learning. [S.l.: s.n.], 2012

MURTHY, Sreerama K.. Automatic Construction of Decision Trees from Data: A Multi-Disciplinary Survey. Data Mining And Knowledge Discovery, Princeton, v. 2, p.345-389, 1998.

PAGE, C. Innovation in gourmet and specialty food and drinks. UK: Business Insights, 2006.

PAUSTENBACH, D.J. Primer on human and environmental risk assessment. In Human and Ecological Risk Assessment. New York, USA, p. 3–83. 2002.

PEEBLES, E. D. et al. Effects of nicarbazin on the blood glucose and liver glycogen statuses of male broilers^{1,2}. Poultry Science, [s.l.], v. 91, n. 9, p.2183-2188, 21 ago. 2012. Oxford University Press. <http://dx.doi.org/10.3382/ps.2012-02343>.

PENZ JUNIOR, A. M.; BRUNO, D. G. Impacts of feed texture and particle size on broiler and layer feeding patterns. In: WORLD'S POULTRY CONGRESS. Salvador: Poultry Federation, 2012. p. 1 - 8. Disponível em: <http://www.facta.org.br/wpc2012-cd/pdfs/plenary/Antonio_Mario_Penz_Jr.pdf>. Acesso em: 01 out. 2015.

READ, J. et al. Batch-incremental versus instance-incremental learning in dynamic and evolving data. 2013. Disponível em: <<http://albertbifet.com/wp-content/uploads/2013/10/IDA2012.pdf>>.

REIG, Milagro; TOLDRÁ, Fidel. Veterinary drug residues in meat: Concerns and rapid methods for detection. Meat Science, v. 78, n. 1-2, p.60-67, jan. 2008. <http://dx.doi.org/10.1016/j.meatsci.2007.07.029>.

RUGGIERI, S. Yadt: Yet another decision tree builder. Generated on Tue Oct 19 2010 13:09:32 for YaDTby 1.7.1 <http://www.di.unipi.it/~ruggieri> Version 1.2.5 (October 2010) (c) Salvatore Ruggieri, 2002-2010 <http://www.di.unipi.it/~ruggieri>

RUGGIERI, S. Yadt: Yet another decision tree builder. In: Proceedings of the 16th International Conference on Tools with Artificial Intelligence. Computer Society, 2004. p. 260–265. ISBN 0-7695-2236-X.

SAINI, D.; RAJAVAT. A. Performance Evaluation System for Decision Tree Algorithms. International Journal of Computers & Technology, 01 nov. 2013, v.11 (8), p.2879-2886.

SALZBERG, Steven L. Book Review: C4.5: by J. Ross Quinlan..Boston: Kluwer Academic Publisher, 1994. 5 p.

SCHINCKEL, A.P.; RICHERT, B.T.; HERR, C.T. et al. Development of a model to describe the compositional growth and dietary lysine requirements of pig fed ractopamine. *Journal of Animal Science*, v.81, p.1106-1119, 2003.

SHAH-HOSSEINI, H. Binary tree time adaptive self-organizing map. *Neurocomputing*, Tehran, v. 74, p.1823-1839, 01 mar. 2011.

SHAH-HOSSEINI, H.; SAFABAKHSH, R.. TASOM: A New Time Adaptive Self-Organizing Map. *Transactions On Systems*, Tehran, v. 33, p.271-282, 02 abr. 2003.

SILVA, W. V. et al. Avaliação da Escolha de um fornecedor sob Condição de Riscos a partir do Método de Árvores de Decisão. *Revista de Gestão USP*, São Paulo, v. 15, n. 3, p. 77-94, jul.-set., 2008.

SINCLAIR, Neil et al. An Advanced SOM Algorithm Applied to Handover Management Within LTE. *Ieee Transactions On Vehicular Technology*, Glasgow, v. 5, n. 62, p.1883-1894, 2013.

STIGLIC, Gregor et al. Comprehensive Decision Tree Models in Bioinformatics. *Plos One*, [s.l.], v. 7, n. 3, p.1-14, 30 mar. 2012. Public Library of Science (PLoS). DOI: 10.1371/journal.pone.0033812.

THOMPSON, Colin S. et al. Effective monitoring for ractopamine residues in samples of animal origin by SPR biosensor and mass spectrometry. *Analytica Chimica Acta*, [s.l.], v. 608, n. 2, p.217-225, fev. 2008. Elsevier BV. <http://dx.doi.org/10.1016/j.aca.2007.12.019>.

UNITED STATE DEPARTMENT OF AGRICULTURAL. Livestock & Meat International Trade Data. 2015. Disponível em: <<http://www.ers.usda.gov/data-products/livestock-meat-international-trade-data.aspx>>. Acesso em: 15 fev. 2016.

VIDYASAGAR, Mathukumalli. Identifying Predictive Features in Drug Response Using Machine Learning: Opportunities and Challenges. *Annu. Rev. Pharmacol. Toxicol.*, [s.l.], v. 55, n. 1, p.15-34, 6 jan. 2015. Annual Reviews. DOI: 10.1146/annurev-pharmtox-010814-124502.

ZHANG, H. et al. Decision trees for identifying predictors of treatment effectiveness in clinical trials and its application to ovulation in a study of women with polycystic ovary syndrome. *Human Reproduction*, [s.l.], v. 25, n. 10, p.2612-2621, 17 ago. 2010. Oxford University Press (OUP). DOI: 10.1093/humrep/deq210.

ZYLBERSZTAJN, D.; FARINA E. M. Q. Strictly coordinated food-systems: exploring the limits of the Coasian Firm. *International Food and Agrobusiness Management Review*, Stanford, v. 2, n. 2, p. 249-265, 1999

**ANEXO A – MAPAS DE DETECÇÕES DE RESÍDOS E CONTAMINANTES EM AVES
E SUÍNOS POR ANO E SUBSTÂNCIA**

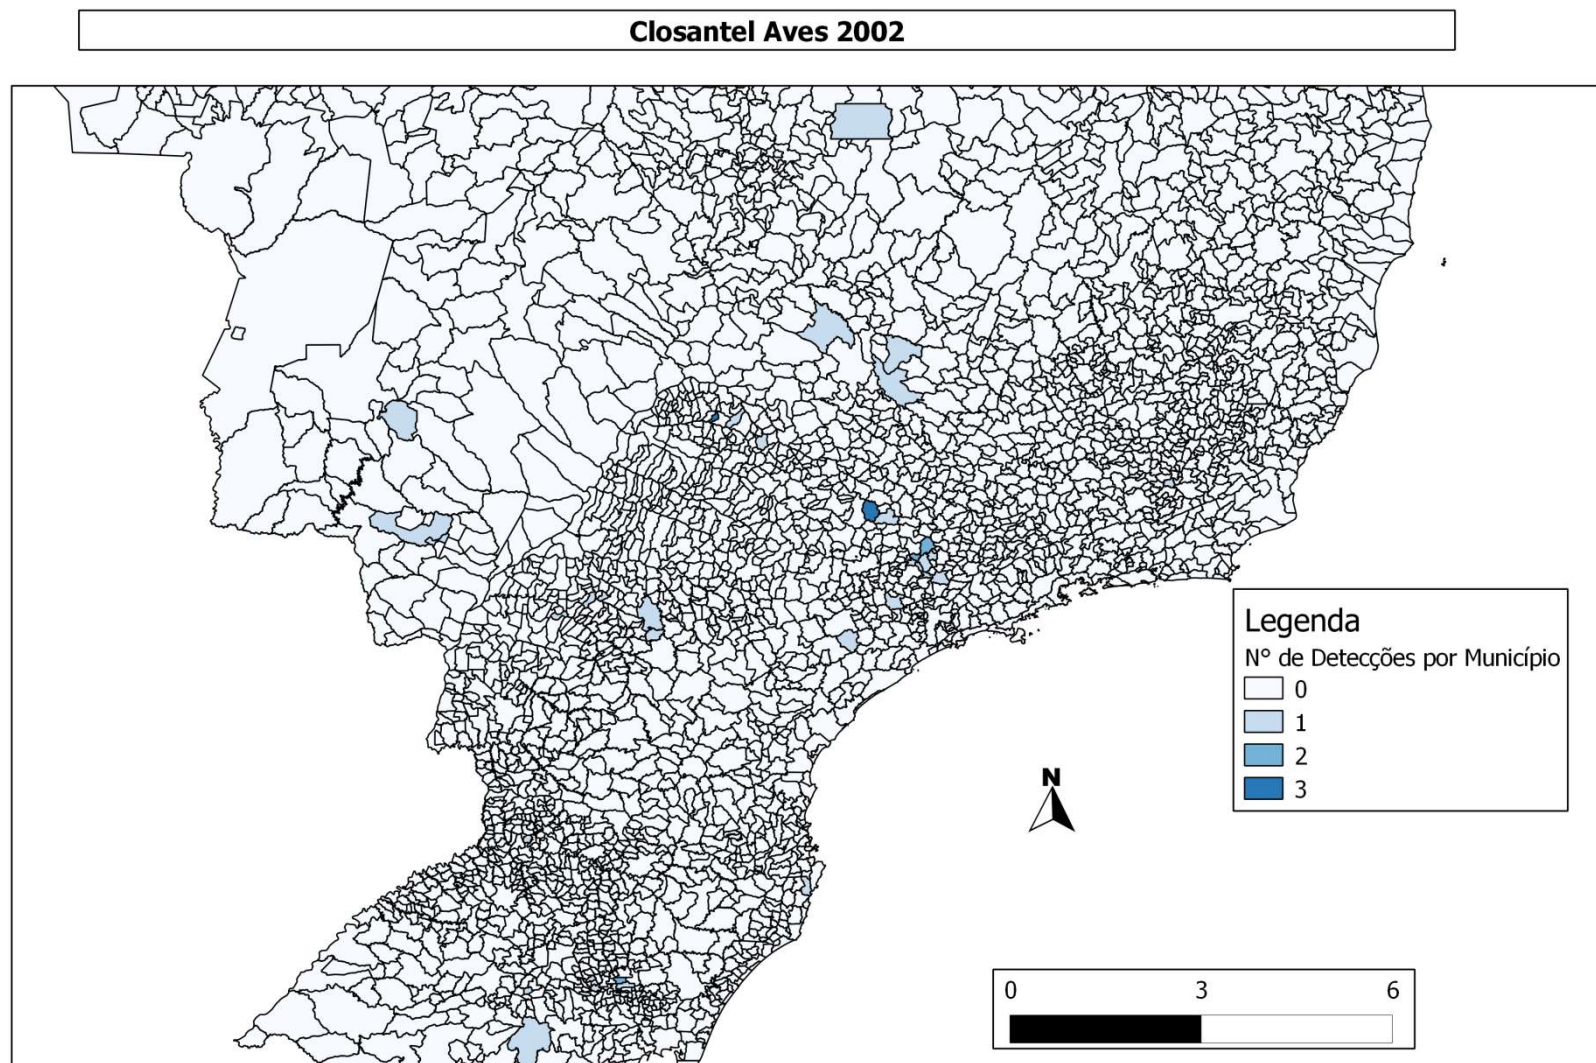


Figura 1. Detecção de Resíduo de Closantel em Aves 2002. Fonte: elaborado com dados do SISRES.

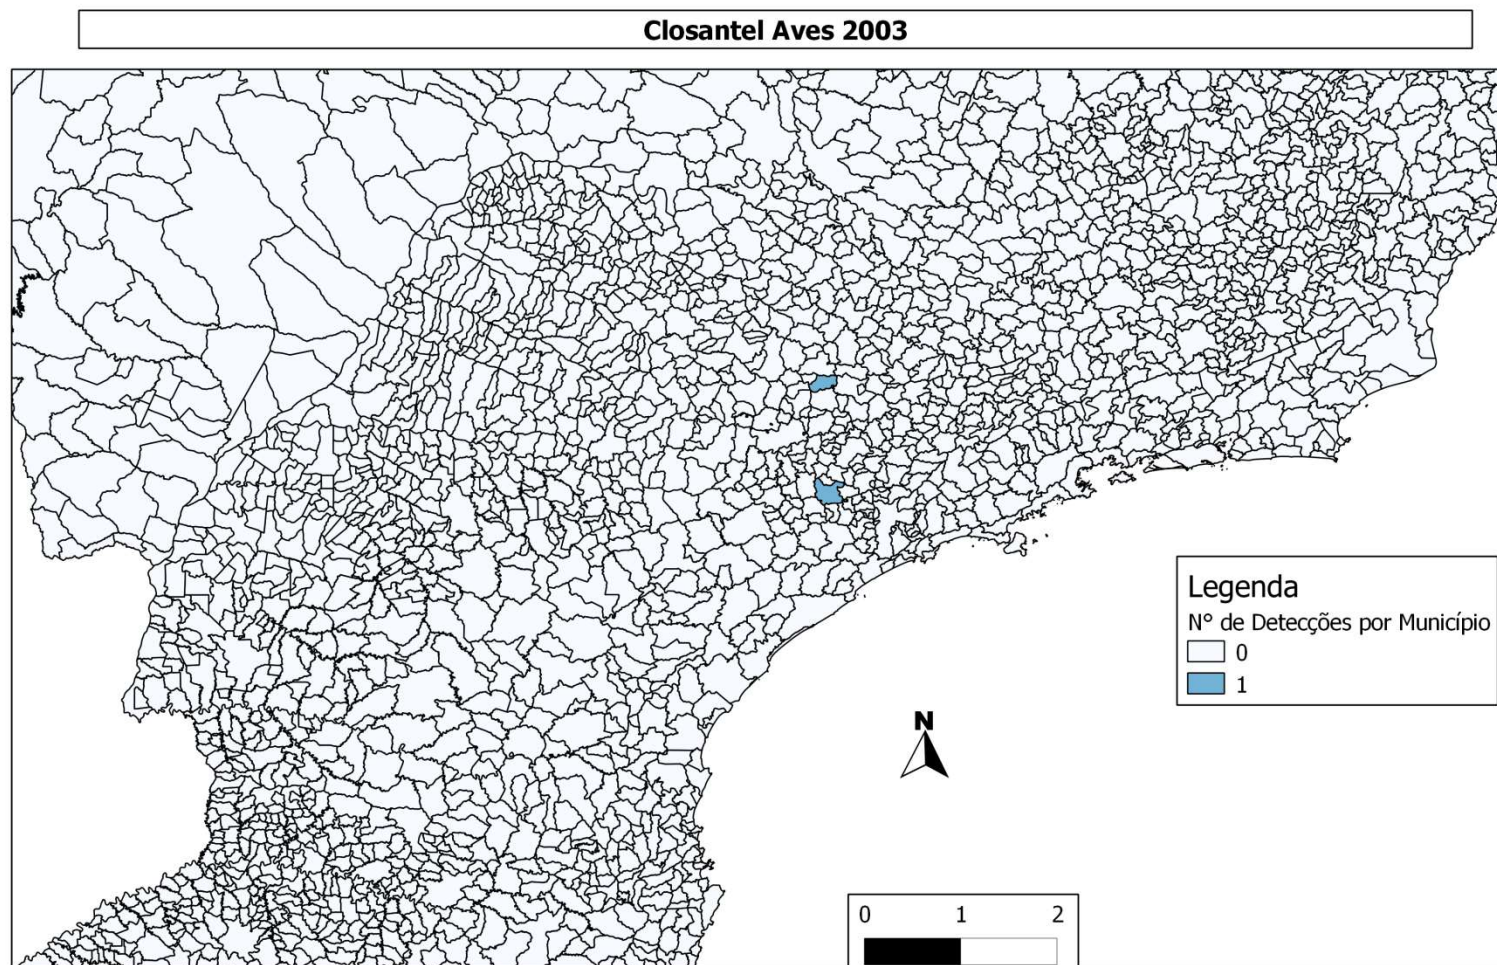


Figura 2. Detecção de Resíduo de Closantel em Aves 2003. Fonte: elaborado com dados do SISRES.

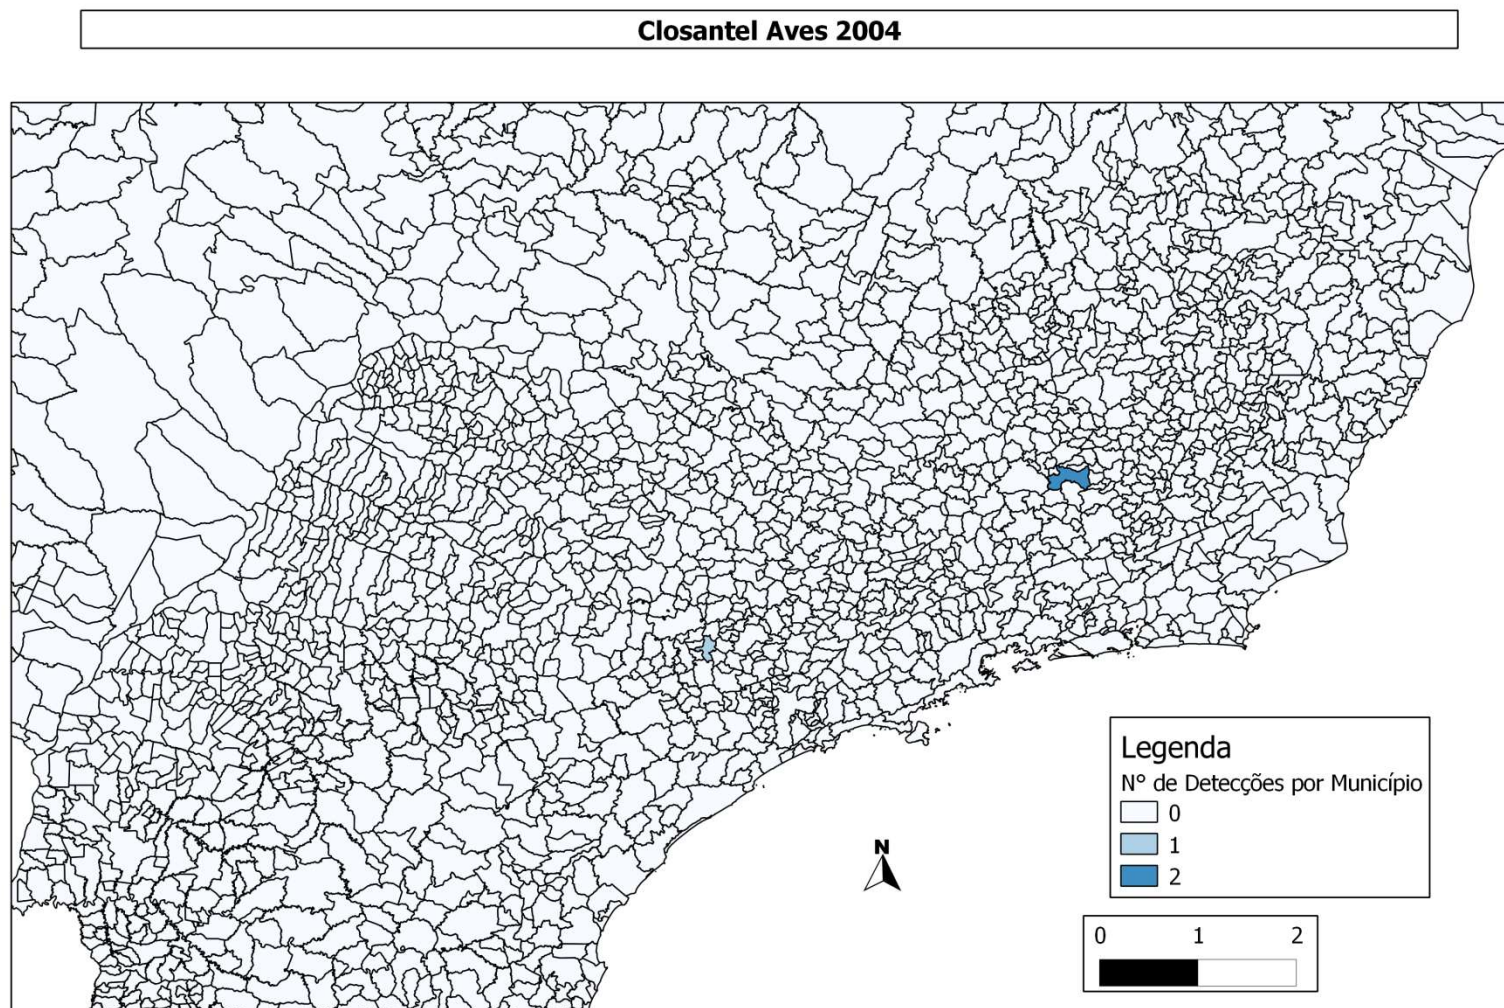


Figura 3- Detecção de Resíduos de Closantel em Aves 2004. Fonte: elaborado com dados do SISRES.

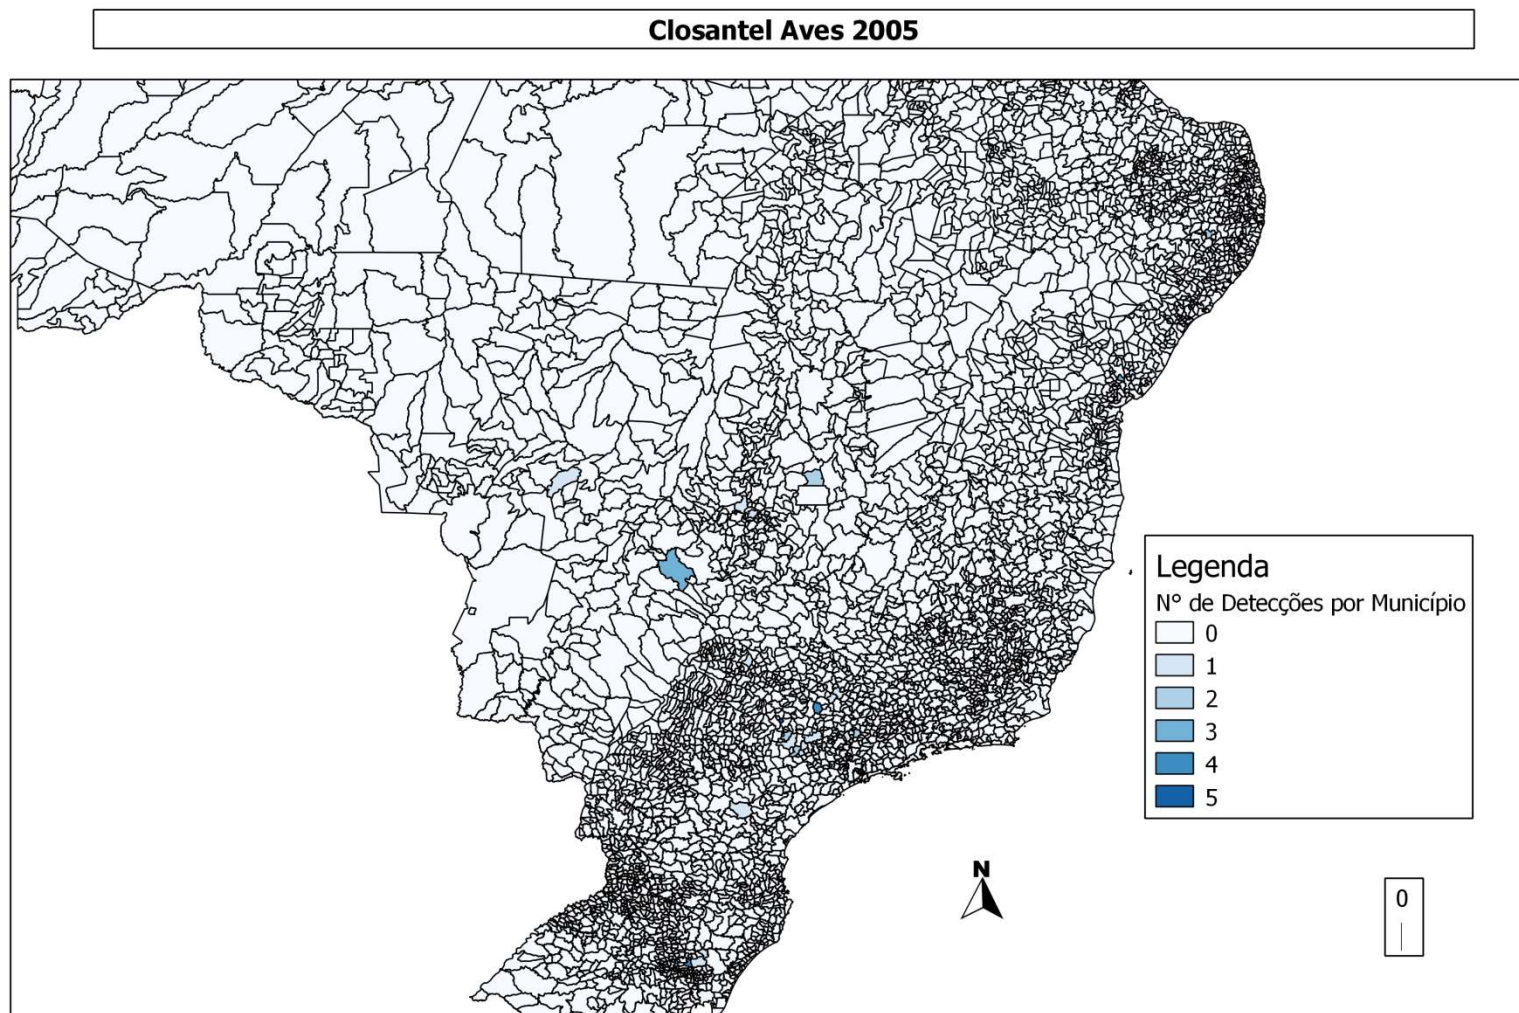


Figura 4. Detecção de Resíduos de Closantel em Aves 2005. Fonte: elaborado com dados do SISRES.

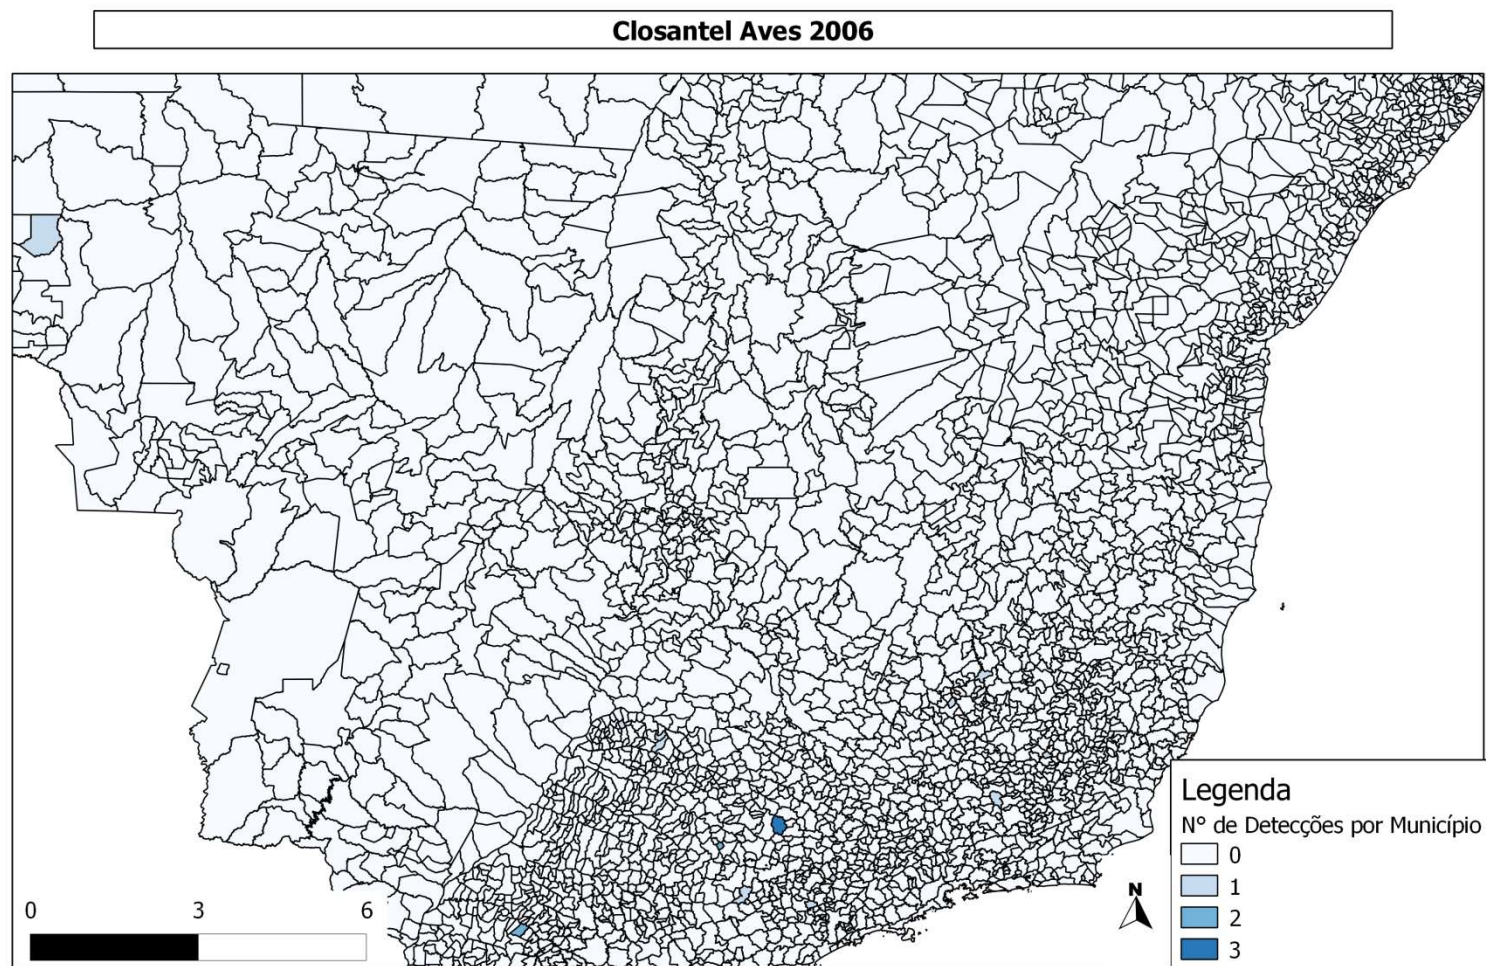


Figura 5. Detecção de Resíduos de Closantel em Aves 2006. Fonte: elaborado com dados do SISRES.

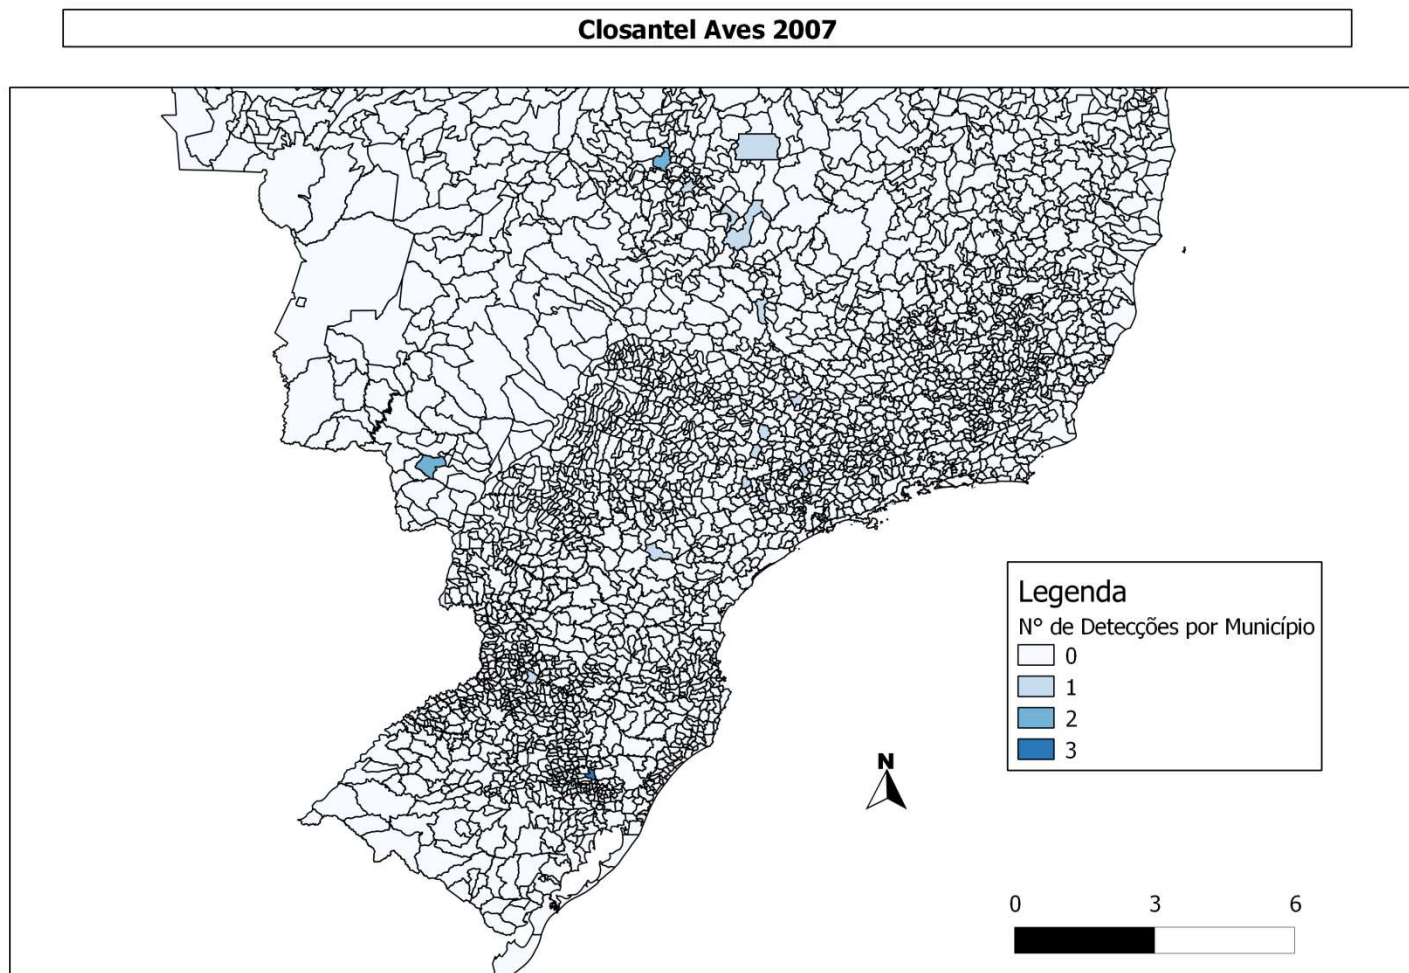


Figura 6. Detecção de Resíduos de Closantel em Aves 2007. Fonte: elaborado com dados do SISRES.

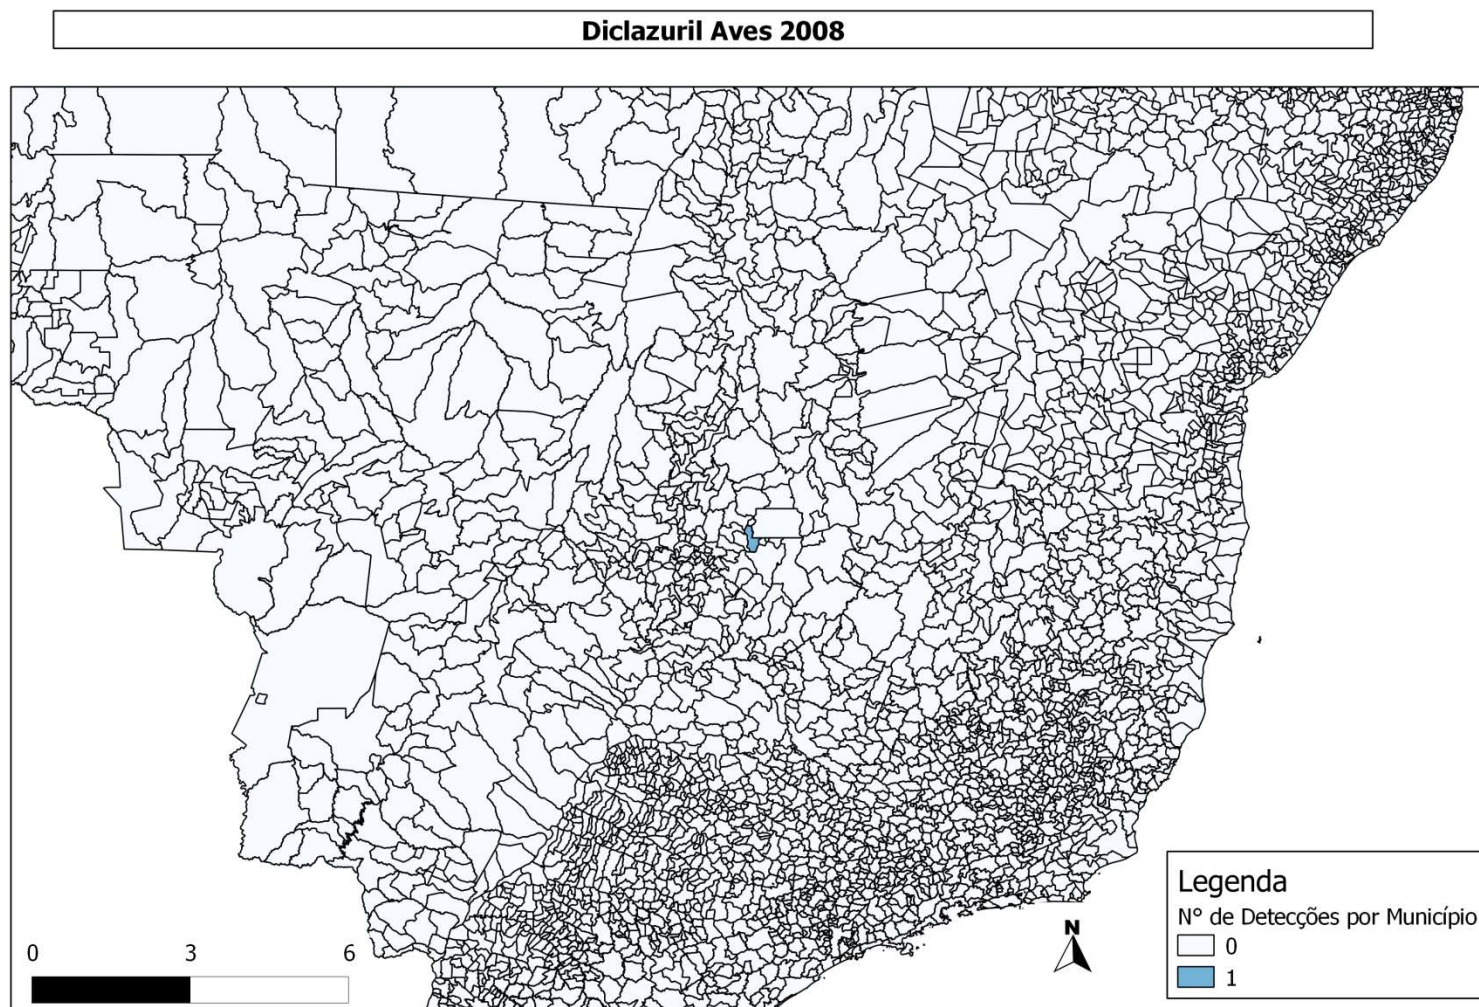


Figura 7. Detecção de Resíduos de Diclazuril em Aves 2008. Fonte: elaborado com dados do SISRES.

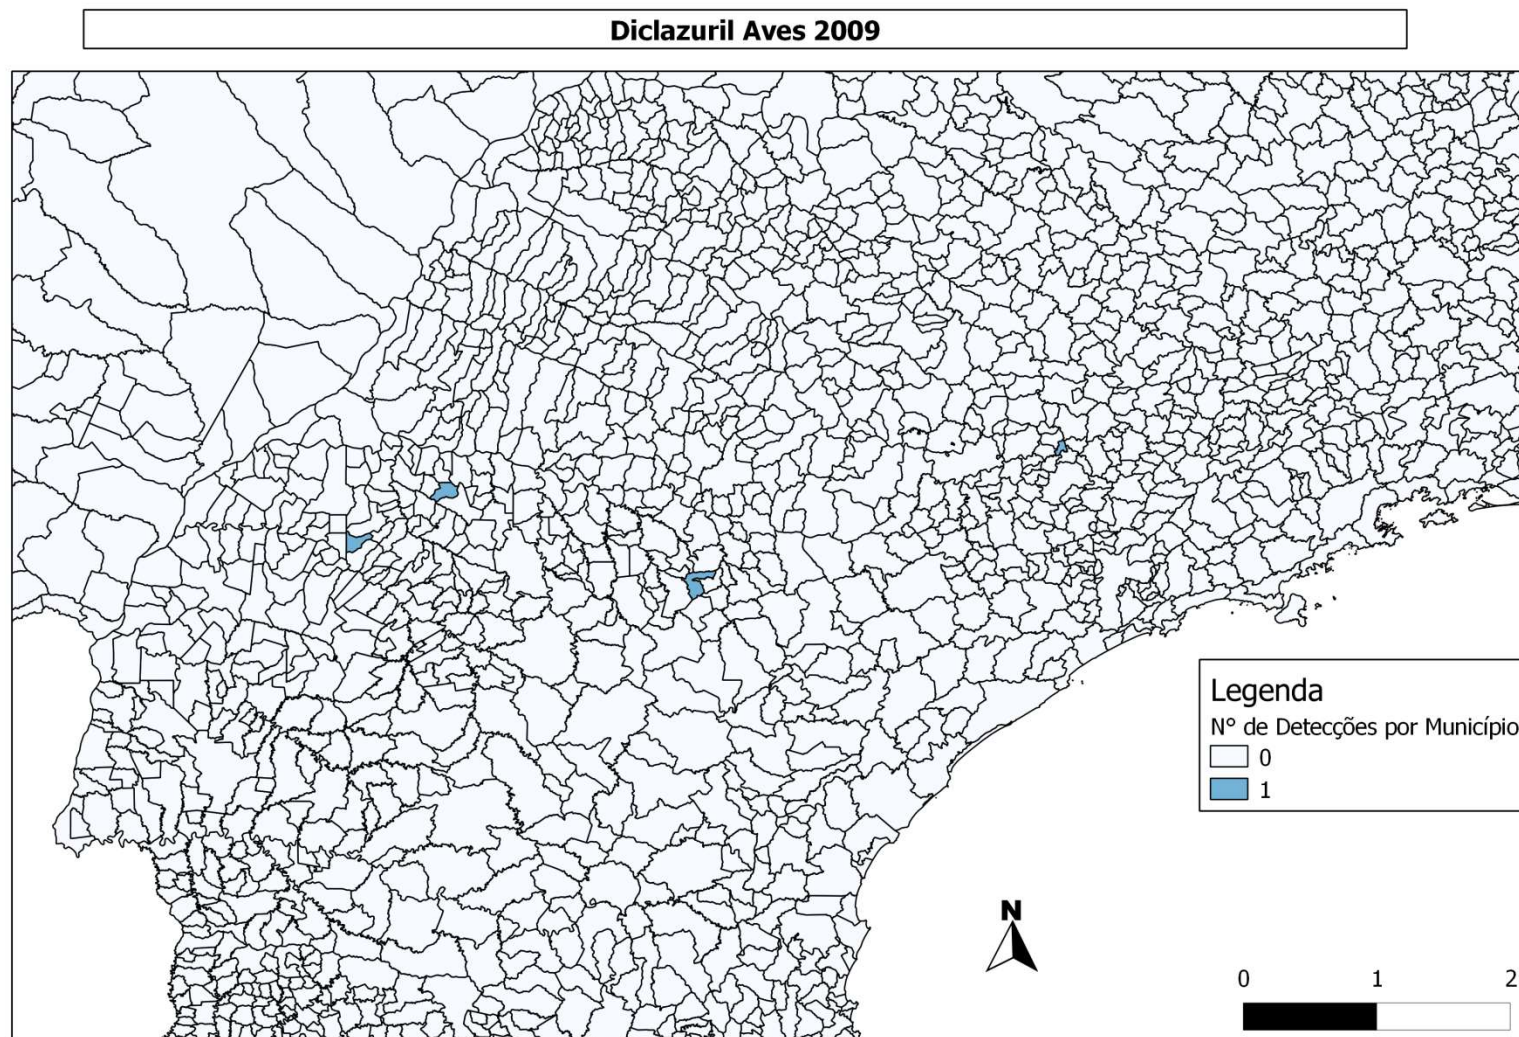


Figura 8. Detecção de Resíduos de Diclazuril em Aves 2009. Fonte: elaborado com dados do SISRES.

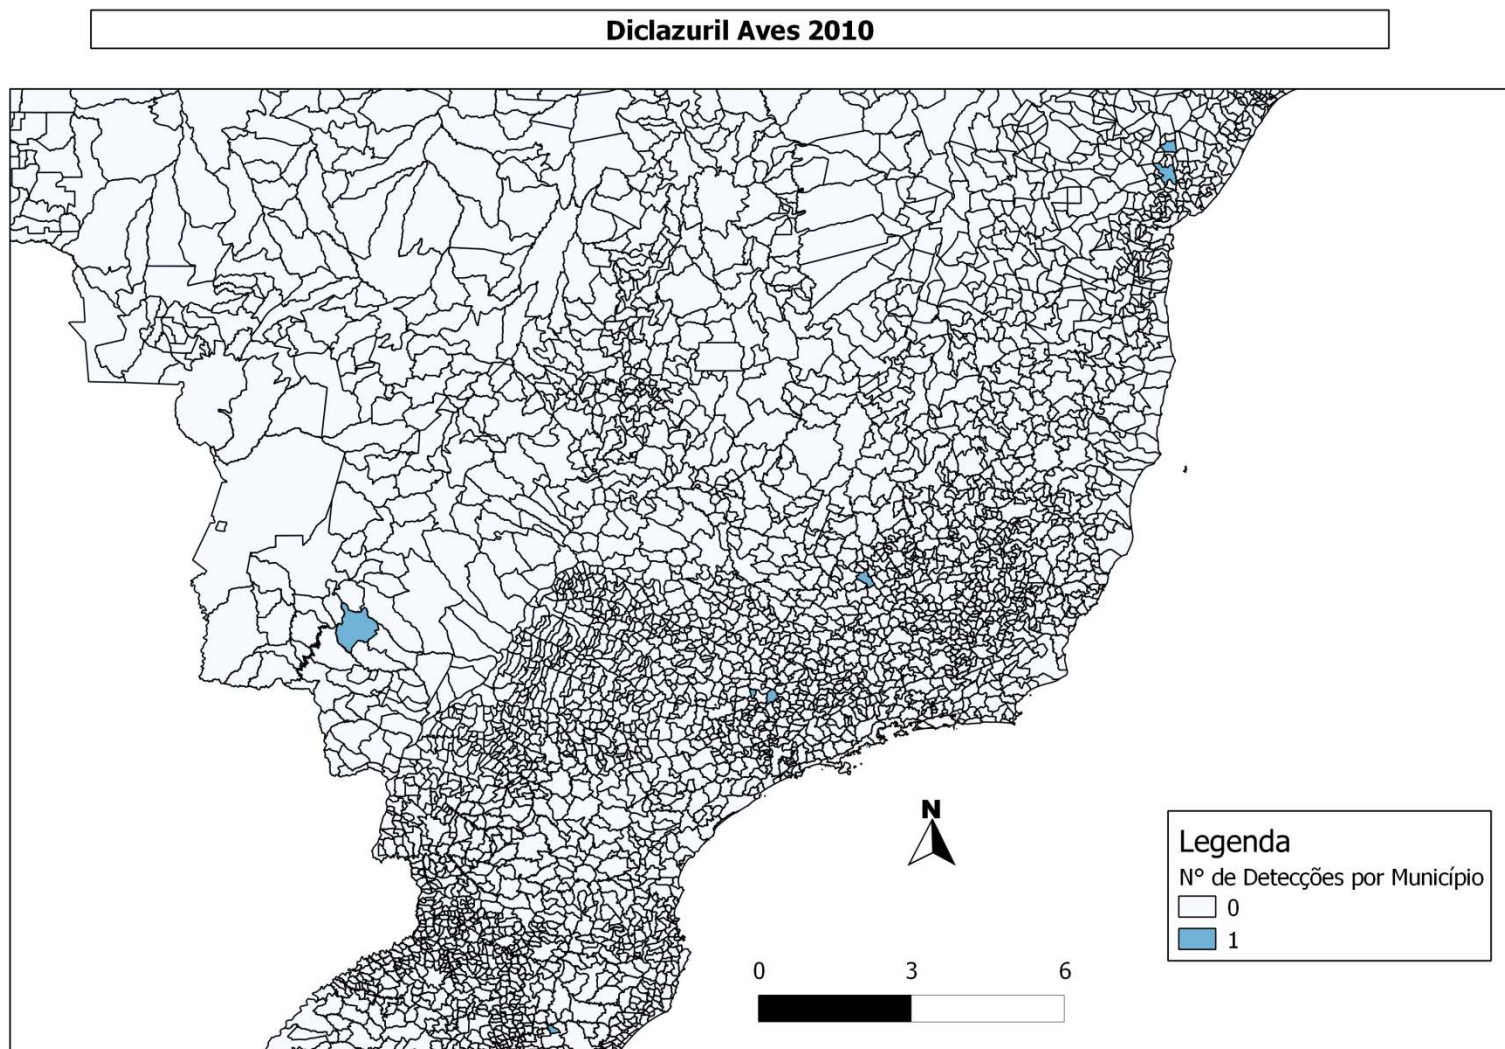


Figura 9. Detecção de Resíduos de Diclazuril em Aves 2010. Fonte: elaborado com dados do SISRES.

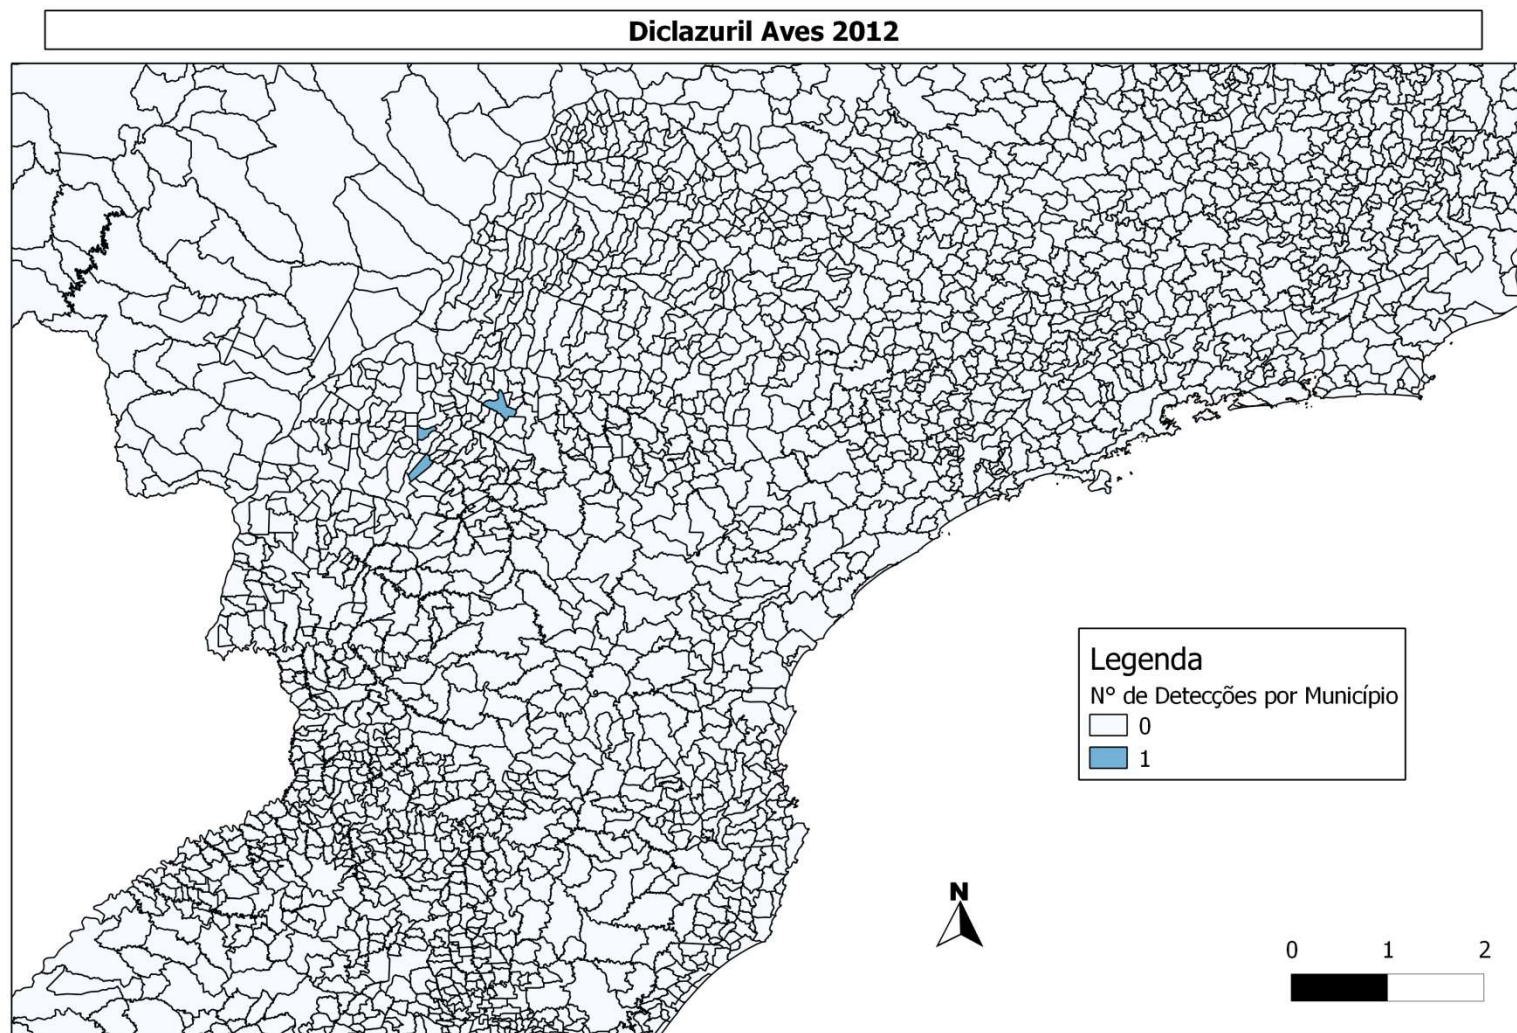


Figura 10. Detecção de Resíduos de Diclazuril em Aves 2012. Fonte: elaborado com dados do SISRES.

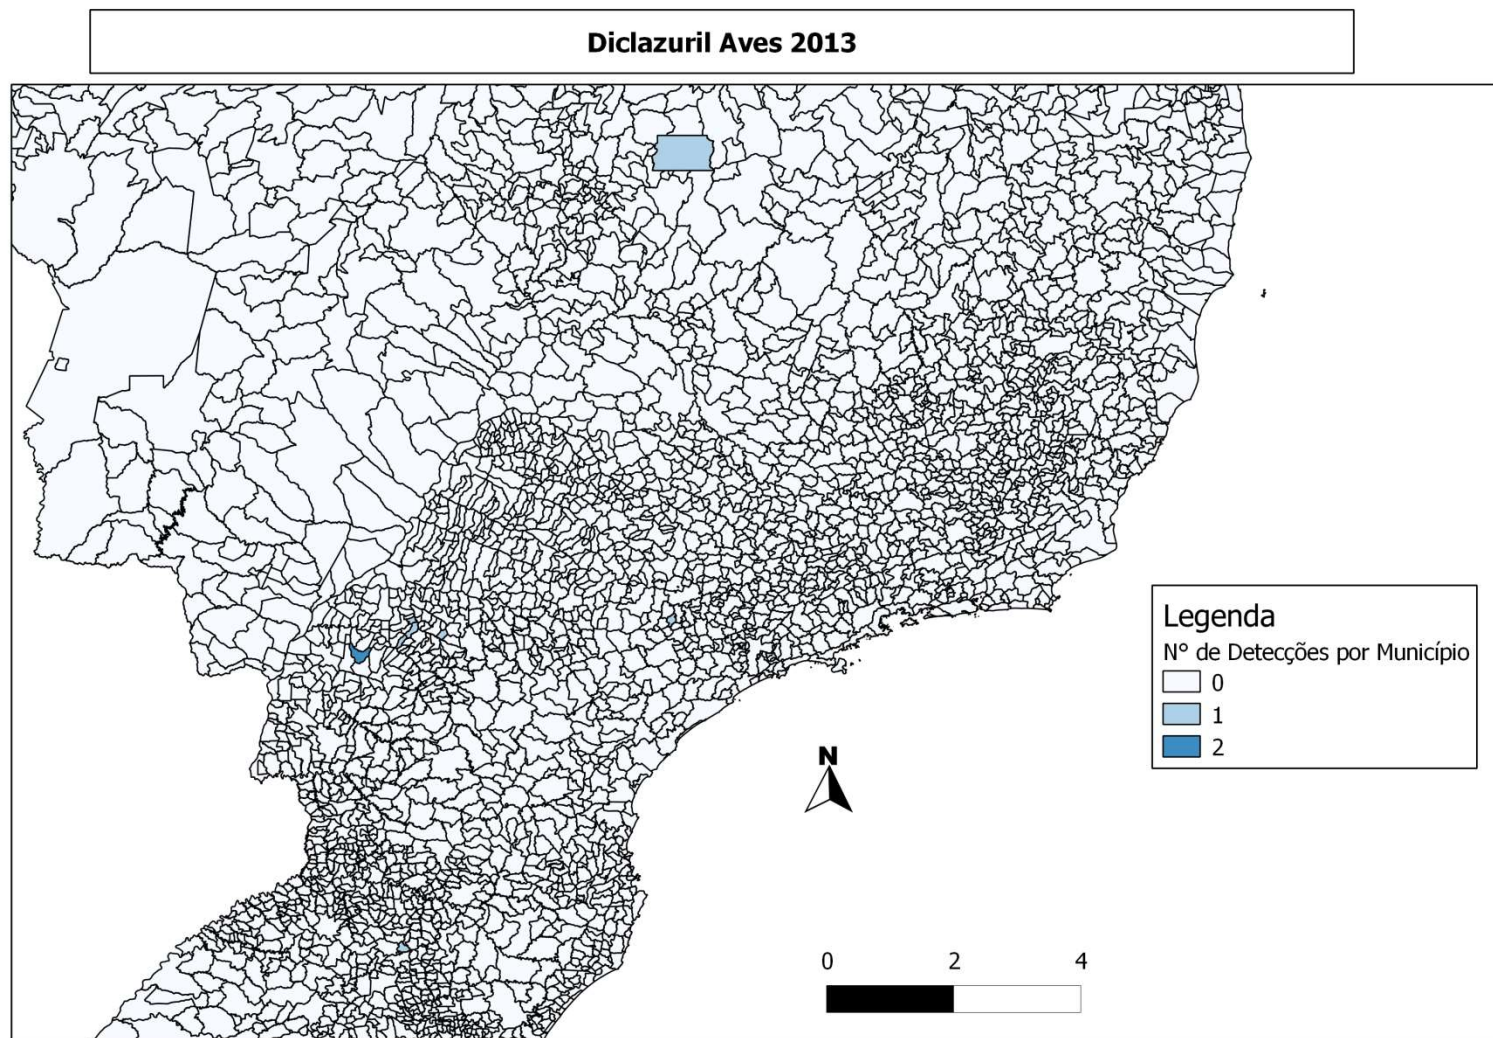


Figura 11. Detecção de Resíduos de Diclazuril em Aves 2013. Fonte: elaborado com dados do SISRES.

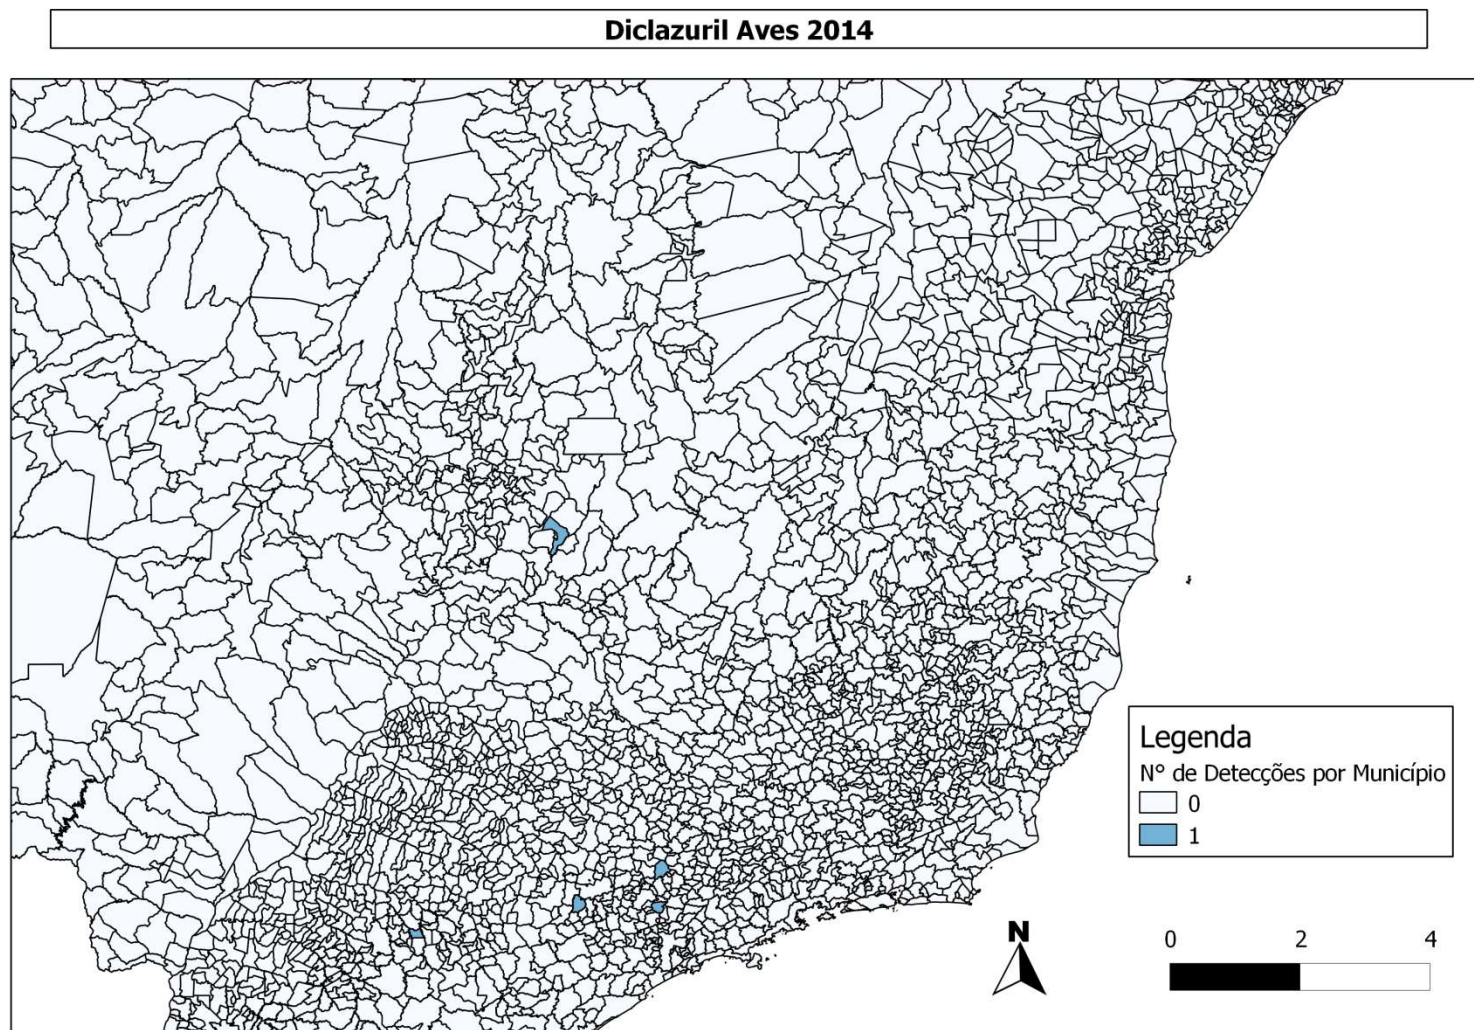


Figura 12. Detecção de Resíduos de Diclazuril em Aves 2014. Fonte: elaborado com dados do SISRES.

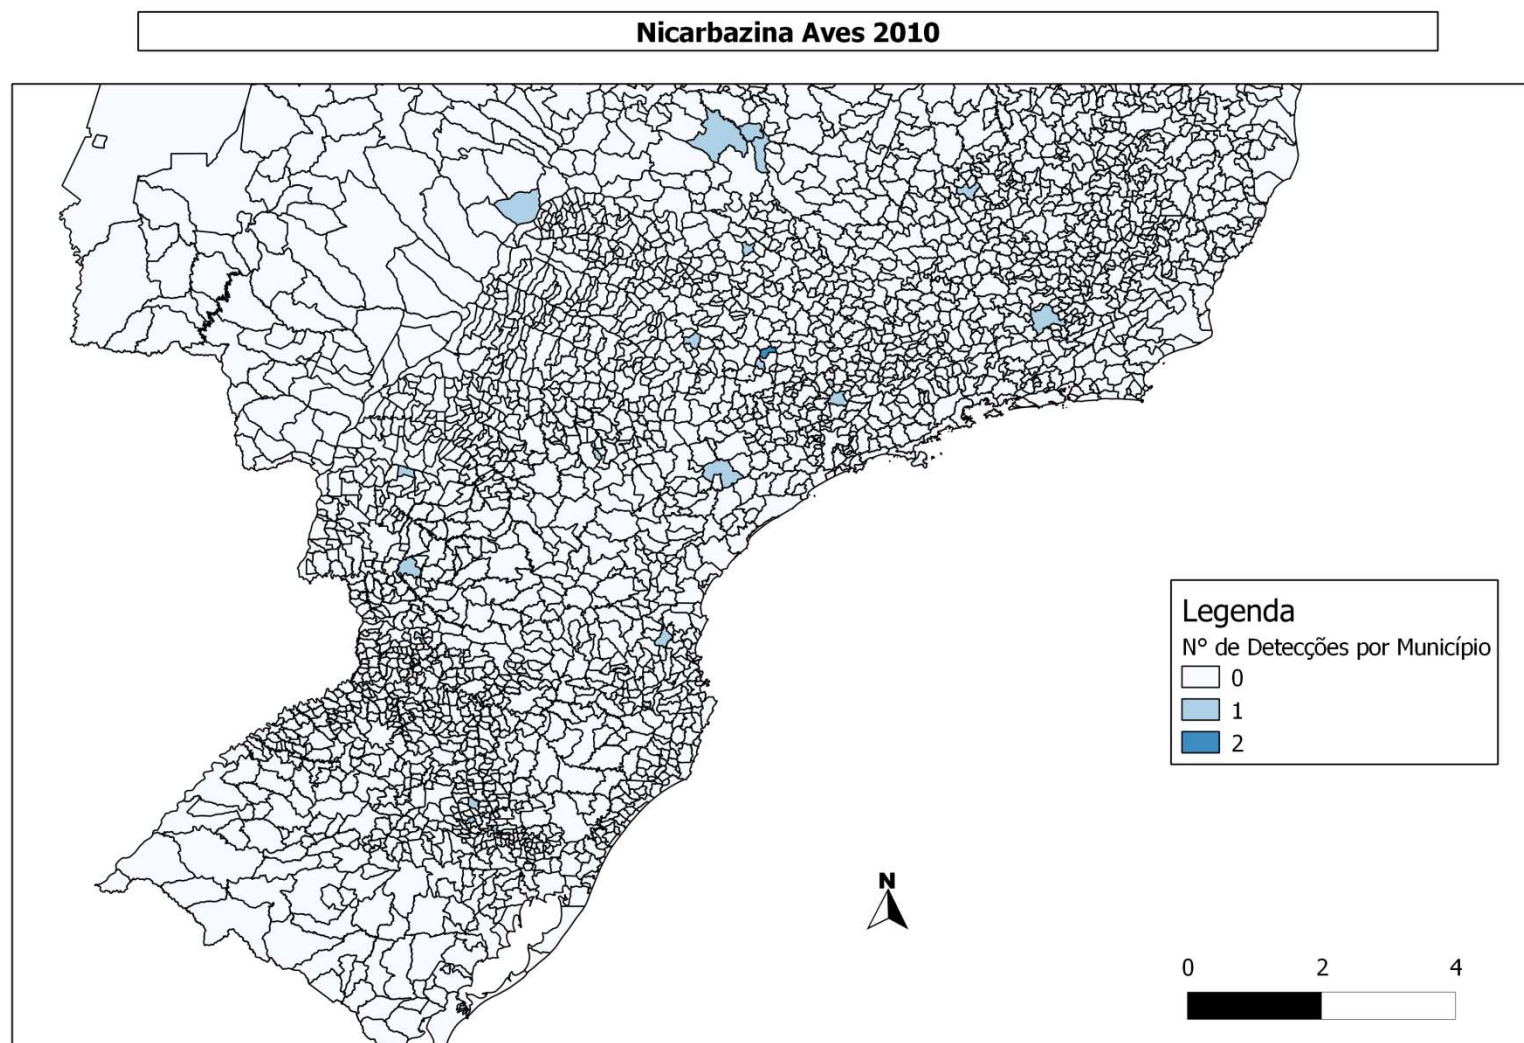


Figura 13. Detecção de Resíduos de Nicarbazina em Aves 2010. Fonte: elaborado com dados do SISRES.

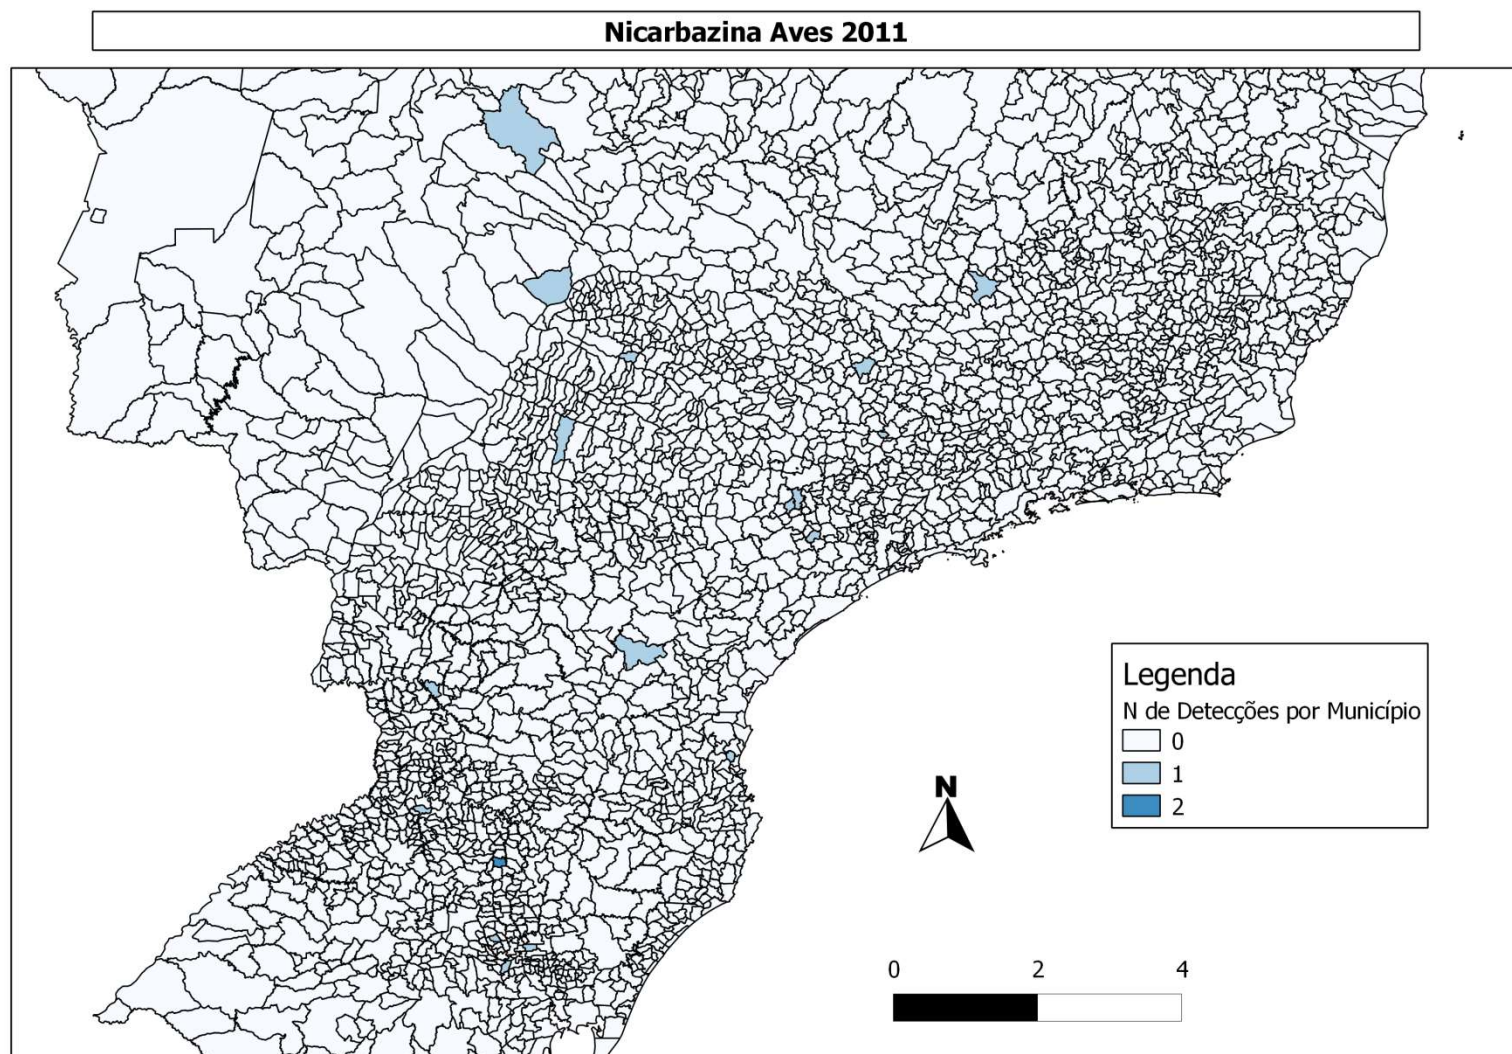


Figura 14. Detecção de Resíduos de Nicarbazina em Aves 2011. Fonte: elaborado com dados do SISRES.

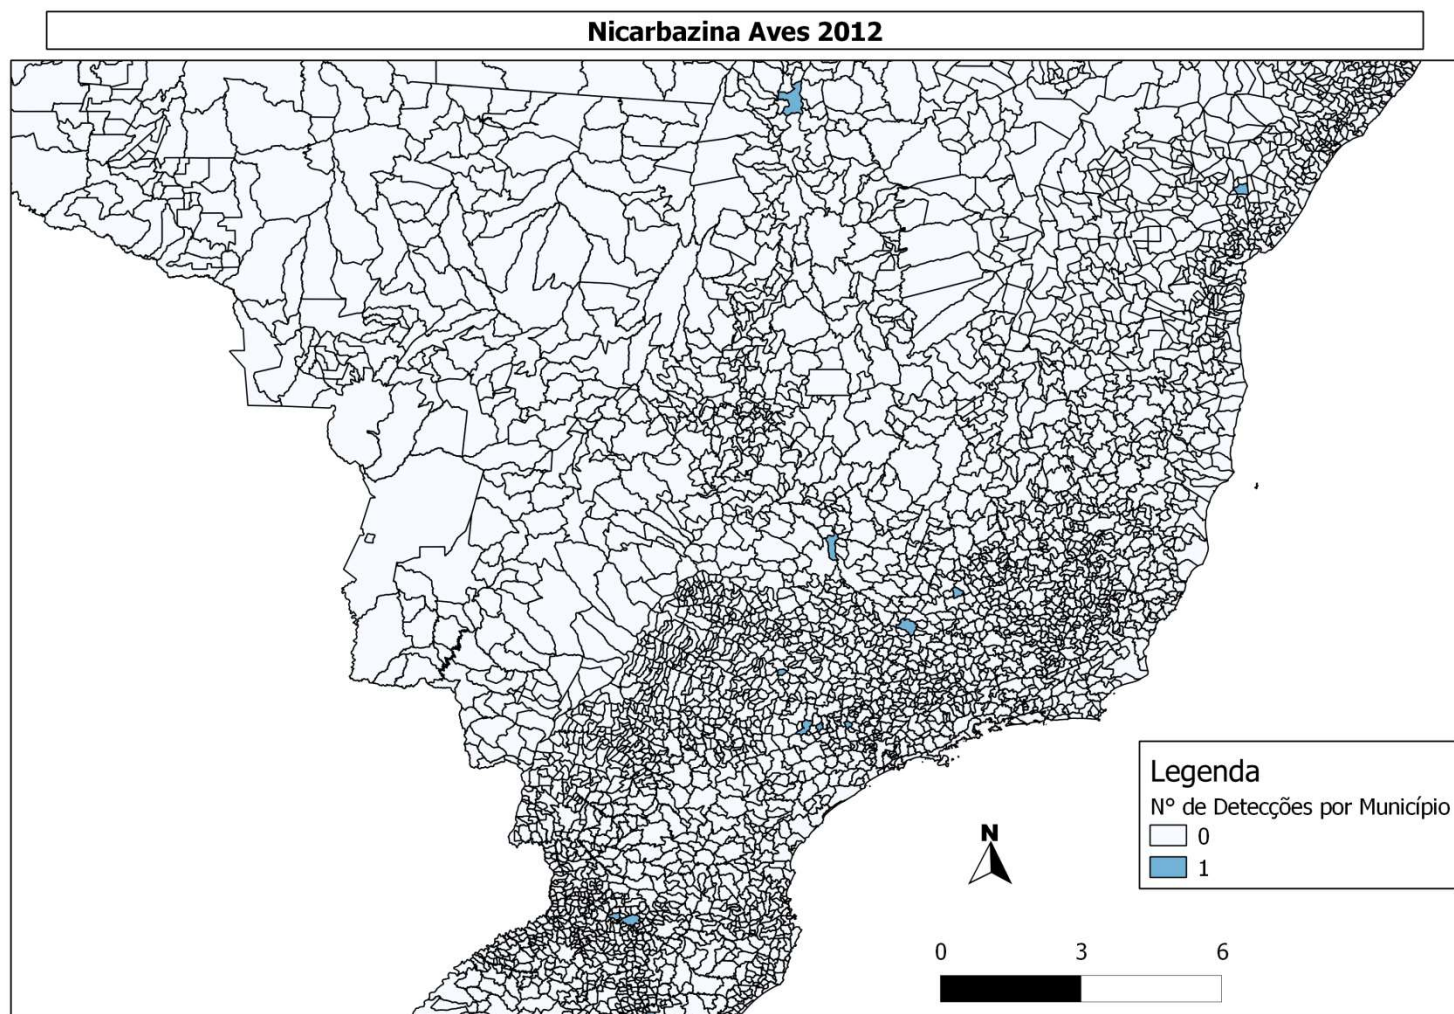


Figura 15. Detecção de Resíduos de Nicarbazina em Aves 2012. Fonte: elaborado com dados do SISRES.

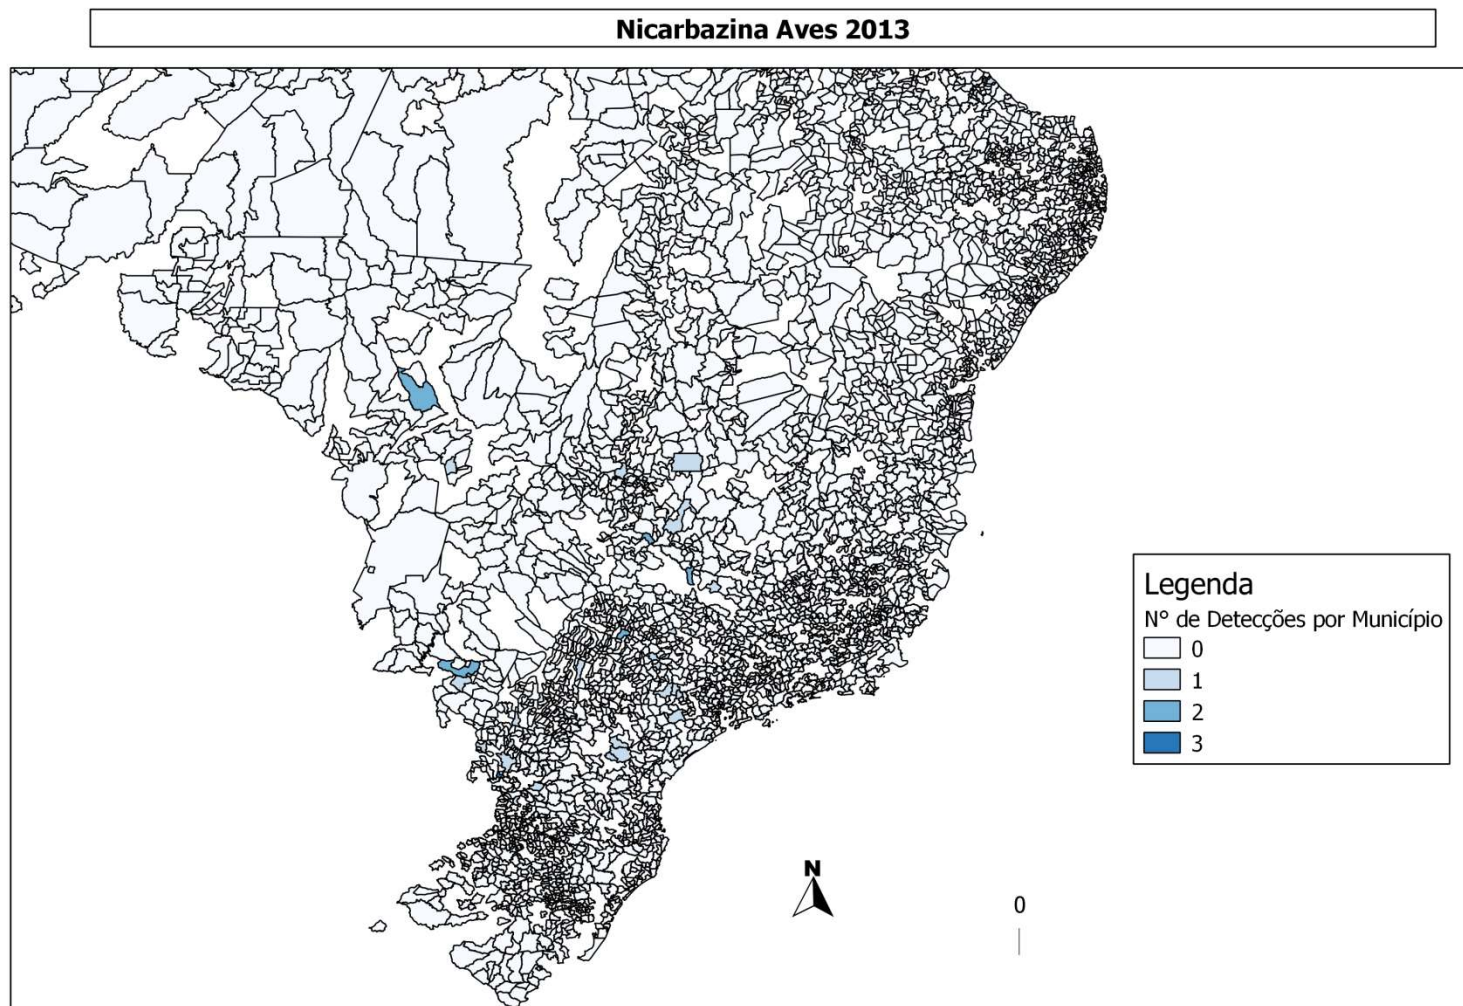


Figura 16. Detecção de Resíduos de Nicarbazina em Aves 2013. Fonte: elaborado com dados do SISRES.

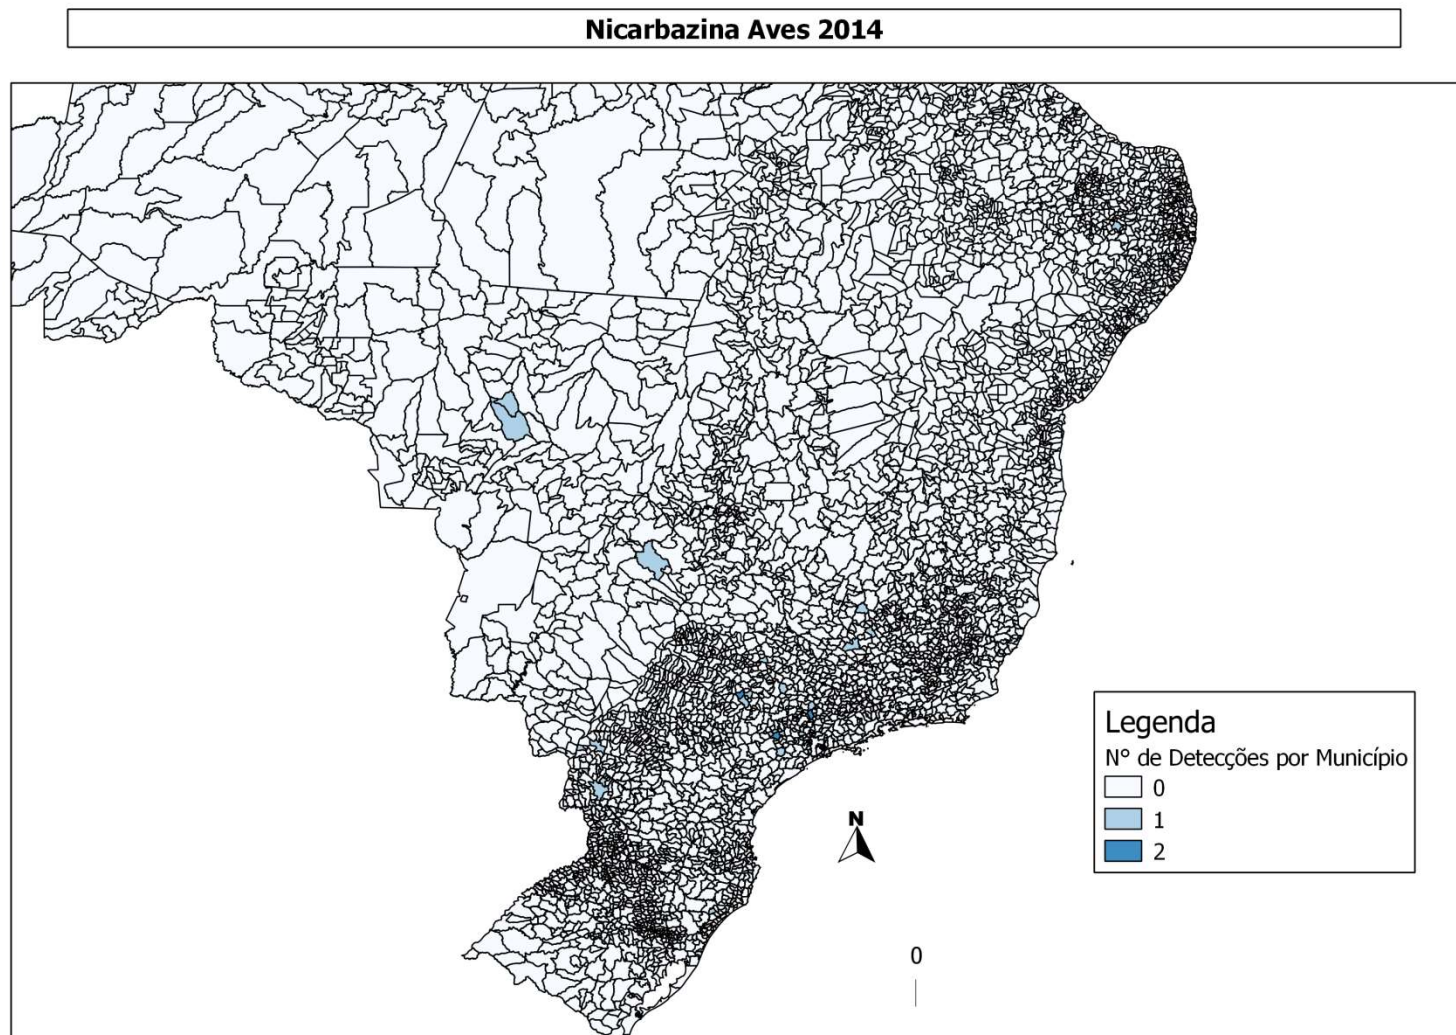


Figura 17. Detecção de Resíduos de Nicarbazina em Aves 2014. Fonte: elaborado com dados do SISRES.

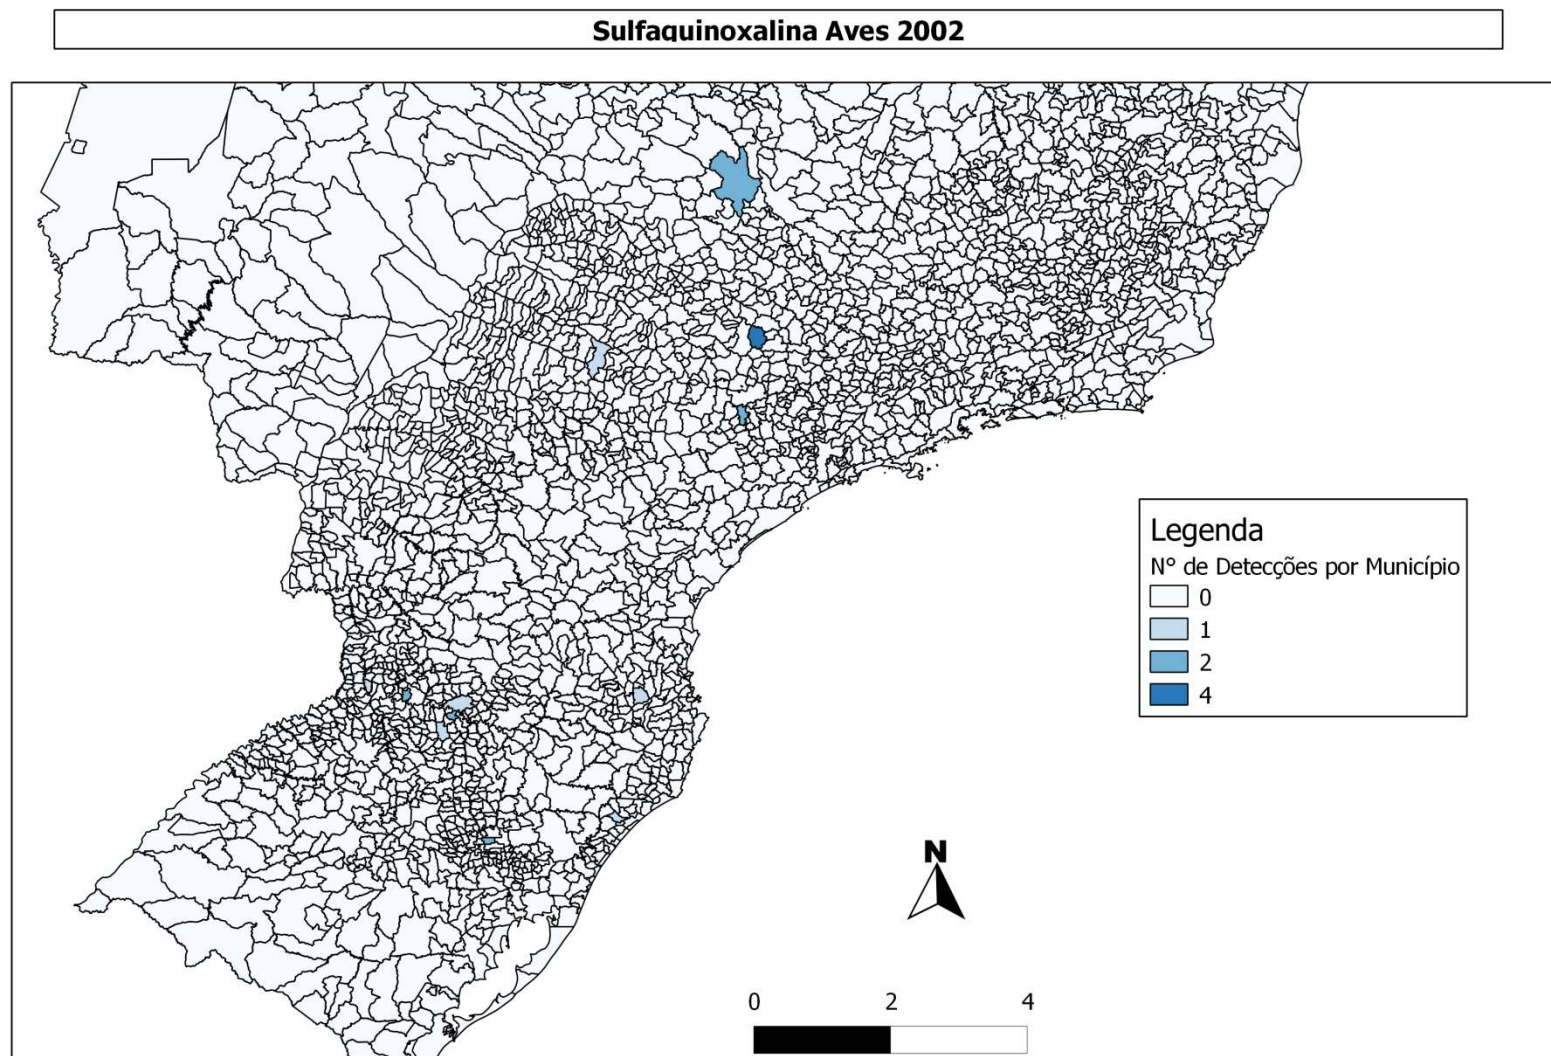


Figura 18. Detecção de Resíduos de Sulfaquinoxalina em Aves 2002. Fonte: elaborado com dados do SISRES.

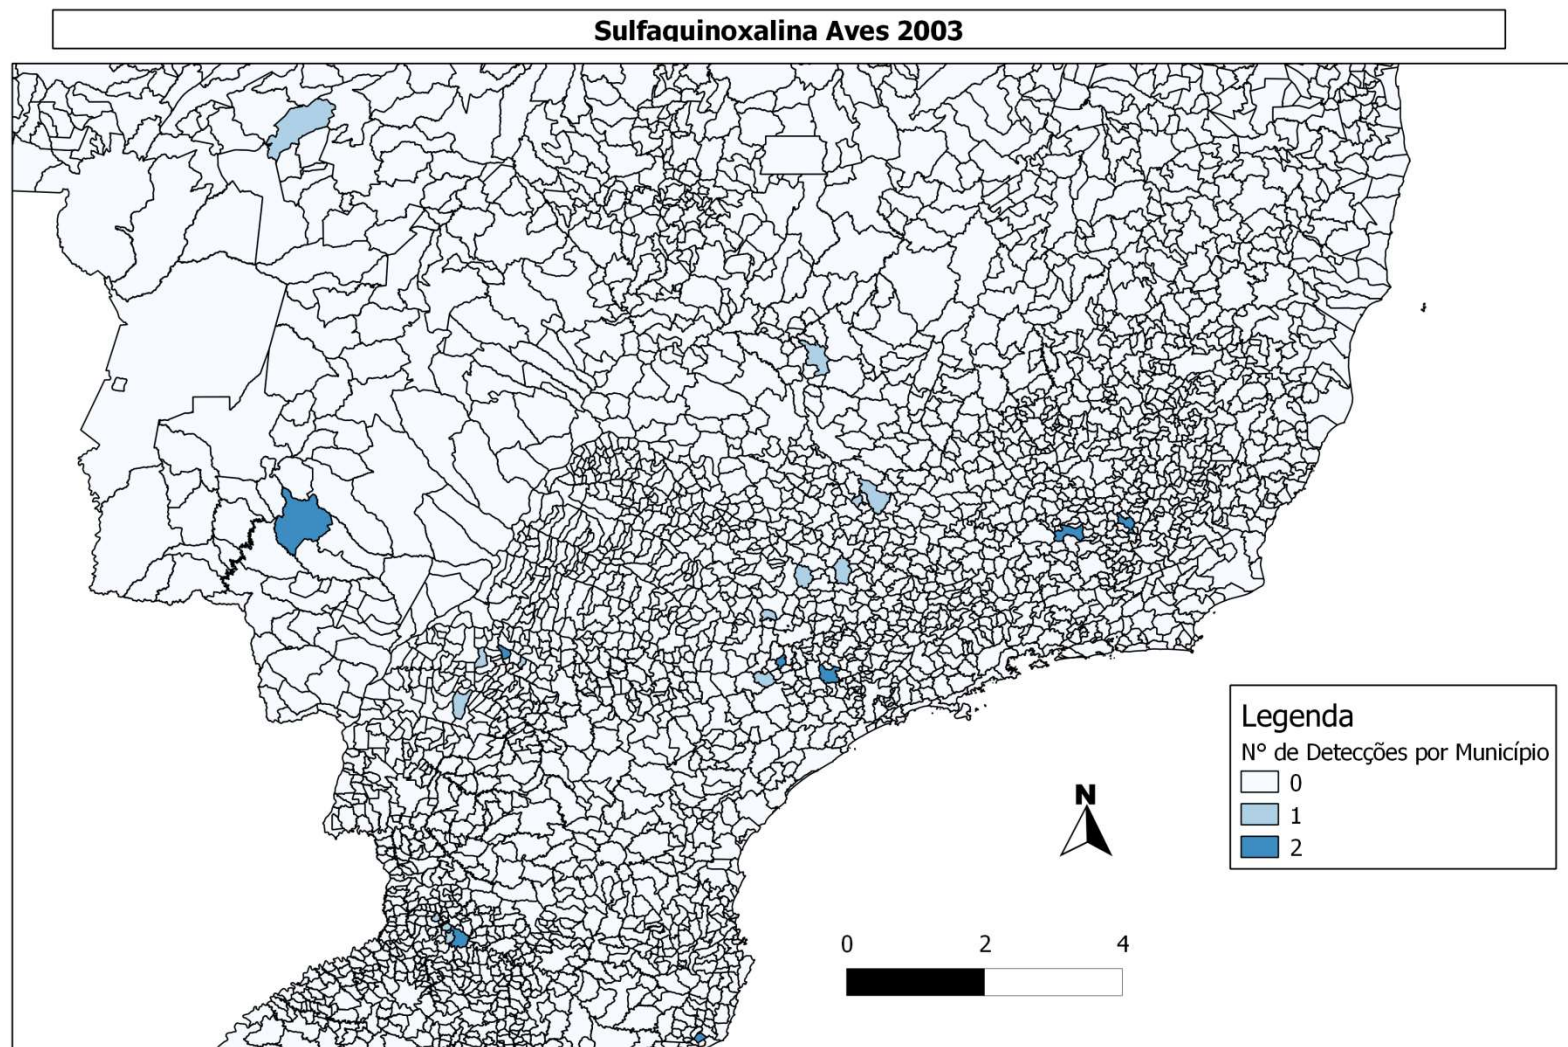


Figura 19. Detecção de Resíduos de Sulfaquinoxalina em Aves 2003. Fonte: elaborado com dados do SISRES.

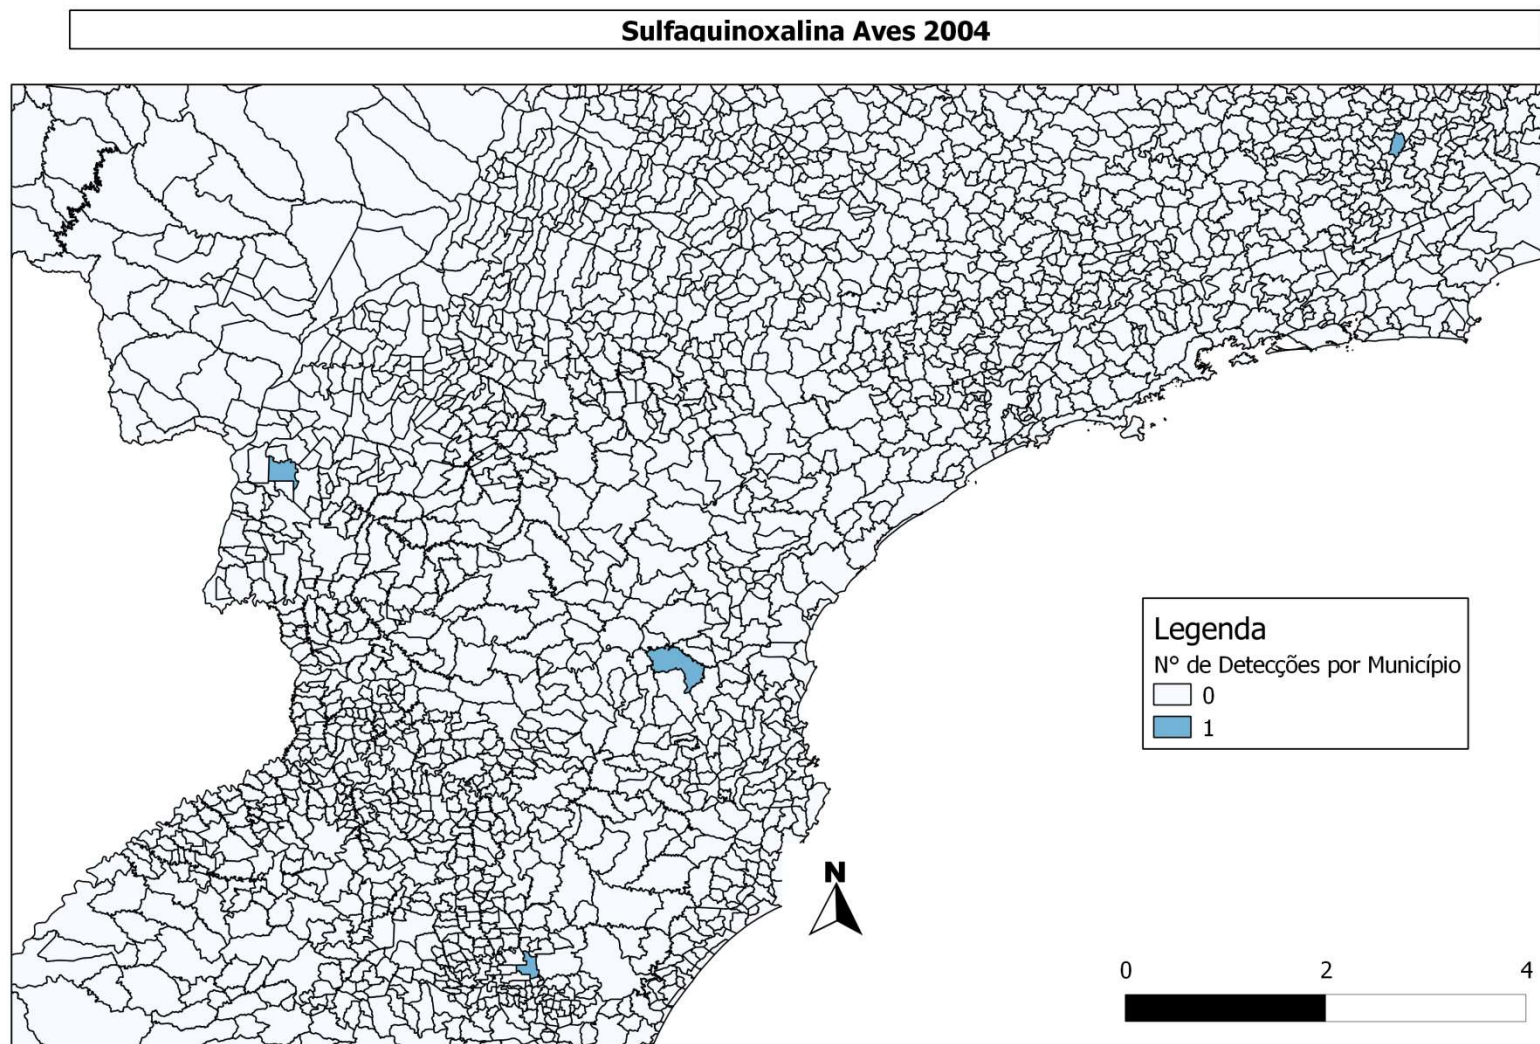


Figura 20. Detecção de Resíduos de Sulfaquinoxalina em Aves 2004. Fonte: elaborado com dados do SISRES.

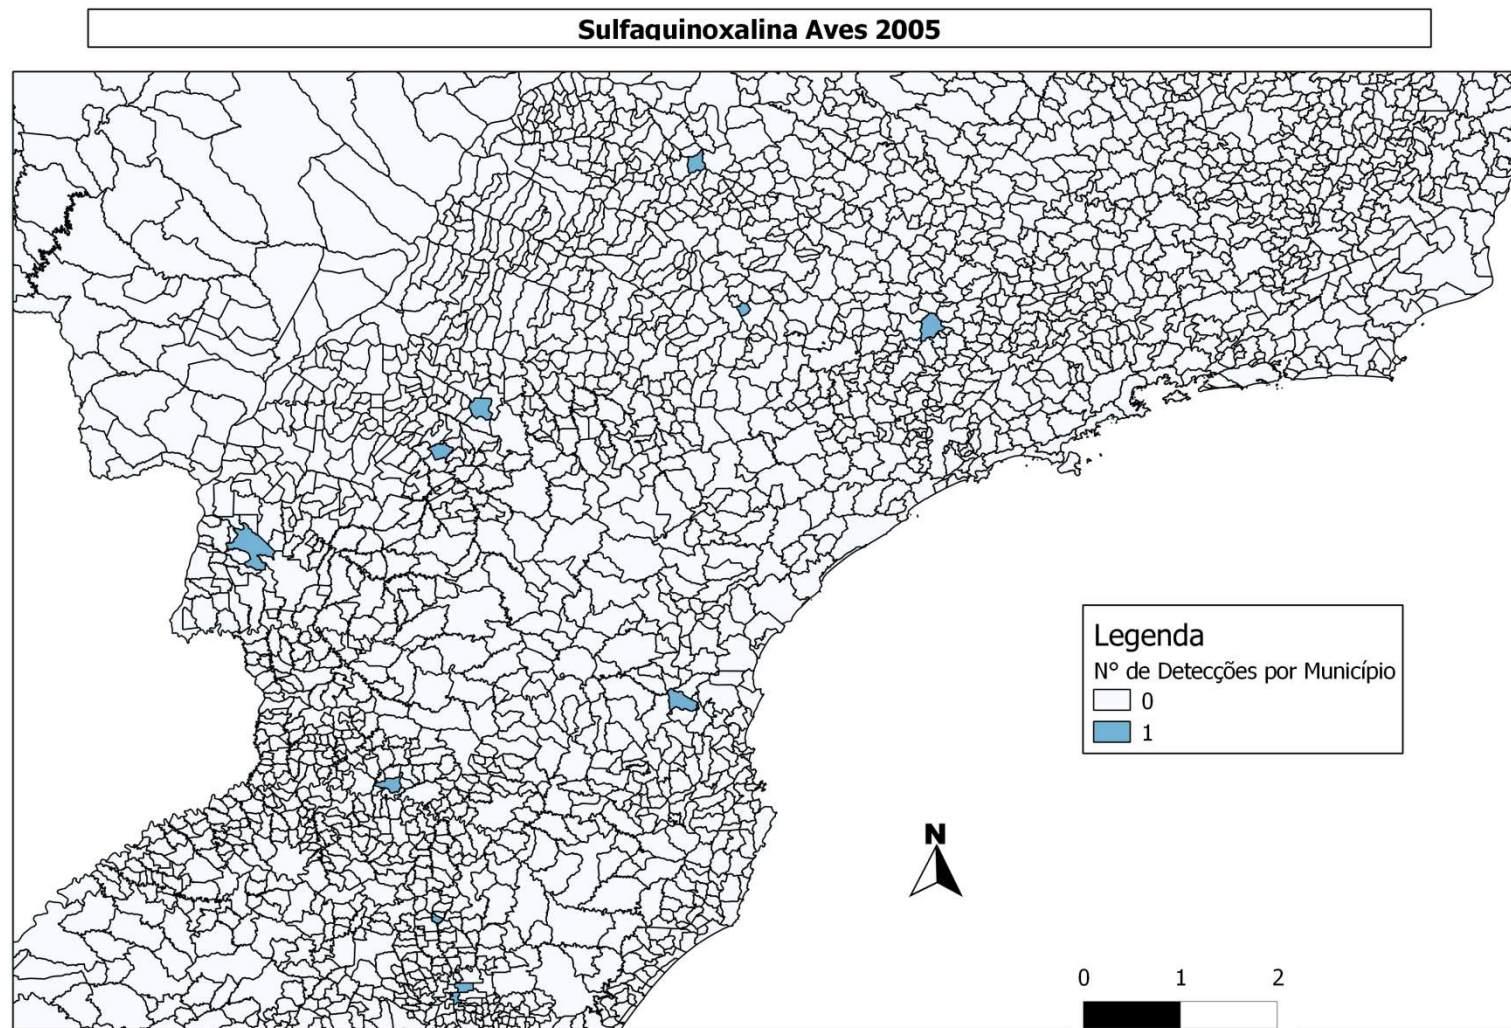


Figura 21. Detecção de Resíduos de Sulfaquinoxalina em Aves 2005. Fonte: elaborado com dados do SISRES.

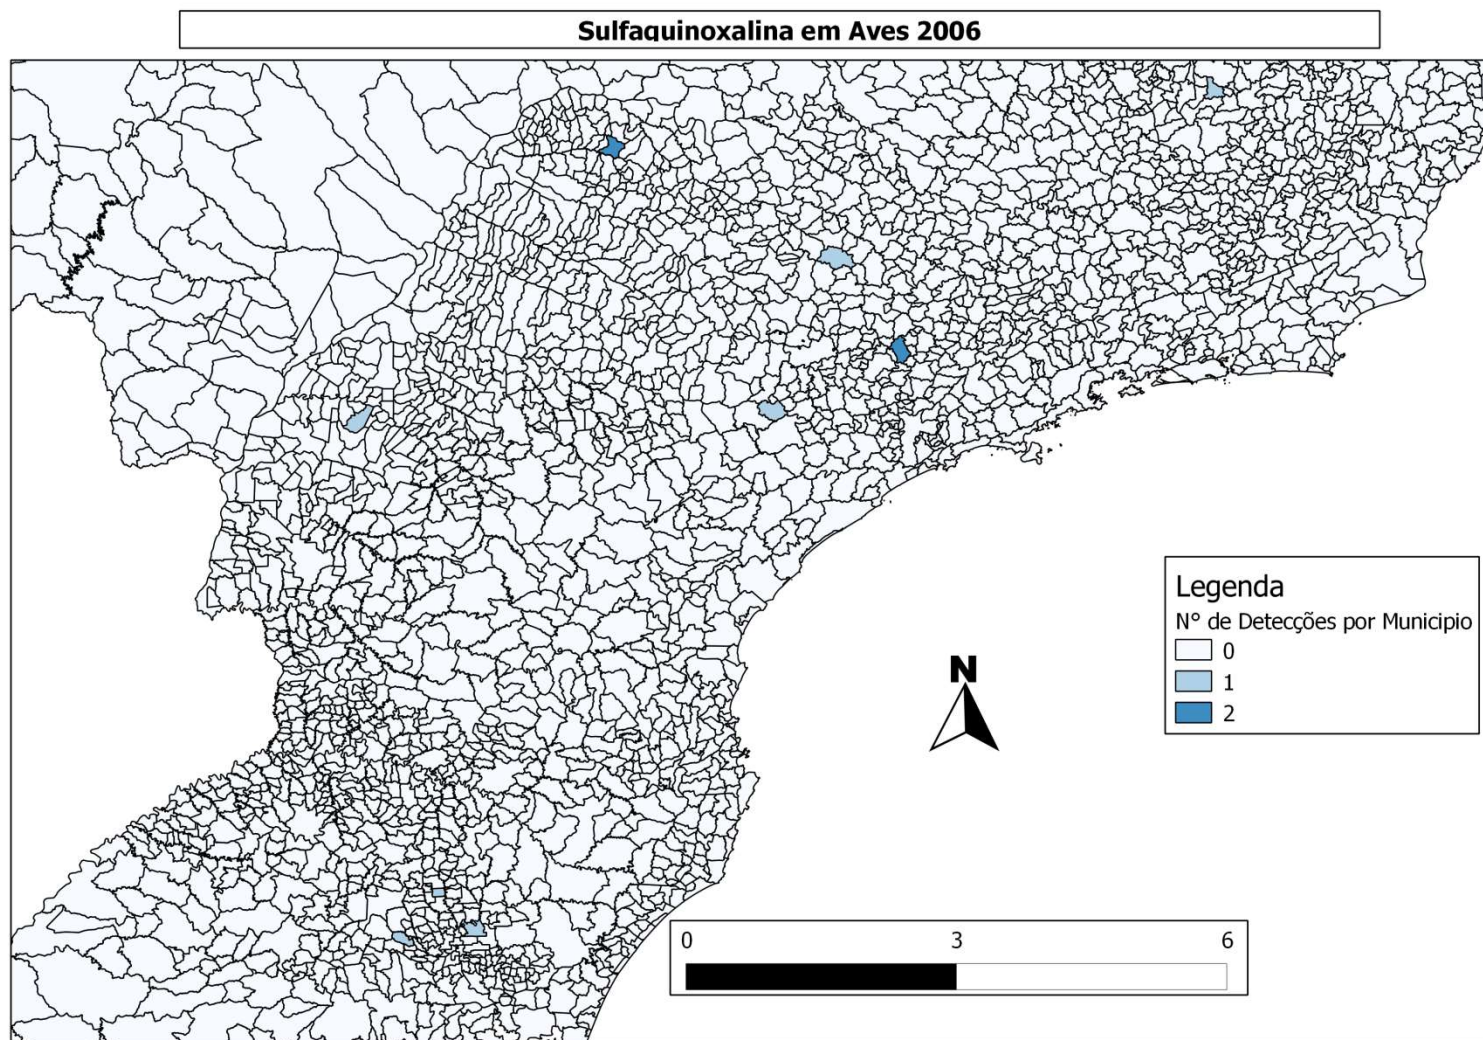


Figura 22. Detecção de Resíduos de Sulfaquinoxalina em Aves 2006. Fonte: elaborado com dados do SISRES.

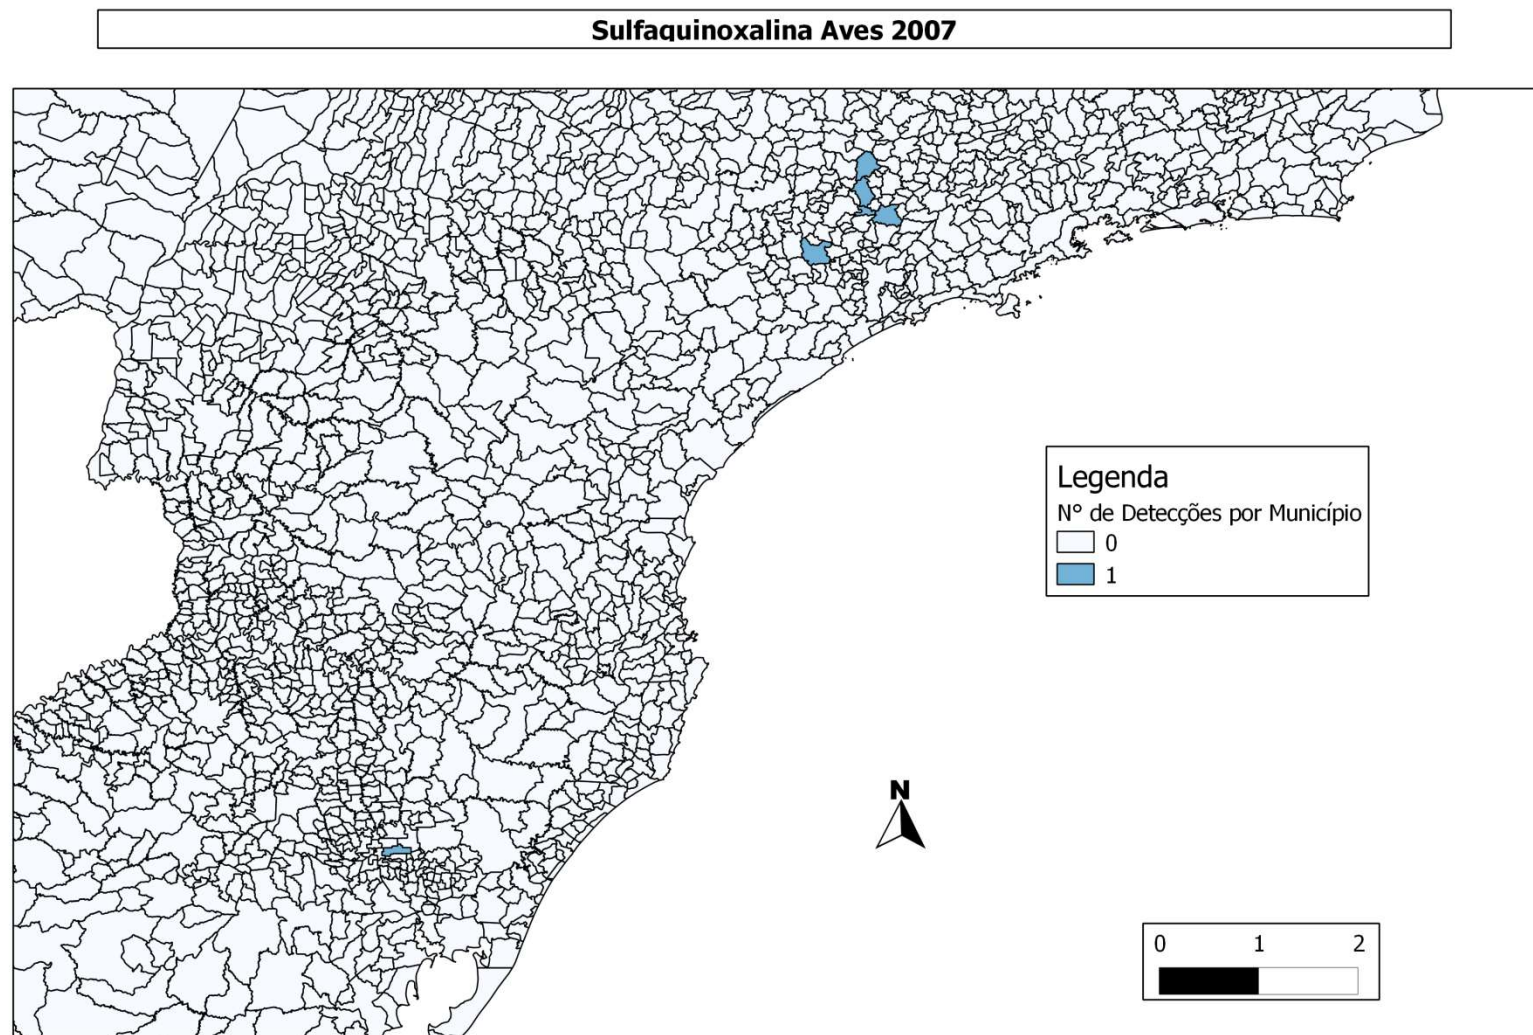


Figura 23. Detecção de Resíduos de Sulfaquinoxalina em Aves 2007. Fonte: elaborado com dados do SISRES.

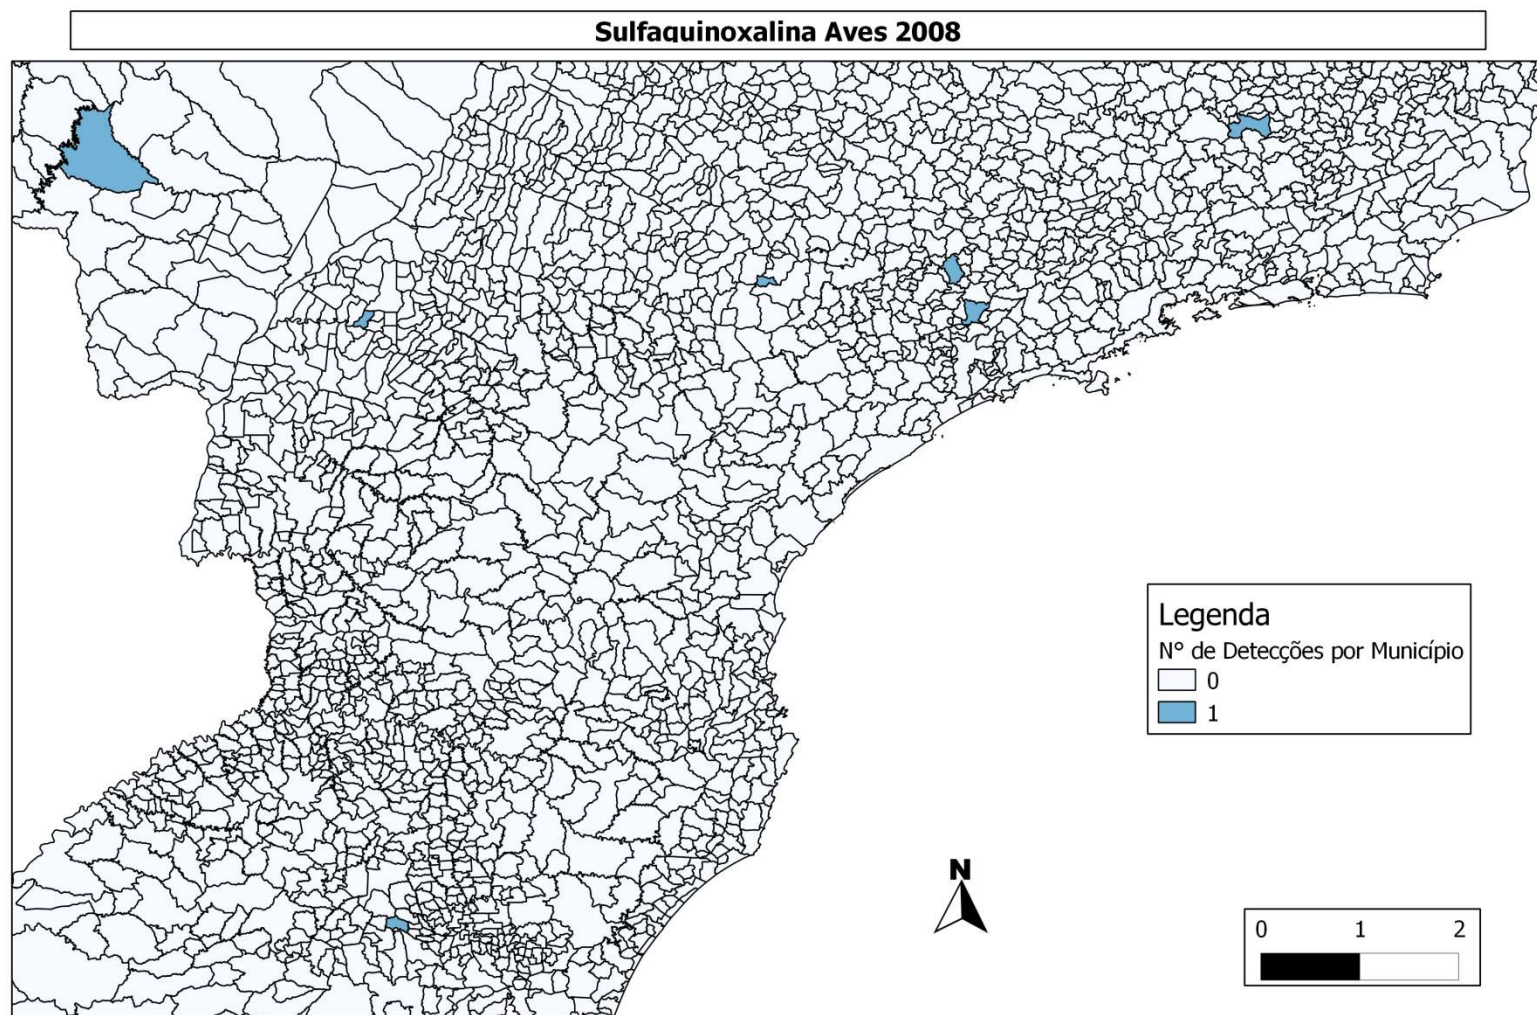


Figura 24. Detecção de Resíduos de Sulfaquinoxalina em Aves 2008. Fonte: elaborado com dados do SISRES.

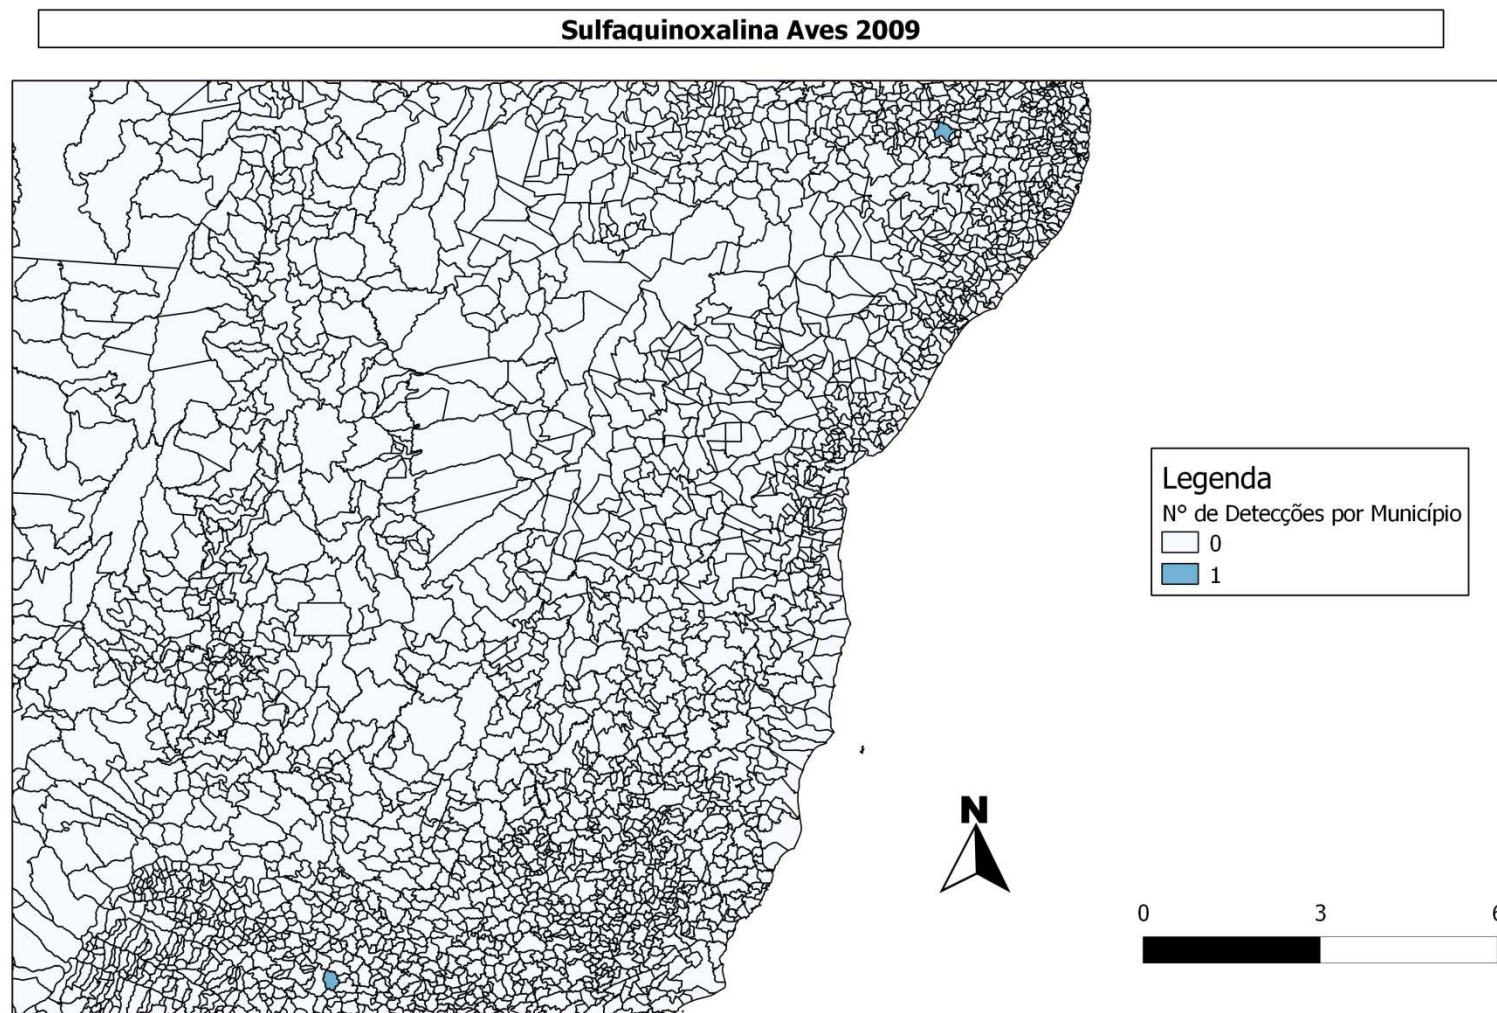


Figura 25. Detecção de Resíduos de Sulfaquinoxalina em Aves 2009. Fonte: elaborado com dados do SISRES.

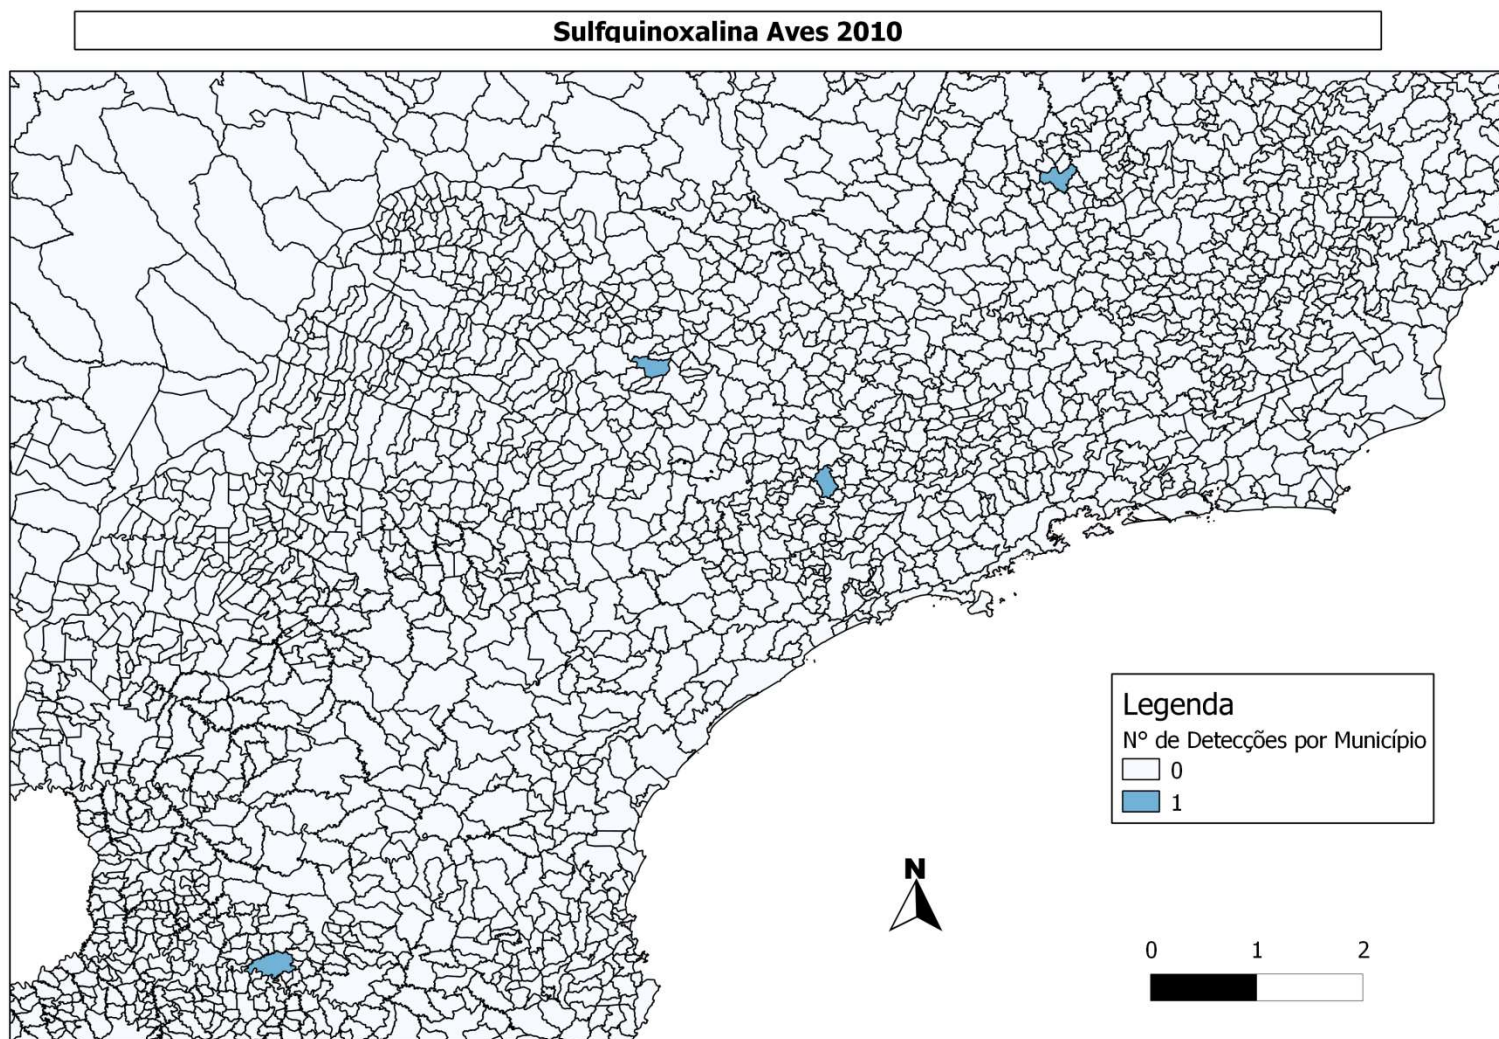


Figura 26. Detecção de Resíduos de Sulfaquinoxalina em Aves 2010. Fonte: elaborado com dados do SISRES.

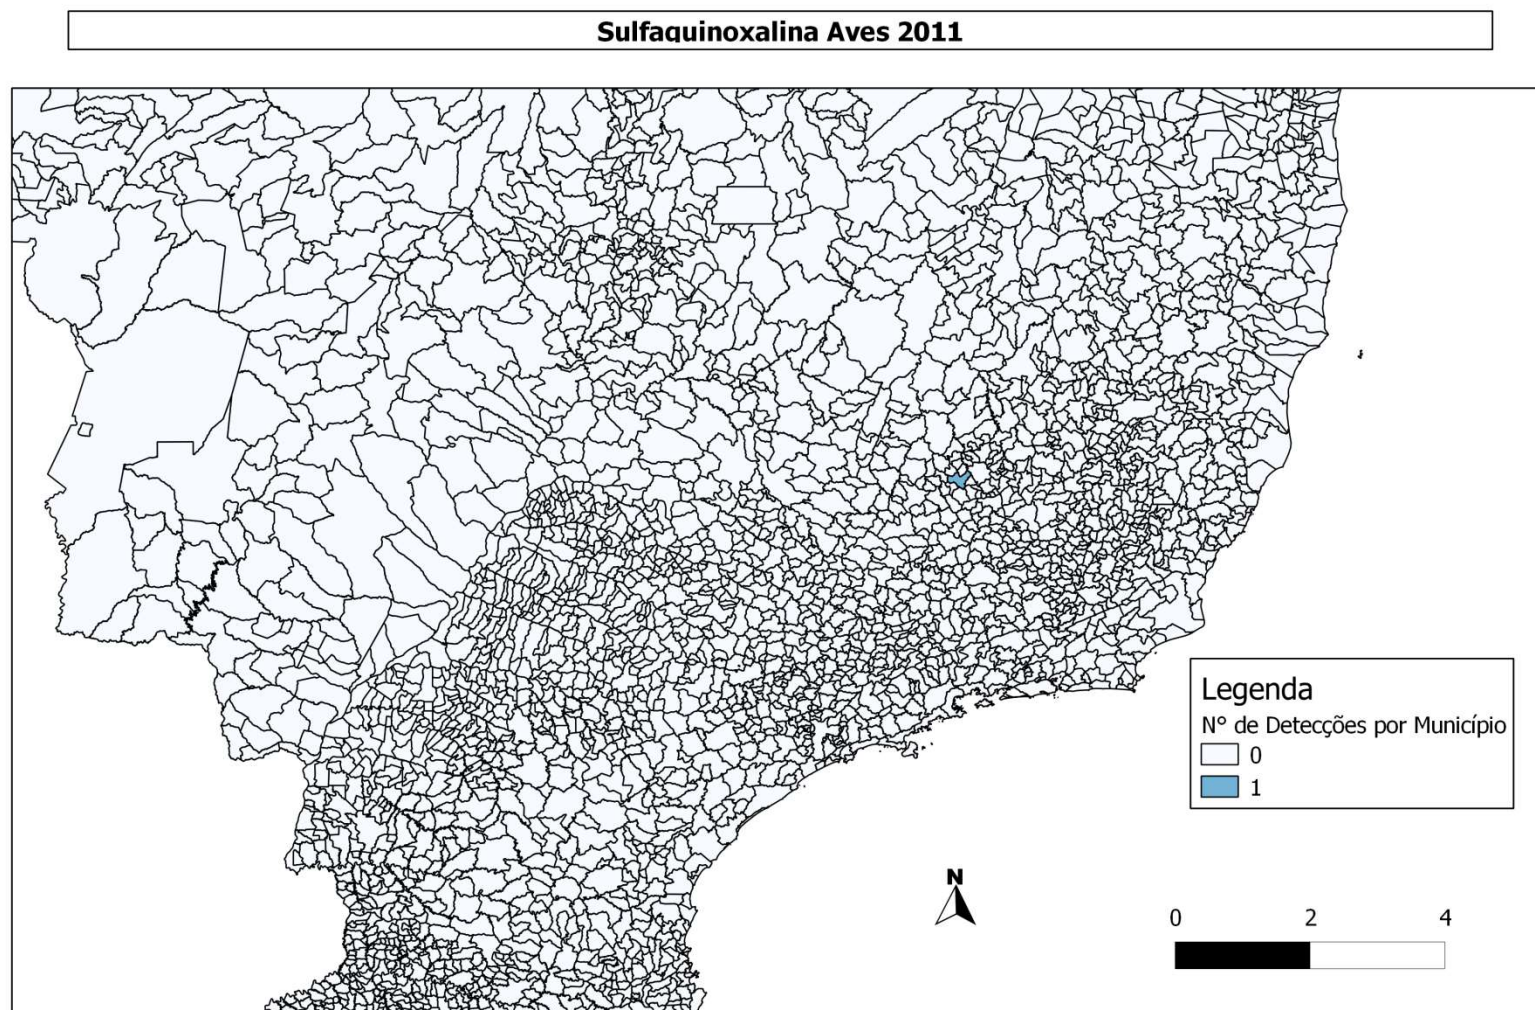


Figura 27. Detecção de Resíduos de Sulfaquinoxalina em Aves 2011. Fonte: elaborado com dados do SISRES.

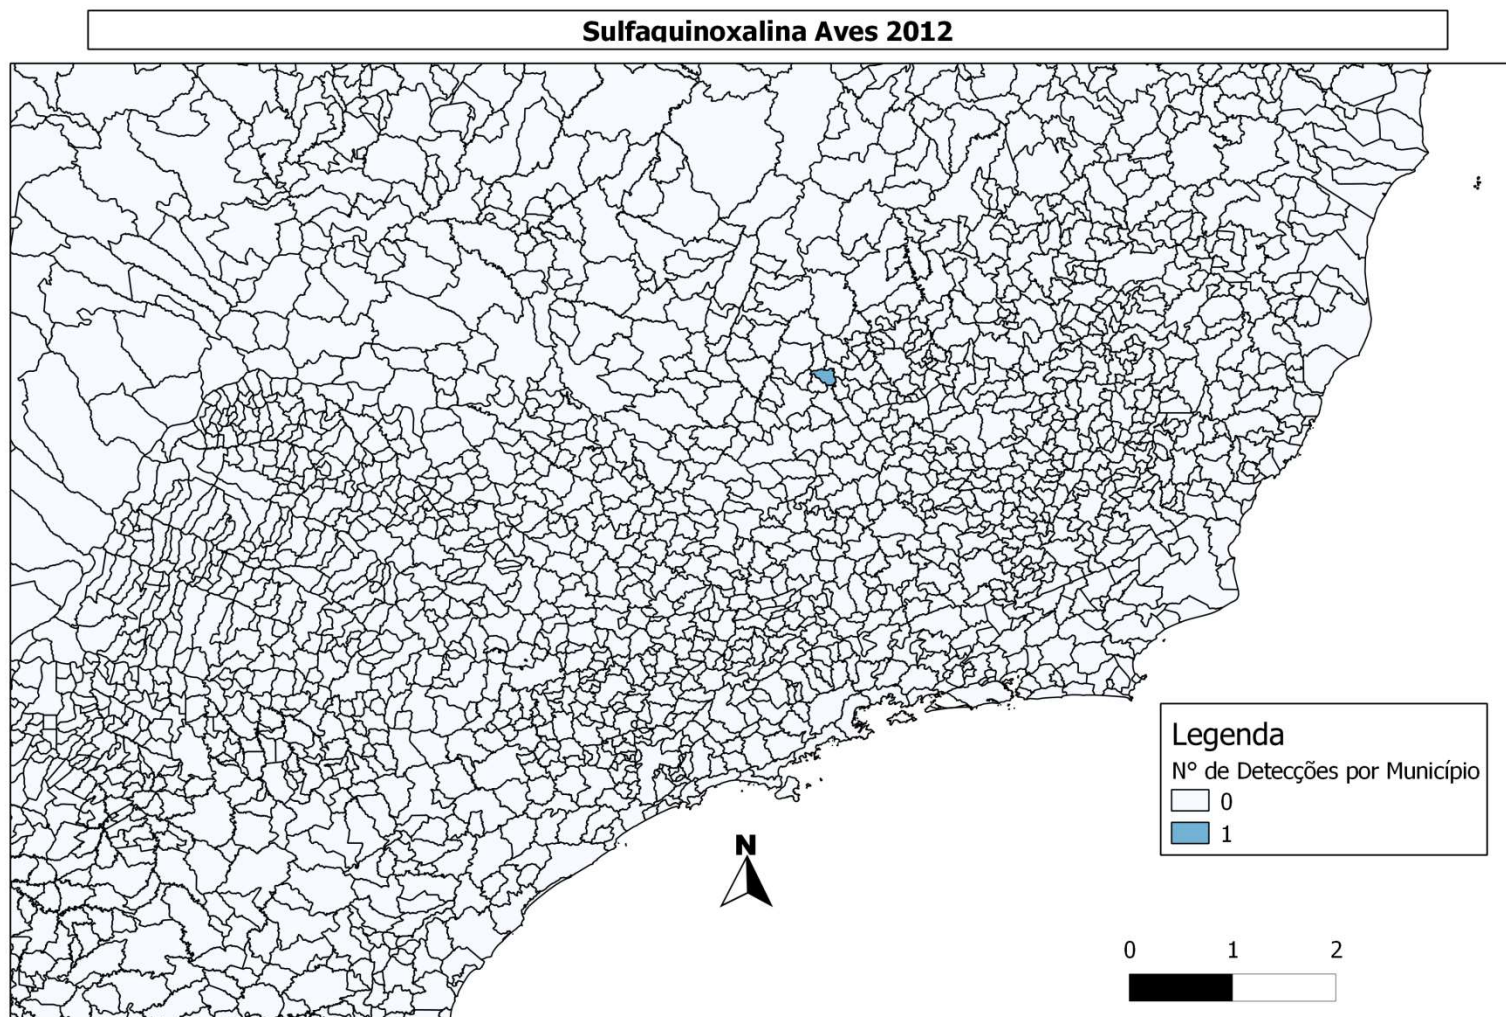


Figura 28. Detecção de Resíduos de Sulfaquinoxalina em Aves 2012. Fonte: elaborado com dados do SISRES.

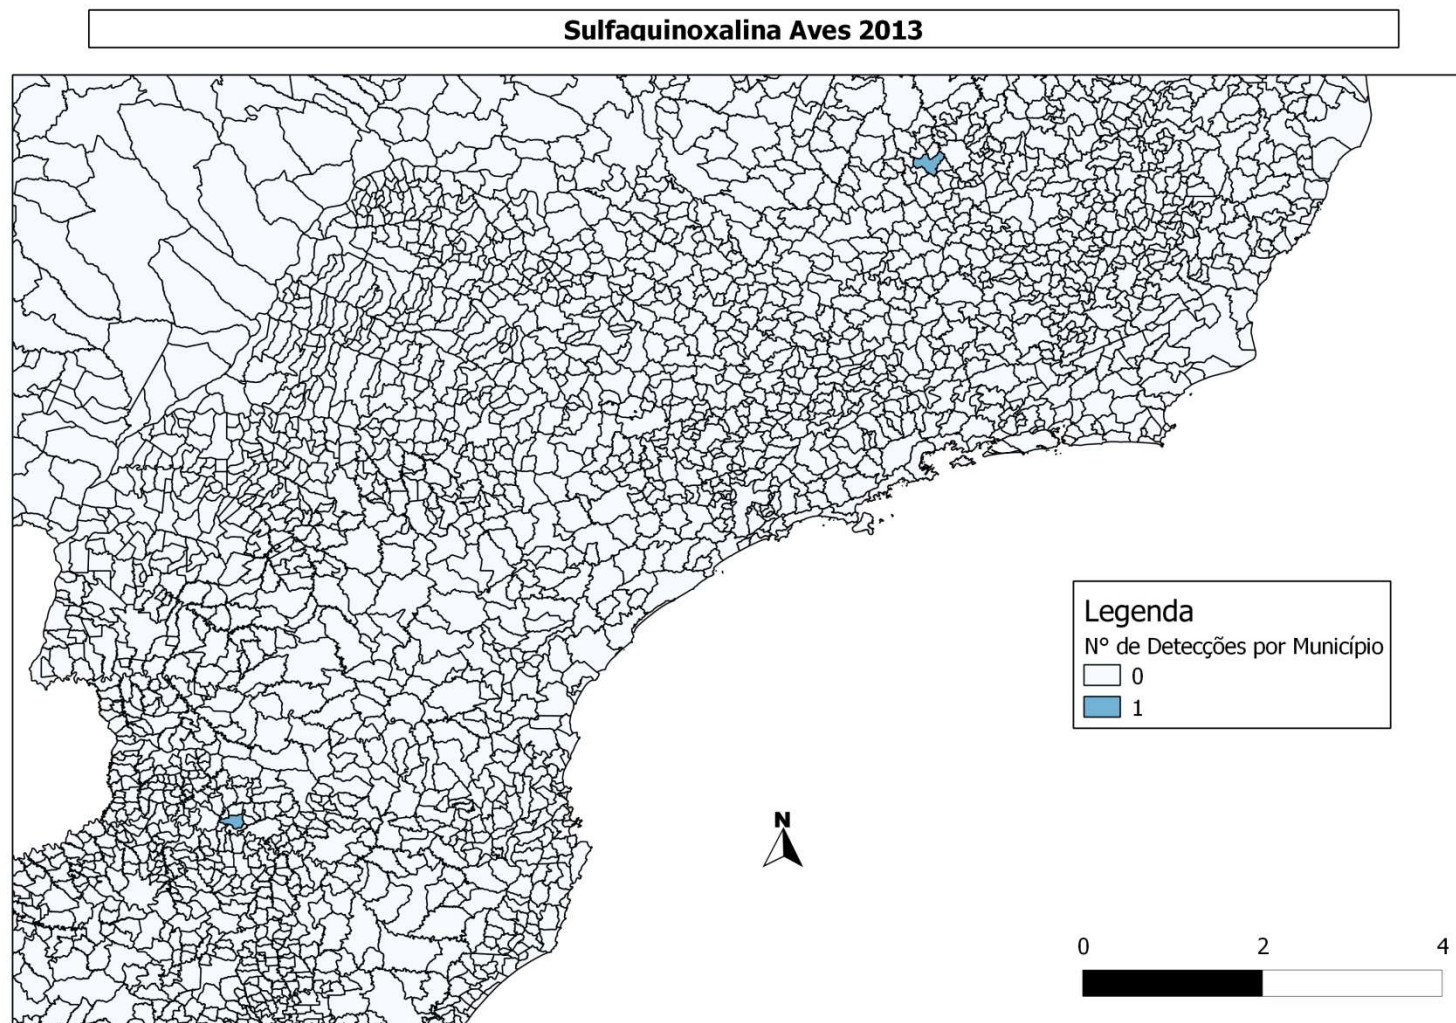


Figura 28. Detecção de Resíduos de Sulfaquinoxalina em Aves 2013. Fonte: elaborado com dados do SISRES.

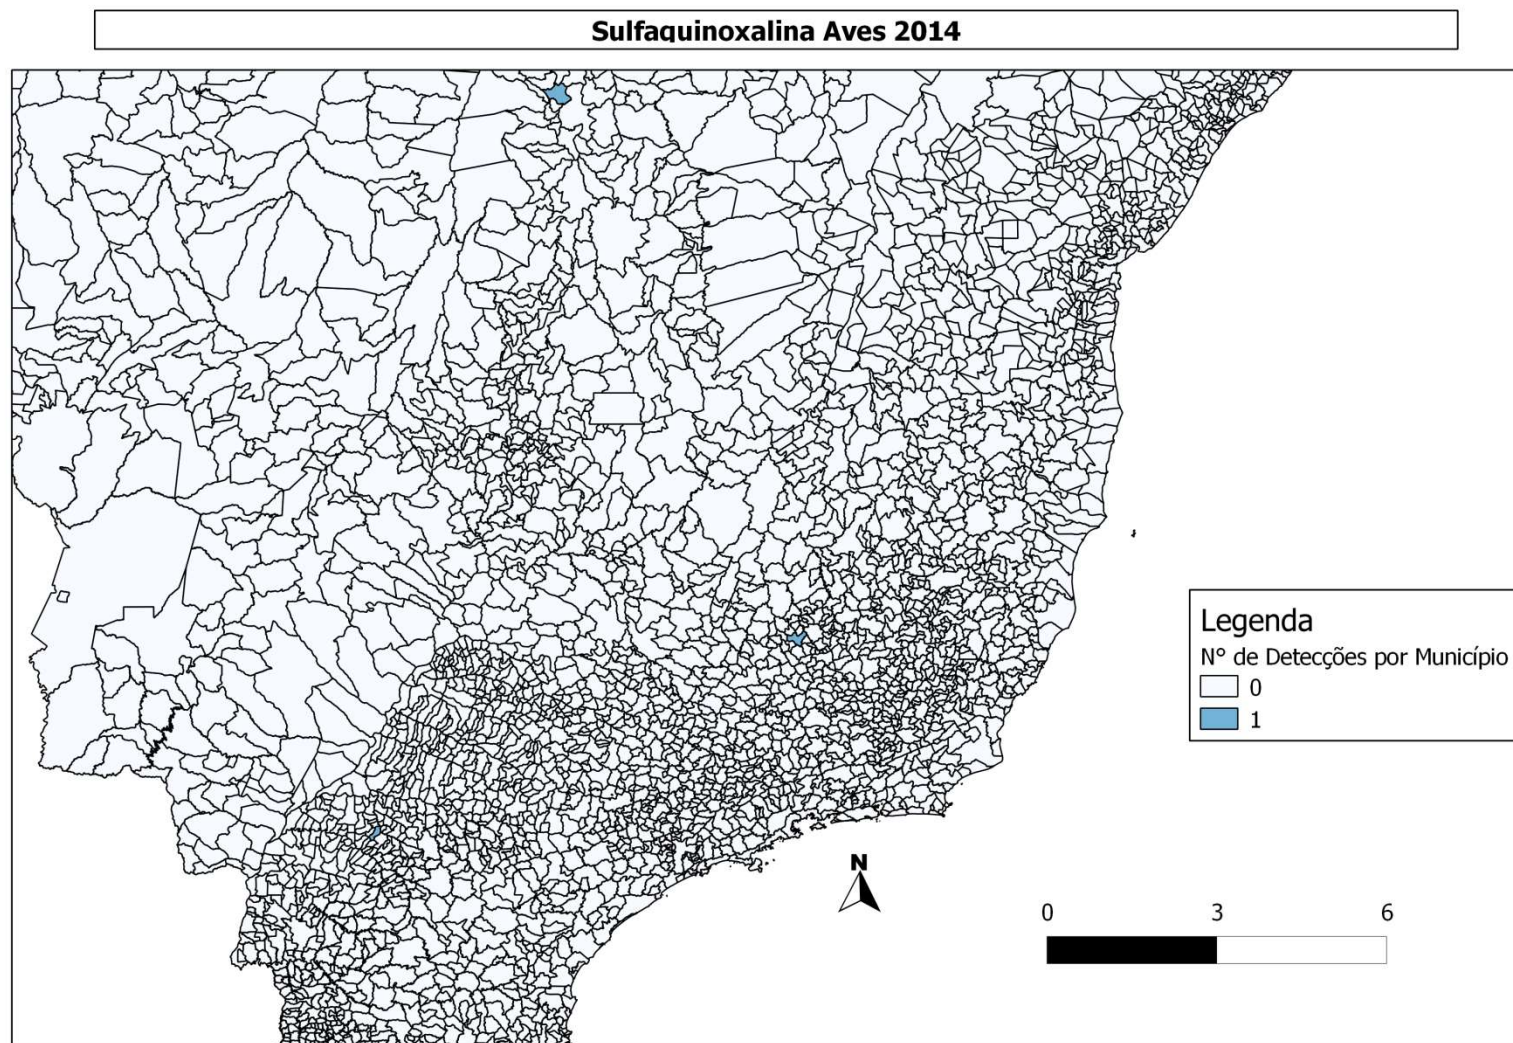


Figura 29. Detecção de Resíduos de Sulfaquinoxalina em Aves 2014. Fonte: elaborado com dados do SISRES.

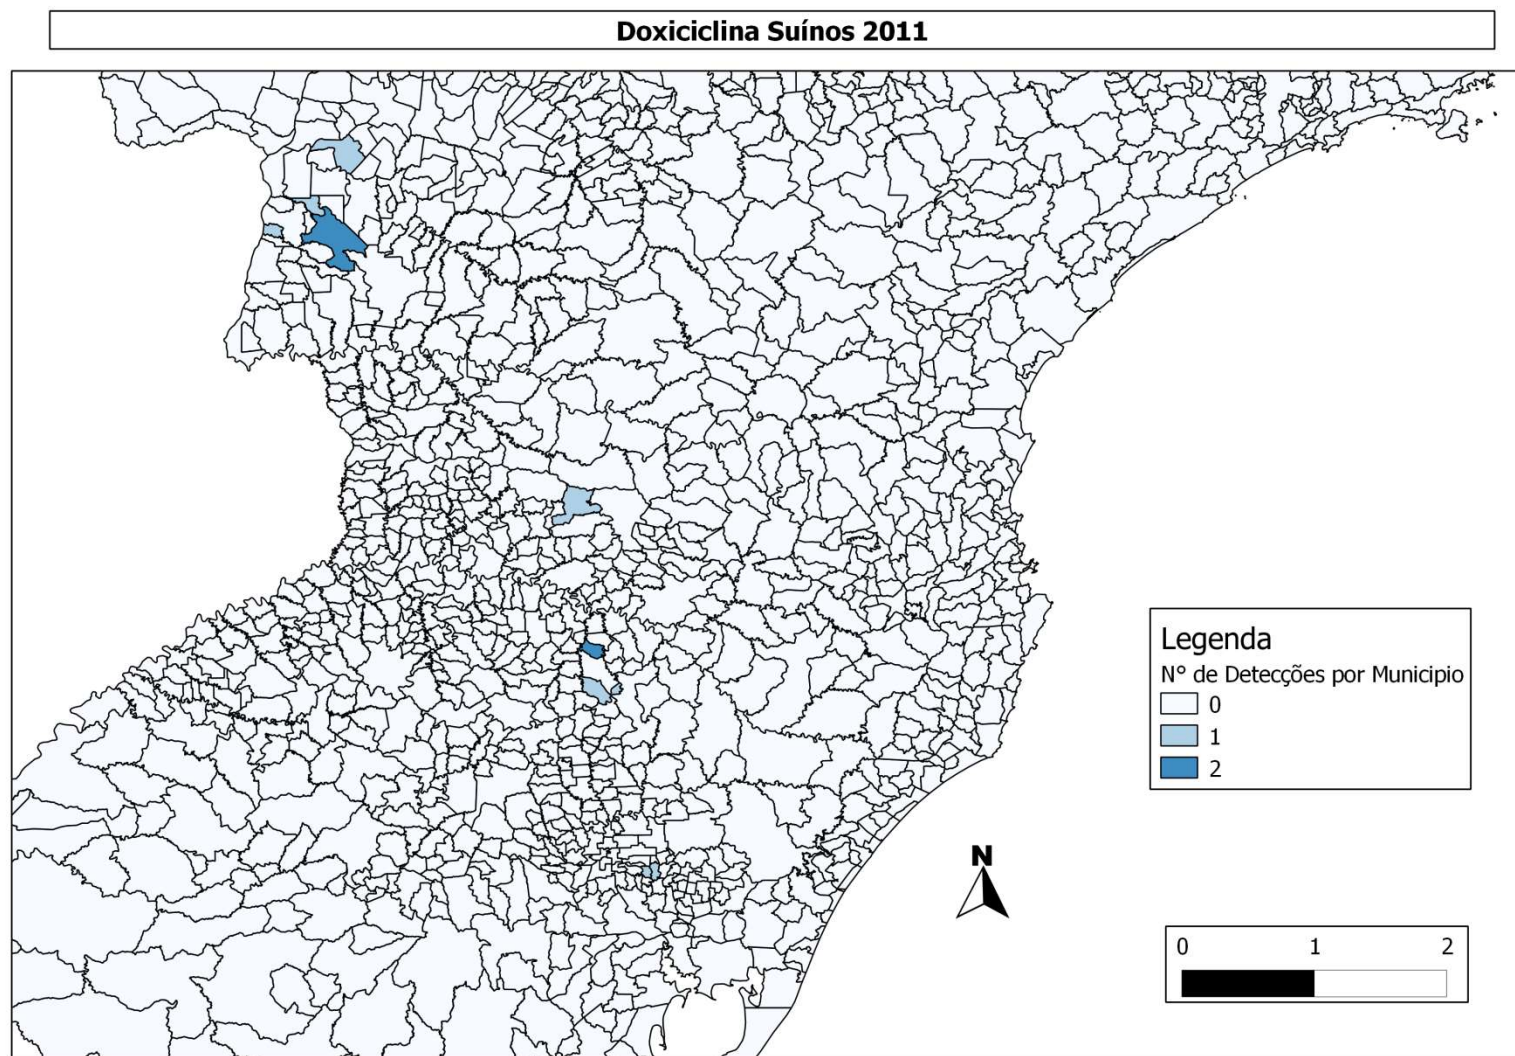


Figura 30. Detecção de Resíduos de Doxiciclina em Suínos 2011. Fonte: elaborado com dados do SISRES.

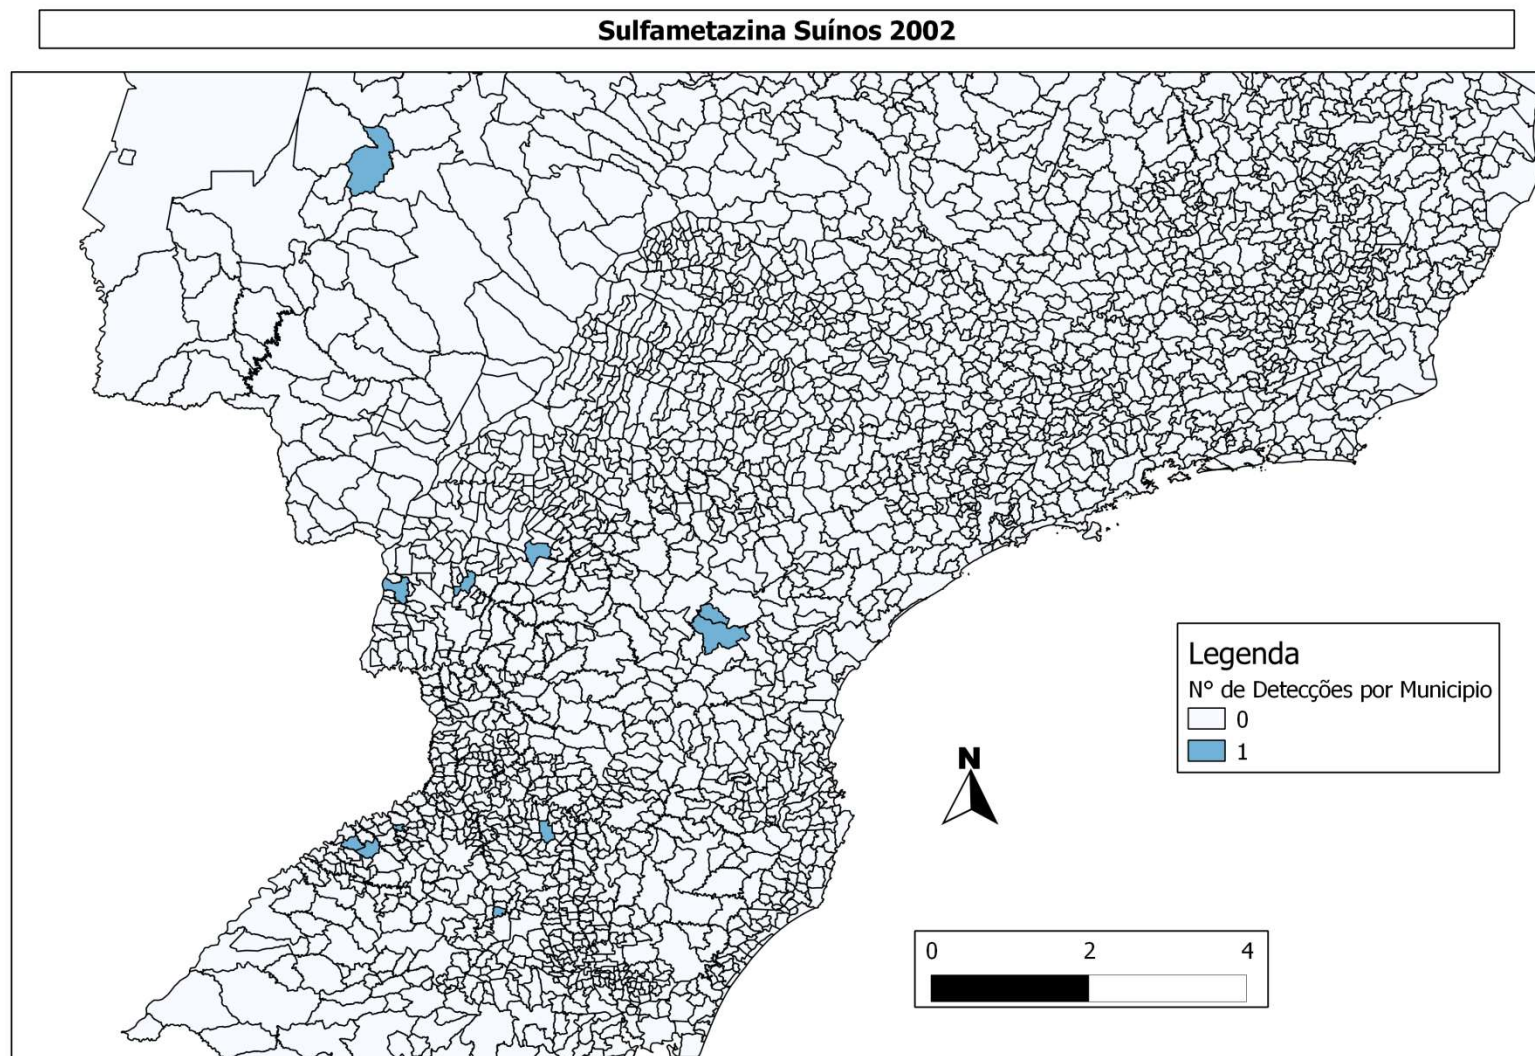


Figura 31. Detecção de Resíduos de Sulfametazina em Suínos 2002. Fonte: elaborado com dados do SISRES.

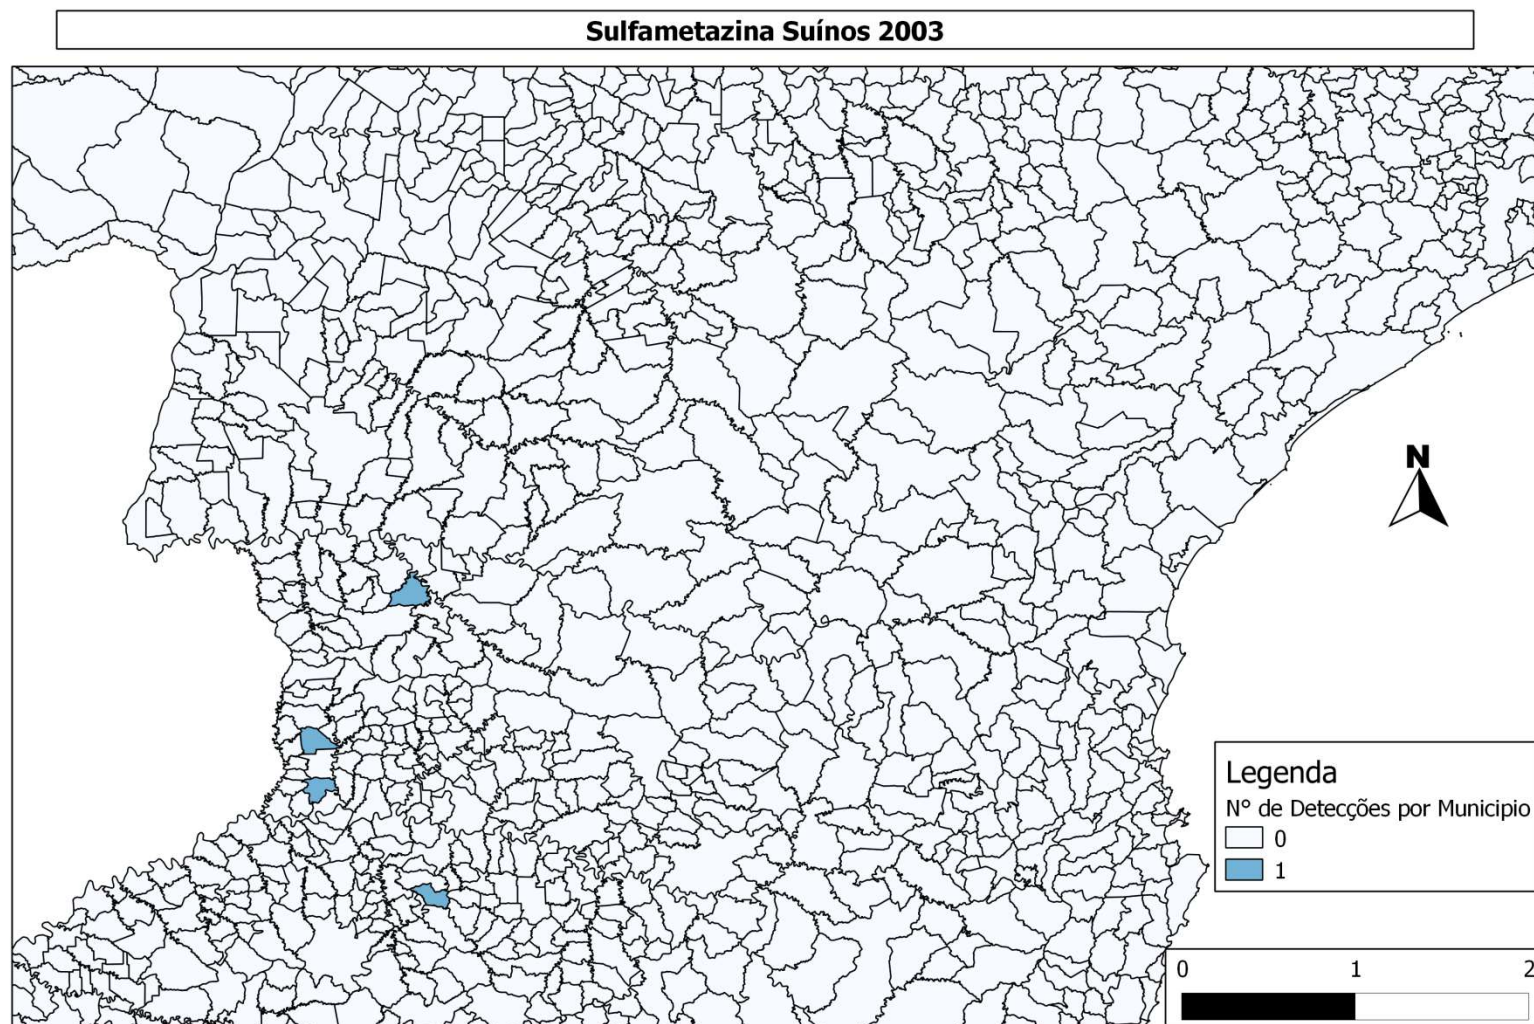


Figura 32. Detecção de Resíduos de Sulfametazina em Suínos 2003. Fonte: elaborado com dados do SISRES.

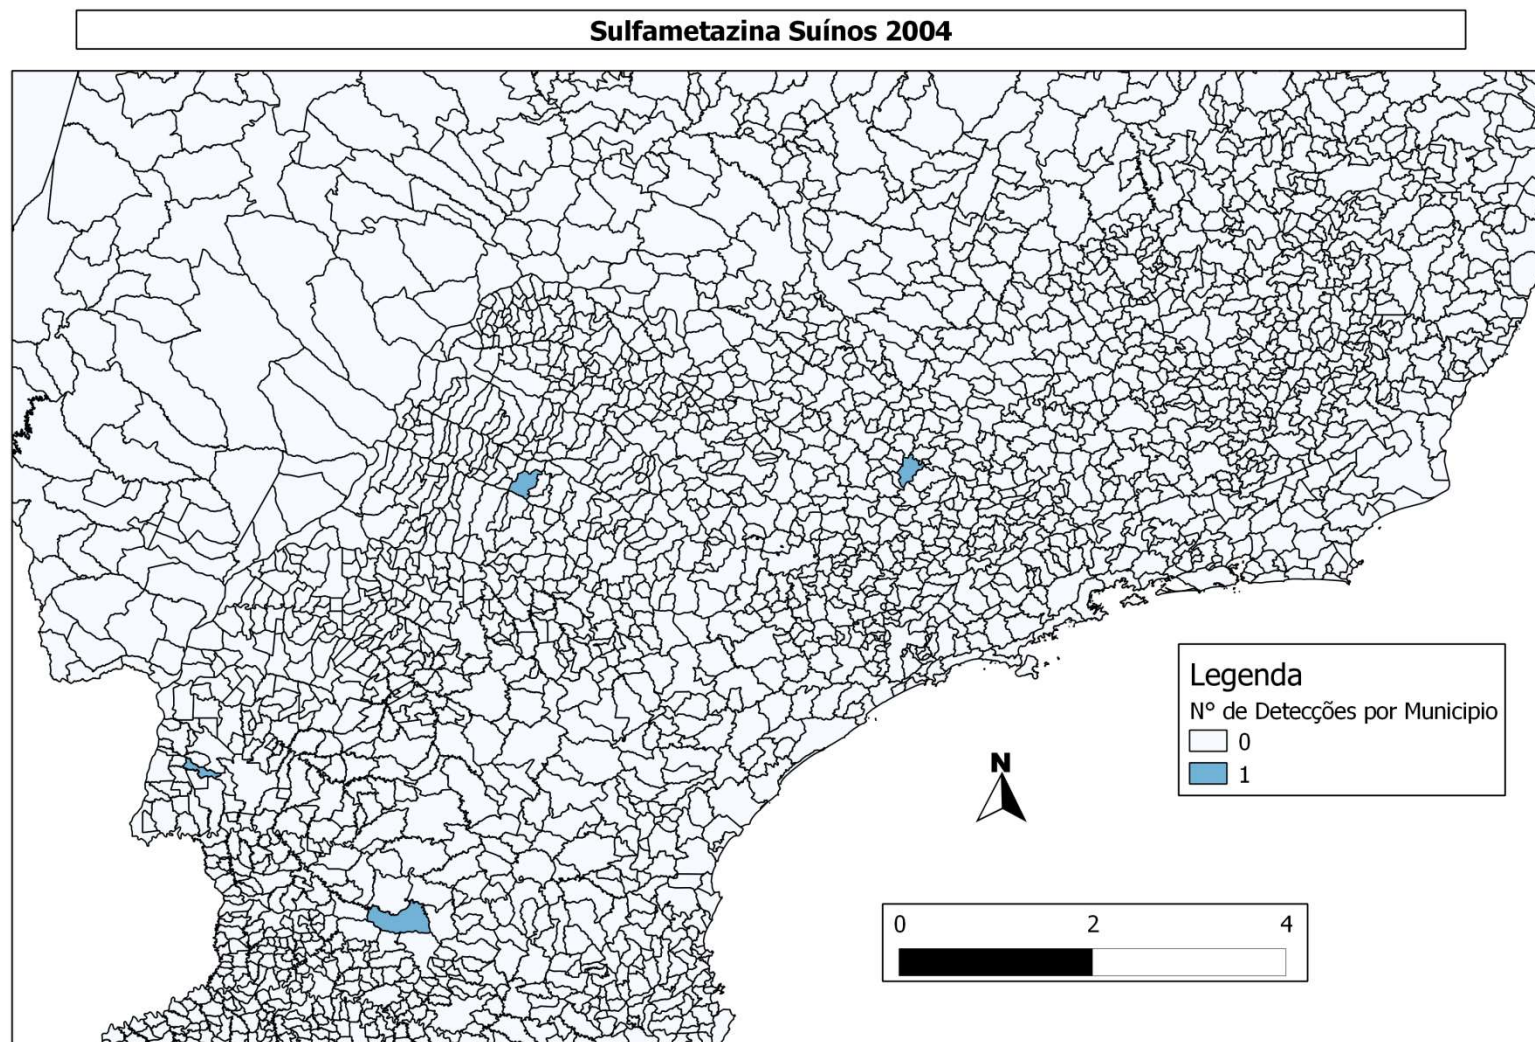


Figura 33. Detecção de Resíduos de Sulfametazina em Suínos 2004. Fonte: elaborado com dados do SISRES.

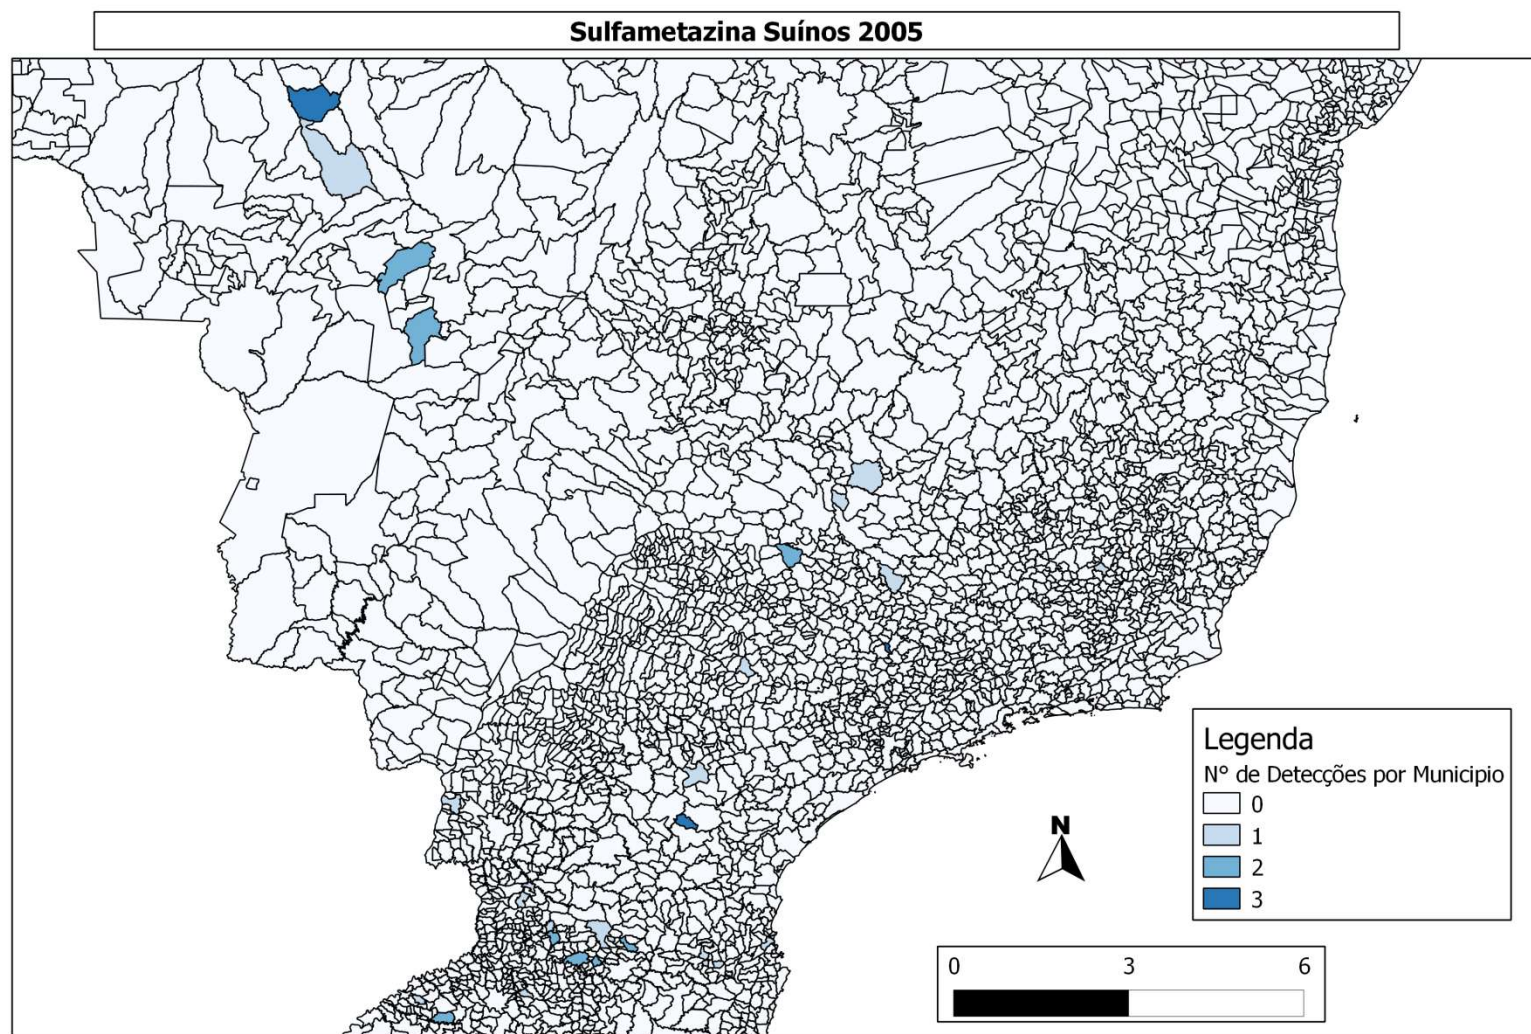


Figura 34. Detecção de Resíduos de Sulfametazina em Suínos 2005. Fonte: elaborado com dados do SISRES.

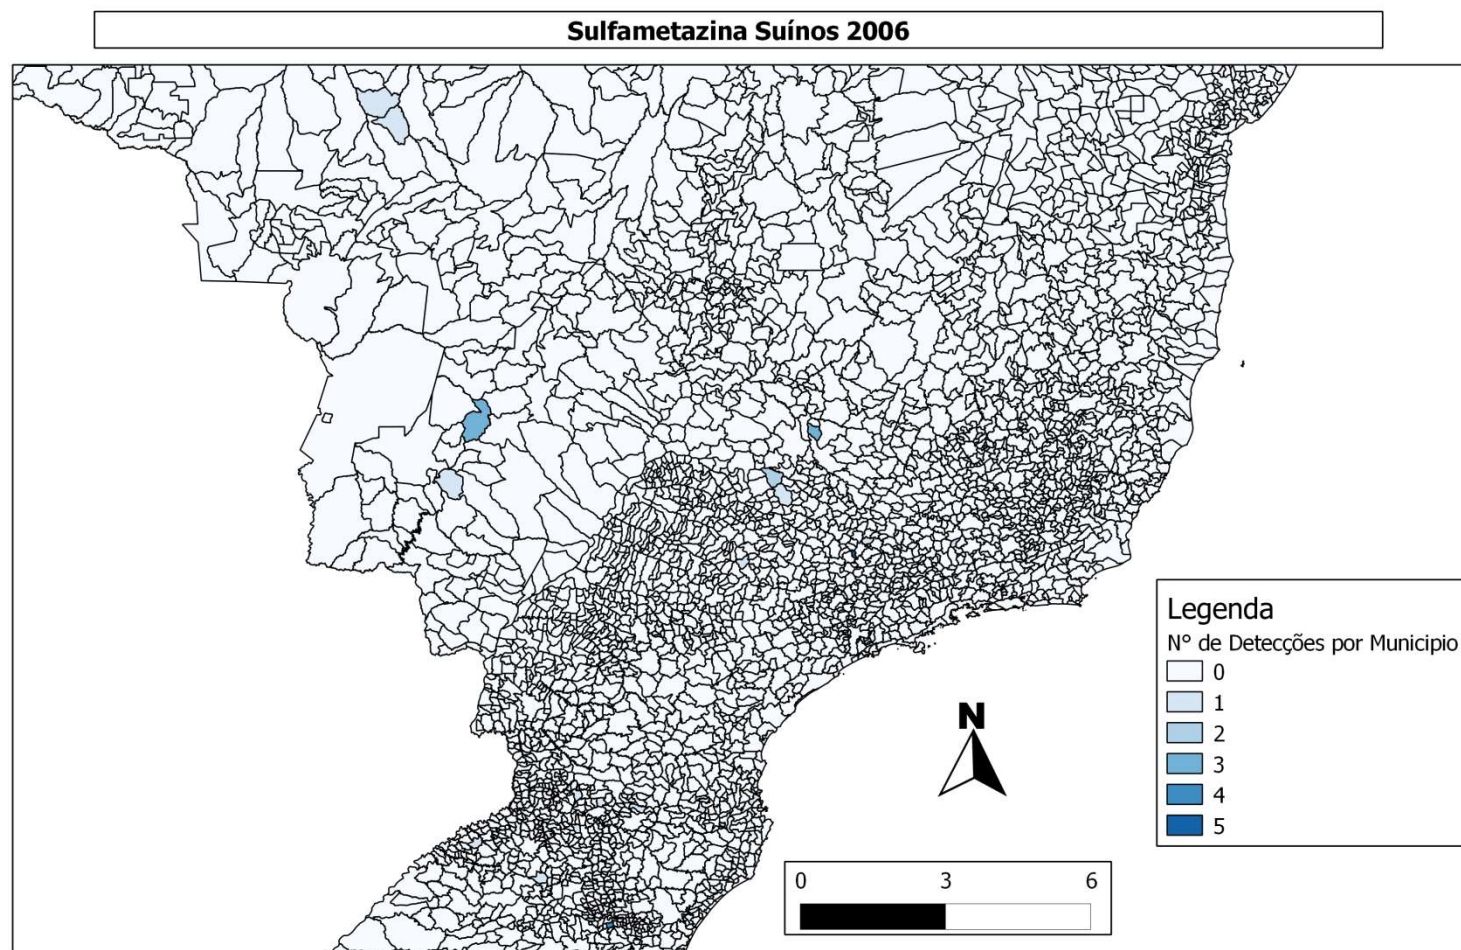


Figura 35. Detecção de Resíduos de Sulfametazina em Suínos 2006. Fonte: elaborado com dados do SISRES.

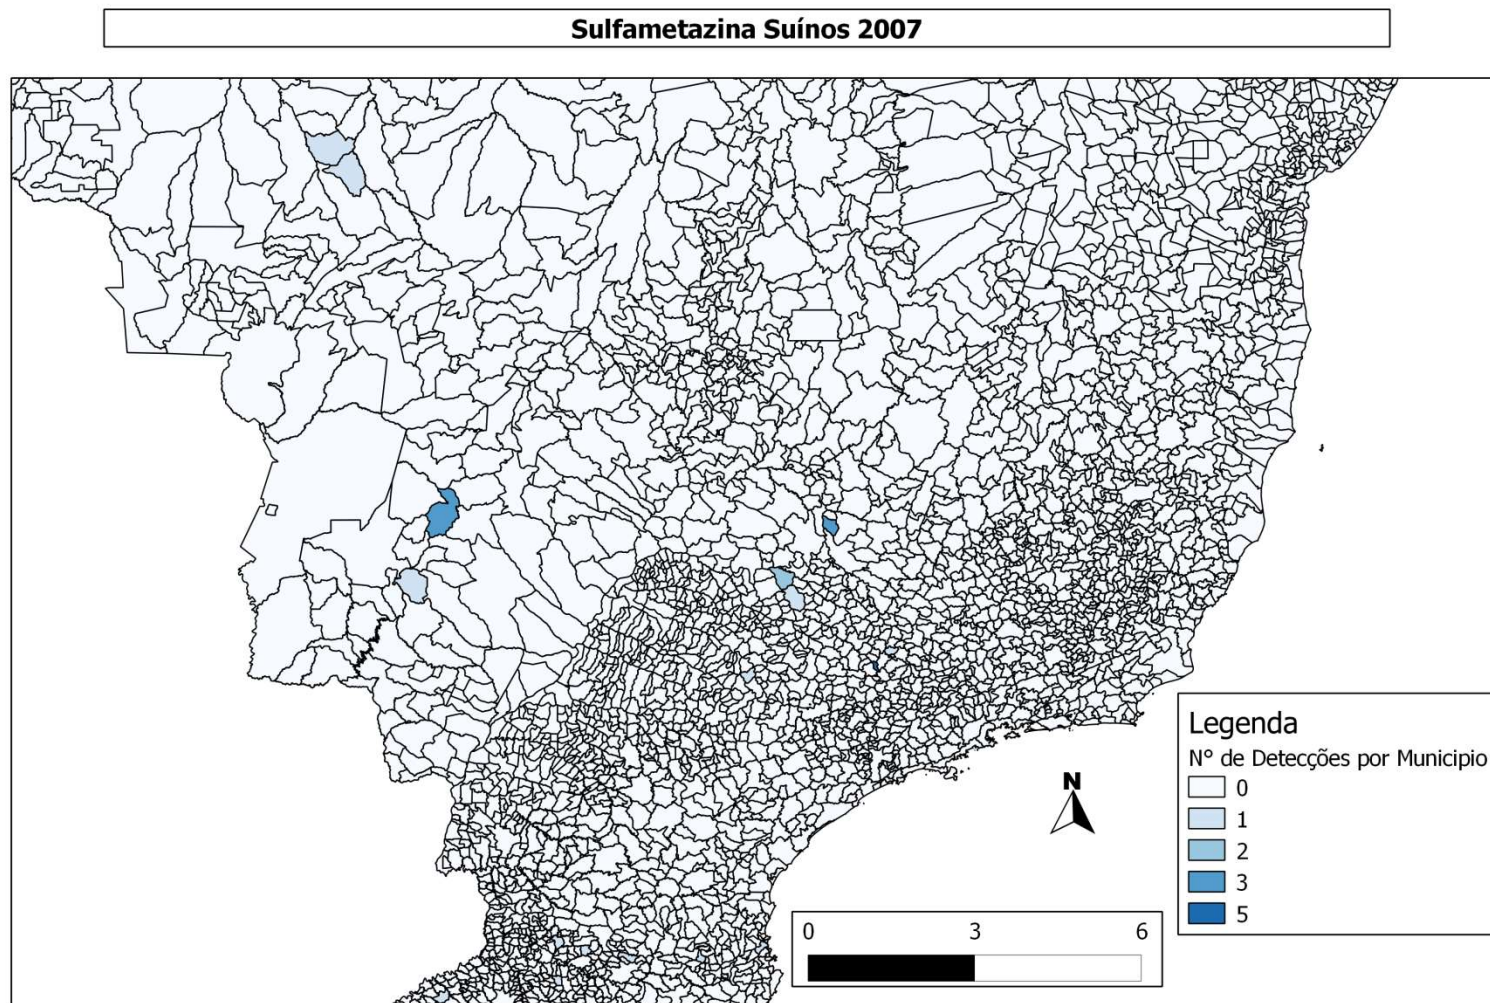


Figura 36. Detecção de Resíduos de Sulfametazina em Suínos 2007. Fonte: elaborado com dados do SISRES.

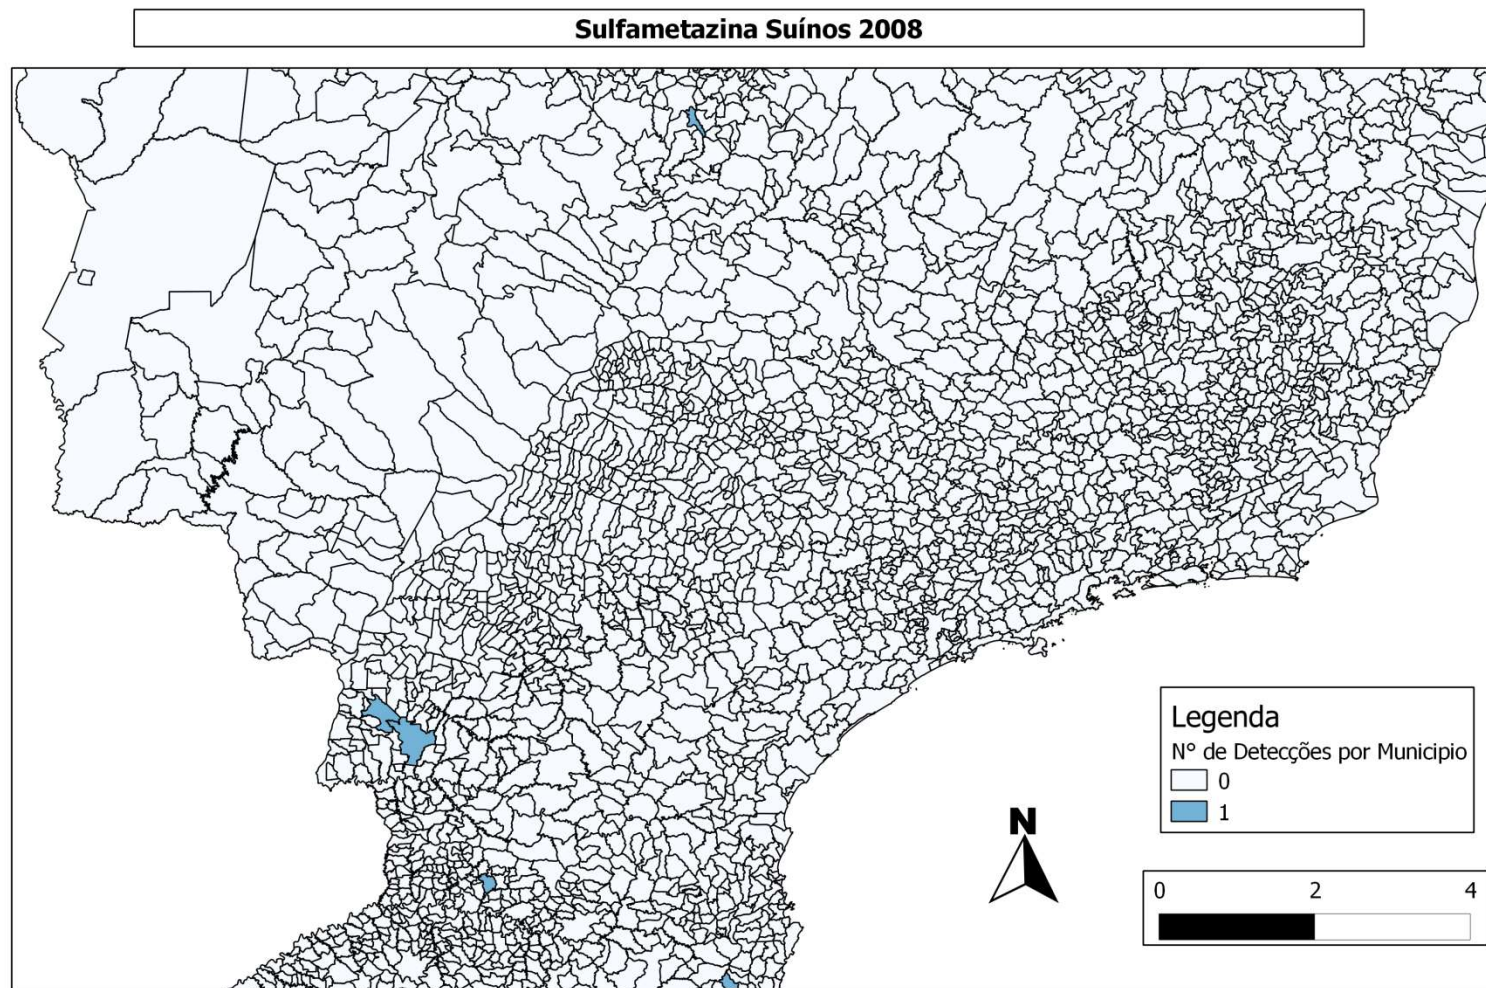


Figura 37. Detecção de Resíduos de Sulfametazina em Suínos 2008. Fonte: elaborado com dados do SISRES.

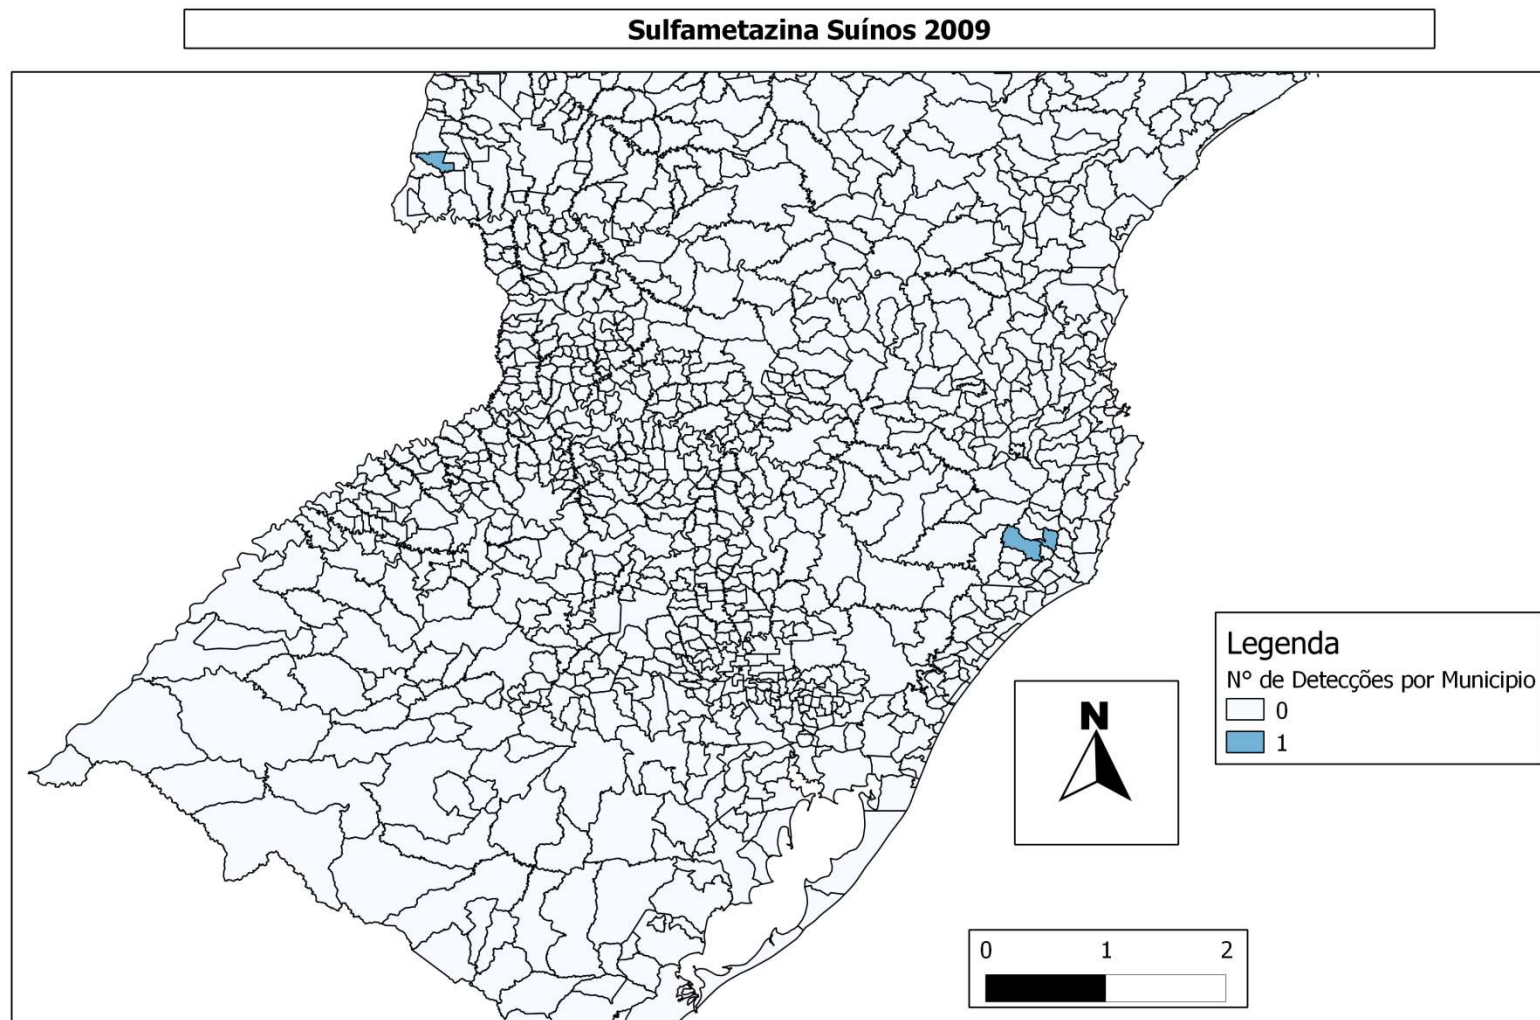


Figura 38. Detecção de Resíduos de Sulfametazina em Suínos 2009. Fonte: elaborado com dados do SISRES.

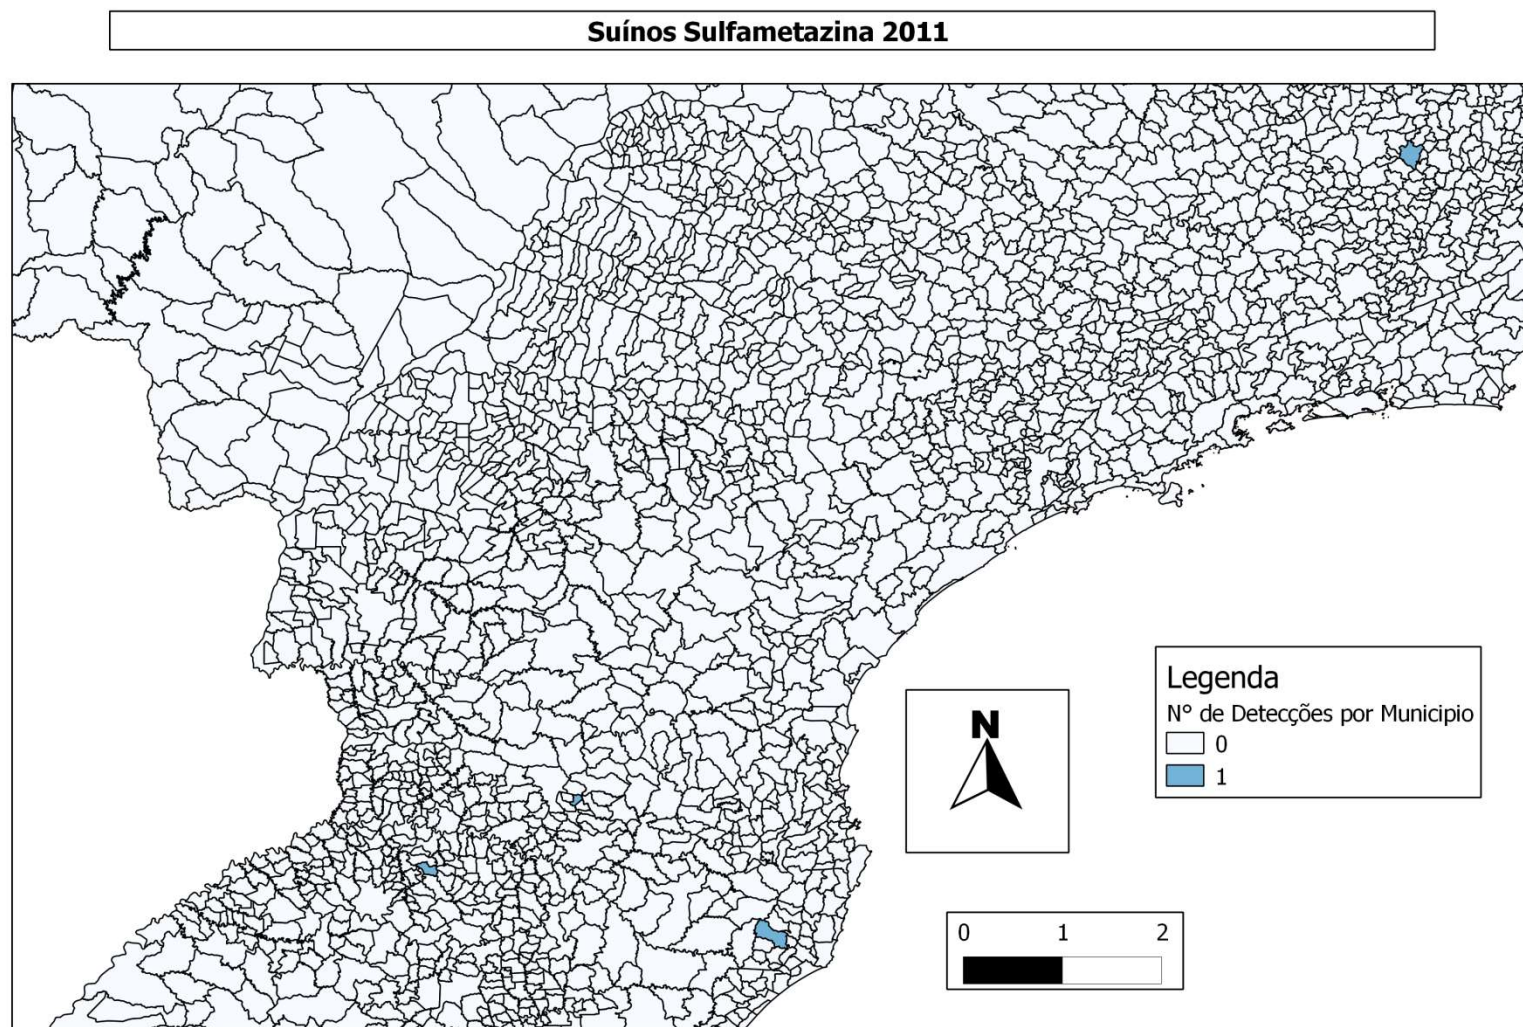


Figura 39. Detecção de Resíduos de Sulfametazina em Suínos 2011. Fonte: elaborado com dados do SISRES.

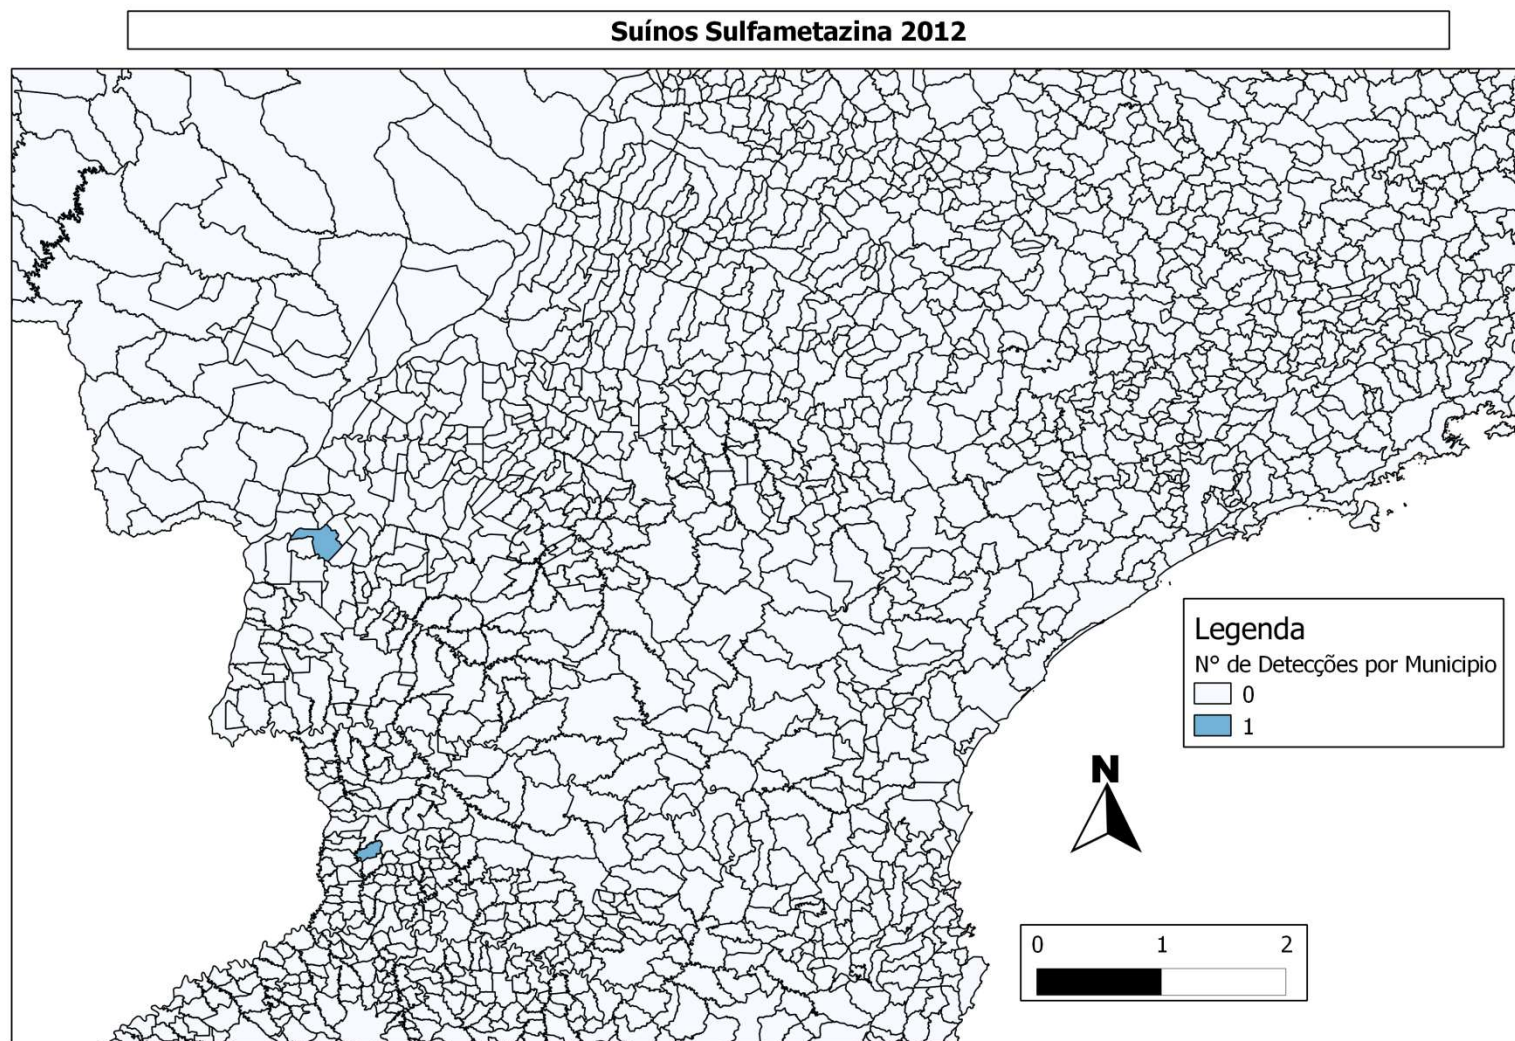


Figura 40. Detecção de Resíduos de Sulfametazina em Suínos 2012. Fonte: elaborado com dados do SISRES.


Suínos Sulfametazina 2014

Figura 41. Detecção de Resíduos de Sulfametazina em Suínos 2014. Fonte: elaborado com dados do SISRES

